

CONTROL PREDICTIVO BASADO EN UN MODELO NEURODIFUSO AUTO-REGRESIVO APLICADO AL PROCESO DE ARRANQUE DEL GENERADOR DE VAPOR DE UNA UNIDAD TERMOELÉCTRICA

José Antonio Ruz Hernández, Dionisio Antonio Suárez Cerda, Evgen Shelomov

*Universidad Autónoma del Carmen, Facultad de Ingeniería
Calle 56 # 4 X Av. Concordia, Cd. del Carmen, Cam., México
Tel./Fax: (938) 26516, jrutz@pampano.unacar.mx*

Abstract: En el presente trabajo se desarrolla un esquema de control monovariante para ser aplicado durante el arranque del generador de vapor de una unidad termoeléctrica. Las acciones de control que produce el esquema son, sin embargo, aplicadas manualmente por el operador de la unidad. Es decir, el sistema es en realidad un mecanismo de ayuda para esta etapa de la operación de una unidad termoeléctrica, el cual genera sugerencias para el operador. El diseño llevado a cabo consiste de un algoritmo de control predictivo basado en un modelo neurodifuso del proceso que se va a controlar para lograr el seguimiento de la curva de referencia especificada

Keywords: Control Predictivo, Modelo Neurodifuso, Estimación, Generador de vapor.

1. INTRODUCCIÓN

El mejoramiento de la operación de las centrales termoeléctricas, es una preocupación permanente de todas las instancias que intervienen en el proceso de generación, ya que una mejor operación siempre es traducible en beneficios financieros, así como de bienestar colectivo. El proceso de calentamiento del generador de vapor de una unidad termoeléctrica es en esencia un problema de control, el cual se resuelve tradicionalmente en forma manual y por personal experimentado. La principal dificultad técnica que se encuentra para un manejo automatizado de esta etapa del arranque en este tipo de unidades es la existencia

de un gran retardo de transporte que puede originar inestabilidad y dificultad en mantener la temperatura de calentamiento en una razón de cambio controlada.

El control predictivo convencional utiliza modelos de predicción lineales para estimar las salidas futuras del proceso [1,2]. Para plantas no lineales, los modelos lineales no son lo suficientemente buenos. La derivación de un modelo del proceso basado en las leyes de elementos y los principios de conservación comúnmente no es sencilla, resultando una actividad cara y lenta. Pueden lograrse ahorros significativos en tiempo y dinero mediante la aplicación de modelos basados en redes neuronales y lógica difusa [3].

Una variedad de esquemas de control utiliza modelos difusos, ejemplos de algunos de ellos lo constituyen el *control inverso*, el *control con modelo interno* y el *control predictivo basado en modelos difusos* [4]. En el presente trabajo se utiliza una variante de éste último al que hemos denominado *control predictivo basado en un modelo neurodifuso auto-regresivo* [5] ya que el modelo es obtenido mediante un sistema tipo ANFIS [6,7].

2. PLANTEAMIENTO DEL PROBLEMA

Durante la mayor parte del proceso de arranque del generador de vapor, el operador debe cuidar de no sobrepasar ciertos límites en el gradiente de la temperatura de los tubos bajantes [8]. Las acciones de control que el operador tiene disponibles para manipular la temperatura de calentamiento del fluido en el generador de vapor son la cantidad de combustible que se consume así como la apertura de los drenes de vapor ubicados a lo largo de las líneas de vapor. Sin embargo, por cuestiones operativas estos drenes son manejados con reserva ya que tienen que sujetarse a un programa gradual de derre y preferentemente no deben usarse como acciones de control.

En otra etapa del calentamiento y presurización del generador de vapor las restricciones se imponen ya no sobre la temperatura en los bajantes sino sobre la diferencia entre las temperaturas de vapor principal y de saturación en el domo. No obstante, por razones operativas el control continúa realizándose de la misma manera solamente disminuyendo el valor de referencia del gradiente hasta un valor tal que por experiencia se sabe que el sobrecalentamiento quedará dentro de sus límites de diseño.

Después de un cierto tiempo de calentamiento comienza a registrarse valores positivos de la presión de vapor principal. Esta es otra variable sobre la cual debe ponerse atención. No existen realmente restricciones fuertes sobre su evolución, pero debe garantizarse que siempre mantenga un valor creciente. Esta variable se ve afectada por la posición de los drenes así como por la utilización de vapor en el calentamiento de las líneas de vapor y de los metales de la turbina. La figura 1, muestra las curvas de calentamiento y presurización del arranque en frío del generador de vapor.

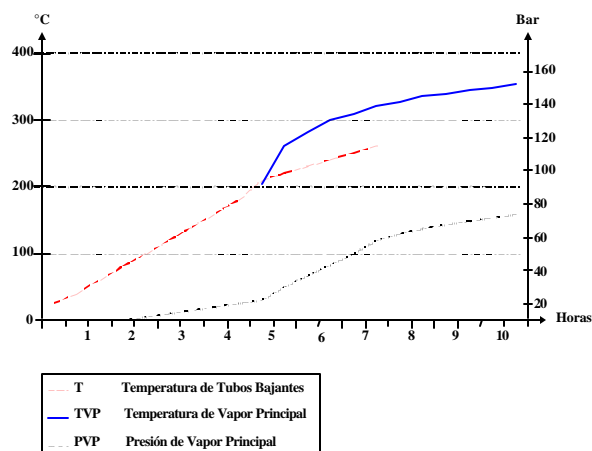


Fig. 1 Curvas de Calentamiento y presurización del generador de vapor.

En primera instancia, el problema a resolver puede verse como el de controlar la temperatura interna de las tuberías bajantes respetando un límite máximo del gradiente en esta variable, ya que si éste se reduce mucho o con regularidad se tienen tiempos muy prolongados en el arranque del generador de vapor, lo cual representa costos adicionales de operación ya que un mayor tiempo de arranque implica mayor consumo de combustible, agua desmineralizada y energía del Sistema Eléctrico Nacional.

Asimismo, a medida que se incrementa la rapidez de un arranque, se disminuye el consumo de los insumos señalados, pero al mismo tiempo los esfuerzos térmicos a los que se somete el generador de vapor son más severos y consecuentemente los tubos bajantes sufren un envejecimiento prematuro.

Con referencia a la descripción anterior, el problema que se resuelve en este trabajo es el de diseñar e implantar a nivel de simulación un esquema de control que estime el flujo de combustible óptimo requerido para respetar las condiciones descritas para este proceso.

3. DESARROLLO DEL ALGORITMO DE CONTROL

Para resolver la problemática presentada se ha diseñado un algoritmo de *control predictivo basado en un modelo neurodifuso auto-regresivo*, cuyo esquema se ilustra en la figura 2. Esto es, se utiliza *identificación neurodifusa* para obtener un modelo auto-regresivo a partir de datos experimentales de

temperatura y del flujo de combustible involucrados en el proceso de arranque del generador de vapor y que será empleado como *predictor* en una estrategia de *control óptimo* que involucre en el problema de *optimización numérica* las restricciones que envuelve el problema tecnológico que se ha planteado mediante la minimización de una función de costo cuadrática que normalmente involucra el error entre la predicción y la señal de referencia, así como los cambios en el esfuerzo de control.




Fig. 2: Esquema de control predictivo basado en un modelo neurodifuso auto-regresivo.

En nuestro caso, la identificación neurodifusa se realizó empleando un sistema tipo ANFIS, con un vector de entradas de dimensión 2, 5 funciones de pertenencia del tipo campana generalizada por entrada, 25 reglas del tipo Takagi-Sugeno [9], 30 parámetros antecedentes y 75 consecuentes. Para ello, se realizaron varios entrenamientos con los datos experimentales a 10 segundos obtenidos en el arranque de una unidad termoeléctrica bajo el esquema serie-paralelo con diferentes entradas candidatas cuyos parámetros antecedentes y consecuentes se sintonizaron mediante el Algoritmo de Aprendizaje Híbrido que combina la Regla de Retropropagación y el Estimador de Mínimos Cuadrados para escoger finalmente aquellas que proporcionaron el menor error de entrenamiento después de 10 iteraciones.

Este criterio de selección de las entradas es sencillo y produjo resultados satisfactorios [10]. La función que define a la red que logró reproducir mejor los datos correspondientes a la salida de la planta fue:

$$\hat{T}(k) \approx f(T_{k-1}, u_{k-3}) \quad (1)$$

Donde:

T_{k-1} = Valor histórico de temperatura con una muestra de atraso en °C.

u_{k-3} = Valor histórico del flujo de combustible en m^3/H con un retardo de tres muestras.

La suma de errores cuadráticos o error total de medición en el entrenamiento fue de 0.115 y para obtener la versión auto-regresiva fue necesario retroalimentar los valores que proporciona el modelo obtenido, como se muestra en la figura 3.




Fig. 3: Modelo neurodifuso auto-regresivo a 10 segundos correspondiente al proceso.

La comparación entre los datos de temperatura de la planta y la aproximación con el modelo auto-regresivo se muestran en la figura 4, con líneas continua y discontinua, respectivamente, donde puede observarse que ambas están prácticamente superpuestas.




Fig 4: Gráfica comparativa entre la aproximación obtenida con el modelo neurodifuso auto-regresivo y la temperatura de salida de la planta en °C.

En cuanto al problema de optimización numérica, se tienen las siguientes consideraciones principales:

- Dado que el operador dispone en su tablero de una precisión de un decimal, el paso de combustible empleado en la optimización para determinar el flujo de combustible óptimo estará dado por:

$$\Delta = 0.1 m^3 / hora \quad (2)$$

- El intervalo correspondiente al flujo de combustible mínimo y máximo es:

$$0 \leq u_k \leq 10 \text{ m}^3/\text{hora} \quad (3)$$

- No existe un modelo matemático del proceso a controlar, tampoco se conocen sus derivadas y en consecuencia también se desconocen sus propiedades, solo se cuentan con datos experimentales del mismo.
- Se dispone de un modelo neurodifuso auto-regresivo del proceso a controlar.

Además, para desarrollar el algoritmo de control debemos tomar en cuenta las siguientes condiciones operativas reales para el caso de cualquier termoeléctrica con características semejantes a la que hemos identificado:

- Durante 10 minutos, la señal de control u_k permanecerá constante.
- Cada 10 minutos el operador tomará la medición correspondiente a la temperatura real de la planta.
- La señal de control se actualizará cada 10 minutos.
- El operador cerrará el lazo de control cada 10 minutos.

El problema de optimización radica ahora en determinar el flujo de combustible óptimo u_k , que minimiza la siguiente función objetivo:

$$J(u_k) = \mathbf{a}_k (\hat{T}_{k+1} - \text{ref}_{k+1})^2 + \mathbf{b}_k (u_{k-1} - u_k)^2 \quad (4)$$

Donde

\hat{T}_{k+1} = Predicción de temperatura en °C

correspondiente a los próximos 10 minutos.

ref_{k+1} = Referencia de temperatura en °C

correspondiente a los próximos 10 minutos.

u_k = Flujo de combustible óptimo en m^3/H a emplear en los siguientes 10 minutos

u_{k-1} = Gasto de combustible aplicado en el proceso en el período anterior.

\mathbf{a}_k = escalar correspondiente al peso del error cuadrático de temperatura.

\mathbf{b}_k = escalar correspondiente al peso del esfuerzo de control.

Para minimizar la función objetivo anterior, se realiza una búsqueda para determinar el flujo óptimo de combustible y para lograrlo se ha implementado un procedimiento que consiste en variar el flujo de

combustible de acuerdo a (2) en el intervalo dado en (3) y evaluarlo en la función objetivo de tal modo que por comparación entre una evaluación y otra se localiza el valor de flujo de combustible que minimiza (4). Ya que en (4) se requiere conocer T_{k+1} es necesario efectuar d predicciones¹, evaluando para ello el modelo neurodifuso auto-regresivo. Las $d-1$ predicciones iniciales involucran el flujo de combustible conocido del período anterior $k-1$, donde d es el retardo correspondiente a la señal de flujo de combustible en el modelo neurodifuso²:

$$\begin{aligned} \hat{T}_k^2 &= f(T_k^1, u_{k-1}) \\ \hat{T}_k^d &= f(\hat{T}_k^{d-1}, u_{k-1}) \end{aligned} \quad (5)$$

Donde

$$\hat{T}_k^1 = T_k^{\text{real}} \quad (6)$$

Es la temperatura real del período k .

Una vez efectuadas las predicciones iniciales, debemos calcular aquellas donde el flujo de combustible óptimo a aplicar en el período deberá determinarse con el procedimiento de optimización:

$$\begin{aligned} \hat{T}_k^{d+1} &= f(\hat{T}_k^d, u_k) \\ \hat{T}_k^{dli} &= f(\hat{T}_k^{dli-1}, u_k) \\ \hat{T}_{k+1}^{dli} &= f(\hat{T}_k^{dli}, u_k) \end{aligned} \quad (7)$$

Nótese que el flujo de combustible óptimo a determinar está denotado por u_k dado que el gasto de combustible es conocido durante las primeras predicciones debido al retardo d que maneja el modelo. Estas predicciones deben efectuarse iterativamente para cada variación del flujo de combustible y en cada período k , de 10 minutos a considerar en el arranque del generador de vapor.

¹ 60 en este caso ya que el modelo trabaja a 10 segundos.

² 3 muestras de 10 segundos en este caso.

4. RESULTADOS DE SIMULACIÓN

Se realizaron pruebas de simulación programando el algoritmo de control en Matlab para un arranque con una señal de temperatura de referencia convencional cuyo seguimiento se muestra en la figura 5. Con esta referencia se pretende un gradiente inicial de arranque de 91°C/Hora descendiendo a 75°C/Hora hasta llegar a 60°C/Hora . El comportamiento del gradiente de temperatura se muestra en la figura 6 y el flujo o gasto de combustible óptimo sugerido al operador en la figura 7.




Fig. 5: Seguimiento para una señal de temperatura de referencia convencional, nótese que resultaron sobrepuestas.




Fig. 6: Comportamiento del gradiente de temperatura alcanzado en líneas discontinuas.




Fig. 7: Gasto de combustible óptimo sugerido al operador.

5. CONCLUSIONES

Con los resultados expuestos observamos que se satisfacen los requerimientos principales de diseño para resolver el problema con el algoritmo de control desarrollado y que además puede aplicarse a las diferentes unidades termoelectricas del país.

La identificación neurodifusa demostró la eficiencia de este tipo de técnicas para obtener modelos confiables del proceso a partir de datos, de una manera sencilla y que son útiles al emplearse como predictores en los esquemas de control predictivo basados en el modelo.

Es posible mejorar el comportamiento del gradiente de temperatura añadiendo un tercer término que lo involucre en la función objetivo a minimizar.

Se aporta un esquema de control basado en un modelo neurodifuso auto-regresivo que representa una mejora en la operación de las centrales termoelectricas.

REFERENCIAS

- [1].- D. W. Clarke, C. Mohtadi, P.S. Tuffs, "Generalized Predictive Control", *Automatica*, Vol. 23, No. 2, pp. 137-160, 1987.
- [2].- J. M. Sousa, R. Babuška, P. Bruijn, H. B. Verbruggen, "Comparison of Conventional and Fuzzy Predictive Control", *Proceedings of the IEEE*, 1996.
- [3].- R. Babuška, "An Overview of Fuzzy Modeling and Model-Based Fuzzy Control", *World Scientific Series in Robotics and Intelligent Systems- Vol. 23, Fuzzy Logic Control Advances in Applications, Part I: Tutorials pp. 3-36, World Scientific Publishing Co. Pte. Ltd., 1999.*
- [4].- R. Babuška, H. B. Verbruggen, "An Overview of Fuzzy Modeling for Control", *Control Eng. Practice*, Vol. 4 No. 11, pp. 1593-1606, 1996.
- [5].- J.A. Ruz Hernández, *Sintonización óptima de un controlador difuso para el calentamiento y presurización del generador de vapor de una unidad termoeléctrica*, Tesis de Maestría en Ingeniería de Control, pp. 29-44, Universidad Autónoma del Carmen, Cd. del Carmen, Campeche, México, Mayo de 2001.
- [6].- J-S Roger Jang, "ANFIS: Adaptive-Network-based Fuzzy Inference System", *IEEE Transactions on Systems, Man and Cybernetics*, Vol. 23, No. 3, May/June 1993.
- [7].- J-S Roger Jang, CH-T Sun, "Neuro Fuzzy Modeling and Control", *Proceedings of the IEEE*, Vol. 83, No.3, March. 1995.
- [8].- Comisión Federal de Electricidad, *Procedimiento de Operación General*, Centro de Adiestramiento de Operadores Ixtapantongo.
- [9].- T. Takagi and M. Sugeno, "Fuzzy Identification of systems and its applications to modeling and control", *IEEE Trans. Syst., Man, Cybern.*, Vol 15, pp. 116-132, 1985.
- [10].- J. – S Roger Jang, "Input Selection for ANFIS learning", *Proceedings of the Fifth IEEE International Conference on Fuzzy Systems*, Vol. 2, pp. 1493-1499, 1996.