



RICARDO NAVAS.*
EDGAR CASTILLO MONROY**

**DESARROLLO DE UNA
ESTRATEGIA CON BASE
EN TÉCNICAS DE
INTELIGENCIA
ARTIFICIAL PARA EL
CONTROL DE UNA TORRE
DE ABSORCIÓN DE
HIDROCARBUROS
PESADOS EN PLANTAS
DE PROCESAMIENTO DE
GAS NATURAL CON
CARGA VARIABLE**

** Ingeniero Químico. Tesis de grado para optar el título de MSc en Ingeniería Química, Universidad Industrial de Santander, UIS. Centro de Estudios Ambientales, Bucaramanga, Colombia.*

*** Ph.D. Universidad Industrial de Santander, UIS. Centro de Estudios Ambientales, Bucaramanga, Colombia*





Ricardo Navas Mantilla

Resumen

El gas natural proveniente de los pozos de crudo, contiene hidrocarburos pesados los cuales se remueven para su distribución y venta como productos líquidos, éste proceso de remoción se lleva a cabo en una torre de platos que absorbe los hidrocarburos pesados. Sin embargo, la frecuente

variación en el volumen de suministro de gas a la torre absorbadora hace que su funcionamiento sea muy inestable lo que conlleva problemas operacionales que afectan su buen desempeño, ya que los sistemas de control convencional presentan baja respuesta para el caso expuesto. La idea de este trabajo es determinar cuantitativamente una estrategia de control para una torre absorbadora, basada en técnicas de inteligencia artificial.

Introducción

El gas natural proveniente de los pozos de crudo contiene Metano, Etano, hidrocarburos pesados (Propano, Butano, Pentano +), CO₂, N₂, etc. Una etapa clave en el procesamiento del gas natural, consiste en la remoción de los hidrocarburos pesados para su posterior distribución y venta. Este proceso de remoción, se lleva a cabo en una torre de platos, absorbadora. Sin embargo, la frecuente variación en el volumen de suministro a la torre, hace que su funcionamiento sea muy inestable lo que conlleva problemas operacionales que afectan su buen desempeño y el de la planta de procesamiento de gas en general. Atacar este problema desde el punto de vista del suministro no es una opción viable, ya que los centros productores no pueden asegurar la constancia de la carga. Una alternativa posible, consiste en atacar el problema *in situ*, adecuando el funcionamiento de la torre a las permanentes variaciones en la carga de gas a la planta de procesamiento. Los sistemas de control convencional, presentan baja respuesta para estos casos. Se ha encontrado que los sistemas de inteligencia artificial pueden retroalimentarse con nuevas condiciones de operación, y mejorar su desempeño (Hoskins y Himmelblue). Los estudios de Ramchandran y Russell muestran que un sistema de redes neuronales predice adecuadamente el comportamiento de estas torres. Estos modelos sólo utilizan redes neuronales de las herramientas de inteligencia artificial disponibles. Nuestro enfoque, desea incluir modelos de lógica difusa con redes neuronales, ya que los modelos fuzzy pueden definir rangos de aleatoriedad y las redes neuronales tienen la capacidad de adaptación a las condiciones de campo y así de ésta manera determinar cuantitativamente una estrategia de control basada en técnicas de inteligencia artificial, para una torre absorbadora de productos condensables.

Esquema operacional y metodológico para el desarrollo de la estrategia de control

Se realizó en primera instancia la simulación de la torre sobre un ambiente de simulación

multitarea, en el que se implementó la estrategia de control neuro-fuzzy. Para la simulación no se utilizó simulador comercial, sino que se desarrolló uno particular para la torre, teniendo en cuenta balances de masa, energía, equilibrio, etc.

Balace de masa por componente en el plato j:

$$0 = \left(\frac{L_{j-1}}{U_{j-1}^L} \right) u_{j-1,i}^L + \left(\frac{V_{j+1}}{U_{j+1}^V} \right) u_{j+1,i}^V - \left(\frac{L_j}{U_j^L} \right) u_{j,i}^L - \left(\frac{V_j}{U_j^V} \right) u_{j,i}^V - \frac{du_{j,i}^V}{dt} - \frac{du_{j,i}^L}{dt}, \quad j=1, \dots, N; i=1, \dots, C \quad (\text{Ec.1})$$

Sumatoria de volúmenes de vapor en el plato j:

$$0 = \sum_{i=1}^C u_{j,i}^V - U_j^V, \quad j=1, \dots, N \quad (\text{Ec.2})$$

Sumatoria de volúmenes de líquido en el plato j:

$$0 = \sum_{i=1}^C u_{j,i}^L - U_j^L, \quad j=1, \dots, N \quad (\text{Ec.3})$$

Relación de equilibrio en el plato j:

$$0 = \frac{\gamma_{j,i}^L K_{j,i} u_{j,i}^L}{U_j^L} - \frac{\gamma_{j,i}^V u_{j,i}^V}{U_j^V}, \quad j=1, \dots, N; i=1, \dots, C \quad (\text{Ec.4})$$

Balace de energía en el plato j:

$$0 = \left(\frac{L_{j-1}}{U_{j-1}^L} \right) E_{j-1}^L + \left(\frac{V_{j+1}}{U_{j+1}^V} \right) E_{j+1}^V - \left(\frac{L_j}{U_j^L} \right) E_j^L - \left(\frac{V_j}{U_j^V} \right) E_j^V - M_j C_V^s \frac{dT_j}{dt} - \frac{dE_j^V}{dt} - \frac{dE_j^L}{dt}, \quad j=1, \dots, N \quad (\text{Ec.5})$$

Sumatoria de entalpías de la fase vapor en el plato j:

$$0 = \sum_{i=1}^C \hat{H}_{j,i} u_{j,i}^V - E_j^V, \quad j=1, \dots, N \quad (\text{Ec.6})$$

Sumatoria de entalpías de la fase líquida en el plato j:

$$0 = \sum_{i=1}^C \hat{h}_{j,i} u_{j,i}^L - E_j^L, \quad j=1, \dots, N \quad (\text{Ec.7})$$

Para las cuales se pueden establecer las $N(2C+5)$ variables para los N platos de la torre, donde el total de volumen de líquido y vapor en cada plato se conoce.

El esquema de ecuaciones algebraicas y diferenciales obtenido para la simulación dinámica de la torre con más de una derivada,

se puede resolver por medio del algoritmo generalizado, método semi-implícito de Runge-Kutta, Michelsen¹ 1976. Este método requiere determinar los valores iniciales del sistema de variables $N(2C+5)$ independientes, por lo tanto se desarrolló el método de suma de flujos en estado estable, según el algoritmo de Burningham y Otto 1967. Los datos de equilibrio de fases de los componentes utilizados fueron tomados de Prausnitz et. al.³

Para validar la exactitud del simulador desarrollado se recopiló de información de campo del funcionamiento de la torre, cromatografía, temperatura y presión del gas de entrada a la torre, flujo y composición del varsol, etc. se realizaron las

corridas en el simulador desarrollado para obtener el comportamiento del mismo y realizar la comprobación con los datos obtenidos en campo, esto nos permitió verificar que el simulador predice con alta exactitud el comportamiento de la torre con un coeficiente de correlación del 98.2%. En la Figura 1 se muestra el diagrama típico de una torre, con su nomenclatura.




Figura 1. Diagrama de una torre absorbidora de platos.

Estrategia de control Neuro-Fuzzy

El objetivo del entrenamiento de la red neuronal fue predecir el flujo óptimo de varsol a partir del flujo y composición de la corriente de gas de entrada cargado a la torre. No se tuvieron en cuenta otras variables como la presión ya que varían poco. Por lo tanto, inicialmente se debió determinar el flujo óptimo de varsol para cada una de las condiciones del gas de entrada a la torre, dado que sólo se tiene un dato para el flujo de varsol obtenido de los datos tomados en campo. Para hacer esto, se hicieron corridas a cada uno de los datos de gas de entrada, en el simulador desarrollado y se estipularon ocho flujos de varsol entre 50 y 120 gpm, donde se obtuvo el óptimo bajo criterios económicos. Una

vez se tenían los flujos óptimos de varsol se procedió a configurar la red neuronal, por lo que se corrieron diferentes arquitecturas disponibles en la caja de herramientas de redes neuronales de Matlab - versión 3.0 y para entrenar la red neuronal se tomaron como datos de entrada el flujo de gas entre 26 y 34.5 MSCFD con su respectiva composición y como dato de salida el flujo de varsol, entre 75 y 110 gpm, que son los rangos normales de operación de la torre. Para obtener la mejor configuración se realizaron casos de sondeo variando el número de capas internas, número de neuronas por capa, con diferentes arreglos de funciones de transferencia y técnicas de entrenamiento y se encontró que la mejor configuración de red neuronal fue de cuatro capas, con nueve neuronas en la primera, siete, siete y una en la última. El entrenamiento de redes neuronales es una tarea ardua y al azar, por lo que se trató en este trabajo de cubrir una vasta gama de posibilidades. De estas redes neuronales entrenadas, se realizó una clasificación de las mejores, según la correlación entre el valor predicho y el dado. En la Tabla 1 se listan los mejores casos en orden, según el factor de correlación.

Para determinar la capacidad de estimación del flujo óptimo de varsol por parte de las redes neuronales entrenadas, se realizó una validación de dichos entrenamientos con los datos óptimos de operación de la planta y se realizaron pruebas de extrapolación e interpolación. Según los datos obtenidos para las estimaciones de interpolación, se tiene que la configuración Early41b-bfg, Bay02 y Bay09a son los mejores casos que predicen el flujo óptimo de varsol. En

Tabla 1. Configuraciones de entrenamiento de las redes neuronales seleccionadas

Nombre Red	Prom Errores	std Errores	Iteraciones	Prom(m)	Prom(b)	Prom(r)
Bay09a	0.056	0.202	38	0.971	2.079	0.990
Early4-cgp	0.044	0.072	17	0.988	0.586	0.988
Early41b-bfg	0.108	0.238	27	0.998	-0.119	0.987
Early4-cgf	0.050	0.073	16	0.874	8.953	0.987
Early41a-bfg	0.541	2.105	19	0.979	1.234	0.986

la Figura 2 se aprecia la dispersión de los datos alrededor de la línea de pendiente 1 e intersección 0, mientras para la extrapolación se obtuvieron buenos resultados con las configuraciones Bay09a, Early41a-bfg y Early41b-bfg, según estos resultados podemos escoger los tres primeros de cada análisis. Calculando para estos cuatro casos comunes, el error típico producido en la estimación del valor calculado versus valor real presentado en la planta, se concluye que las dos mejores configuraciones de redes neuronales entrenadas son Bay09a y Early41b-bfg, la Tabla 2 muestra estos resultados obtenidos.

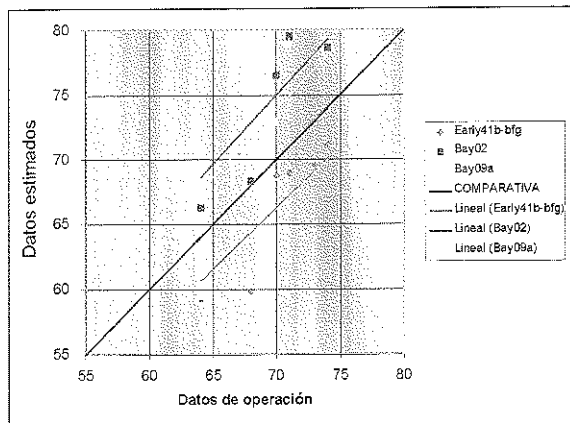


Figura 2.

Curvas comparativas, interpolación de configuraciones neuronales

Tabla 2. Errores típico xy

	Interpolación	Extrapolación
Bay09a	1.282	2.542
Early41b-bfg	1.693	3.460
Early4 a-bfg	2.456	6.038
Bay02	1.670	22.102

El elemento final en el lazo de control es una válvula, cuyo control de flujo de aceite absorbente se realizó por medio de la herramienta de inteligencia artificial lógica difusa (*fuzzy logic*), donde una vez se obtiene el flujo óptimo de varsol éste valor se toma como setpoint y se compara con el flujo de varsol de la torre obteniéndose la variable lingüística de entrada Errorflujovarsol la cual se configura con

la variable de salida Aperturaválvula en sus características difusas como se observa en la Figura 3, y se determinan el número de términos lingüísticos para cada una de las variables, tipo de función de pertenencia, el universo de las variables y por último se configuraron las reglas que rigieron el comportamiento del control difuso, algunas de las reglas lingüísticas utilizadas son:

- Si Errorflujovarsol = ExtremoN entonces Aperturaválvula = MuyRápidoAbrir
- Si Errorflujovarsol = GrandeN entonces Aperturaválvula = RápidoAbrir
- Si Errorflujovarsol = MedianoN entonces Aperturaválvula = Abrir
- Si Errorflujovarsol = PequeñoN entonces Aperturaválvula = LentoAbrir

Donde:

Errorflujovarsol: Es la variable lingüística de entrada y se toma como la diferencia entre el fujo de varsol a la torre, actual, y el flujo de varsol que debería tener, dado por la red neuronal, setpoint. Su universo se tomó entre -20 y 20 gpm de varsol, donde el valor negativo corresponde a abrir la válvula que controla el flujo de varsol.

ExtremoN, GrandeN, MedianoN, PequeñoN: Son algunos de los términos lingüísticos de la variable lingüística de entrada.

Aperturaválvula: Es la variable lingüística de salida y es el valor de la señal que se le envía a la válvula de control, su universo se tomó entre -4 y 4 mv.

MuyRápidoAbrir, RápidoAbrir, Abrir, LentoAbrir: Son algunos de los términos lingüísticos de la variable lingüística de salida.

El valor obtenido de la variable lingüística de salida Aperturaválvula lo toma la ecuación dinámica de la válvula, obteniéndose el nuevo flujo de varsol a partir del desplazamiento del émbolo, y ese nuevo valor es el que se utiliza para continuar con la simulación dinámica de la torre ante cualquier perturbación.




Figura 3. Configuración de las variables de entrada.

Análisis de la estrategia de control Neuro-Fuzzy

Con las configuraciones de redes neuronales Bay09a y Early41b-bfg, el sistema de lógica difusa y la ecuación de comportamiento dinámico de la válvula que conforman el sistema de control neuro-fuzzy, se trabajó para las condiciones reales tomadas de la planta y mostradas en la figura 4., donde se aprecia la poca estabilidad del proceso en cuanto de producción de hidrocarburos pesados dentro del aceite rico, varsol e hidrocarburos pesados.

En la Figura 5, se puede observar la respuesta del control neuro-fuzzy obtenida fuera de línea en el simulador desarrollado, en la cual se aprecia que el esquema de control neuro-fuzzy desarrollado logró en




Figura 4. Gráfica de producción de aceite rico.

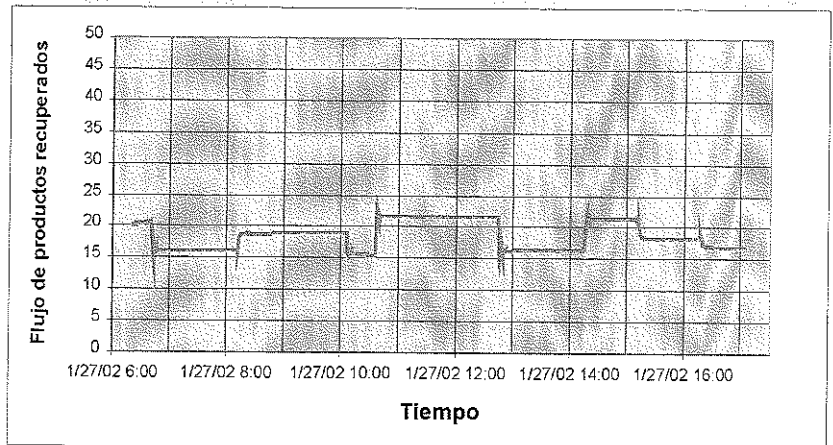


Figura 5. Respuesta del control neuro-fuzzy

un corto periodo de tiempo estabilizar la respuesta del proceso ante una perturbación, y por lo tanto estabilizar el flujo de aceite rico en el valor óptimo, obtenido a partir del flujo óptimo de varsol. Cabe resaltar que el sistema logra el estado estable en menos de 10 minutos, que en caso contrario, el proceso en estado manual que se muestra en la Figura 5 nunca se logra alcanzar.

CONCLUSIONES

- Se desarrolló una estrategia de control predictivo neuro-fuzzy para el control del flujo de aceite absorbente óptimo requerido para la absorción de productos licuables del gas natural para una torre de absorción de platos perforados.
- Se realizó la optimización del entrenamiento de la red neuronal con datos de carga variable de gas natural rico para la estimación del flujo de aceite absorbente óptimo y se configuró y sintonizó la variables de entrada y salida del control difuso para obtener la mejor respuesta del esquema neuro-fuzzy predictivo bajo situaciones de variación del flujo de carga de gas natural.
- El modelo de control predictivo neuro-fuzzy desarrollado presenta un buen comportamiento bajo altas variaciones en las condiciones de carga de gas natural. La exactitud de la predicción de la red neuronal posee bajo error, alrededor del 3%. La

estabilidad mostrada por el esquema propuesto fue muy buena, alcanzando el estado estable en menos de 10 minutos sin presentar inestabilidad en el proceso.

- Por último se desarrolló una herramienta computacional robusta para la simulación y desarrollo de estrategias de control con elementos de inteligencia artificial.

Nomeclatura

L:	flujo molar total de líquido en el plato
V:	flujo molar total de vapor en el plato
U:	volumen molar total en el plato
u:	volumen molar del componente en el plato
t:	tiempo
N:	número de platos
C:	número de componentes
γ :	coeficiente de actividad
K:	constante de equilibrio
E:	energía en el plato
M:	masa del metal de la columna
Cv:	capacidad calorífica a volumen constante
\hat{h} :	entalpía de la fase líquida
\hat{H} :	entalpía de la fase vapor

Índices

j:	indica la numeración de los platos
i:	indica la numeración de los componentes
L:	fase líquida
V:	fase vapor

Referencias

1. Hopkins J.C. and Himmelblue D.M., Artificial neural network models of knowledge representation in chemical engineering, Computers chemical engineering, vol. 12, pp. 881-890, 1992.
2. Ramchandran S., Russell R. R., A very simple structure for neural network control of distillation, Journal Process Control, vol. 5, No. 2, pp. 115-128, 1995.
3. Michelsen M. L., An efficient general purpose method of integration of stiff-ordinary differential equations, AIChE J. 22(3) pag. 594, 1976.
4. Burningham D.W. and F.D. Otto, Hydrocarbon Processing 46(10), pag. 163-170, 1967.
5. Prausnitz J. M., Eckert C.A., Orye R.V., and O'Connell J.P., Computer calculation for multicomponent vapor-liquid equilibria, Prentice-Hall book company, New york, 1963.
6. Holland C. D., Fundamentals of multicomponent distillation, McGraw-Hill book company, New York, 1981.
7. Holland C. D., Liapis A. I., Computer methods for solving dynamic separation problems, McGraw-Hill book company, New York, 1983.
8. Luyben W. L., Practical distillation control, Van Nostrand Reinhold, New York, 1992.
9. Rosenblatt, F. Principles of neurodynamics, Perceptrons and the theory of brain mechanisms, Sparta, Washington, 1961.
10. Safavi A.A., Noorail A., Romagnoli J.A., A hybrid model formulation for a distillation column and the on-line optimisation study, Journal Process Control, vol. 9, pp. 125-134, 1999.