

## Un neuro-controlador estable en tiempo real para reducir el consumo de energía en una bomba centrífuga ante perturbaciones

Eduardo Yudho-Montes de Oca<sup>a</sup>, Mario Cesar Maya-Rodríguez<sup>a, \*</sup>, René Tolentino-Eslava<sup>a</sup>, Yair Lozano-Hernández<sup>b</sup>

<sup>a</sup>Instituto Politécnico Nacional, Escuela Superior de Ingeniería Mecánica y Eléctrica, Unidad Zacatenco, CDMX, 07738, México.

<sup>b</sup>Sección de Estudios de Posgrado e Investigación, Unidad Profesional Interdisciplinaria de Ingeniería Campus Hidalgo, Instituto Politécnico Nacional, 42163, San Agustín Tlaxiaca, Hidalgo, México.

**To cite this article:** Yudho-Montes de Oca, E., Maya-Rodríguez, M. C., Tolentino-Eslava, R., Lozano-Hernández, Y. 2022. A real-time stable neuro-controller to reduce the energy consumption in a centrifugal pump under disturbances. Revista Iberoamericana de Automática e Informática Industrial 19, 265-273. <https://doi.org/10.4995/riai.2022.16060>

### Resumen

En este trabajo se propuso la aplicación de un método de sintonización en línea basado en redes neuronales para un controlador PID que regula el flujo en una bomba centrífuga. Se llevó a cabo la implementación de un algoritmo de retropropagación modificado estable en el sentido de estabilidad de entrada a estado para actualizar los pesos de una red neuronal. Se empleó la energía consumida por la bomba para mantener un determinado flujo en la tubería de una estación experimental como indicador para evaluar la eficiencia del controlador. Se llevaron a cabo diferentes pruebas experimentales para mostrar el rendimiento del controlador propuesto en diferentes condiciones, tales como ausencia de perturbaciones, perturbaciones constantes y perturbaciones dependientes del tiempo. Se implementó una válvula proporcional para generar las perturbaciones en el sistema. El controlador se comparó con un controlador PID clásico y un método de ajuste en línea basado en redes neuronales para un controlador PID con algoritmo de retropropagación sin modificación. Los resultados mostraron que el método de ajuste en línea basado en redes neuronales con un algoritmo de aprendizaje estable produjo un menor consumo de energía en la bomba centrífuga de hasta 4 Watt-hora de acuerdo con los resultados reportados.

**Palabras clave:** Redes Neuronales, Control de procesos, Control en tiempo real, Control adaptable por redes neuronales, Sistemas de suministro y distribución de agua.

### A real-time stable neuro-controller to reduce the energy consumption in a centrifugal pump under disturbances

#### Abstract

In this paper, the application of an on-line tuning method based on neural networks for a PID controller was proposed to regulate the flow in a centrifugal pump. The implementation of a modified back-propagation algorithm stable in the sense of input-to-state stability was carried out to update the weights of a neural network. The energy consumed by the pump to maintain a certain flow in the pipeline of an experimental station as an indicator to assess the efficiency of the controller was chosen. Different experimental tests to show the performance of the proposed controller under different conditions were carried out such as non-disturbance, constant disturbances and time-dependent disturbances. A proportional valve was implemented to generate the disturbances in the system. The controller was compared with a classical PID controller and an on-line tuning method based on neural networks for a PID controller without back-propagation modification. The results showed that the on-line tuning method based on neural networks with a stable learning algorithm produced a lower energy consumption in the centrifugal pump.

**Keywords:** Neural Networks, Process control, Real-time control, Adaptive control by neural networks, Water supply and distribution systems.

\*Autor para correspondencia: mmayar@ipn.mx

## 1. Introducción

En los procesos industriales es necesario el movimiento de líquidos y gases, utilizando bombas, ventiladores y compresores accionados por motores eléctricos. De acuerdo a un estudio de la Agencia Internacional de Energía, los motores consumen el 46 % de la energía generada a nivel mundial (Waide and Brunner, 2011), el consumo de energía total de los motores eléctricos de distribuye en la siguiente forma: las bombas y ventiladores representan el 19 % cada uno, los compresores el 32 % y el movimiento mecánico 30 % (Waide and Brunner, 2011). La regulación del flujo en un sistema de bombeo se efectúa mediante dos métodos: estrangulamiento con una válvula y velocidad variable mediante variadores de frecuencia (Nourbakhsh et al., 2010) y (Al-Khalifah and Mcmillan, 2012).

De acuerdo con (Al-Khalifah and Mcmillan, 2012) y (Nault and Papa, 2015), el consumo de energía de las bombas es uno de los factores de mayor costo y está ligado al ciclo de vida de las mismas; por lo que al regular el flujo a través de la velocidad de los motores, se reducen los costos de energía debido a que el equipo proporciona el par necesario para suministrar el flujo requerido, con lo que se obtiene un control más rápido ya que no depende de la acción mecánica de la válvula, beneficiándose así el ciclo de vida de los sistemas de bombeo (Al-Khalifah and Mcmillan, 2012).

En (Sarbu and Valea, 2015), se destacan que las bombas accionadas por motores eléctricos representan entre el 25 % y el 50 % del uso total de energía eléctrica en instalaciones industriales; además uno de los problemas en estos sistemas con velocidad variable es la eficiencia del arreglo bomba-motor bajo una condición de operación dada. De forma similar, (Marchi et al., 2012) mencionan que en los sistemas de distribución de agua, una parte significativa del costo operativo está relacionado con el bombeo, por lo que el ahorro en los costos de operación depende de las características y/o el uso del sistema de bombeo, para lo cual es recomendable utilizar esquemas de control de velocidad variable. Por otro lado, en los procesos industriales el controlador Proporcional-Integral-Derivativo (PID) ha sido el principal método de control debido a la simplicidad de su estructura, así como su robustez ante el ruido y perturbaciones. Sin embargo, es necesario encontrar las ganancias adecuadas que en la mayoría de las situaciones industriales es mediante conocimiento a priori (Xi-fan, 2009). Por lo anterior, surge la idea de implementar algoritmos de control tipo PID autosintonizables en línea para evitar un desempeño deficiente del controlador a causa de diferentes puntos de operación, no linealidades o retardos presentes en el sistema.

Se han propuesto diversos esquemas de controladores PID autosintonizables basados en métodos de identificación, lógica difusa y redes neuronales, entre otros. No obstante, las redes neuronales han destacado. El Perceptrón Multicapa (MLP), cuya estructura es la Red Neuronal Artificial (RNA) más aplicada, utiliza pesos sinápticos para conectar cada capa de la red, de tal forma que procesa la información recibida en las unidades de entrada y las propaga capa a capa hacia adelante, de izquierda a derecha. Para ello, cada nodo del MLP tiene una función de activación no lineal y la red se dice que está completamente conectada (Haykin, 2010) y (Aggarwal, 2018). Sin embargo, es necesaria una fase de entrenamiento para mejorar el desempeño

de la red, en la cual, el método más utilizado es el algoritmo de retropropagación (BP), que requiere una señal de error para propagarla a través de la red y ajustar los pesos sinápticos.

Las redes neuronales se han aplicado en una gran variedad de problemas de control debido a su precisión de aproximación y capacidad para resolver los problemas descritos por una relación entrada-salida sin el conocimiento exacto de un modelo matemático (Miroslav and Stefan, 2003), incluyendo la identificación de sistemas (Boutalis et al., 2014) y el control. En (Fujinaka et al., 2000) se propone una arquitectura de control PID neuronal autosintonizable basado en un MLP con un algoritmo BP modificado para evitar el problema de los mínimos locales, el cual fue aplicado para estabilizar un sistema de doble péndulo invertido.

Por otro lado, (Hu et al., 2012) aplicaron un PID neuronal con el algoritmo de entrenamiento BP para evaluar la capacidad de controlar el flujo en una tubería de una planta con modelo conocido. Otras aplicaciones de este tipo de controlador se han desarrollado en el control de nivel de dos tanques (Pirabakaran and Becerra, 2002) y en procesos altamente no lineales como la neutralización de pH en procesos industriales (Chen and Huang, 2004; Yang and Wu, 2016). Además, en (Ramos-Velasco et al., 2016) un PID neuronal fue propuesto en función de un esquema de identificación y sintonizador en línea, basado en funciones de activación de base radial y wavelets para un motor de inducción trifásico sin carga; mientras que en (Sedighzadeh and Rezazadeh, 2008), se presenta un esquema similar al anterior donde se busca el control de velocidad para un generador/turbina eólica, mostrando resultados únicamente por simulación, cabe mencionar que en estos trabajos no se consideran el desempeño de los controladores bajo perturbaciones externas. De acuerdo con (Fujinaka et al., 2000), no conocer el modelo matemático de un sistema afecta el desempeño de un sintonizador basado en redes neuronales, por lo que la mayoría de los esquemas dependen de emuladores que trabajan en paralelo para mejorar el proceso de sintonización. Con base en lo anterior, en este trabajo se propone un PID neuronal con una regla de aprendizaje estable en sentido de Lyapunov para evaluar la energía consumida por una bomba centrífuga.

Para comparar el desempeño del sistema con la regla de aprendizaje propuesta, se implementa un PID neuronal con el algoritmo BP y con el método convencional de sintonización de Ziegler-Nichols basado en la respuesta del sistema en lazo abierto. Se realizó una evaluación experimental con y sin perturbaciones, que pueden ser constantes o dependientes del tiempo. Las perturbaciones se generaron con el porcentaje de apertura de una válvula proporcional.

El control de plantas industriales en el mundo real es un problema complejo debido a que la naturaleza del sistema puede llegar a ser altamente no lineal. Por otra parte, industrialmente, los controladores clásicos como el PID y sus variantes son los más usados actualmente para el control de variables esenciales en la producción de bienes y servicios como es el flujo, nivel, temperatura y presión.

Los controladores industriales normalmente son sintonizados a prueba y error. Cuando el sistema es lo suficientemente flexible y se cuenta con la información necesaria, entonces se aplican técnicas de sintonización las cuales dependen de un mo-

delo matemático parametrizado. Cabe mencionar que las anteriores condiciones son realmente difíciles de cumplir en aplicaciones prácticas y el tiempo necesario para satisfacerlas puede causar complicaciones para la resolución de un problema en la línea de producción, ocasionadas por una perturbación externa o falla de un equipo en la cercanía.

Los argumentos anteriores desembocan en tres características inherentes a cualquier control: la estabilidad, la robustez y el uso adecuado de la energía. En muchos de los trabajos actuales sobre el tema no se toma en cuenta lo anterior, ya que sus experimentos son idealizados, por tanto no evalúan el comportamiento de la planta y del controlador en condiciones del mundo real.

En consecuencia, esto representa un problema común en la investigación, debido a que los esfuerzos se enfocan en obtener técnicas, algoritmos y métodos más sofisticados ó estéticos; olvidando que uno de los principales fines es la solución de problemas reales que involucran su implementación práctica y la discusión de los resultados con base en simulaciones para llevar a cabo una comparación en lo experimental bajo condiciones controladas y posteriormente, bajo condiciones que afecten el desempeño del sistema tales como perturbaciones, ruido, desconocimiento de parámetros y fallas de los equipos.

Es por ello que en este trabajo se presentan los resultados y discusión de los mismos, al comparar el controlador autosintonizable estable propuesto bajo diferentes condiciones experimentales determinadas por la presencia y ausencia de perturbaciones en una plataforma de bajo costo contra la forma de controladores industriales comúnmente usados.

El trabajo está organizado de la siguiente manera. En la sección 2 se desarrolla el método de sintonización on-line basado en redes neuronales, así como la regla de aprendizaje estable. En la sección 3 se muestran los resultados obtenidos, análisis y discusión; por último en la sección 4 se presentan las conclusiones obtenidas de este trabajo.

## 2. Diseño del Controlador

El controlador PID clásico es ampliamente utilizado en el control de procesos debido a que tiene una arquitectura de control a lazo cerrado que compara la salida del sistema con el valor deseado. El desempeño del controlador depende de tres parámetros conocidos como ganancias Proporcional ( $K_p$ ), Integral ( $K_i$ ) y Derivativa ( $K_d$ ), que pueden obtenerse mediante técnicas convencionales que se basan en suposiciones sobre el sistema, al igual que el método de Ziegler-Nichols que está basado en la respuesta al escalón y produce un desempeño razonable para lazos simples y sólo se aplica en procesos estables (Singh and Kaur, 2014).

### 2.1. PID estable autosintonizable

De acuerdo con (Narendra and Parthasarathy, 1991), un sistema no lineal se puede expresar en términos de sus señales de entrada y salida de la siguiente manera:

$$\hat{y}(k) = NN[\hat{y}(k-1), \dots, \hat{y}(k-n), u(k-1), \dots, u(k-n), r(k-1), \dots, r(k-n), e(k), \dots, e(k-n)], \quad (1)$$

donde  $\hat{y}$  es la salida de la red neuronal,  $u$  es la señal de control,  $r$  es el punto de referencia,  $e$  es la señal de error y  $n = 1, 2, \dots$ , es el retardo en el tiempo. El mapeo de entrada-salida de un MLP de una sola capa oculta se parametriza como:

$$\hat{y}(k) = \Gamma [V_{jo} \cdot \Phi [W_{ij} \cdot X(k)]] \quad (2)$$

Para un MLP,  $\Gamma$  y  $\Phi$  son funciones de activación no lineales,  $W$  y  $V$  son las matrices de pesos sinápticos y  $X(k)$  es el vector de entradas, para  $i = 1, \dots, ni$ ,  $j = 1, \dots, nh$  y  $o = 1, \dots, no$ , y el vector de entrada se define como:

$$X(k) = [y(k), y(k-1), u(k), u(k-1), r(k), r(k-1), e(k), e(k-1), e(k-2)], \quad (3)$$

donde  $y$  representa el comportamiento de la variable de proceso en el tiempo y  $r$  es la referencia para la variable de proceso, en la Figura (1), se muestra un esquema de lo descrito anteriormente.

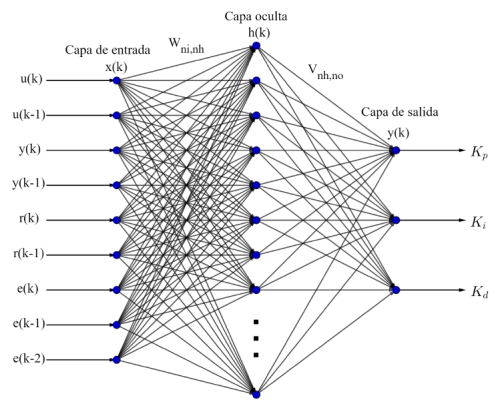


Figura 1: Esquema de la red neuronal.

Un sistema no lineal puede controlarse con un PID sintonizado por redes neuronales mediante el esquema de la Figura 2, la cual está basada en el controlador PID digital en su forma de velocidad (Al-Khalifah and Mcmillan, 2012) donde la regulación del flujo suministrado por la bomba es expresado de la siguiente manera:

$$u(k) = u(k-1) + K_p(e(k) - e(k-1)) + K_I e(k) + K_D(e(k) - 2e(k-1) + e(k-2)). \quad (4)$$

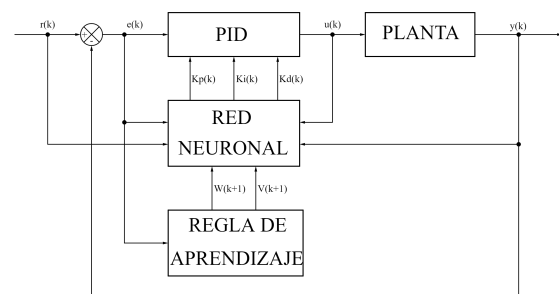


Figura 2: Esquema de control del sintonizador neuronal.

Este esquema utiliza un MLP que propaga la información desde la capa de entrada a la capa oculta como:

$$\begin{aligned} \text{net}_j(k) &= \sum_{i=1}^{ni} W_{ij} \cdot x_i; \\ h_j(k) &= \Phi(\text{net}_j(k)), \end{aligned} \quad (5)$$

donde  $ni$  es la cantidad de entradas de la red,  $x$  son los datos de la capa de entrada y  $W$  es la matriz de pesos sinápticos que une a la capa de entrada con la capa oculta. De la misma manera, la información se propaga de la capa oculta a la capa de salida según:

$$\text{net}_o(k) = \sum_{j=1}^{nh} V_{jo} \cdot h_j, \quad (6)$$

donde  $nh$  es la cantidad de nodos de la capa oculta,  $h$  es la respuesta de la capa oculta y  $V$  es la matriz de pesos sinápticos que une a la capa oculta con la capa de salida. Las salidas del MLP utilizado son las ganancias proporcional ( $K_P$ ), integral ( $K_I$ ) y derivativa ( $K_D$ ), que están dadas por:

$$O_o(k) = \Gamma(\text{net}_o(k)). \quad (7)$$

Las funciones de activación  $\Gamma$  y  $\Phi$  deben ser una función Sigmoide para asegurar que las ganancias del controlador PID sean positivas (Fujinaka et al., 2000). Además, se utiliza la siguiente función de costo para evaluar la salida del sistema:

$$J(k) = \frac{1}{2} e^2(k), \quad (8)$$

donde  $e(k)$  es la señal de error, que representa la diferencia entre el punto de referencia  $r$  y la salida del sistema  $y$  en el instante  $k$ . La sintonización dinámica de las ganancias depende de una modificación del algoritmo BP para evitar el problema de caer en un mínimo local (Fujinaka et al., 2000), la cual se describe por:

$$W(k+1) = W(k) - \eta \frac{\partial J(k)}{\partial W(k)} + \alpha \Delta W(k-1) + \beta W(k-2). \quad (9)$$

El gradiente del error está dado por  $\frac{\partial J(k)}{\partial W(k)}$ . Usando la regla de la cadena para descomponerlo con respecto a la capa de salida se tiene:

$$\frac{\partial J(k)}{\partial V_{jo}(k)} = \frac{\partial J(k)}{\partial y(k)} \cdot \frac{\partial y(k)}{\partial u(k)} \cdot \frac{\partial u(k)}{\partial O_o(k)} \cdot \frac{\partial O_o(k)}{\partial \text{net}_o(k)} \cdot \frac{\partial \text{net}_o(k)}{\partial V_{jo}(k)}, \quad (10)$$

donde el gradiente local de la capa de salida es:

$$\delta_o = \frac{\partial J(k)}{\partial y(k)} \cdot \frac{\partial y(k)}{\partial u(k)} \cdot \frac{\partial u(k)}{\partial O_o(k)} \cdot \frac{\partial O_o(k)}{\partial \text{net}_o(k)}, \quad (11)$$

con:

$$\begin{aligned} \frac{\partial J(k)}{\partial y(k)} &= -(r(k) - y(k)); \\ \frac{\partial O_o(k)}{\partial \text{net}_o(k)} &= \Gamma'(\text{net}_o(k)). \end{aligned} \quad (12)$$

En el gradiente local de la capa de salida (10),  $\frac{\partial y(k)}{\partial u(k)}$  representa el Jacobiano del sistema, y no es posible encontrarlo si los

parámetros del sistema son desconocidos, por lo que es compensado con la constante de aprendizaje  $\eta$ . Además,  $\frac{\partial u(k)}{\partial O_o(k)}$  depende del controlador PID digital (4), así:

$$\begin{aligned} \frac{\partial u(k)}{\partial O_1(k)} &= e(k) - e(k-1); \\ \frac{\partial u(k)}{\partial O_2(k)} &= e(k); \\ \frac{\partial u(k)}{\partial O_3(k)} &= e(k) - 2e(k-1) + e(k-2), \end{aligned} \quad (13)$$

donde las salidas  $O_1$ ,  $O_2$ ,  $O_3$  representan a las ganancias  $K_P$ ,  $K_I$  y  $K_D$  respectivamente. Así el gradiente local de la capa de salida se reescribe como:

$$\delta_o = -(r(k) - y(k)) \cdot \frac{\partial y(k)}{\partial u(k)} \cdot \frac{\partial u(k)}{\partial O_o(k)} \cdot \Gamma'(\text{net}_o). \quad (14)$$

La corrección de los pesos para la capa de salida se define como (Haykin, 2010):

$$\Delta V_{jo}(k) = \eta \delta_o(k) h_j. \quad (15)$$

La actualización de los pesos en la capa de salida para el sintonizador neuronal viene dada por la siguiente ecuación:

$$V_{jo}(k+1) = V_{jo}(k) - \eta \delta_o h_j + \alpha \Delta V_{jo}(k-1) + \beta \Delta V_{jo}(k-2), \quad (16)$$

donde  $\alpha$  y  $\beta$  se utilizan para evitar el problema de un mínimo local (Fujinaka et al., 2000).

Mediante la regla de la cadena se descompone el gradiente de la capa oculta teniéndose:

$$\begin{aligned} \frac{\partial J(k)}{\partial W_{ij}(k)} &= \frac{\partial J(k)}{\partial y(k)} \cdot \frac{\partial y(k)}{\partial u(k)} \cdot \frac{\partial u(k)}{\partial O_o(k)} \cdot \frac{\partial O_o(k)}{\partial \text{net}_o(k)} \\ &\quad \cdot \frac{\partial \text{net}_o(k)}{\partial h_j(k)} \cdot \frac{\partial h_j(k)}{\partial \text{net}_j(k)} \cdot \frac{\partial \text{net}_j(k)}{\partial W_{ij}(k)}, \end{aligned} \quad (17)$$

donde el gradiente local para la capa oculta se expresa como:

$$\delta_j = \left( \sum_{o=1}^{no} \delta_o \cdot V_{jo} \right) \cdot \Gamma'(\text{net}_j), \quad (18)$$

La corrección en la capa oculta está dada por (Haykin, 2010):

$$\Delta W_{ij}(k) = \eta \delta_j(k) x_i, \quad (19)$$

y los pesos se actualizan por (Fujinaka et al., 2000):

$$W_{ij}(k+1) = W_{ij}(k) - \eta \delta_j x_i + \alpha \Delta W_{ij}(k-1) + \beta W_{ij}(k-2). \quad (20)$$

La necesidad de conocer el Jacobiano del sistema o de compensarlo mediante la constante de aprendizaje  $\eta$  genera problemas en el comportamiento del esquema de autosintonización. Con el fin de mejorar la sintonización de las ganancias, se propuso utilizar un algoritmo BP modificado y estable en el sentido de la Estabilidad de Entrada-Estado (ISS), para lo cual, (Yu and Li, 2003) desarrollaron un análisis de su estabilidad. En este trabajo, el algoritmo de BP modificado se identifica como BPS y está descrito por las siguientes ecuaciones:

$$\begin{aligned} V(k+1) &= V(k) - \eta_k \delta_o h_j + \alpha \Delta V(k-1) + \beta \Delta V(k-2); \\ W(k+1) &= W(k) - \eta_k \delta_j x_i + \alpha \Delta W(k-1) + \beta \Delta W(k-2), \end{aligned} \quad (21)$$

donde  $\eta_k$  se determina con:

$$\eta_k = \frac{\eta}{1 + \|\Phi' x^T(k)\|^2}, 0 < \eta \leq 1, \quad (22)$$

donde  $\Phi'$  representa la derivada de la función de activación.

## 2.2. Perturbaciones

La evaluación de la capacidad de los controladores para regular el flujo con una perturbación constante, se efectuó con la siguiente función de perturbación:

$$f_1(t) = \begin{cases} 100\% & \text{si } 0 \text{ s} < t \leq 100 \text{ s} \\ VO_1 & \text{si } 100 \text{ s} < t \leq 200 \text{ s}, \end{cases} \quad (23)$$

donde 100% representa la apertura total de la válvula y  $VO_1$  el porcentaje de apertura de la válvula proporcional.

Para evaluar la robustez de los controladores, así como su capacidad de regulación y seguimiento, se realizaron pruebas con dos perturbaciones dependientes del tiempo. La primera perturbación es una función triangular periódica con una frecuencia de 0.02 Hz, dada por la siguiente expresión:

$$f_2(t) = \begin{cases} \frac{VO_2 - VO_1}{24.64 \text{ s}} \cdot t + VO_1 & \text{si } 0 \text{ s} < t \leq 24.64 \text{ s} \\ \frac{VO_1 - VO_2}{24.64 \text{ s}} \cdot t + VO_2 & \text{si } 24.64 \text{ s} < t \leq 49.28 \text{ s}. \end{cases} \quad (24)$$

La segunda perturbación es una función sinusoidal descrita por:

$$f_3(t) = VO \sin(0.1t + \pi) + (VO_2 - VO), \quad (25)$$

la cual tiene una frecuencia de  $0.1 \frac{\text{rad}}{\text{s}}$  y VO es:

$$VO = \frac{VO_2 - VO_1}{2}, \quad (26)$$

de tal forma que la función depende de los porcentajes de apertura menor ( $VO_1$ ) y mayor ( $VO_2$ ). Cada función se repite hasta cumplir el tiempo definido para los experimentos.

## 3. Resultados Experimentales

La estación experimental empleada en este trabajo y su diagrama de tubería e instrumentación se muestran en la Figura 3. El prototipo tiene un tanque atmosférico con capacidad de 4 litros, una válvula proporcional de 12 mm (0.5 plg) de diámetro, cuyo ángulo de apertura se puede ajustar entre  $0^\circ$  y  $90^\circ$  con una señal de alimentación de  $0 V_{CD}$  a  $5 V_{CD}$  y una bomba centrífuga de  $12 V_{CD}$  con diámetro en la succión y descarga de 12 mm (0.5 plg), que proporciona un flujo de 6.5 LPM y una presión de 3 mH<sub>2</sub>O. Se tiene un medidor de flujo tipo turbina (FT) basado en efecto Hall con una válvula check que mantiene lleno al tramo vertical de la tubería, la cual reduce el flujo a 4.2 LPM.




Figura 3: Estación experimental.

El sensor de flujo tiene un alcance de 1.67 LPM a 30 LPM y proporciona una señal de pulsos con una frecuencia proporcional al flujo. Se obtuvo el tiempo de muestreo de forma empírica debido a que el medidor entrega una señal de pulsos, de tal forma que al proponer un valor de 880 ms se obtuvo una medición que permitía una respuesta rápida del controlador sin comprometer a la medición del flujo.

Para monitorear el consumo de energía de la bomba, la estación dispone de transductores de tensión (ET) y de corriente eléctrica (IT) con un alcance de  $0 V_{CD}$  a  $16.5 V_{CD}$  y de  $0 A$  a  $5 A$ , respectivamente. Además, se tiene un transductor de presión diferencial (PDT) que monitorea el incremento de presión de la bomba con un alcance de  $\pm 15 \text{ psi}$  y un transductor de presión manométrica (PT) ubicado en la descarga con un alcance de  $0 \text{ psi}$  a  $15 \text{ psi}$ . Se utilizó un Arduino MEGA 2560 como tarjeta de adquisición de datos y el software MATLAB/Simulink para el desarrollo del controlador y sintonizador basado en redes neuronales. El intercambio de datos entre Simulink y el prototipo a través de la tarjeta Arduino MEGA 2560 se efectuó mediante comunicación serial.

Se utilizó un puente H para realizar el control de flujo con la bomba a velocidad variable; mientras que con la válvula proporcional se perturbó al sistema través de cambios en la posición del obturador entre  $0^\circ$  y  $90^\circ$ . Se implementó un controlador PI digital sintonizado a través de redes neuronales con una regla de aprendizaje estable, para evaluar el consumo de energía de la bomba centrífuga de la estación experimental ante diferentes condiciones de operación.

Se realizaron cuatro experimentos en la estación propuesta para evaluar el desempeño del sintonizador neuronal discutido en la Sección 2. Además, el consumo de energía de la bomba con el controlador PI sintonizado por el método propuesto se comparó contra el algoritmo BP y el método de Ziegler-Nichols.

Cada evaluación tuvo una duración de 10 minutos y la respuesta del sistema debía cumplir con los siguientes puntos de referencia:

$$r(t) = \begin{cases} 3.5 \text{ LPM} & \text{si } 0 \text{ s} < t \leq 200 \text{ s} \\ 2.5 \text{ LPM} & \text{si } 200 \text{ s} < t \leq 400 \text{ s} \\ 4 \text{ LPM} & \text{si } 400 \text{ s} < t \leq 600 \text{ s}. \end{cases} \quad (27)$$

Cada experimento comenzó con la bomba centrífuga detenida y la válvula proporcional con 100% de apertura. El nivel de agua en el tanque se mantuvo constante con un volumen de 3 L. Se utilizaron las mismas ganancias calculadas por el método convencional de Ziegler-Nichols en todos los experimentos, mientras que el MLP implementado para el controlador PI se

mantuvo con los mismos pesos iniciales y constantes de aprendizaje durante cada prueba con el fin de hacer la comparación bajo las mismas condiciones con ambas reglas de aprendizaje. Debido a que se realizaron diferentes pruebas con los controladores P, PI y PID, siendo la ley de control PI la seleccionada para este caso de estudio debido que fue la que mostró un mejor desempeño en la minimización de los índices de desempeño propuestos.

A través del segundo método de Ziegler-Nichols, denominado ganancia crítica el cual es realizado a lazo cerrado, se usó un controlador proporcional y se aumentó esta ganancia hasta que el sistema mostró un comportamiento libre oscilatorio, la última ganancia proporcional registrada es llamada Ganancia Crítica y se determinó el periodo de oscilación en segundos. Con los parámetros y haciendo uso de la tabla de sintonización (Ogata, 2010) se obtuvieron las ganancias  $K_p$  y  $K_I$  del controlador PI de 0.486 y 0.1504, respectivamente.

Por otro lado, el MLP del sintonizador neuronal tiene 9 entradas descritas por (3), 90 nodos y 2 salidas. Las matrices de peso iniciales  $W$  y  $V$  para el MLP fueron obtenidas con números aleatorios dentro del intervalo de -0.5 a 0.5 y las constantes de aprendizaje  $\eta$ ,  $\alpha$  y  $\beta$  tenían valores de 0.04, 0.004 y 0.0005, respectivamente. Los hiper-parámetros (constantes de aprendizaje, nodos y pesos iniciales) del sintonizador neuronal comúnmente se encuentran a prueba y error. Sin embargo, es importante mencionar que debido a las características de la ley de aprendizaje propuesta en este trabajo, el número de experimentos para encontrar hiper-parámetros funcionales es disminuido por las condición de estabilidad y robustez del método de control.

### 3.1. Sistema sin perturbaciones

El primer experimento evaluó la capacidad de regulación y seguimiento de cada método de sintonización ante los puntos de referencia propuestos en (27) sin perturbaciones. La Figura 4 muestra la respuesta obtenida.




Figura 4: Respuesta de los controladores sin perturbaciones.

La corriente, tensión y potencia consumida durante el experimento se muestran en la Figura 5, se observa que el método de Ziegler-Nichols requiere un mayor consumo de energía. Además, la señal de control en tensión eléctrica suministrada a la bomba centrífuga, provocó una dinámica lenta con este método.




Figura 5: a) Corriente, b) Tensión y c) Potencia consumidas por la bomba sin perturbaciones.

Los valores estimados por la red neuronal con ambas reglas de aprendizaje se muestran en la Figura 6. Se observa que la ganancia proporcional estimada se mantiene cerca del valor calculado con el método de Ziegler-Nichols, mientras que la ganancia integral estimada fue mayor.




Figura 6: Ganancias estimadas sin perturbación.

Para comparar el desempeño de los controladores se utilizó el Error Cuadrático Medio (MSE), la Integral del Valor Absoluto del Error (IAE), la señal de control promedio, la Integral de la Variación Total del Control (TVU) y la evaluación del consumo energético. Los resultados obtenidos se muestran en la Tabla 1.

Tabla 1: Índice de rendimiento del controlador PI.

Índice	PI ZN	PI BP	PI BPS
MSE (LPM)	0.1533	0.0822	0.084
IAE (LPM)	56.4255	25.2988	24.5976
PWM Promedio	197.9367	197.6914	197.1883
TVU (PWM)	641.8671	707.2996	653.8251
Wh Promedio	0.7085	0.6973	0.6993
TVU (Wh)	21.1486	20.5748	20.1417

De acuerdo con lo observado en la Figura 4 y Figura 5, el desempeño del método BPS aparentó ser mejor que el método ZN ante el seguimiento de los puntos de ajuste y con respecto a la energía consumida. Esto es notable durante el cambio en el punto de referencia, debido a que el comportamiento transitorio con el método BPS es mejor. Sin embargo, en la Tabla 1 se observa que el método propuesto redujo el índice IAE en un 56.41 % y el consumo energético en un 4.76 % comparado con el método ZN.



### 3.2. Sistema con perturbación constante

En el segundo experimento se propuso alcanzar los puntos de ajuste (27) con la aplicación de la perturbación (23). La respuesta obtenida se muestra en la Figura 7, en la que es posible observar que la respuesta del sistema presenta mayores oscilaciones ante las perturbaciones con los métodos ZN y BP.

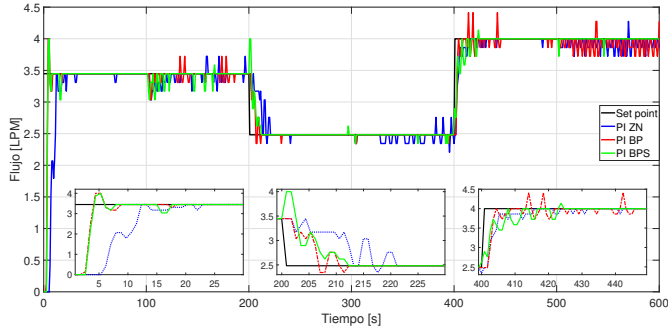


Figura 7: Respuesta del controlador ante perturbación constante.

Los parámetros eléctricos de tensión, corriente y potencia consumida por la bomba con cada método se muestran en la Figura 8. Se debe resaltar que durante la etapa final de la prueba experimental, la regla de aprendizaje BP provocó oscilaciones en el consumo energético.




Figura 8: a) Corriente, b) Tensión y c) Potencia Consumida por la bomba ante una perturbación constante

Debido a la perturbación aplicada, las ganancias estimadas se comportaron como se muestra en la Figura 9. A diferencia del caso anterior, la regla de aprendizaje BP generó más oscilaciones en la ganancia proporcional.




Figura 9: Ganancias estimadas con perturbación constante.

Al igual que en el caso anterior, los resultados se evaluaron por medio del MSE y el IAE además del valor promedio y el índice TVU para la señal de control y la potencia. Los resultados se muestran en la Tabla 2.

Tabla 2: Desempeño del controlador PI ante una perturbación constante.

Índice	PI ZN	PI BP	PI BPS
MSE (LPM)	0.1842	0.0916	0.093
IAE (LPM)	81.4007	48.0334	38.4742
PWM Promedio	209.881	211.2126	199.522
TVU (PWM)	1632.7578	2095.758	1512.8772
Wh Promedio	0.7336	0.7223	0.6932
TVU (Wh)	25.8917	24.6301	23.6487

Las perturbaciones son un efecto común en las aplicaciones industriales, ya que las condiciones de operación ideales y los ambientes controlados no son factibles de lograr debido al ambiente en el que se ubican los procesos. El desempeño que se muestra en la Figura 7 y la energía utilizada que se observa en la Figura 8 muestran que la robustez es una característica importante para el diseño de controladores. El sintonizador con el algoritmo de aprendizaje BP puede volverse inestable rápidamente, comprometiendo la integridad del sistema. Además, el método de Ziegler-Nichols presenta problemas ante el rechazo activo de perturbaciones. Esto se verifica al consultar la Tabla 2 en donde el método BPS minimizó el índice IAE en un 52.74 % y el consumo energético fue reducido en un 8.66 % en comparación con el método ZN.

### 3.3. Sistema con perturbación triangular

En el tercer experimento se analiza al controlador ante los puntos de referencia descritos en (27) con la trayectoria descrita por (24). La respuesta se muestra en la Figura 10. El sintonizador neuronal con el algoritmo BPS no tiende a presentar oscilaciones como las observadas con los otros métodos de sintonización, además de presentar sobreimpulsos menores en comparación con el algoritmo BP.




Figura 10: Respuesta del controlador ante perturbación triangular.

El consumo de la tensión, la corriente y la potencia de la bomba centrífuga con el controlador PI sintonizado con cada método de sintonización se muestran en la Figura 11, en donde se observa que el método de ZN y la regla de aprendizaje BP producen mayores oscilaciones en el consumo energético, debido a la respuesta que provocaron en el sistema.




Figura 11: a) Corriente, b) Tensión y c) Potencia consumidas por la bomba ante una perturbación triangular.

De las perturbaciones aplicadas y los cambios en el punto de referencia, se obtuvo la evolución de las ganancias que se muestra en la Figura 12. Se observa que la regla de aprendizaje BP produce oscilaciones en la ganancia proporcional estimada en diferentes puntos del experimento, debido a la forma en que la regla BP respondió con la perturbación propuesta.




Figura 12: Ganancias estimadas ante una perturbación triangular.

Los resultados de este experimento se analizaron mediante el MSE y el IAE para evaluar el desempeño del controlador PI con cada método de sintonización. Además, la señal de control y la potencia consumida por la bomba se analizaron mediante el valor promedio y el TVU. Los valores obtenidos se muestran en la Tabla 3.

Tabla 3: Desempeño del controlador PI ante perturbación triangular

Índice	PI ZN	PI BP	PI BPS
MSE (LPM)	0.2102	0.1259	0.1103
IAE (LPM)	128.9492	96.8221	81.9343
PWM Promedio	209.7581	211.5928	210.7261
TVU (PWM)	2176.3688	3048.1695	2472.0477
Wh Promedio	0.71	0.7114	0.6967
TVU (Wh)	29.4173	28.2912	24.8755

### 3.4. Sistema con Perturbación Sinusoidal

En el cuarto experimento se evaluó al controlador ante la perturbación sinusoidal descrita en (25). La respuesta del controlador PI se muestra en la Figura 13, en la que se observa el efecto de la perturbación en la respuesta de cada método de sintonización, donde el algoritmo BPS redujo las oscilaciones y produjo una respuesta más rápida ante los cambios en el punto de ajuste.




Figura 13: Respuesta del controlador ante perturbación sinusoidal.

La tensión, la corriente y la potencia consumida por la bomba centrífuga con el controlador PI ante la perturbación sinusoidal se muestra en la Figura 14, donde se observa que la respuesta del controlador sintonizado con la regla BP provocó mayores incrementos en la potencia consumida.




Figura 14: a) Corriente, b) Tensión y c) Potencia consumida por la bomba centrífuga ante una perturbación sinusoidal.

El comportamiento obtenido de las ganancias se muestra en la Figura 15, en donde se observó que la regla de aprendizaje BP produjo mayores oscilaciones en las ganancias estimadas durante las perturbaciones y cambios del punto de referencia.




Figura 15: Ganancias estimadas ante una perturbación sinusoidal.

La Tabla 4 muestra la evaluación de los resultados obtenidos durante el experimento, a través de los índices de desempeño propuestos.



Tabla 4: Desempeño del controlador PI ante una perturbación sinusoidal.

Índice	PI ZN	PI BP	PI BPS
MSE (LPM)	0.2094	0.1114	0.1068
IAE (LPM)	124.4048	88.8257	77.8036
PWM Promedio	209.1972	211.8006	211.2432
TVU (PWM)	1307.686	2095.758	2055.021
Wh Promedio	0.7014	0.6932	0.6794
TVU (Wh)	28.9709	24.6301	22.4126

En este trabajo se propusieron dos tipos de perturbaciones que varían con el tiempo: la triangular y la sinusoidal. Estas se seleccionaron para evaluar el desempeño del controlador propuesto ante cambios agresivos que pudieran afectar la dinámica de un proceso. Se observa en las Figura 10 y Figura 13, que los controladores aceptan y rechazan ciertos tipos de perturbaciones, esta propiedad es importante tomarla en cuenta en el diseño de controladores. El controlador PID puede compensar perturbaciones constantes. No obstante, el esquema propuesto permite reducir el efecto de las perturbaciones al sintonizar el algoritmo en tiempo real, lo que proporciona una mayor robustez al compensar las perturbaciones de primer grado, las cuales normalmente requieren una acción de control integral adicional (Lozano-Hernández et al., 2019). Además, en la mayoría de las secciones de la trayectoria propuesta del punto de referencia, el controlador PI sintonizado con un algoritmo estable en el sentido ISS, presenta un mejor desempeño. Sin embargo, esta inspección no es suficiente para determinar cuál es el mejor. Analizando la Tabla 3, se observa que el método propuesto redujo el IAE en un 36.46% y el consumo energético en un 15.44%. Por otro lado, en la Tabla 4 se muestra que el método BPS redujo el IAE en un 37.4% y el consumo energético en un 22.64%.

#### 4. Conclusiones

El controlador propuesto se implementó en una estación experimental para la variable de proceso de flujo, en la que una bomba de corriente directa es el elemento final de control. Una servoválvula se emplea para perturbar el sistema. La implementación del método BPS para un sintonizador neuronal con las condiciones de operación evaluadas en: la ausencia de perturbación, perturbación constante y perturbación variante en el tiempo; muestran que el controlador propuesto en este trabajo tiene propiedades y características que mejoran las respuestas obtenidas por los controladores clásicos, lo anterior debido a que un PID es capaz de compensar sólo las perturbaciones constantes. En relación al esquema propuesto, este permite reducir el efecto de las perturbaciones sintonizando el algoritmo en tiempo real. El algoritmo BPS proporciona mayor robustez que el método BP ante cambios bruscos en la dinámica del proceso. Se observó que el algoritmo estable redujo el índice IAE entre un 30% y 50% durante las pruebas experimentales.

#### Referencias

- Aggarwal, C., 2018. Neural Networks and Deep Learning. Springer International Publishing.
- Al-Khalifah, M.H., Mcmillan, G., 2012. Control valve versus variable speed drive for flow control.
- Boutalis, Y., Theodoridis, D., Kottas, T.L., Christodoulou, M., 2014. System identification and adaptive control.
- Chen, J., Huang, T.C., 2004. Applying neural networks to on-line updated pid controllers for nonlinear process control. *Journal of Process Control* 14, 211 – 230.
- Fujinaka, T., Kishida, Y., Yoshioka, M., Omatu, S., 2000. Stabilization of double inverted pendulum with self-tuning neuro-pid, in: Proceedings of the IEEE-INNS-ENNS International Joint Conference on Neural Networks. IJCNN 2000. Neural Computing: New Challenges and Perspectives for the New Millennium, pp. 345–348 vol.4.
- Haykin, S., 2010. Neural Networks and Learning Machines. volume volume. Third ed., Pearson.
- Hu, K.m., Li, Y.z., Guan, X.m., 2012. Research of the pipe flow measurement and control system based on bp neural networks pid, in: Advances in Technology and Management, Springer Berlin Heidelberg, Berlin, Heidelberg.
- Lozano-Hernández, Y., Frías, O., Lozada-Castillo, N., Juárez, A., 2019. Control algorithm for taking off and landing manoeuvres of quadrotors in open navigation environments. *International Journal of Control Automation and Systems* 17, 2331–2342.
- Marchi, A., Simpson, A., Ertugrul, N., 2012. Assessing variable speed pump efficiency in water distribution systems. *Drinking Water Engineering and Science* 5, 15–21.
- Miroslav, C., Stefan, K., 2003. Neural networks for real time control systems. IFAC Proceedings Volumes 36, 135 – 142. 2nd IFAC Conference on Control Systems Design, Bratislava, Slovak Republic, 7-10 September 2003.
- Narendra, K.S., Parthasarathy, K., 1991. Gradient methods for the optimization of dynamical systems containing neural networks. *IEEE Transactions on Neural Networks* 2, 252–262.
- Nault, J., Papa, F., 2015. Lifecycle assessment of a water distribution system pump. *Journal of Water Resources Planning and Management* 141.
- Nourbakhsh, S.A., Jaumotte, B.A., Hirsch, C., Parizi, H., 2010. Turbopumps and pumping systems.
- Ogata, K., 2010. Ingeniería de control moderna, Pearson.
- Pirabakaran, K., Becerra, V., 2002. Pid autotuning using neural networks and model reference adaptive control. IFAC Proceedings Volumes 35, 451 – 456. 15th IFAC World Congress.
- Ramos-Velasco, L.E., Domínguez-Ramírez, O.A., Parra-Vega, V., 2016. Wavenet fuzzy pid controller for nonlinear mimo systems: Experimental validation on a high-end haptic robotic interface. *Applied Soft Computing* 40, 199–205. doi:10.1016/j.asoc.2015.11.014.
- Sarbu, I., Valea, E., 2015. Energy savings potential for pumping water in district heating stations. *Sustainability* 7, 1–15.
- Sedighzadeh, M., Rezazadeh, A., 2008. Adaptive pid control of wind energy conversion systems using raspl mother wavelet basis function networks. *International Journal of Electrical and Computer Engineering* 2, 62–66. URL: <https://publications.waset.org/vol13,doi:doi.org/10.5281/zenodo.1077309>.
- Singh, A., Kaur, A., 2014. Tuning techniques of pid controller: A review, in: National Conference on Advances in Engineering and Technology of International Journal of Engineering Research and Applications.
- Waide, P., Brunner, C., 2011. Energy-efficiency policy opportunities for electric motor-driven systems.
- Xi-fan, Y., 2009. Application of self-tuning of pid control based on bp neural networks in the manufacturing process. *Modular Machine Tool and Automatic Manufacturing Technique*.
- Yang, Y., Wu, Q., 2016. A neural network pid control for ph neutralization process, in: 2016 35th Chinese Control Conference (CCC), pp. 3480–3483.
- Yu, W., Li, X., 2003. Discrete-time neuro identification without robust modification. *IEE Proceedings - Control Theory and Applications* 150, 311–316.