

INTELIGENCIA ARTIFICIAL EN EL PROCESO DE OBTENCIÓN DE ALÚMINA

Franyelit Suárez¹, Sucre Cando Pacheco², Gustavo Almeida³

frangelits@gmail.com, sucre.candop@ug.edu.ec, gustavoalmeida@uti.edu.ec

¹Pontificia Universidad Católica del Ecuador, Sede Esmeraldas, Ecuador

²Universidad de Guayaquil, Ecuador

³Universidad Tecnológica Indoamérica, Ecuador

Recibido (30/06/18), aceptado (18/07/18)

Resumen: Con el fin de optimizar el proceso y controlar las variables en los tanques de lavado del proceso de producción de alumina, se ha considerado el diseño de un tanque de mezclado, que maneje los flujos entrantes de líquidos, tanto calientes como fríos, para manipular la temperatura de salida del tanque, así como el torque y a su vez visualizar las variables asociadas. Se espera que dicho sistema no solo aumente la eficiencia de la mezcla sino que también reduzca el riesgo involucrado en el manejo de sustancias a altas temperaturas. Al diseñar la supervisión inteligente, se espera desarrollar estrategias con medidas de las variables en tiempo real y modelos de uso robustos contra las perturbaciones. El sistema se desarrolló en Matlab© utilizando un modelo neuronal. Se trabajaron las variables de densidad, torque, turbidez, nivel del tanque y nivel de lodo en los tanques espesadores, para analizar la calidad del producto y su vinculación al ciclo Bayer.

Palabras Clave: Sistema inteligente, Redes de Backpropagation, supervisión inteligente, extracción de bauxita, proceso bayer.

ARTIFICIAL INTELLIGENCE IN THE PROCESS OF OBTAINING ALUMINA

Abstract: In order to optimize the process and control the variables in the washing tanks of the aluminum production process, the design of a mixing tank has been considered, which handles incoming liquid flows, both hot and cold, for manipulate the outlet temperature of the tank, as well as the torque and simultaneously visualize the associated variables. It is expected that this system not only increases the efficiency of the mixture but also reduces the risk involved in the handling of substances at high temperatures. When designing intelligent supervision, the strategies of use of variables in real time and robust use models against disturbances. The system was created in Matlab © using a neuronal Backpropagation model. We worked on density, torque, turbidity, tank level and mud level in the thickener tanks, to analyze the quality of the product and its link to the Bayer cycle.

Keywords: Intelligent system, Backpropagation networks, intelligent supervision, bauxite extraction, Bayer process.

I. INTRODUCCIÓN

Muchas plantas de obtención de alumina están obteniendo importantes beneficios económicos gracias a la utilización de tecnología de control avanzada. La globalización de los mercados, la consolidación de los productores y la aparición de sustitutos han creado un ambiente más competitivo que promueve una producción más óptima.

A lo largo de todo el proceso Bayer, el control avanzado se está convirtiendo en la herramienta preferida para obtener el rendimiento del capital empleado, ya que utiliza la infraestructura existente y requiere un mínimo de personal de apoyo. La tecnología de control predominante utilizada para lograr estos resultados es el control inteligente. En este trabajo se expondrán las aplicaciones y beneficios de este método

en la producción de alumina.

El aumento de la producción, el rendimiento y la calidad se está produciendo en muchas áreas del ciclo Bayer mediante un sistema de supervisión inteligente, sobre todo en la visualización de torque, densidad, turbidez y nivel de bauxita. También se ha demostrado que esta tecnología es adecuada para el lavado/espesado de material. La aplicación de nuevas tecnologías podría conducir a nuevos beneficios en el proceso. Es posible que otros procesos individuales como la molienda, la precipitación y la calcinación resulten apropiados para la aplicación de estas tecnologías de fácil acceso.

El diseño de un modelo de proceso basado en redes neuronales permite crear un entorno de trabajo apto a diferentes usuarios[6],[7] y con la versatilidad de ser modificado, además de permitir un estudio en el

comportamiento de las variables que intervienen en el proceso sin necesidad de ir al campo.

Díaz [1], desarrolló en Colombia, un sistema de control basado en redes neuronales para la estimación y control de la dosificación de coagulante en una planta de tratamiento de aguas, con este estudio se logró optimizar la capacidad de estimación de la dosis y la proyección del ahorro del consumo de coagulante mediante la implementación de un controlador difuso. Estos resultados constituyen una prueba de la utilidad de la aplicación de técnicas de control inteligente para el control de procesos químicos.

Mariña [2], desarrolló el modelo del tanque del área de oxalato de C.V.G BAUXILUM, con el fin de simular un sistema de control automático para el proceso de deslicorización del hidrato. Para esto realizó un estudio basado en variables de estado y concluyó con un análisis matemático de las variables del proceso.

Cardona [3], realizó un modelo matemático del sistema de medición de nivel de turbidez y lodo de los tanques del área 35 de C.V.G BAUXILUM, basando su estudio en un sistema de ecuaciones.

Suárez [4], desarrolló un sistema de visualización de variables de los tanques lavadores/espesadores del proceso Bayer, considerando las redes neuronales artificiales de backpropagation, obteniendo un rendimiento del 0,5% al 1%.

En este trabajo se presentan cuatro secciones; la primera aporta los antecedentes de esta investigación, luego se expone la metodología desarrollada, en la siguiente sección se encuentran los resultados y finalmente se presentan las conclusiones.

II. DESARROLLO

El desarrollo de un modelo inteligente para el proceso de decantación y lavado de lodo en el proceso de obtención de alúmina, permite realizar un análisis predictivo de las variables que intervienen en el proceso de los tanques lavadores y espesadores de esta parte del proceso[8-10], además contribuye al desarrollo de futuros controladores inteligentes.

En ocasiones el modelado de procesos industriales es llevado a cabo gracias al empleo de múltiples procedimientos matemáticos desarrollados a partir del estudio de las variables que intervienen en éstos y los fenómenos físicos participantes [12-15],[18]. El modelado de procesos resulta necesario para obtener resultados acerca del comportamiento de las variables del mismo, permitiendo la generación de un análisis predictivo. Sin embargo el empleo de grandes ecuaciones en el modelo de procesos requiere de una inversión de tiempo notable y no permite un acceso

dinámico que actúe directamente a los valores arrojados por tales procesos[16].

Con este trabajo se dio respuesta a una situación industrial empleando inteligencia artificial. Las más recientes investigaciones [5] demuestran la eficiencia del empleo de estos procedimientos aplicados al modelado de procesos industriales.

A. Proceso Bayer

El proceso Bayer es el proceso de obtención de alúmina, presentado por Karl Bayer en 1880. Constituye el único proceso en el mundo para la obtención de alúmina a partir de la trituración de la bauxita, y en consecuencia la obtención del aluminio.

Trituración y molienda

Con esta etapa comienza la primera fase del proceso Bayer, donde se prepara la materia prima, agregándole cal viva con el fin de regenerar el hidróxido de sodio controlando las impurezas (carbonatos) presentes en ella. Esta fase tiene como función disminuir el tamaño con que se recibe el material en la planta de aproximadamente 10 mm hasta un óptimo que garantice la disolución total de la alúmina durante el proceso de digestión, donde el óxido de aluminio es disuelto en el licor cáustico para obtener una mayor concentración de sólidos (820 g/l) y un porcentaje granulométrico menor o igual a 300 micrones. Se lleva a cabo en un conjunto de cinco circuitos de equipos, cada uno formado por un triturador de placas y un molino de bolas, con capacidad de 200 toneladas por hora.

Predesilicación

Seguidamente la suspensión de bauxita molida (pulpa de molienda) es conducida a la etapa siguiente, con el propósito de eliminar la sílice reactiva (caolita, la cual constituye un factor de contaminación del producto), a fin de obtener un material final dentro de las especificaciones requeridas, antes del proceso de digestión.

Digestión

La mezcla obtenida es bombeada a los digestores (recipientes cilíndricos de 420 metros cúbicos de capacidad), donde se agrega licor fuerte caliente (temperatura de 162 grados centígrados y concentración de soda cáustica superior a 160 gr/l), antes de entrar al primer tanque en servicio de una serie de cuatro recipientes, con el fin de realizar la extracción de la alúmina formando soluciones de aluminato de sodio y producir la precipitación de la sílice reactiva.

Precipitación

El flujo de licor madre proveniente de la etapa de enfriamiento se dirige hacia el primero de los tanques 1 650 metros cúbicos de capacidad, con agitadores mecánicos incorporados, donde se induce la aglomeración y crecimiento de los cristales de trihidratos de alumina por adición de una suspensión de semillas finas y gruesas, obtenidas de la descarga inferior de los tanque clasificadores secundarios y terciarios ubicados en el sector de clasificación de las fracciones de alumina donde ocurre la cristalización.

La precipitación ocurre de dos maneras:

Aglomeración: agrupamiento de partículas sólidas que ocurre alrededor de la suspensión de semilla fina, alimentada desde el área de control de oxalato.

Crecimiento: aumento de tamaño posterior a la inclusión del flujo de semilla gruesa proveniente del proceso de filtración de semilla gruesa.

La suspensión de semilla y el licor madre de alumina, fluyen por gravedad a través de doce tanques precipitadores durante un promedio de doce horas, a una temperatura de 74 a 78 grados centígrados, con aglomeración y crecimiento de los cristales de alumina.

Calcinación

Calcinación es la última etapa del proceso Bayer, destinada para producir alumina de grado metalúrgico a partir de los sólidos provenientes de la filtración del producto. Las partículas filtradas se someten a etapas de precalentamiento y secado, operando bajo la acción de un Vénturi donde los sólidos son fluidizados por el gas de desecho proveniente de la segunda fase de secado, aprovechando el contenido calorífico del gas.

La figura 1 muestra el proceso Bayer con el aporte de control difuso, para el control de nivel, temperatura y vapor en las diferentes áreas del proceso.

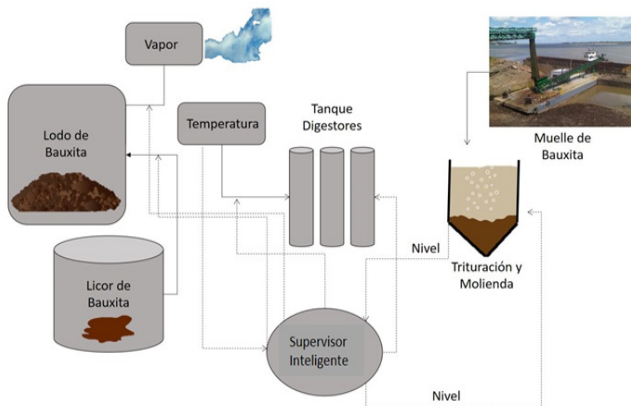


Figura 1. Proceso Bayer con supervisor inteligente

B. Sistema de Adquisición de datos

Sistema PHD de adquisición de datos.

El servidor de Matrikon OPC para Honeywell PHD se utiliza para extraer datos en tiempo real de históricos. Cualquier sistema se puede conectar con este servidor usando los estándares de la comunicación de OPC DA (acceso de los datos) o de OPC HDA (acceso histórico de los datos). El sistema permite:

- Tener acceso a los datos en tiempo real.
- Tener acceso a todos los tipos disponibles del punto de PHD.
- Timestamps de DCS
- Hojeado automatizado
- Acceso a distancia sin modificaciones locales de la configuración ni del registro
- Lectura y escritura
- Lista agregada: Promedio, Delta, Interpolado, Máximo, MaximumActualTime, Mínimo, MinimumActualTime, Cuesta De la Regresión, Desviación De Estándar, TimeAverage

El servidor de Matrikon OPC para Honeywell TDC3000 AxM permite a usuarios de OPC recuperar procesos y valores calculados de Honeywell TDC3000 AxM.

Beneficios del supervisor inteligente

Las principales ventajas de un sistema de supervisión de variables inteligente en las áreas de procesamiento de bauxita, consisten en un mayor rendimiento, entre 0,5 y 1%, un mejor control de la temperatura y, en algunos casos, un menor consumo de vapor. El consumo de energía es importante cuando la disponibilidad de vapor limita la producción, de lo contrario el uso óptimo del vapor es necesario para alcanzar los objetivos de rendimiento y calidad. El uso de diferentes técnicas ha sido utilizado en el proceso de molienda de material minero, siendo de mayor utilidad aquellas técnicas avanzadas de control, sin embargo el control inteligente ha tenido poca relevancia. Sin embargo las técnicas inteligentes para la molienda aportan importantes beneficios en la calidad del producto. Algunas de las variables necesarias para el control de molienda son las dimensiones de las partículas, el volumen de la carga y la densidad de la mezcla. En un molino de bolas típico, la aplicación controla la carga del molino, los sólidos del molino, la densidad de alimentación del ciclón, el tamaño de las partículas y la velocidad de alimentación del ciclón. El control difuso ofrece su aporte mediante la manipulación de velocidad de transporte del material,

además de intervenir en el flujo de agua de la molienda, del sumidero y el reciclaje. Uno de los beneficios más significativos en el proceso de molienda consiste en las mejoras en la distribución de la carga y en el tamaño de las partículas.

Un sistema inteligente de visualización y control de variables en otras áreas del proceso, puede lograr la manipulación del flujo hacia las unidades de evaporación y de derivación. Este sistema logra una mayor estabilidad en las tasas de evaporación, logrando el control en el suministro de licor de bauxita. Se ha estimado un rendimiento de 0,25 a 0,5%, reducción de las pérdidas de soda cáustica como consecuencia del aumento en la capacidad de lavado de 0,25% a 0,5%.

El proceso de decantación, que constituye el proceso de lavadores y espesadores de lodo, conforma un conjunto de variables involucradas con el suministro de material para lograr una mezcla óptima. Este proceso es controlado por sistemas de supervisión y control industrial, que no se relacionan con el control inteligente. Suárez [4] desarrolló una herramienta de visualización de variables de los tanques lavadores/espesadores, usando redes neuronales artificiales fue posible revisarlas en tiempo real, así como llevar a cabo la generación de históricos del proceso. El proceso consta de la instrumentación suficiente para la medición de lodo, nivel, torque del rastrillo, flujo de fluoculante y suministro de licor. Además puede incluirse el control de los sólidos de desbordamiento.

El proceso Bayer para la obtención de alúmina está provisto de numerosas variables (Figura 2), controladas por sistemas industriales de adquisición y monitoreo. Pueden listarse algunos parámetros involucrados en el proceso, que fueron considerados para el control difuso.

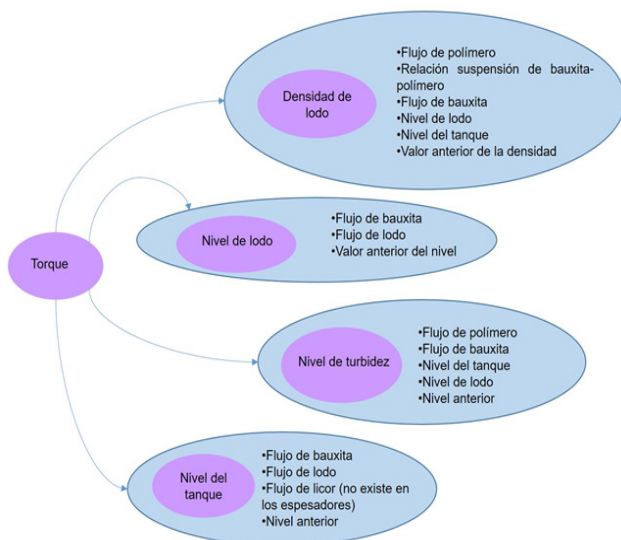


Figura 2. Variables presentes en los tanques espesadores/

lavadores del proceso Bayer de obtención de alúmina.

En la etapa de precipitación el flujo de licor madre proveniente de la etapa de enfriamiento se dirige hacia el primero de los tanques de 1650 metros cúbicos de capacidad, con agitadores mecánicos incorporados, donde se induce la aglomeración y crecimiento de los cristales de trihidratos de alúmina por adición de una suspensión de semillas finas y gruesas, obtenidas de la descarga inferior de los tanques clasificadores secundarios y terciarios ubicados en el sector de clasificación de las fracciones de alúmina donde ocurre la cristalización. Esta área consta de 10 tanques cristalizadores con capacidad volumétrica de 1650 metros cúbicos, 15 de 3000 metros cúbicos por cada fase, en tanto que los 10 recipientes de 4500 metros cúbicos constituye un tren común a ambas etapas.

La precipitación ocurre de dos maneras:

Aglomeración: agrupamiento de partículas sólidas que ocurre alrededor de la suspensión de semilla fina, alimentada desde el área de control de oxalato.

Crecimiento: aumento de tamaño posterior a la inclusión del flujo de semilla gruesa proveniente del proceso de filtración de semilla gruesa.

La suspensión de semilla y el licor madre de alúmina, fluyen por gravedad a través de doce tanques precipitadores durante un promedio de doce horas, a una temperatura de 74 a 78 grados centígrados, con aglomeración y crecimiento de los cristales de alúmina. Esta se pasa luego a un enfriamiento por expansión instantánea, con extracción de vapor por medio de la generación de vacío parcial, a fin de obtener una disminución de 6 0C y el correspondiente incremento en la precipitación.

El sistema inteligente en el área de precipitación pudiera ser factible, sin embargo la mayor parte de los parámetros no tienen medición continua, lo cual limita el uso de los controles inteligentes en esta etapa. La mayor efectividad radica en el uso del control predictivo, específicamente para manejar el flujo a través de unidades paralelas para controlar los niveles del tanque de una manera que minimiza los cambios de flujo, limita el flujo de la unidad a las limitaciones de la unidad (como el flujo máximo del banco debido al desbordamiento de la presa), y podría ser extendido para manejar las tasas de semilla.

La tecnología de control es muy amplia, y comprende un conjunto de elementos que deben ser compensados para obtener importantes beneficios.

Control Regulatorio

Este control consiste en el conocido controlador de una sola entrada y una sola salida que se utiliza para regular la mayoría de los lazos de control, que puede conocerse como lazo Proporcional, Integral, Derivativo, PID. Suele ser apropiado para sistemas de primer orden, donde se regula la presión, el flujo o el nivel, rechazando las perturbaciones presentes en el sistema. Sin embargo, es posible encontrar los siguientes inconvenientes:

- El controlador debe supervisar otros valores y tomar decisiones para intervenir en los límites establecidos.
- Respuesta lenta del sistema, ocasionando inestabilidad en el ajuste de cada ciclo.

Control predictivo multivariable

Este tipo de control presenta un importante uso en los procesos industriales, sobre todo por su capacidad de predicción, su respuesta rápida, conocimiento de las interacciones.

Lógica difusa y sistemas inteligentes

La lógica difusa y los sistemas inteligentes, ofrecen grandes ventajas en el manejo de variables complejas no lineales, en procesos donde la respuesta es rápida. Pueden manejar un gran número de variables y pueden realizar procesos predictivos según el tipo de sistema inteligente aplicado. Además es posible realizar sistemas mixtos con diferentes técnicas inteligentes y aportar mejores resultados al proceso.

III. RESULTADOS

Se analizaron datos de la bauxita kárstica y la bauxita latérite de los trópicos. La bauxita kárstica se encuentran en la Zona de confluencia entre la Cordillera Costero Catalana y la Cordillera Ibérica. El Macizo de la Nevera de Fuentespalda está compuesto por materiales jurásicos y cretácicos con una estructura anticlinal, que se encuentran rodeados por materiales terciarios como este tipo de bauxita. Por otro lado la bauxita latérite se encuentra en los países tropicales, donde el clima es húmedo de selva.

El análisis se desarrolló tomando en cuenta el proceso de Decantación y Lavado de Lodo Rojo en el proceso de tratamiento de Bauxita Latérite, constituida por veintiocho tanques, dispuestos en dos etapas similares, cada una de ellas conformadas por cuatro tanques espesadores y diez lavadores. Además de los tanques se encuentran asociados al sistema un conjunto de bombas de descarga inferior, bombas de rebose, bombas de recirculación, instrumentos de medida como densímetros, flujómetros, medidores de turbidez y lodo,

también se incluyen las válvulas de control.

Espesadores: aquí comienza la separación del lodo, la cual se realiza por asentamiento de las partículas por gravedad en el fondo del tanque, quedando en la parte superior el licor claro de rebose. El lodo es recuperado como una suspensión de alta densidad, y enviado a través de la bomba de descarga inferior hasta la primera etapa de lavado.

Lavadores: el lavado del lodo consiste en hacer pasar la suspensión de descarga inferior de los espesadores en contracorriente con el agua de lavado, a través de cinco etapas de lavado.

Para el estudio se ha considerado la selección de 1588 datos por cada variable del proceso (Figura 2), aproximadamente 14292 datos en total.


Para lograr un mejor manejo de las variables, se subdividió la red neuronal en cinco sub redes con el fin de simplificar el procedimiento de entrenamiento. Para esto se lograron establecer las siguientes estructuras, obteniendo cada variable en eje de las ordenadas y el tiempo en el eje de las abscisas:

Red del Nivel de Lodo:

Esta primera red fue realizada con una estructura de retropropagación, con retardos. La red está compuesta de treinta neuronas de entrada, cuarenta intermedias y una de salida. La red inicial no arrojó resultados satisfactorios debido a la falta de datos de entrenamiento en el estudio, de tal forma que fue necesario incrementar notablemente el número de datos del sistema para lograr una mayor efectividad. Habiendo aumentado el número de datos, se incrementó también el número de neuronas y retardos para lograr una mejor convergencia en el entrenamiento. Los niveles de lodo pueden variar según el día, por tanto las simulaciones deben corresponderse según la selección de la fecha, la figura 3 muestra los resultados en días distintos, en todos ellos con un error entre 0,5 y 0,8%.



(a)




(b)

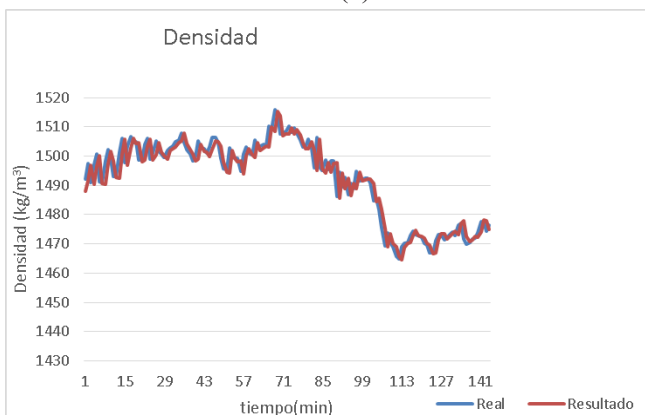
Figura 2. (a) Nivel de lodo para día 1. (b) Nivel de lodo para día 2. En ambos casos el error está entre 0,5% y 0,8%, resultando un entrenamiento aceptable.

Red de la Densidad.

Basados en la red anterior, se desarrolló la red de la densidad del lodo. Esta red está conformada por cuatro capas; la primera con una neurona, la segunda con cuarenta neuronas, la tercera con cincuenta y cinco y la última con una, a diferencia de la red de nivel de lodo, esta red está constituida por cinco entradas, lo cual exigió un mayor número de retardos y un incremento notable en el número de neuronas en cada capa.



(a)

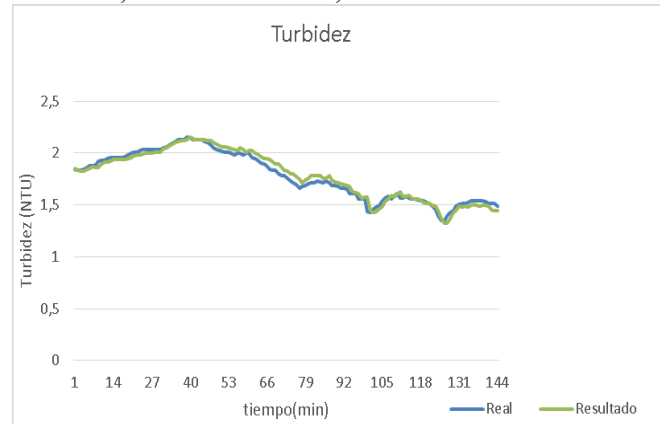


(b)


Figura 3. (a) Densidad del día 1. (b) Densidad del día 2. En ambas simulaciones el error fue de 0,5% al 0,8%, siendo un valor aceptable para el proceso.

Red de Nivel de Turbidez.

Esta red está conformada por cuarenta neuronas de entrada y veinticinco intermedias, tiene treinta retardos y fue entrenada con 7940 datos de entrada y presentó una convergencia en pocos ciclos de recorrido. En la figura 4 se muestra la concordancia del valor real con el simulado, con un error de 0,8%.



(a)




(b)


Figura 4. (a) Turbidez del día 1. (b) Turbidez del día 2. La turbidez, al igual que las demás variables fluctúan de un día a otro, sin embargo el sistema inteligente sigue los patrones con un error entre 0,5% y 0,8%.

Red de Nivel del Tanque.


Esta es la red más pequeña de todas, tiene tres entradas fundamentales. Está constituida por cuatro capas; una neurona en la primera capa, cincuenta y cinco neuronas en la segunda, veinte en la tercera y una en la última. Sin embargo esta red no presenta convergencia en su entrenamiento a pesar de arrojar excelentes resultados en las pruebas. La figura 5 muestra el nivel de tanque de dos días aleatorios, la red neuronal sigue el patrón con mínimo error, entre 0,5% y 0,8%.




(a)



(a)



(b)



(b)

Figura 6. (a) Nivel del tanque día 1. (b) Nivel del tanque día 2.

Red de Torque.

Esta red presentó una convergencia inmediata a los estudios realizados. Está compuesta por treinta neuronas de entrada, veinticinco en la capa intermedia y una en la capa de salida. Tiene cuarenta retardos y sus funciones de entrenamiento son lineales, los resultados se observan en la figura 7.

Figura 7. Torque del día 1. Torque del día 2.

Es importante señalar que si el día elegido para la simulación presenta fallas en la adquisición de datos, éstos serán reflejados en las gráficas correspondientes. También es importante tener conocimiento del estado de los tanques que se encuentran en funcionamiento, ya que de elegir un tanque fuera de servicio no se obtendrán los resultados deseados o se presentarán ambigüedades en los resultados obtenidos. La discrepancia entre las líneas indicadas como “real” y “resultado” independientemente, indican las posibles fallas existentes en los datos reales, ya que los resultados son tomados de un entrenamiento con datos previamente estudiados y seleccionados en los que se consideraron tanques con comportamiento excelente. Cualquier valor que sea modificado en la hoja de datos del sistema se verá reflejado en las gráficas respectivas, así como en la determinación del error relativo de estas hojas.

Realización de la Interfaz Gráfica de Usuario.

La interfaz está conformada por una hoja de simulación simultánea de todas las variables del proceso, así como también contiene una hoja de simulación de cada una de las variables en forma independiente, con acceso a la data de cada una de éstas y con la facilidad de poder modificar los datos de simulación. Los datos

son obtenidos en tiempo real.

Esta interfaz realiza una conexión con Matlab durante la simulación, al igual que se vincula con Visual Basic y con el PHD de la empresa, mostrando los datos en el entorno de Microsoft Excel, donde hace la generación de las gráficas y resultados de la

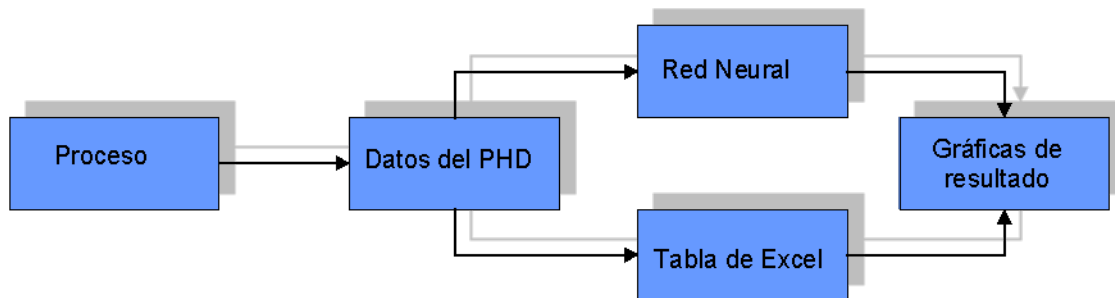


Figura 8. Interfaz de usuario

Es posible simular todas las variables de forma simultánea o cada una de ellas de forma individual, para esto es posible acceder a cada una de las opciones de simulación con la barra de selección.

IV. CONCLUSIONES

El modelo de proceso con redes neuronales facilita el análisis matemático del modelo con variables de estado. Para lograr una modelación efectiva es necesario realizar un análisis minucioso de las variables que intervienen en el proceso. Pudiendo descartar los datos errados. El resultado del modelo de proceso no es una ecuación matemática tangible, sino, una estructura basada en inteligencia artificial cuyos parámetros no son de fácil modificación. Sin embargo una vez entrenada permite la adaptación continua de los nuevos datos ingresados. Logrando resultados similares en días distintos con situaciones distintas. El modelo de proceso obtenido, es un modelo simple que permite visualizar las fallas de las variables del proceso en comparación con los resultados esperados de las mismas.

V. REFERENCIAS

- [1]Díaz, J. (2010) “Sistemas de control basado en redes neuronales y lógica difusa para la estimación y control de la dosificación de coagulante en una planta de tratamiento de agua” Escuela de Ingeniería Eléctrica y Electrónica. Universidad del Valle. Colombia. [Artículo en línea] Disponible en jfdiaz@uniweb.net.co
- [2]Mariña, J.(2003) Tesis: “diseño y simulación de un sistema de control automático para el proceso de deslicorización del hidrato en C.V.G BAUXILUM”. UNEXPO. Edo. Bolívar. Venezuela.
- [3] Cardona, Alberto. (2002) Tesis: “Modelo matemático

del sistema de medición de nivel de turbidez y lodo ubicado en tanques lavadores y espesadores del área 35 de C.V.G BAUXILUM”. UNEXPO. Edo. Bolívar. Venezuela.

[4]Suárez, F. (2004). Diseño e implementación del modelo de proceso de los tanques lavadores y espesadores del área 35 de c.v.g bauxilum, empleando redes neuronales y utilizando los datos estadísticos obtenidos. Tesis de grado. Repositorio UNEXPO Puerto Ordaz.

[5]Troncone, N. (2012)Trabajo de Ascenso: “Introducción a las Redes Neuronales”. UNEXPO. Edo. Bolívar. Venezuela.

[6] Amari, S-I. (1967) “A theory of adaptive pattern classifiers” IEEE. Transactions on Electronic Computers.

[7]Ncirole, D., Freeman, P., Feltoe, N., Freeman, N. (2000) “The Improvements in Control of the Mill 3 Circuit at Alcoa’s Wagerup Refinery” Paper presented at the Seventh Mill Operators' Conference, Kalgoorlie, Western Australia.

[8]Neil Freeman, “The Benefits of Advanced Control for Alumina Refining” Paper presented at the TMS Annual Meeting, San Antonio, Texas.

[9]Ponce, L., Rojas, A. “Control de servosistemas no lineales utilizando redes neuronales”. Facultad de Ingeniería Eléctrica y electrónica de la Universidad Nacional de Ingeniería de Lima. Perú. [Artículo en línea] Disponible en <http://fice.uni.edu.pe>.

[10]Mathur, A., Rodgers, R. (1997)“Advanced Controller for Grinding Mills: Results from a Ball Mill Circuit in a Copper Concentrator” Paper presented at the CIM District 5 Mining Conference, Fort McMurray, Alberta.

[11]Díaz, J. (2011) “Sistemas de control basado en

redes neurales y lógica difusa para la estimación y control de la dosificación de coagulante en una planta de tratamiento de agua” Escuela de Ingeniería Eléctrica y Electrónica. Universidad del Valle. Colombia. [Artículo en línea] Disponible en jfdiaz@uniweb.net.co

[12]Gómez, M. (2007) “Ejemplo de aplicación de una red de retropropagación” [Artículo en línea] Disponible en www.iiia.cisc.es

[13]Nooraii, A. (2003) “Applying Multivariable Control Technology At Alcoa World Alumina” (Paper presented at the Honeywell User’s Group Annual Meeting, Brisbane, Australia.

[14]Rumelhard, D., Hinton, G & Willians, R. (1986)“Learning representations by backpropagation errors”. Neture.

Bryson, A. HO, Y. (1969) “Applied optimal control” Blaisted. New York.

[15]Mason, D. (1998) “Process Control Technology Saving Energy” Australian Energy News, 10.

Parker, D. (1982)“Learning Logic”. Invention report, Office of Thechnology Licensing Stanford University.

[16] Rumph, James. (2002) “Expert Grinding Control at Phelps Dodge Sierrita” Paper presented at SME Mineral Processing Meeting, Arizona, Spring.

[17]The MathWorks. [Empresa en línea]. Disponible en www.themathworks.es

[18] Werbos, P. (1974) “Beyond Regression: New tools for prediction and analysis in the behavioral sciences” Ph. D. Dissertation, Haravard University.

[19]Márquez, K., Ortiz, R., Márquez O. y Márquez, J. (2016) Aspectos de la higiene y seguridad industrial en el área de reducción de una planta de aluminio en Venezuela. Rev. Universidad, Ciencia y Tecnología, vol.20 no.78.

[20]Arroyo, L. (2010) “Redes Neuronales” [Articulo en línea]. Disponible en www.gc.ssr.upm.es/inves/neural/ann2/supmodel/backpro.htm