



Ingeniería. Revista de la Universidad de
Costa Rica

ISSN: 1409-2441

marcela.quiros@ucr.ac.cr

Universidad de Costa Rica
Costa Rica

López Sosa, Ixmit Jaryth; Pérez Pacheco, Sergio Alejandro
Redes neuronales de base radial como modelos dinámicos para la puesta en marcha de
columnas de destilación por lotes
Ingeniería. Revista de la Universidad de Costa Rica, vol. 28, núm. 1, enero-junio, 2018,
pp. 15-28
Universidad de Costa Rica
Ciudad Universitaria Rodrigo Facio, Costa Rica

Disponible en: <https://www.redalyc.org/articulo.oa?id=44170540002>

- Cómo citar el artículo
- Número completo
- Más información del artículo
- Página de la revista en redalyc.org

redalyc.org

Sistema de Información Científica
Red de Revistas Científicas de América Latina, el Caribe, España y Portugal
Proyecto académico sin fines de lucro, desarrollado bajo la iniciativa de acceso abierto

Redes neuronales de base radial como modelos dinámicos para la puesta en marcha de columnas de destilación por lotes

Radial Basis Neural Networks as Dynamic Models for the Start-Up of Batch Distillation

Ixmit Jaryth López Sosa

Escuela de Ingeniería Química, Universidad de Carabobo, Valencia, Venezuela

Ixmitl@yahoo.com

Sergio Alejandro Pérez Pacheco

Escuela de Ingeniería Química, Universidad de Carabobo, Valencia, Venezuela

sperez@uc.edu.ve

Recibido: 3 de setiembre 2017

Aceptado: 12 de octubre 2017

Resumen

En la literatura existen pocos modelos rigurosos para describir el perfil de temperatura durante el periodo de puesta en marcha de las columnas de destilación. En este trabajo, se desarrolla un modelo empleando redes neurales de base radial con datos recolectados durante el período de puesta en marcha de una columna de destilación discontinua para la de mezcla etanol y agua. El entrenamiento de la eficacia de la red neuronal se obtiene realizando un pre-procesamiento de las entradas y un cambio de escala. Para obtener el perfil de temperatura, se recolectan datos a lo largo de diferentes puntos de la columna y los resultados se aplican a múltiples redes. Esto permite la construcción del perfil de temperatura en la columna hasta obtener un error cuadrático medio menor que los valores máximos establecidos durante el preprocesamiento ($mse = 0,001$) de las redes. Finalmente, se obtiene un modelo que permite observar la transición en la columna desde el estado frío vacío hasta el estado estacionario, normalmente un desafío en los modelos convencionales.

Palabras clave:

Destilación, redes neuronales artificiales, proceso de arranque, modelación.

Abstract

Few rigorous models exist in literature for describing the temperature profile during start-up periods of distillation columns. In this work, a model is developed by applying several radial basis neural networks to data collected during the start-up period of a batch distillation column consisting of ethanol and water. Neural network efficiency training is introduced through rescale



entry pre-processing series. To obtain the temperature profile, data points are obtained along different points of the column, and the results are applied to multiple networks. This allows construction of the temperature profile in the column consisting of a mean square error less than the maximum established values set during the efficiency pre-processing ($mse = 0.001$) of the networks. This model also allows observation of transition in the column from the empty cold state to the steady state, normally a challenge in conventional models.

Keywords:

Start-up, Distillation, Artificial Neural Networks, modelation.

1. INTRODUCCIÓN

La destilación discontinua es una operación unitaria ampliamente utilizada en la química fina, farmacéutica, bioquímica, e industria de alimentos para procesar pequeñas cantidades de materiales de alto valor añadido al separar mezclas de componentes que presenten puntos de ebullición distintos.

En los últimos años se ha evidenciado un creciente y renovado interés en los procesos por lote. Esto se debe a que las características del mercado favorecen a productos químicos y bioquímicos de alto valor agregado y bajo volumen de producción que, a menudo, están sujetos a un alto nivel de incertidumbre (Bonsfills y Puigjaner, 2004).

El proceso de start-up o puesta en marcha de una columna de destilación se refiere al período en el que la columna se transfiere desde un estado inicial a temperatura ambiente hasta las condiciones de operación de estado estacionario. Durante la puesta en marcha de una columna de destilación por lotes convencional, la columna es calentada hasta que las condiciones hidráulicas se establezcan. Por lo tanto, este período se define como el período antes de iniciar el retiro de los productos.

Durante el proceso de puesta en marcha, en una etapa cualquiera podemos considerar VI fases (ver figura 1) (Reepmeyer, Pepke y Wozny, 2004). En la fase I, la columna está vacía, a presión ambiente; en la fase II la columna se comienza a llenar de líquido, la temperatura es la misma del líquido que entra, asumiendo que no hay pérdida de calor y un flujo de líquido abandona la sección. En la fase III el vapor comienza a ascender; finalmente, la etapa se calienta hasta alcanzar la temperatura de burbuja y llega a la fase IV.

En la fase IV la ecuación de equilibrio de fases se activa. Ahora hay acumulación de vapor hasta que la presión es más alta que en la parte superior y el vapor comienza a abandonar (fase V). Cuando se inicia el reflujo en la columna, las secciones de la columna por encima del rehervidor se llenan y en la etapa VI todos los flujos (líquido y vapor) que entran y salen son mayores que cero.




Figura 1. Fases en una etapa durante el proceso de puesta en marcha de una columna de destilación. Original de Reepmeyer, Pepke y Wozny, 2004.

La operación de puesta en marcha involucra períodos transitorios muy complejos debido a los cambios drásticos y simultáneos en muchas variables de estado. Debido a que estas transiciones dinámicas se consideran como períodos no productivos, se han realizado algunas investigaciones con el fin de minimizar el tiempo de puesta en marcha,

el consumo de energía o la cantidad de los productos de desecho (González Velasco, Castresana Pelayo, González Marcos y Gutiérrez Ortiz, 1987; Ruiz, Cameron, y Gani, 1988; Fieg, Wozny, Kruse, 1993; Barolo, Guarise, Rienzi y Trotta, 1994; Sorensen y Skogestad, 1996; Han y Park, 1997; Costa, Vieiral, Secchi y Biscaia Jr., 2003).

Kister (1979) realizó un trabajo donde explica la complejidad de la modelación del proceso de puesta en marcha de una columna de destilación, y plantea que, de acuerdo con el comportamiento dinámico, este consta de tres fases, desarrollando así lo que se conocerá como el modelo de las tres fases, mediante la agrupación de la etapa II a la etapa V en una sola, considerada la etapa semicontinua en su totalidad.

La primera, llamada la fase discontinua, se caracteriza por su corto período de tiempo y la naturaleza discontinua de todas las variables (hidráulicas y de transferencia). La segunda fase, llamada la etapa semi-continua se caracteriza por las variables transitorias no-lineales. Al final de esta etapa, las variables hidráulicas alcanzan sus valores de estado estacionario. La tercera fase, llamada fase continua, se caracteriza por las respuestas lineales transitorias de todas las variables. Al final de esta etapa, todas las variables alcanzan sus valores de estado estacionario (89–91).

Gani, Ruiz y Cameron (1986) presentan un modelo para columnas de destilación capaz de simular el proceso de puesta en marcha para una columna de destilación operando en forma continua. El modelo consiste en una serie de ecuaciones diferenciales ordinarias obtenidas a partir de los balances de materia y energía alrededor de cada etapa, y un conjunto de ecuaciones/correlaciones algebraicas utilizadas para predecir las propiedades físicas, la hidráulica de platos, y un conjunto de procedimientos opcionales (por la dinámica del reflujo). En este trabajo, el proceso de puesta en marcha emplea una técnica de integración numérica eficiente que puede manejar las discontinuidades.

Wittgens y Skogestad (2000) profundizan en la dinámica de flujo (hidráulica bandeja), considerándola de vital importancia para la dinámica de respuesta inicial de columnas de destilación. Los parámetros más importantes son el líquido retenido, la constante de tiempo hidráulica y la constante de vapor que representa el efecto inicial de un cambio en el flujo de vapor o en el flujo de líquido. En el trabajo se presentan métodos para determinar estos parámetros experimentalmente, y para comparar los resultados con estimaciones de las correlaciones disponibles, tales como la fórmula Francis Weir.

Wang, Li, Wozny y Wang (2003) parten del modelo de las tres fases profundizado por Ruiz et al. (1988), pero aplicado a un proceso de destilación por lotes y partiendo desde un estado inicial vacío y frío con un modelo detallado para la conmutación desde el estado de no equilibrio al estado de equilibrio. Anteriormente, Hangos, Hallager, Csaki y Jorgensen (1991) habían planteado la fase discontinua con un modelo de no-equilibrio simplificado; Lowe (2001) también describió esta fase de un estado de no-equilibrio al estado de equilibrio, donde la temperatura de ebullición del componente ligero se utiliza como el punto de conmutación a la fase de equilibrio. Sin embargo, Wang et al. (2003) plantean un modelo riguroso bandeja por bandeja que describe el comportamiento dinámico de inicio en una columna de destilación a partir

de un estado vacío y frío. El modelo se basa en la física, así como la consideración de los cambios en las propiedades termodinámicas durante el inicio de la columna. Cada bandeja se describirá de una fase de no equilibrio, donde la transferencia de masa y energía tiene lugar, a una fase equilibrio líquido-vapor.

La secuencia de las transiciones de una bandeja es:

Estado vacío (EV) ---> Acumulación de líquido (AL) ---> Equilibrio líquido-vapor (ELV).

El modelo describe la operación de puesta en marcha mostrando dos tipos de conmutación de propiedades en una bandeja. El primero, para la conmutación desde el estado de no equilibrio al estado de equilibrio. La segunda conmutación es de la operación sin reflujo a la operación con el reflujo. La fase de no equilibrio incluye el EV y la AL durante el cual no hay separación en la bandeja. Con el aumento de la temperatura, la bandeja cambia desde la fase no equilibrio a la fase de equilibrio (el estado de ELV). Así, la presión del punto de burbuja se utiliza como el primer parámetro de conmutación.

Elgue, Prat, Cabassud, Le Lann y Cezerac (2004) desarrollan dos modelos matemáticos. El primer modelo llamado “modelo sencillo”, se basa en una versión mejorada del modelo de puesta en marcha desarrollado por Albet, Le Lann, Joulia y Koehret (1994a; 1994b). La introducción de un parámetro adicional en el llenado del plato constituye la principal diferencia. Al principio del llenado, el plato se supone demasiado frío para generar un flujo de vapor. La relación de llenado representa el valor de la retención de líquido en la medida que el plato está lo suficientemente caliente como para generar un flujo de vapor que sube al siguiente plato. Los autores llaman a este evento: evento de generación de vapor local (LVGE).

El modelaje para la simulación de columnas de destilación discontinua durante la operación de arranque es un problema muy difícil debido a la complejidad del comportamiento dinámico (Elgue et al., 2004). Solo unos pocos modelos rigurosos para las columnas de destilación durante la puesta en marcha se encuentran disponibles en la literatura y, en general, requiere una gran cantidad de parámetros relacionados con la geometría de los platos o el empaque.

Las redes neuronales han atraído la atención de los investigadores en una amplia variedad de campos de la ingeniería en las últimas décadas. Se compone de muchos elementos que tienen una relación no lineal entre los vectores de entrada y de salida. Comparada con otras tecnologías de modelado (Lippman, 1987), la red neuronal tiene una principal ventaja: el carácter no lineal. Se ha aplicado con éxito en la construcción de varios modelos de problemas del mundo real (Lu, Fang, Lin, Chen y Chen, 2007).

No se conocen trabajos preliminares sobre la modelación del proceso de puesta en marcha de una columna de destilación similar a la de esta investigación; sin embargo, entre las investigaciones donde se ha empleado una red neuronal para la modelación de una columna de destilación se tiene la construcción de un modelo para un sistema de destilación con catalizador de carbonato de dimetilo, y un método de optimización de algoritmo genético se utilizó para la búsqueda de parámetros de funcionamiento óptimos, basados en la técnica de red neuronal (Shi y Zuo, 2006).

Por otro lado, Pollock G. y Eldridge R. (2000) plantearon un modelo para obtener la altura equivalente a un plato teórico (HETP) en diversos tipos de relleno estructurado, utilizando una red neuronal. La HETP se predijo usando una red entrenada con datos semiempíricos. El modelo de red neuronal produce una predicción muy exacta experimentalmente de los valores de la HETP, y resultó más exacto que el modelo semiempírico tradicional de Rocha, Bravo y Fair (1996). En ninguna de estas investigaciones se plantea la modelación completa del proceso de puesta en marcha de una columna de destilación.

Es por lo anterior que el objetivo del presente trabajo es desarrollar un modelo para la estimación del perfil de temperaturas en una torre de destilación por lotes durante la etapa de arranque o puesta en marcha empleando redes neuronales artificiales.

2. MATERIALES Y MÉTODOS

2.1 Desarrollo del modelo neuronal

Las redes neuronales artificiales (RNA) o simplemente redes neuronales, constituyen una de las áreas de la inteligencia artificial que ha despertado mayor interés en los últimos años, y constituyen una herramienta general para abordar una amplia clase de problemas de identificación de sistemas dinámicos (Narendra y Parthasarathy, 1990).

El modelado empleando redes neuronales artificiales representa un marco eficaz para desarrollar modelos no estructurados, que han demostrado ser muy adecuados para modelar fenómenos altamente complejos y no lineales. Debido a su inherente naturaleza para modelar y recordar complejidades, las redes neuronales artificiales tienen aplicaciones en diversas áreas de la Ingeniería Química (Baratti, Vacca y Servida, 1995; Page, Gomm y Williams, 1993; Baratti, Corti y Servida, 1997; Stephanopoulos y Han, 1996; Wu, Tang, Hu, Quan, Song y Li, 2006).

Existen diferentes programas informáticos que permiten manejar redes neuronales de manera sencilla. Uno de los más potentes, y que será utilizado en este trabajo, es la Toolbox de redes neuronales de Matlab (Demuth y Beale, 1998).

Para el aprendizaje de la red se utilizó el aprendizaje off line; en este, se distingue entre una fase de aprendizaje con entrenamiento y una fase de operación o funcionamiento, existiendo un conjunto de datos de entrenamiento y un conjunto de datos de test o prueba que serán utilizados en la validación. En las redes con aprendizaje off line, los pesos de las conexiones permanecen fijos después de que termina la etapa de entrenamiento de la red. Debido precisamente a su carácter estático, estos sistemas no presentan problemas de estabilidad en su funcionamiento.

Se ha seleccionado trabajar con redes neuronales de base radial, las cuales tienen conexiones feedforward, que pueden ser de aprendizaje supervisado o híbrido (combinación entre aprendizaje supervisado y no supervisado) dado que su aplicación en procesos de esta naturaleza es cada vez mayor debido a los buenos resultados que se han obtenido con este tipo de redes donde el tiempo de entrenamiento es substancialmente inferior al requerido por otros algoritmos y por su capacidad de generalización.

Para la construcción de la red neuronal de base radial empleando Matlab se utiliza el comando `newrb`. Su sintaxis es:

$$\text{net} = \text{newrb}(\text{P}, \text{T}, \text{GOAL}, \text{SPREAD}, \text{MN}, \text{DF}); \quad (1)$$

donde:

`net` es la red de base radial

`P` es la matriz con los datos de entrada

`T` es la matriz con los datos de salida

`GOAL` es el error objetivo

`SPREAD` es la varianza del ancho de la campana Gaussiana (por defecto 1).

`MN` es el máximo número de neuronas en la primera capa

`DF` es la evolución del número de neuronas mostradas durante el entrenamiento (por defecto 25).

Los datos de entrada y salida (`P` y `T`) se dividen en dos grupos: un primer grupo que servirá para la creación de la red neuronal y un segundo grupo que servirá para la validación de la red obtenida.

2.2 Selección de los datos y de las variables de entrada

La recolección de datos se constituye en el punto definitivo y crucial para el éxito de la obtención y utilización de un modelo, ya que este solo refleja los datos con los cuales fue entrenado. Es por ello que recomiendan que la escogencia final de los datos sea llevada a cabo por personal asociado y con conocimiento del proceso (López, Rodríguez y Mujica, 2011).

En esta investigación los datos fueron recolectados durante pruebas realizadas empleando una mezcla etanol-agua con concentración inicial diferente, que varió entre 12% y 20%. Durante las pruebas se midió la temperatura desde el momento en que inicia el calentamiento hasta la estabilización de la temperatura en cada punto de medición a lo largo de la columna. Cada día las condiciones ambientales de trabajo eran diferentes y no controladas. Para el desarrollo de los modelos neuronales se empleó un 75% de los datos recolectados (247 patrones), y se reservó el 25% (83 patrones) restante para la validación de los resultados. Los datos fueron clasificados por corridas, seleccionando aleatoriamente las corridas que serían empleadas para el entrenamiento.

Para la selección de las variables de entrada y la de mayor significancia, algunos consideran que no hay una correlación que permita conseguir cuál es la variable que más impacta en la salida (Nascimento y Oliveira, 2016); sin embargo, para nuestro caso, se cuenta con una medición de temperatura en el tiempo, por lo que serán las variables seleccionadas, además de las condiciones iniciales (temperatura ambiente y concentración inicial). Véase la figura 2.




Figura 2. Datos recolectados durante las pruebas para la modelación de la temperatura en un punto cualquiera en la columna empleando RNA.

2.3 Pre-procesamiento de los datos

El entrenamiento de la red neuronal se puede hacer más eficiente si se emplean técnicas que pueden mejorar en algunos casos la eficacia del entrenamiento, como, por ejemplo, llevar a cabo un pre-procesamiento en las entradas y objetivos de la red, que consiste en reescalar las entradas (Demuth y Beale, 1998).

En este caso, los datos de la serie se normalizan o transforman a valores comprendidos entre -1 y 1 empleando la siguiente ecuación:

$$z_t = \frac{2y_t - (y_{\max} + y_{\min})}{y_{\max} - y_{\min}} \quad (2)$$

donde:

y_t son los valores originales de la serie

y_{\max} es el valor máximo de la serie

y_{\min} es el valor mínimo de la serie

z_t es la serie transformada en valores entre -1 y 1

2.4 Validación de los modelos obtenidos

Para la validación de la capacidad predictiva de la red obtenida se debe disponer de un conjunto de datos que permitirá determinar el error que se obtiene con la red ante nuevos escenarios.

Para la red de base radial se dispone de un conjunto de datos de prueba que representarán el 25% de la totalidad de los datos y servirán para llevar a cabo la prueba. Los datos de validación fueron seleccionados aleatoriamente de la totalidad de pruebas realizadas, donde se tenían condiciones ambientales y composición inicial diferente.

La función `sim` permite comprobar si la red diseñada permite predecir la salida con datos nuevos que no fueron utilizados durante el entrenamiento:

$$s = \text{sim}(\text{net}, P) \quad (3)$$

donde:

s es la matriz con resultados (salidas) de la simulación

P son los datos de entrada seleccionados para la simulación

Tanto con los datos de entrenamiento como con los datos de validación se determina el cuadrado del error medio (mse) entre las salidas obtenidas por la red y los valores reales con la siguiente función:

$$mse = mse(s, T) \quad (4)$$

donde:

mse es el cuadrado del error medio

s es el vector de elementos de la salida de la red obtenido con el modelo

Adicionalmente, se realiza un análisis de regresión entre la respuesta de la red y los datos objetivo (targets) correspondientes. En la Toolbox de redes neuronales de MatLab este análisis se realiza mediante la función '`postreg`':

$$[m, b, r] = \text{postreg}(T, s) \quad (5)$$

donde:

m es la pendiente de la regresión lineal

b es ordenada en el origen de la regresión lineal

r es el coeficiente de correlación entre los datos

3. RESULTADOS

A continuación se describen y presentan los resultados obtenidos durante el proceso de entrenamiento y validación de la red neuronal.

Para obtener la red neuronal de base radial se realizaron pruebas modificando la amplitud de la Campana de Gauss originada por la función radial, es decir, la desviación estándar. Algunos autores (Broomhead y Lowe, 1988) recomiendan y consideran a este ancho como un valor constante para cada una de las funciones radiales consideradas en

la capa oculta y, de este modo, contribuiría a simplificar los pasos de construcción del modelo de entrenamiento de la red.

En la tabla 1 y tabla 2 se presentan los resultados obtenidos al construir la red neuronal en el rehervidor con datos empleados para el entrenamiento de la red (tabla 1), y los resultados obtenidos posteriormente con los datos de validación (tabla 2). En ambos casos se emplea el error cuadrático medio (mse) y el coeficiente de correlación para evaluar los resultados de cada caso.

Tabla 1. Resultados obtenidos al construir la red de base radial en el rehervidor con datos de entrenamiento.

Ancho de la campana Gaussiana	Neuronas en la capa oculta	Entrenamiento	
		mse	Coefficiente de correlación
1	30	0.0010	0.9990
8	35	0.0010	0.9988
10	50	0.0010	0.9988

La red neuronal a seleccionar se debe hacer tomando en cuenta los resultados durante el entrenamiento y con los datos reservados para la validación, ya que una red puede arrojar un error aceptable durante el entrenamiento, pero puede no ser la más adecuada con datos nuevos no empleados para entrenar, y esto podría deberse a uno de los problemas más típicos en el entrenamiento de las redes neuronales artificiales, conocido como sobre-entrenamiento.

Tabla 2. Resultados obtenidos al construir la red de base radial en el rehervidor con datos de validación (20% molar en etanol).

Ancho de la campana Gaussiana	Neuronas en la capa oculta	Validación	
		mse	Coefficiente de correlación
1	30	0.6492	0.9949
8	35	0.6482	0.9958
10	50	0.6541	0.9954

El sobre-entrenamiento significa que el error de entrenamiento es muy bajo, pero el error ante nuevas entradas resulta elevado. Es decir, la red no es capaz de generalizar correctamente lo aprendido ante nuevas situaciones.

En la tabla 1 se puede observar que los mejores resultados se obtienen con una campana gaussiana de 8, aunque todos los casos evaluados durante el entrenamiento logran alcanzar el error meta ($mse=0.001$) con mayor o menor número de neuronas en la capa oculta. Sin embargo, con una campana gaussiana de 8 se logra el menor error con los datos de validación y el mejor coeficiente de correlación (ver tabla 2).

En el entrenamiento y validación de la red de base radial para las mediciones de tope en la columna de destilación, al igual que para el rehervidor, se fue ajustando el ancho de la Campana Gaussiana y evaluando el error (mse) obtenido en cada caso, así como el coeficiente de correlación (R). Los mejores resultados se obtienen con un ancho en la campana gaussiana de 5.1, 65 neuronas en la capa oculta donde se logra obtener un error (mse) de 0.001 con un coeficiente de correlación de 0.9992 durante el entrenamiento; y con los datos de validación también se obtiene como resultado en este caso un error (mse) de 0.9334 y un coeficiente de correlación de 0.9838.

En las figuras 3 y 4, se observa la representación gráfica del proceso de calentamiento arrojado por el modelo neuronal para la temperatura en el rehervidor y tope de la columna, respectivamente, cuando se utiliza una mezcla al 20% molar en etanol. Se puede observar que el modelo puede describir el proceso de puesta en marcha bastante bien.

La dinámica del proceso obtenida con el modelo se corresponde con lo esperado según los datos de validación. Los modelos logran predecir con bastante exactitud los cambios en la curva de calentamiento que representan cada una de las fases que se presentan durante el proceso de puesta en marcha de la columna, hasta alcanzar la temperatura de estabilización de la columna donde se considera estado pseudo estable.




Figura 3. Temperatura en el rehervidor (mezcla inicial al 20% molar en etanol).




Figura 4. Temperatura en el tope (mezcla inicial al 20% molar en etanol).

En la figura 4, se puede observar cómo en el tope de la columna ocurre la transición del estado vacío (EV) a la acumulación de líquido (AL) y el posterior equilibrio líquido-vapor (ELV), denominado por Kister (1979) como modelo de las tres fases, validando su planteamiento al agrupar de la etapa II a la etapa V en una sola, considerada la etapa semicontinua en su totalidad y, adicionalmente, se demuestra que la fase de acumulación de líquido es bastante corta, en comparación con las otras fases del proceso de puesta en marcha.

4. CONCLUSIONES

La red neuronal de base radial seleccionada en cada caso para modelar el proceso de arranque de la planta piloto de destilación por cargas permite obtener resultados de manera rápida, y con un bajo error e inferior al máximo establecido durante el entrenamiento.

Los perfiles de temperatura obtenidos con redes neuronales coinciden satisfactoriamente con los obtenidos experimentalmente en la columna durante el proceso de puesta en marcha.

Los modelos neuronales permiten describir el proceso de puesta en marcha o start-up de la columna por lotes. Se trata de un proceso riguroso, donde el cambio de una fase a la otra es difícil de modelar empleando los balances de materia y energía, dada la complejidad en la dinámica desde el estado de no equilibrio al de equilibrio y operación con reflujo.

REFERENCIAS

- Albet, J., Le Lann, J. M., Joulia, X., y Koehret, B. (1994a). Evolution et tendances in simulation of rectification discontinue. *Chemical Engineering Journal*, 54, 85–106.
- Albet, J., Le Lann, J. M., Joulia, X., y Koehret, B. (1994b). Operation policies for start-up in the case of batch rectification involving chemical reactions. *ICHEME Symposium Series 133*, 63-70.
- Baratti, R., Corti, S. y Servida A. (1997). A feedforward control strategy for distillation columns. *Artif. Intell. Eng.*, 11, 405-412.
- Baratti, R., Vacca, G. y Servida, A. (1995). Neural network modelling of distillation columns. *Hydrocarbon Proc.*, 74(6), 35-38.
- Barolo, M., Guarise, G. B., Rienzi, S. A., y Trotta, A. (1994). Nonlinear model-based start-up and operation control of a distillation column: an experimental study. *Industrial and Engineering Chemistry Research*, 33, 3160–3167.
- Bonsfills, A. y Puigjaner, L. (2004). Batch Distillation: simulation and experimental validation. *Chemical Engineering and Processing*, 43(10), 1239-1252.
- Broomhead, D. S., y Lowe, D. (1988). *Multivariable functional Interpolation and adaptive networks*. *Complex Systems*, 2.
- Costa Jr., E. F., Vieira, R. C., Secchi, A. R. y Biscaia Jr., E. C. (2003). Dynamic simulation of high-index models of batch distillation processes. *Latin American Applied Research*, 33, 155-160.
- Demuth, H. y Beale, M. (1998). *Neural network toolbox user's guide (for use with MATLABM)*. The Math Works.
- Elgue, S., Prat, L. E., Cabassud, M., Le Lann, J. M. y Cezerac, J. (2004). Dynamic models for startup operations of batch distillation columns with experimental validation. *Computers & Chemical Engineering*, 2(12), 2735-2747.
- Fieg, G., Wozny, G., y Kruse, C. (1993). Experimental and theoretical studies of the dynamics of start-up and product switchover of distillation columns. *Chemical Engineering and Processing*, 32, 283– 290.
- Gani, R., Ruiz, C. A., y Cameron, I. T. (1986). A generalized dynamic model for distillation columns. I. Model description and applications. *Computers and Chemistry Engineering*, 10(3), 181–198.
- González Velasco, J. M., Castresana Pelayo, J. M., González Marcos, J. A., y Gutiérrez Ortiz, M. A. (1987). Improvements in batch distillation start-up. *Industrial and Engineering Chemistry Research*, 26, 745–750.
- Han, M., y Park, S. (1997). Start-up of distillation columns using nonlinear wave model based control. *IFAC Proceedings Volumes*, 30(9), 659-665.
- Hangos, K. M., Hallager, L., Csaki, Z. S., y Jorgensen, S. B. (1991). A qualitative model for simulation of the startup of a distillation column with Energy Feedback. En L. Puigjaner & A. Espuna (Eds.), *Computer-Oriented Process Engineering*, (pp. 87-92).
- Kister, H. (1979). When tower startup has problems. *Hydrocarbon Processing*, 50(2), 89–94.
- Lippman, P. (1987). An Introduction to Computing with Neural Networks. *IEEE ASSP Magazine*, 4-22.

- López, I., Rodríguez, M., y Mujica, V. (2011) Modelación de las variables de control en la etapa de preneutralización de fertilizantes NPK vía DAP empleando un sistema adaptativo de inferencia neurodifuso (ANFIS). *Revista Ingeniería UC*, 18(3).
- Lowe, K. (2001). *Theoretische und experimentelle Untersuchungen über das Anfahren und die Prozessführung energetisch und stofflich gekoppelter Destillationskolonnen*. (Ph.D. thesis). Technische Universität, Berlin.
- Lu, J., Fang, N., Lin, J., Chen, F. y Chen, G. (2007). *Constructing the Model of Propylene Distillation Based on Neural Networks*. Presentado en: 22nd IEEE International Symposium on Intelligent Control Part of IEEE Multi-conference on Systems and Control Singapore.
- Narendra, K. y Parthasarathy, K. (1990). Identification and control of dynamical systems using neural networks. *IEEE Transactions on Neuronal Networks*, 1(1), 4-27.
- Nascimento, E. O. y Oliveira, L. N. (2016). Sensitivity Analysis of Cutting Force on Milling Process using Factorial Experimental Planning and Artificial Neural Networks. *IEEE Latin America Transactions*, 14(12).
- Page, G., Gomm, J. y Williams, D. (1993). *Application of Neural Networks to Modeling and Control*. Chapman & Hall, London.
- Pollock, G. y Eldridge, R. (2000). Neural Network Modeling of Structured Packing Height Equivalent to a Theoretical Plate. *Ind. Eng. Chem. Res.* 2000, (39), 1520-1525.
- Reepmeyer, F., Pepke, J. y Wozny, G. (2004). Analysis of the Start-up Process for Reactive Distillation. *Chemical Engineering & Technology*, 26(1), 81-86.
- Rocha, J., Bravo, J. y Fair, J. (1996). Distillation Columns Containing Structured Packings: A Comprehensive Model for their Performance. 2. Mass Transfer Model. *Ind. Eng. Chem. Res.* 35(5), 1660-1667.
- Ruiz, C., Cameron, I., y Gani, R., (1988). Generalized dynamic model for distillation columns - III. Study of startup operations. *Computers and Chemistry Engineering*, 12(1), 1- 14.
- Shi, H. y Zuo, F. (2006). Neural Network Modeling and GA Optimization of DMC Catalyst Distillation System. *Journal of Donghua University, Natural Science*, 4.
- Sorensen, E., y Skogestad, S. (1996). Optimal start-up procedures for batch distillation. *Computers and Chemistry Engineering*, 20(Suppl.), 1257-1262.
- Stephanopoulos, G. y Han, C. (1996). Intelligent systems in process engineering: A review. *Comput. Chem. Eng.*, 20, 743-791.
- Wang, L., Li, P., Wozny, G., y Wang, S. (2003). A start-up model for simulation of batch distillation starting from a cold state. *Computers and Chemistry Engineering*, 27, 1485-1497.
- Wittgens, B. y Skogestad, S. (2000). Evaluation of Dynamic Models of Distillation Columns with Emphasis on the Initial Response. *Modeling, identification and control*, 21(2), 83-103.
- Wu, H. X., Tang, Z. G., Hu, H., Quan, C., Song, H. H., y Li, S. Y. (2006). Predictions for Start-Up Processes of Reactive Distillation Column via Artificial Neural Network. *Chem. Eng. Technol.*, 29(6), 744-749.