

ESCUELA POLITÉCNICA NACIONAL

**FACULTAD DE INGENIERÍA ELÉCTRICA Y
ELECTRÓNICA**

**DISEÑO Y SIMULACIÓN DE DOS ESQUEMAS DE CONTROL
INTELIGENTE CON REDES NEURONALES APLICADOS A UN
PROCESO DE NEUTRALIZACIÓN DE PH ALTAMENTE NO LINEAL**

TOMO 1

**TRABAJO DE INTEGRACIÓN CURRICULAR PRESENTADO COMO
REQUISITO PARA LA OBTENCIÓN DEL TÍTULO DE INGENIERO/A EN
ELECTRÓNICA Y AUTOMATIZACIÓN**

DIEGO ALEXIS ORTIZ CUNAR

diego.ortiz@epn.edu.ec

DIEGO PATRICIO VALDIVIEZO ANDINO

diego.valdiviezo@epn.edu.ec

DIRECTOR: ING. GEOVANNY DANILO CHÁVEZ GARCÍA, PhD.

danilo.chavez@epn.edu.ec

DMQ, febrero 2022

CERTIFICACIONES

Nosotros, DIEGO ALEXIS ORTIZ CUNDAR y DIEGO PATRICIO VALDIVIEZO ANDINO declaramos que el trabajo de integración curricular aquí descrito es de nuestra autoría; que no ha sido previamente presentado para ningún grado o calificación profesional; y, que hemos consultado las referencias bibliográficas que se incluyen en este documento.

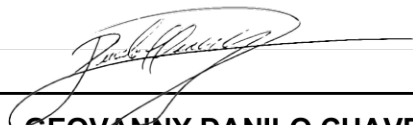


DIEGO ALEXIS ORTIZ CUNDAR



DIEGO PATRICIO VALDIVIEZO ANDINO

Certifico que el presente trabajo de integración curricular fue desarrollado por DIEGO ALEXIS ORTIZ CUNDAR y DIEGO PATRICIO VALDIVIEZO ANDINO, bajo mi supervisión.



GEOVANNY DANILO CHAVEZ
DIRECTOR

DECLARACIÓN DE AUTORÍA

A través de la presente declaración, afirmamos que el trabajo de integración curricular aquí descrito, así como los productos resultantes del mismo, son públicos y estarán a disposición de la comunidad a través del repositorio institucional de la Escuela Politécnica Nacional; sin embargo, la titularidad de los derechos patrimoniales nos corresponde a los autores que hemos contribuido en el desarrollo del presente trabajo; observando para el efecto las disposiciones establecidas por el órgano competente en propiedad intelectual, la normativa interna y demás normas.

DIEGO ALEXIS ORTIZ CUNRAR

DIEGO PATRICIO VALDIVIEZO ANDINO

GEOVANNY DANILO CHÁVEZ GARCÍA

DEDICATORIA

A mi amorosa madre Nancy y a mi ejemplar padre Marco

Quienes son y seguirán siendo el pilar fundamental de mi motivación, por ser ejemplos de humildad, honestidad, entereza y perseverancia. Quienes con sus enseñanzas e inmenso amor han sabido guiarme por un camino de bien y formarme como la persona que soy hoy en día. Quienes sin su apoyo incansable e incondicional no hubiese podido alcanzar este tan anhelado logro.

A mis hermanos Oscar y Brayan

Quienes son el mayor y mejor regalo que mis padres me pudieron haber dado. Quienes con su primer llanto en este mundo me hicieron entender que no estaría solo nunca y que desde ese primer instante han llenado mi vida de alegría y recuerdos maravillosos.

Diego Ortíz

AGRADECIMINETO

A mis padres, hermanos y mi familia en general por el apoyo incondicional que me han brindado desde el momento que inicie esta gran travesía.

A mis amigos John, Cristhian, Alex y Kleber por cada anécdota, cada sonrisa, por su apoyo en los momentos de agobio e incertidumbre y por cada consejo brindado.

A la Escuela Politécnica Nacional y sus docentes que con cada conocimiento y experiencia compartida han contribuido para formarme tanto humana como profesionalmente y me han impulsado a mejorarme día a día.

Al Dr. Danilo Chávez por su guía, tiempo y apoyo desinteresado brindados en el desarrollo de este trabajo de titulación.

Diego Ortíz

ÍNDICE DE CONTENIDO

CERTIFICACIONES	I
DECLARACIÓN DE AUTORÍA	II
DEDICATORIA	III
AGRADECIMINETO	IV
ÍNDICE DE CONTENIDO	V
RESUMEN.....	VII
ABSTRACT	VIII
TOMO I.....	1
1 INTRODUCCIÓN.....	1
1.1 OBJETIVO GENERAL.....	2
1.2 OBJETIVOS ESPECÍFICOS.....	2
1.3 ALCANCE	2
1.4 MARCO TEÓRICO	4
1.4.1 SISTEMAS LINEALES Y NO LINEALES	4
1.4.2 APROXIMACIÓN A MODELOS FOPDT.....	5
1.4.3 SISTEMAS DE CONTROL	7
1.4.3.1 Control PID.....	7
1.4.3.2 Red neuronal feedforward (back propagation).....	9
1.4.3.3 Red neuronal NAR.....	13
1.4.4 ÍNDICES DE DESEMPEÑO (ISE y TVu)	15
1.4.4.1 Integral del error cuadrático (ISE).....	15
1.4.4.2 Variaciones totales de la acción de control (TVu)	15
2 METODOLOGÍA.....	15
3 RESULTADOS, CONCLUSIONES Y RECOMENDACIONES	16
3.1 RESULTADOS	16
3.1.1 RESULTADOS DE LA PRUEBA DE SEGUIMIENTO Y REGULACIÓN DEL PID CLÁSICO.....	18
3.1.2 RESULTADOS DE LA PRUEBA DE SEGUIMIENTO Y REGULACIÓN DEL PID NEURONAL.....	21
3.1.3 RESULTADOS DE LA PRUEBA DE SEGUIMIENTO Y REGULACIÓN DEL PID + RN	24
3.1.4 COMPARACIÓN DE RESULTADOS ENTRE LOS TRES ESQUEMAS DE CONTROL.....	27
3.1.5 COMPARACIÓN DE LAS ACCIONES DE CONTROL GENERADAS POR LOS CONTROLADORES Y DE LOS ÍNDICES ISE Y TVU	29
3.2 CONCLUSIONES.....	37

3.3	RECOMENDACIONES.....	38
4	REFERENCIAS BIBLIOGRÁFICAS.....	39
5	ANEXOS.....	41

RESUMEN

El presente trabajo de titulación presenta el diseño, simulación y comparación de dos esquemas de control inteligente basados en redes neuronales y un controlador tipo PID clásico aplicados a un reactor de neutralización de PH, con características de alta no linealidad el cual presenta cambios tanto en los parámetros de su modelo, como en los retardos de tiempo los cuales son dominantes, esto conforme se varia el punto de operación, los dos esquemas de control inteligente presentados son el de una red neuronal en paralelo a un controlador PID clásico funcionando como soporte y respaldo del PID, por otro lado, el segundo esquema muestra un PID neuronal basado en un PID clásico con ajuste de parámetros por medio de una red neuronal, los resultados son obtenidos mediante una simulación en Matlab-Simulink en donde se compararán el máximo sobrepico y tiempo de establecimiento de los 3 controladores; además, se obtendrán valores de dos índices de desempeño de controladores, ISE y TVu, ante distintos cambios de referencia y perturbaciones a los que será sometido el sistema.

PALABRAS CLAVE: Esquemas de control inteligente, Redes neuronales, PID Clásico, Reactor de neutralización de pH, soporte, respaldo, ajuste de parámetros, índices de desempeño.

ABSTRACT

The present document presents the design, simulation and comparison of two intelligent control schemes based on neural networks and a classic PID type controller applied to a pH neutralization reactor, with high non-linearity characteristics, whose model presents different parameters and variable dominant time delays at different points of operation, the two intelligent control schemes presented are that of a neural network in parallel to a classic PID controller working as a support and backup of the PID, for other way, the second scheme shows a neural PID based on a classic PID with parameter tuning using a neural network, the results are obtained and presented by simulation in Matlab-Simulink, where the maximum overshoot and setting time of system controls will be compared; in addition, values of the different performance indices of controllers such as ISE and TVu will be obtained in the face of different reference changes and disturbances to which the system will be subjected.

KEYWORDS: Intelligent control schemes, Neural Networking, Classic PID, pH Neutralization Reactor, support, backup, parameter tuning, performance indices.

TOMO I

En el Tomo I se presentan los capítulos I, III y IV concernientes al presente trabajo de integración curricular. En el capítulo I se detallan la introducción, objetivo general, objetivos específicos, alcances y marco teórico; en el capítulo III se muestran los resultados obtenidos en el desarrollo de este trabajo, conclusiones y recomendaciones; y por último en el capítulo IV se enlista la bibliografía empleada en este tomo.

1 INTRODUCCIÓN

Dentro del área del control de procesos industriales es muy común encontrarse con procesos que presentan características dinámicas que denoten un comportamiento altamente no lineal [1], es decir sus parámetros de identificación como función de transferencia van variando en distintos puntos de operación, esto junto con otras características propias de los procesos como los retardos en el tiempo de su respuesta los cuales también pueden ser variantes [2], estas características mencionadas, hacen que los controladores clásicos como un PID (Control Proporcional, Derivativo e Integral) no sean capaces de proporcionar un control estable y eficiente ante cambios de referencia o rechazo de perturbaciones cuando el proceso varía en los punto de operación [3].

Uno de los procesos con las características antes mencionadas y con mayor requerimiento de control más comunes dentro de la industria química es el proceso de neutralización de potencial de hidrógeno (pH) [2], el control de esta variable es fundamental dentro de la industria de producción de alimentos, bebidas, cosméticos, farmacéuticos, entre otras, ya que juega un papel importante dentro de la conservación y preservación del producto [4].

La mayor complejidad que se presenta al momento de diseñar un sistema de control para una planta de pH, es su alta no linealidad, ya que un mínimo cambio en la entrada del proceso resulta en un cambio brusco del comportamiento dinámico del sistema, es por ello que dentro de la teoría de control clásica es muy complicado lograr la regulación deseada de esta variable [2] teniendo así un sin número de estrategias de control desarrolladas con las teorías de control moderno [5], [6], teniendo en cuenta esto, el desarrollo de nuevas estrategias de control usando redes neuronales ha tenido un gran avance [7], con lo cual se busca mejorar la eficiencia de los controladores optimizando los parámetros de los mismos, esto con el fin de que puedan adaptarse de mejor manera a las dinámicas de los sistemas no lineales [8], [9], [10].

Ante esta problemática en el presente trabajo se plantea la implementación de dos esquemas de control inteligente basados en redes neuronales para el control de la variable

pH en un proceso químico de neutralización del mismo, los sistemas de control a ser diseñados tendrán como base un controlador tipo PID clásico al cual en un primer esquema se plantea añadir una señal de control compensatoria, dicha señal provendría de una red neuronal ubicada en paralelo a dicho controlador PID clásico + red neuronal (PID + RN) [9], en un segundo esquema se plantea una red neuronal interna capaz de ajustar los parámetros de dicho controlador PID clásico obteniendo con esto un PID neuronal, para que este pueda operar de manera eficiente en los distintos puntos de operación del sistema [9], [11].

1.1 OBJETIVO GENERAL

El objetivo general de este Trabajo de Integración Curricular es:

Diseñar y simular dos esquemas de control inteligente con redes neuronales aplicados a un proceso de neutralización de pH altamente no lineal.

1.2 OBJETIVOS ESPECÍFICOS

Los objetivos específicos de este Trabajo de Integración Curricular son:

- Realizar un estudio bibliográfico sobre: aproximación de sistemas no lineales a un modelo de orden reducido con tiempo muerto (FOPDT), fundamentos de diseño de controladores PID con base en modelos de primer orden con retardo, fundamentos de control inteligente usando redes neuronales y sus aplicaciones en procesos de control de pH.
- Diseñar dos esquemas de control inteligente basados en redes neuronales usando como base los parámetros y comportamiento de un PID clásico.
- Comparar cuantitativamente el rendimiento de los esquemas de control propuestos con el controlador PID clásico usando los indicadores ISE, TVu y las características de la respuesta del sistema: máximo sobrepico y tiempo de establecimiento.

1.3 ALCANCE

- Estudio bibliográfico sobre los esquemas de control inteligente con redes neuronales, para entender sus aplicaciones, ventajas y desventajas en su uso para el control de sistemas altamente no lineales.
- Estudio a cerca de las redes neuronales de adaptación con algoritmos de entrenamiento por retropropagación (backpropagation), aplicada a esquemas

de control neuronal con el fin de obtener los criterios de diseño para la creación de los esquemas de control propuestos.

- Revisión bibliográfica a cerca de las técnicas de aproximación de sistemas de orden-superior o sistemas no-lineales, a sistemas de primer orden con tiempo muerto (FOPDT); mediante el uso de datos experimentales de entrada y salida, para la obtención de los diferentes modelos empíricos en los distintos puntos de operación del sistema en estudio.
- Estudio de los parámetros de la planta de neutralización de pH presentada en [E. Iglesias, 2006], con la modificación en el tiempo de retardo propuesta en [E. Anchitipan, 2020], para el respectivo análisis de la no linealidad de éstos y la influencia que tiene el tiempo de retardo generado por el transmisor sobre la respuesta del sistema y la controlabilidad de este.
- Simulación del reactor de neutralización de pH en Simulink para observar su comportamiento y obtener datos en distintas condiciones de operación.
- Obtención de modelos lineales FOPDT de nuestra planta de estudio en distintos puntos de operación, con la respectiva sintonización de un PID por cada uno de estos puntos, para finalmente realizar un promedio de los parámetros de los PIDs sintonizados previamente y obtener un PID global con el que se compararán los esquemas de control inteligentes a diseñar.
- Diseño de una red neuronal que trabajará en paralelo con un controlador PID clásico (PID + RN), con el fin de que esta red neuronal sea capaz de compensar la señal de control dada por el PID clásico [10].
- Diseño de una red de backpropagation con el fin de ajustar los parámetros de un PID clásico para obtener un PID neuronal [10].
- Simulación de los esquemas de control propuestos junto con la planta usando el software Simulink para evaluar el desempeño de estos ante cambio de referencia y perturbaciones.
- Comparación del desempeño de los esquemas de control propuestos con un PID clásico mediante índices de rendimiento ISE, TVu y las características de la respuesta del sistema: máximo sobrepico y tiempo de establecimiento.

1.4 MARCO TEÓRICO

En esta sección se presenta los fundamentos teóricos usados para el desarrollo del presente trabajo de titulación. Se empieza con la revisión bibliográfica de lo que son los sistemas lineales y no lineales, se continua con la revisión del método para realizar aproximaciones de sistemas a modelos de primer orden, controladores PID, redes neuronales y su aplicación a controladores, y por último se investigará sobre los índices que miden el desempeño de controladores ISE, TVu.

1.4.1 SISTEMAS LINEALES Y NO LINEALES

Ya sea en la naturaleza, en la industria o en la vida cotidiana están presentes un sin número de procesos dinámicos los cuales pueden ser descritos como sistemas que en la mayoría de casos tienen características de comportamiento no lineal [12]. La mayoría, por no decir todos los sistemas dinámicos pueden ser representados mediante sus entradas y un conjunto de ecuaciones diferenciales lineales que se relacionan entre sí, estas ecuaciones contienen el menor número de variables con la cuales se puede determinar el comportamiento dinámico del sistema, a este conjunto de variables se les da el nombre de variables de estado [1]. Teniendo esto en cuenta, a continuación, se define lo que es un sistema lineal y no lineal.

Un sistema es lineal cuando cumple con los siguientes principios.

- **Principio de Homogeneidad:** este principio nos dice que, si la respuesta de un sistema es $r_1(t)$ ante una entrada $c_1(t)$, al multiplicar una constante α por la entrada, $\alpha * c_1(t)$, esta constante se verá reflejada en los valores de la salida de dicho sistema, $\alpha * r_1(t)$ [12].
- **Principio de superposición:** este principio nos dice que si obtenemos una respuesta $r_1(t)$ al aplicar una entrada $c_1(t)$ a un sistema y luego obtenemos $r_2(t)$ ante una entrada $c_2(t)$; entonces la respuesta esperada al aplicar la suma de las entradas ($c_1(t)+c_2(t)$) a dicho sistema será $(r_1(t) + r_2(t))$ [12].

Por otro lado, un sistema es no lineal cuando no cumple con los principios anteriormente descritos, el estudio de este tipo de sistemas es muy importante debido a que como se mencionó anteriormente prácticamente todos los sistemas presentes en la industria son de este tipo [12].

1.4.2 APROXIMACIÓN A MODELOS FOPDT

Como se había dicho anteriormente, gran parte de los procesos industriales tienen características no lineales, por lo cual sus modelos matemáticos tienden a ser bastante complejos, esto deriva en algunas complicaciones o problemas al momento de desarrollar el análisis y diseño de controladores para este tipo de sistemas, teniendo esto en cuenta, se han desarrollado métodos para obtener modelos aproximados lineales de orden reducido los cuales sean capaces de replicar el comportamiento de dichos sistemas no lineales, esto con el fin de facilitar el diseño de controladores para este tipo de sistemas tomando como base de diseño los parámetros del modelo de orden reducido obtenido [13].

Uno de los métodos para obtener este tipo de aproximaciones es el propuesto por Smith y Corripio, el cual está basado en el análisis de la curva de reacción resultante al estimular a un sistema a una entrada tipo paso, este procedimiento permite obtener un modelo lineal de primer orden con tiempo muerto (FOPDT) cuya función de transferencia está representada en la ecuación 1.1 [13].

$$G(s) = \frac{Y(s)}{U(s)} = \frac{K}{\tau s + 1} e^{-\theta s} \quad (1.1)$$

Donde:

- $G(s)$: Función de transferencia del modelo FOPDT.
- $Y(s)$: Variable de salida del proceso.
- $U(s)$: Variable de entrada del proceso.
- K : Ganancia del proceso.
- τ : Constante de tiempo del proceso.
- θ : retardo de tiempo del proceso.

A continuación, se describe el proceso para la obtención del modelo FOPDT.

Con el sistema de control en lazo abierto (sin realimentación) y estando el sistema en estado estable en un punto de operación se genera un cambio de tipo escalón de $\pm 10\%$ en la entrada y se registran los datos en la salida del sistema, esto hasta que este vuelva a estar estable en un nuevo punto de operación.

En la Figura 1.1 se muestra la variación tipo escalón que se debe dar a la entrada del sistema y la salida del proceso esperada.




Figura 1.1 Variación en la entrada y salida del sistema.

Donde:

- t_1 : Tiempo que demora la señal de salida en llegar al 28.3% de y_u .
- t_2 : Tiempo que demora la señal de salida en llegar al 63.2% de y_u .
- y_u : Valor final de la salida.
- Δy : Variación de la salida.
- Δu : Variación de la entrada.

Luego se mide el tiempo que el sistema se demora en llegar al 28.3% y al 63.2% del valor de la salida del sistema en el nuevo punto de establecimiento mencionado; los parámetros concernientes al modelo FOPDT mostrado en la ecuación 1.1 pueden ser calculados con las ecuaciones 1.2, 1.3, 1.4 [13].

$$K = \frac{\Delta Y}{\Delta U} \quad (1.2)$$

$$\tau = 1.5(t_2 - t_1) \quad (1.3)$$

$$\theta = t_2 - \tau \quad (1.4)$$

Para los sistemas representados bajo un modelo FOPDT, se puede decir que tienen retardo dominante cuando la relación entre el retardo y la constante de tiempo del sistema es mayor que uno, como se muestra en la ecuación 1.5 [13], lo cual supone un mayor esfuerzo en el diseño de controladores para este tipo de sistemas ya que la detección de las perturbaciones o cambios de referencias no son detectadas a tiempo haciendo que el

controlador no sea capaz de generar la acción de control en el momento correcto lo cual puede causar que el sistema pierda estabilidad [14].

$$\frac{\theta}{\tau} > 1 \quad (1.5)$$

1.4.3 SISTEMAS DE CONTROL

Los sistemas de control son de principal importancia dentro de la industria y poseen un sin número de aplicaciones, su objetivo es generar una señal de control necesaria para que el proceso para el cual fue diseñado sea capaz de alcanzar los resultados esperados en el menor tiempo posible y manteniendo el estándar de calidad necesario en el producto terminado, esto se logra cuando el controlador interactúa con los elementos de la planta que pueden modificar la operación de esta como lo pueden ser sistemas de transporte, robots, variadores, etc. [15].

El diseño de controladores para los sistemas con retardo dominante representa un verdadero desafío ya que controladores clásicos como lo es el tipo PID llegan a no ser suficientes para que el sistema se estabilice en el tiempo y valores de funcionamiento deseados [3], es por eso que la investigación de nuevas estrategias de control usando redes neuronales para ser aplicados a procesos con comportamiento no lineal ha avanzado mucho en los últimos años [7], [16], dichas investigaciones han sido enfocadas en optimizar los parámetros los controladores para que estos puedan manejar de mejor manera la dinámica variante propia de los sistemas no lineales [9].

1.4.3.1 Control PID

Dentro de la industria el controlador tipo PID es una de las estrategias más usadas a pesar de que existen estrategias mucho más avanzadas y con mejor funcionamiento en procesos donde la prioridad sean la economía y la sencillez en la operación del sistema de control [17], esto se debe a la sencillez de su estructura, configuración fácil y la característica más relevante la cual es que puede ser implementado a sistemas sin necesidad de conocer los modelos de estos, la estructura de un controlador PID continuo viene dada por la ecuación 1.6 y su función de transferencia viene dada por la ecuación 1.7 [17] [18].

$$u(t) = K_c * e(t) + \frac{K_c}{T_i} \int e(t) dt + K_c * T_d \frac{de(t)}{dt} \quad (1.6)$$

Donde:

$u(t)$: Acción de control.

- K_c : Ganancia Proporcional del controlador.
 T_i : Tiempo integral del controlador.
 T_d : Tiempo derivativo del controlador.
 $e(t)$: Error existente entre la respuesta del sistema y la referencia [17].

$$G(s) = \frac{U(s)}{E(s)} = K_c + \frac{K_c}{T_i s} + K_c * T_d s \quad (1.7)$$

Donde:

- $G(s)$: Función de transferencia del controlador PID.
 $U(s)$: Transformada de Laplace de la respuesta del controlador.
 $E(s)$: Transformada de Laplace del error existente entre la respuesta del sistema y la referencia [17].

Un controlador tipo PID está conformado por los siguientes términos:

- **Acción de control Proporcional (Kp):** esta acción de control genera una señal de salida proporcional a la del error, esto quiere decir que cuanto más grande sea el error, mayor será el valor de la señal de la acción de control proporcional.

Como consecuencias de aumentar el valor de la acción de control proporcional se tiene que se aumenta la velocidad de respuesta del sistema y disminuye el error en estado estable, pero vuelve al sistema inestable [19].
- **Acción de control integral (Ki):** esta acción de control genera una señal de salida proporcional a la integral del error, en otras palabras, genera una señal proporcional a la acumulación de la señal del error lo que hace que el valor de esta señal sea cada vez mayor, con esto se consigue que error en estado permanente disminuya, pero vuelve al sistema inestable debido a que se dota al sistema de una mayor inercia lo cual a su vez incrementa la velocidad del sistema [19].
- **Acción de control Derivativa (Kd):** esta acción de control genera una salida proporcional a la derivada del error, que en otras palabras se le podría llamar la velocidad del error; y ayuda a mejorar la respuesta transitoria del sistema. Hay que tener cuidado con esta acción de control ya que si el error varía de manera brusca haría que se genere una señal de energía ilimitada a la salida del controlador lo puede ser catastrófico para el actuador.

Como consecuencias de aumentar la constante K_d se tiene que se aumenta la estabilidad del sistema controlado, la velocidad del sistema disminuye, pero el error en estado estable permanece igual [19].

Como se había mencionado anteriormente, una de las propiedades de los controladores tipo PID es que pueden ser implementados a un sistema sin necesidad de conocer el modelo de este, para esto se usan métodos de sintonización para la estimación de sus parámetros (K_c , T_i y T_d). Para el desarrollo de este trabajo de titulación el método de sintonización a usar es el de Dahlin porque el controlador resultante no genera respuestas bruscas [13], pero tiene la desventaja de que el controlador resultante de la sintonización de Dahlin usando los parámetros del modelo FOPDT será válido únicamente alrededor del punto de operación en el cual fueron calculados dichos parámetros, entonces mientras más se aleje el sistema del punto de operación para el cual se obtuvo el modelo FOPDT más rendimiento perderá el controlador ya que los parámetros del modelo en un sistema no lineal cambian conforme se mueve el punto de operación [20].

Las ecuaciones para sintonizar el controlador tipo PID con el método de Dahlin se presentan en la Tabla 1.1.

Tabla 1.1 Ecuaciones del método de sintonización de PID de Dahlin.

Constante del controlador	Ecuación
K_c	$\frac{1}{2K} \left(\frac{\tau}{t_0} \right)$
T_i	τ
T_d	$\frac{t_0}{2}$

1.4.3.2 Red neuronal feedforward (back propagation)

Las redes neuronales artificiales (RNA's) son sistemas de procesamiento basados en algoritmos computacionales que han ido tomando mayor importancia dentro de los campos de la ciencia y tecnología ya que son de gran ayuda al momento de resolver problemas en procesos con comportamiento no lineal y que involucran muchas variables, esto de manera óptima que los métodos tradicionales [21].

Las redes neuronales tienen las siguientes cualidades:

- Funciones de activación no lineales.

- La estructura, con la cual son capaces de realizar computación en paralelo.
- Algoritmos de entrenamiento con los cuales ajustan los pesos de las conexiones para que la red sea capaz de desarrollar la tarea para la cual fue creada [9].

Con esto se dice que las redes neuronales artificiales pueden emular el funcionamiento de una red neuronal biológica real [9].

Las RNA's internamente se componen de neuronas (unidades simples de cómputo) las cuales poseen un conjunto de entradas y salidas resultantes de la interconexión con las otras neuronas de la red, dichas conexiones están ponderadas por un conjunto de pesos que indica el nivel de importancia que tiene esa conexión con respecto al resto, dichos pesos son de valor inicial aleatorio; y la resultante de dicha ponderación es evaluada por una función de activación en cada neurona generando así un valor a la salida de esta para luego ser enviado a todas las neuronas de la siguiente capa [9].

Una de las estructuras más conocidas es la llamada red feedforward cuya estructura se caracteriza por normalmente estar dispuesta en capas que por lo general son 3 [9]:

- Una capa de entrada donde ingresan los datos a ser evaluados por la red, estos datos pueden ser multivariantes, por lo general esta capa suele tener n conexiones; pero a modo explicativo en la figura 1.2 se muestran cuatro: p_1 a p_4 [9].
- Cero o más capas ocultas donde se encuentran las neuronas las cuales tienen un cierto valor de ajuste b^1_1 , esto nos da a entender que esta neurona es la primera de la primera capa oculta, todas las neuronas de esta capa están conectadas con todas las entradas de la red neuronal y como se dijo anteriormente cada conexión tiene un peso dado $iw_{1,1}^{1,1}$ [9].
- Por último se tiene una capa de salida en la que el dato resultante no estará sometido a un modelo matemático [21], a excepción de la capa de entrada, las capas ocultas y de salida tienen un número determinado de neuronas, cada una de las cuales tiene conexiones con las neuronas de la capa anterior las cuales están ponderadas por pesos tal y como se muestra en la Figura 1.2, dichas conexiones son evaluadas por las funciones de activación y el dato resultante de cada neurona es enviado a todas las neuronas de la siguiente capa, con esto se puede ver que la información viaja desde la capa de entrada hacia la capa de salida unidireccionalmente, esto para que dicha información nunca pase por la misma neurona dos veces hasta antes de que la red genere una salida correspondiente al dato en análisis [9] [22].

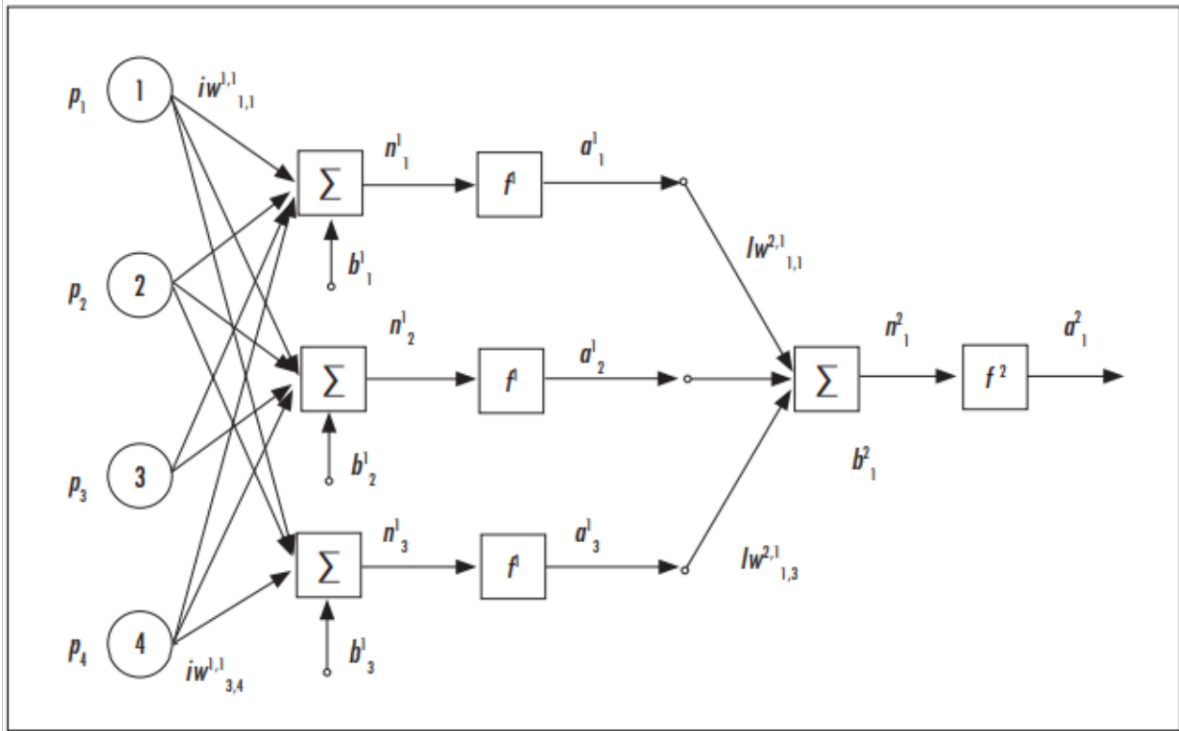


Figura 1.2 Estructura de una RNA feedforward.

Donde:

n^1_1 : Es la entrada a la función de activación de la primera capa oculta y se describe en la ecuación 1.8.

$$n^1_1 = \sum_{n=1}^4 iw^{1,1,R} * P_R + b^1_1 \quad (1.8)$$

f^1 : Es la función de activación que puede ser cualquier función diferenciable, a modo de ejemplo en la ecuación 1.9 se muestra la función sigmoidea.

$$f^1 = \frac{1}{1 + e^{-n}} \quad (1.9)$$

n^2_1 : Es la suma de las contribuciones de cada neurona de la capa oculta y a su vez pasa a ser una de las entradas de la capa de salida, este valor se determina mediante la ecuación 1.10.

$$n^2_1 = \sum_{S=1}^3 iw^{2,1,S} * a^1_S + b^2_1 \quad (1.10)$$

a^2_1 : es la salida de la red representada en la ecuación 1.11, la cual luego se comparará con la salida deseada y_d .

$$a^2_1 = f^1(n^2_1) \quad (1.11)$$

Por lo descrito anteriormente, las redes feedforward son una de las herramientas más útiles en procesos donde se necesite realizar interpolación no lineal y multidimensional con un mínimo de error en su salida, por lo que se las emplea principalmente en aplicaciones como: control, electrónica, automatización, economía, entre otros [22].

Habiendo dicho lo anterior, una red neuronal no podría realizar el trabajo para el que fue diseñada sin antes ser entrenada bajo ciertas condiciones o reglas de operación, dichas reglas son llamadas algoritmos de entrenamiento y uno de los más usados para entrenar redes feedforward es el algoritmo backpropagation el cual consta de dos instancias, en una la primera parte la entrada o grupo de entradas son ingresadas a la red para ser ponderadas por los pesos y evaluadas por las funciones de activación, como se había indicado anteriormente los pesos inician con un valor aleatorio, con esto se generan una o un grupo de salidas las cuales a continuación son comparadas con las salidas (y_d) que se espera que la red asocie a las entradas dadas y se calcula el error existente entre estas, a continuación se ingresa otro conjunto de valores a la entrada de la red, a este segundo conjunto de valores se lo conoce con el nombre de ejemplo; nuevamente se propagan estos valores por toda la red y se vuelve a calcular el error entre la salida de la red y la salida esperada, este proceso se repite con todo el conjunto de datos que se tenga como ejemplo y el error resultante (e) se ira acumulando, dicho error es calculado con la ecuación 1.12 [9].

$$e = \frac{(y_d - a^2_1)^2}{2} \quad (1.12)$$

Para la segunda parte, en base al error acumulado (e) se comienzan a ajustar los pesos de las conexiones de todas las capas de modo que el error acumulado vaya reduciéndose, la contribución de cada peso al error acumulado viene dado por δ^1 y δ^2 los cuales se determinan por las ecuaciones 1.13 y 1.14 [9].

$$\delta^2_1 = (y_d - a^2_1) * f'^2(n^2_1) \quad (1.13)$$

$$\delta^1_1 = f'^1(n^1_1) * \delta^2_1 * iw^{2,1}_{1,1} \quad (1.14)$$

Donde:

f^1 y f^2 : son las derivadas de la función de activación.

Al haber finalizado todo este proceso se dice que se ha cumplido una época; luego se repiten las partes uno y dos tantas épocas como sea necesario como para que el error acumulado sea menor o igual al valor del error que se crea conveniente para el proceso, el cálculo para el ajuste de los pesos se realiza por medio de las ecuaciones 1.15 y 1.16 [9].

$$iw_{1,1}^{2,1}(t+1) = iw_{1,1}^{2,1}(t) + \alpha * \delta_1^2 * a_1^1 \quad (1.15)$$

$$iw_{1,1}^{1,1}(t+1) = iw_{1,1}^{1,1}(t) + \alpha * \delta_1^1 * P_1 \quad (1.16)$$

Donde:

α : Es una constante que define la velocidad de aprendizaje de la red neuronal.

A todo este proceso se lo conoce como entrenamiento off line debido a que se tienen todo el conjunto de datos de los ejemplos a disposición y el tiempo necesario para ajustar los pesos de las conexiones por medio del algoritmo de aprendizaje, una vez el error acumulado haya llegado a los límites establecidos como aceptables se considera que la red tiene un conjunto de pesos adecuado, se termina el entrenamiento de la red y se hace uso de ella dentro del proceso [9].

1.4.3.3 Red neuronal NAR

Al igual que la red neuronal feedforward, la red neuronal autorregresiva no lineal (NAR) trata de simular las funciones de una red neuronal biológica, con la diferencia que la red NAR está basada en un sistema inteligente de mapeo no lineal el cual es capaz de crear series de tiempo a partir de los datos de las señales de entrada y salida del sistema en el cual está queriendo ser implementada, este tipo de red se considera una de las mejores para predecir datos de los sistemas con comportamiento no lineal y son capaces de predecir valores futuros basándose en observaciones de datos pasados del sistema, esto hace que cuando se usan en sistemas de control se las considere como esquemas predictivos, la arquitectura de este tipo de redes se muestra en la Figura 1.3 [23].




Figura 1.3 Esquema general de una red neuronal NAR.

La red NAR se considera un tipo de perceptrón multicapa en el cual al después de obtener la serie de tiempo se definen el número de capas y el algoritmo de entrenamiento de la red, el cual al busca modificar el valor de los pesos para que el error resultante sea el menor posible [24], las estructuras de este tipo de redes se determinan mediante prueba y error, lo que da a entender que no hay un método específico para obtener una red que tenga las mejores características para el sistema al cual se implementará, los elementos de la red que se pueden ir modificando son el número de neuronas, de capas ocultas y el algoritmo de entrenamiento [24].

El modelo que describe este tipo de redes se muestra en la ecuación 1.17.

$$\hat{y}(t) = f(y(t-1) + y(t-2) + \dots + y(t-d)) \quad (1.17)$$

Donde:

f : es la función no lineal cuyos valores futuros dependen solo de los valores pasados de la señal de salida [24].

Para el proceso de entrenamiento de este tipo de redes los datos de entrada y salida deben dividirse con base al número de observaciones, esto para definir qué datos serán usados para el entrenamiento y que datos se usarán para la validación de la red, normalmente el 70% de los datos se usa para el entrenamiento y el restante se usa para validar y

comprobar el funcionamiento de la red [25], una vez se hayan realizado estos procesos se analizan los datos resultantes y en caso de que no sean los esperados se puede reentrenar la red o cambiar su estructura, además de los porcentajes de los datos que son usados para el entrenamiento y validación [23].

1.4.4 ÍNDICES DE DESEMPEÑO (ISE y TVu)

Para evaluar el desempeño de los controladores desarrollados en el presente trabajo de titulación en forma cuantitativa se usarán los índices ISE y TVu.

1.4.4.1 Integral del error cuadrático (ISE)

Este índice nos ayuda a medir el desempeño del controlador tanto en estado estable como en estado transitorio, penalizando mayormente este último y toma como base para su cálculo el error existente entre la referencia y la salida del proceso, se dice que un controlador tiene mejor rendimiento cuando más bajo y cercano a cero sea el valor de este índice, el cálculo de este índice se da por medio de la ecuación 1.18 [26].

$$ISE = \int_0^t e(t)^2 dt \quad (1.18)$$

1.4.4.2 Variaciones totales de la acción de control (TVu)

Este índice basa su análisis en la señal generada por el controlador y se calcula por medio de la ecuación 1.19, este índice se usa para analizar las variaciones de la acción de control y se considera que esta es suave cuando el valor de este índice es bajo [27].

$$TVu = \sum_{k=1}^{\infty} |u_{k+1} - u_k| \quad (1.19)$$

2 METODOLOGÍA

El contenido de este capítulo se encuentra disponible en el tomo II.

3 RESULTADOS, CONCLUSIONES Y RECOMENDACIONES

3.1 RESULTADOS

En esta sección se presentan los resultados del funcionamiento obtenido en las simulaciones de los esquemas de control propuestos en el presente trabajo de titulación al ser aplicados al reactor de neutralización de pH presentado en el capítulo 2, dichos esquemas de control serán sometidos a pruebas de regulación y seguimiento para luego ser comparados entre si mediante los valores de máximo sobrepico, tiempo de establecimiento y también haciendo uso de los índices de rendimiento ISE y TVu.

A continuación, se muestra la nomenclatura que será usada en los gráficos de esta sección:

- PID : Controlador PID clásico.
- PID Neuronal : Controlador PID Neuronal, el cual consta de un PID clásico al cual se le realiza un ajuste de parámetros por medio de una red neuronal feedforward.
- PID + RN : Controlador PID + red neuronal, el cual consta de un controlador PID clásico a cuya señal de salida se le añade una señal compensatoria generada por una red neuronal ubicada en paralelo a dicho controlador.
- Referencia : Señal de referencia del nivel de pH en el reactor.




Figura 3.1 Cambios de referencia ascendentes para pruebas de seguimiento.

En la Figura 3.1 se muestran cambios de referencia ascendentes los cuales serán usados en las pruebas de seguimiento, estos parten desde un valor de 7.025 pH hasta llegar a 7.9 pH y se producen cada 15000 [s].




Figura 3.2 Cambios de referencia descendentes para pruebas de seguimiento.

En la Figura 3.2 se muestran cambios de referencia descendentes que inician en 7.025 pH y llegan hasta 4 pH y que ocurren cada 15000 [s] los cuales también serán usados en las pruebas de seguimiento.

Para la prueba de regulación se generan cambios en el flujo de la corriente ácida $q_1(t)$ que ingresará al reactor de neutralización de pH, esto para emular perturbaciones en el sistema, los cambios partirán desde 16.6 [ml/s] para pasar a 15.6 [ml/s] en $t_1 = 60000$ [s] y luego a 17.60 [ml/s] en $t_2 = 90000$ [s] tal y como se muestra en la Figura 3.3.




Figura 3.3 Cambios en el flujo de corriente ácida $q_1(t)$.

3.1.1 RESULTADOS DE LA PRUEBA DE SEGUIMIENTO Y REGULACIÓN DEL PID CLÁSICO




Figura 3.4 Respuesta del sistema con el controlador PID clásico (prueba de seguimiento con cambios de referencia ascendentes).

En la Figura 3.4 se observa como el controlador es capaz de seguir a la referencia propuesta en la Figura 3.1, se puede ver que entre mas incrementa el valor de la referencia menos se demora el sistema en alcanzarla, teniendo asi un tiempo de establecimiento que varia entre los 3900 [s] a 11300 [s]; al mismo tiempo va apareciendo un sobrepico cuyo valor en todos los casos no sobrepasa el 1%, teniendo asi un maximo valor de 0.186% el cual se genera en el paso de referencia de 7.75 pH a 7.9 pH .




Figura 3.5 Respuesta del sistema con el controlador PID clásico (prueba de seguimiento con cambios de referencia descendentes).

En la Figura 3.5 se puede ver como el sistema no sigue la tendencia de disminuir su tiempo de establecimiento conforme la referencia se aleja del punto de operación inicial, esta vez el rango del tiempo de establecimiento se sitúa entre los 6700 [s] a 14400 [s], además se observa que no se generan sobrepicos en ninguna de las variaciones de la referencia planteada en la Figura 3.2.




Figura 3.6 Respuesta del sistema con el controlador PID clásico (prueba de regulación).

En la Figura 3.6 se ve cómo reacciona el sistema ante las perturbaciones planteadas en la Figura 3.3 las cuales corresponden al flujo de corriente ácida $q_1(t)$, se observa que el sistema en la primera perturbación llega a tener un sobrepico del 15.1% y regresa al punto de operación inicial luego de 23900 [s]. En la segunda perturbación el sistema llega a tener un sobrepico del 9.76% y regresa al valor de operación deseado en 29500 [s] contados a partir del tiempo en el que se produjo la perturbación en el flujo de corriente ácida.

Como se puede ver en la Figura 3.4, Figura 3.5 y Figura 3.6 existe un problema predominante el cual es el tiempo de establecimiento del sistema lo cual podría mejorarse incrementando el valor de la constante derivativa K_d en el sistema de control pero esto conlleva a que este empeore su funcionamiento ante cambios de referencia además de aumentar la capacidad de procesamiento computacional necesario para ejecutarlo.

3.1.2 RESULTADOS DE LA PRUEBA DE SEGUIMIENTO Y REGULACIÓN DEL PID NEURONAL

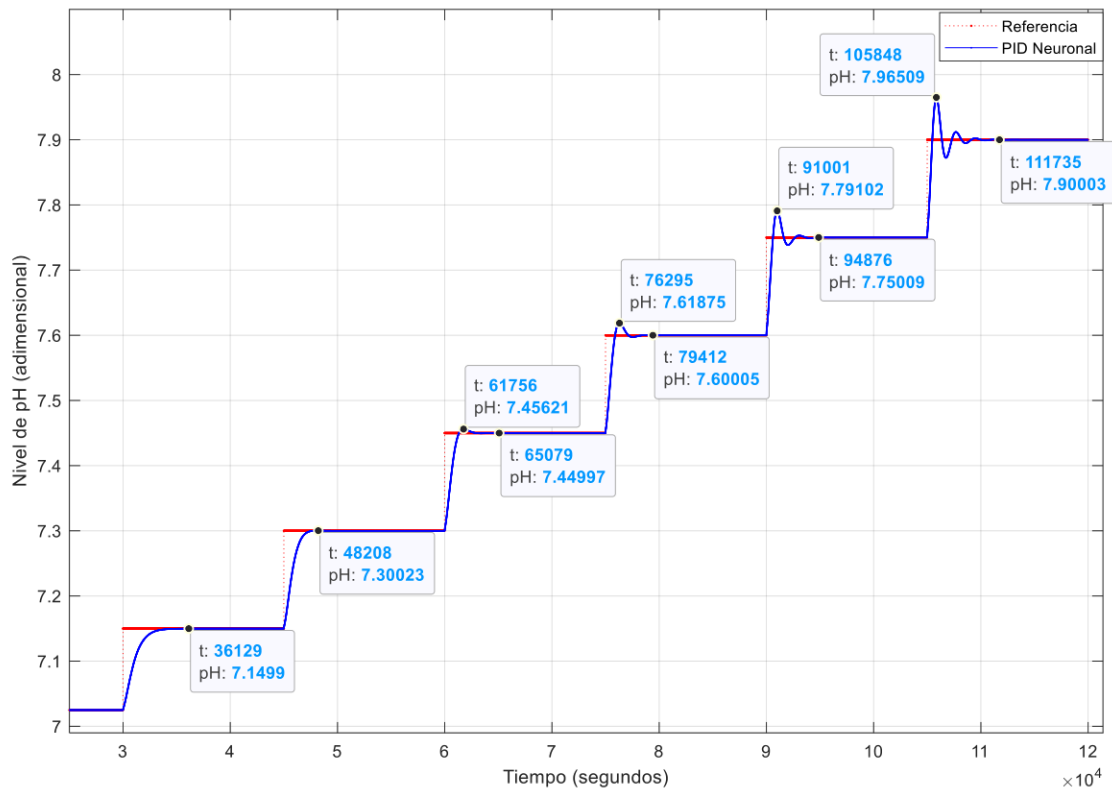


Figura 3.7 Respuesta del sistema con el controlador PID Neuronal (prueba de seguimiento con cambios de referencia ascendentes).

En la Figura 3.7 se observa como el controlador PID Neuronal es capaz de hacer que el sistema siga a la referencia propuesta en la Figura 3.1, al igual que el caso del controlador PID clásico se puede ver que entre mas incrementa el valor de la referencia menos se demora el sistema en alcanzarla, teniendo asi un tiempo de establecimiento que varia entre los 3200 [s] a 6700 [s]; ademas, se genera un sobrepico cuyo valor en todos los casos no sobrepasa el 1%, teniendo como maximo valor 0.822% el cual se genera en el paso de 7.75 pH a 7.9 pH.




Figura 3.8 Respuesta del sistema con el controlador PID Neuronal (prueba de seguimiento con cambios de referencia descendentes).

En la Figura 3.8 se puede ver como el sistema de control al igual que el caso del PID clásico no sigue la tendencia de disminuir el tiempo de establecimiento conforme la referencia se aleja del punto de operación inicial del sistema, en este caso este tiempo se sitúa en un rango entre los 5800 [s] a 10100 [s], además, presenta sobrepicos en algunos de los cambios de referencia planteados en la Figura 3.2, estos sobrepicos no sobrepasan el 2% en ninguna de las variaciones de la referencia, siendo 1.844% el de mayor valor, el cual se genera en el cambio de 5 pH a 4.5 pH.

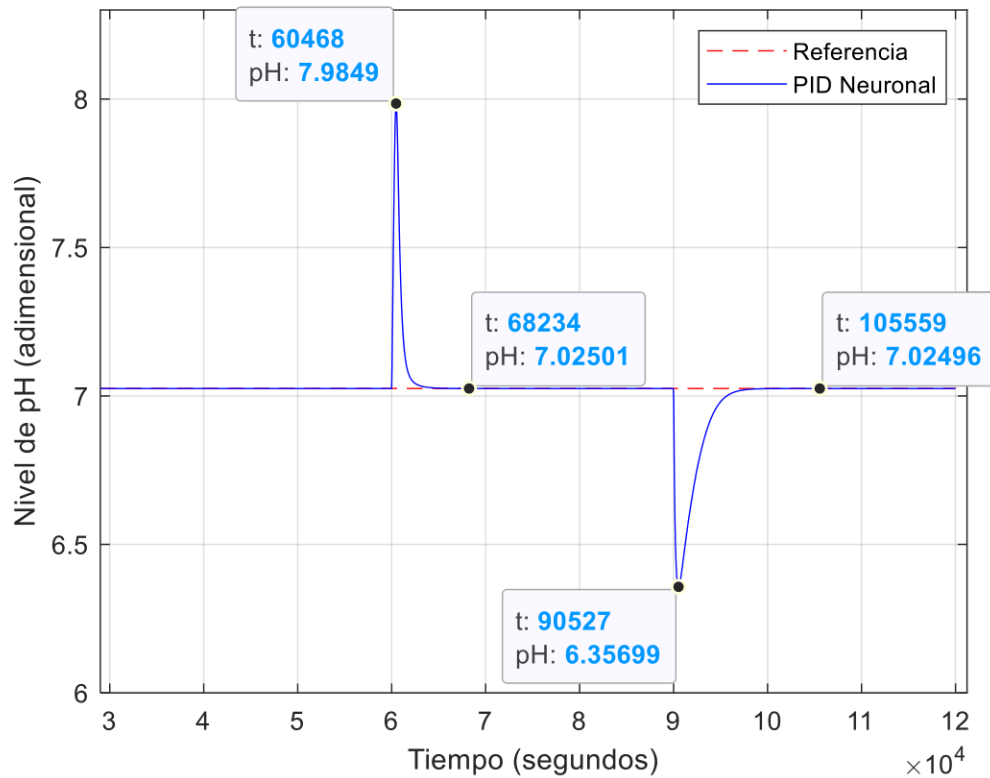


Figura 3.9 Respuesta del sistema con el controlador PID Neuronal (prueba de regulación).

En la Figura 3.9 se ve cómo reacciona el sistema ante las perturbaciones planteadas en la Figura 3.3 las cuales corresponden al flujo de corriente ácida $q_1(t)$, se observa que el sistema en la primera perturbación llega a tener un sobrepico del 13.59% y regresa al punto de operación inicial luego de 8234 [s]. En la segunda perturbación el sistema llega a tener un sobrepico del 9.15% y regresa al valor de operación deseado en 15559 [s] contado a partir del tiempo en el que se produjo la perturbación en el flujo de corriente ácida.

Como se puede ver en la Figura 3.7, Figura 3.8 y Figura 3.9 los valores de los tiempos de establecimiento en la prueba de seguimiento se reducen, pero por el contrario el valor de los sobrepicos incrementa, esto al contrastarlos con los resultados obtenidos con el controlador PID clásico. para la prueba de regulación se observa que tanto el tiempo de establecimiento como el valor de los sobrepicos disminuyen.

Por lo dicho anteriormente se puede decir que la red neuronal si logra ajustar los parámetros del PID que se toma como base para la creación del PID neuronal, pero en caso de querer mejorar la respuesta del sistema disminuyendo el valor de los sobrepicos se podría mejorar el valor de la constante integral K_i en el sistema de control teniendo precaución de no llevarlo a un funcionamiento inestable, en caso de que esto ocurra se

deberá mejorar también el valor de la constante derivativa K_d , esto teniendo en cuenta que entre más se incremente el valor de este parámetro más agresiva y mayor inercia tendrá la señal de control, provocando que ante cambios de referencia dicha señal tienda al infinito lo que hace que la carga computacional y el tiempo de procesamiento se incrementen. Para mitigar este efecto se hace necesario un sistema con mayor potencia computacional.

3.1.3 RESULTADOS DE LA PRUEBA DE SEGUIMIENTO Y REGULACIÓN DEL PID + RN




Figura 3.10 Respuesta del sistema con el controlador PID + RN (prueba de seguimiento con cambios de referencia ascendentes).

En la Figura 3.10 se observa que a pesar de que el controlador PID + RN es capaz de hacer que el sistema siga a la referencia propuesta en la Figura 3.1 este presenta sobrepicos bastante grandes, siendo con diferencia el que mayor sobrepico genera en la respuesta del sistema cuyo valor es 12.60% y se produce en el cambio de referencia de 7.15 pH a 7.3 pH, en cuanto a los tiempos de establecimiento se encuentran en el rango de 6600 [s] a 9166 [s] teniendo así un tiempo de establecimiento, el cual se encuentra entre los valores obtenidos con el PID clásico y el PID Neuronal.

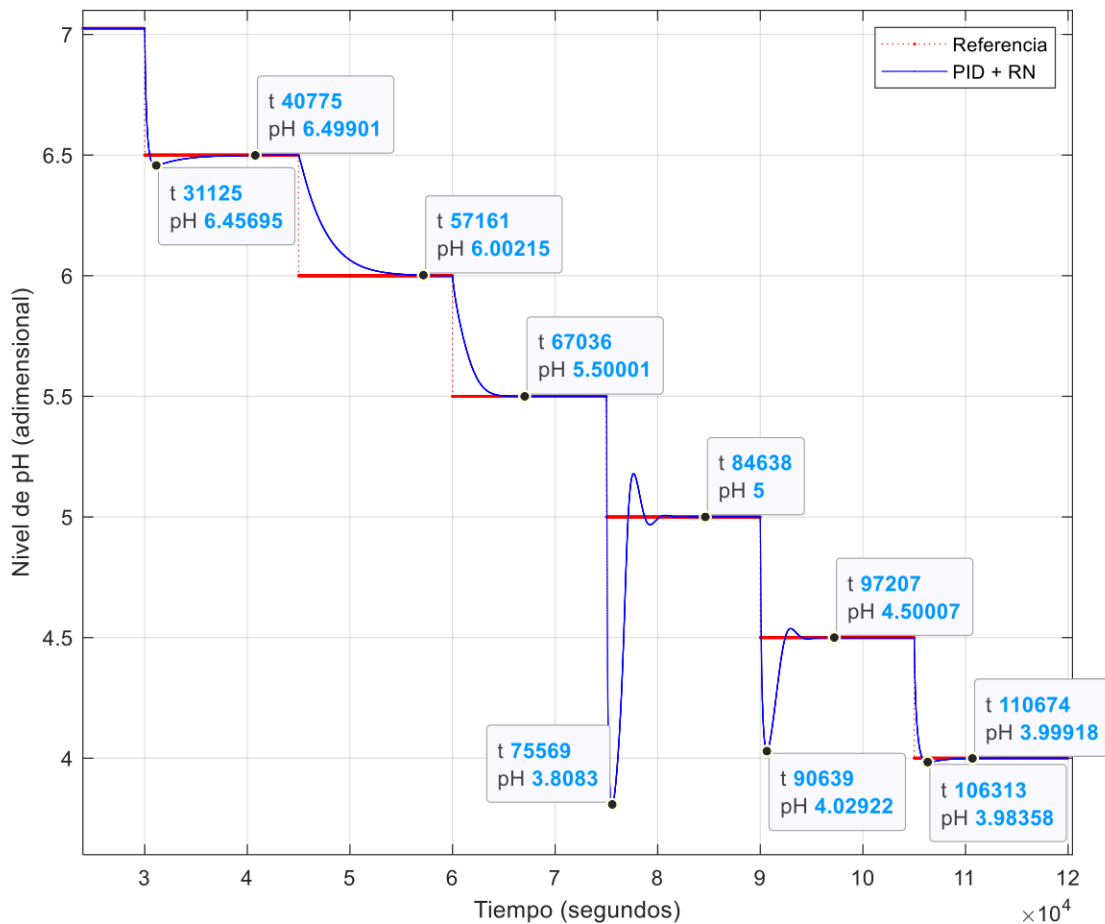


Figura 3.11 Respuesta del sistema con el controlador PID + RN (prueba de seguimiento con cambios de referencia descendentes).

En la Figura 3.11 se puede ver como el sistema de control al igual que el caso de las variaciones en la referencia ascendentes presenta sobrepicos de valor elevado en algunos cambios de referencia, siendo 24% el de mayor valor, el cual se presenta en el cambio de referencia de 5.5 pH a 5 pH, en este caso de los tiempos de establecimiento para los cambios de referencia planteados en la Figura 3.2 se sitúan entre los 5600 [s] a 12200 [s].




Figura 3.12 Respuesta del sistema con el controlador PID + RN (prueba de Regulación).

En la Figura 3.12 se ve cómo reacciona el sistema ante las perturbaciones planteadas en la Figura 3.3 las cuales corresponden al flujo de corriente ácida $q_1(t)$, se observa que el sistema en la primera perturbación llega a tener un sobrepico del 14.41% y regresa al punto de operación inicial luego de 9891 [s], en la segunda perturbación el sistema llega a tener un sobrepico del 9.67% y regresa al valor de operación deseado en 18148 [s] a partir del tiempo en el que se produjo la perturbación en el flujo de corriente ácida.

Como se puede ver en la Figura 3.10, Figura 3.11 y Figura 3.12 los valores de los tiempos de establecimiento en la prueba de seguimiento son menores, pero por el contrario el valor de los sobrepicos incrementa, esto al compararlos con los resultados obtenidos con el controlador PID clásico, mientras que los valores de los sobrepicos y de los tiempos de establecimiento son mayores que los del PID Neuronal. En la prueba de regulación tanto el tiempo de establecimiento como el valor de los sobrepicos se encuentran en un punto intermedio entre los resultados obtenidos con el esquema PID clásico y PID neuronal.

La principal problemática de este sistema de control son los sobrepicos que genera ante cambios de referencia ya que son de un valor bastante elevado, una opción para mitigar este problema es mejorar el valor de la constante integral K_i en el sistema de control teniendo precaución de no llevarlo a un funcionamiento inestable, en caso de que esto

ocurra se deberá mejorar también el valor de la constante derivativa K_d , en este caso hay que tener mucho más cuidado con el ajuste de estos parámetros que el que se tiene con el PID Neuronal ya que como se verá más adelante este sistema presenta una acción de control mucho más agresiva y sensible a los cambios de referencia.

3.1.4 COMPARACIÓN DE RESULTADOS ENTRE LOS TRES ESQUEMAS DE CONTROL

En esta sección se muestran los resultados anteriormente presentados unificados por tipo de prueba, esto para poder visualizar y comparar de mejor manera las respuestas del sistema con los distintos controladores diseñados en el presente trabajo de titulación.

Teniendo esto en cuenta, en la Figura 3.13 se muestran los resultados de los controladores sometidos a los cambios de referencia ascendentes donde se puede observar que el controlador PID + RN es el que genera un mayor sobrepico a la salida del sistema mientras que el de menor valor lo genera el PID clásico, en cuanto al tiempo de establecimiento, el que más rápido hace llegar al sistema a la referencia es el controlador PID Neuronal mientras que el que más se demora en hacerlo es el PID clásico.




Figura 3.13 Comparación de la respuesta del sistema con los esquemas de control propuestos (cambio de referencia ascendente).

En la Figura 3.14 se puede observar como el sistema reacciona ante cambios de referencia descendentes, donde una vez más la respuesta con sobrepicos más elevados es la que tiene el controlador PID + RN, también se observa que el controlador que lleva al sistema a la referencia deseada en menor tiempo es el PID neuronal y el que lo hace en mayor tiempo es el PID clásico, aunque esto cambia dependiendo de la referencia a la que se quiera hacer llegar al sistema, denotando así las características no lineales del sistema y las capacidades de adaptación de las redes neuronales a este tipo de sistemas y sus variaciones de comportamiento dinámico no lineal.




Figura 3.14 Comparación de la respuesta del sistema con los esquemas de control propuestos (cambio de referencia descendente).

En la Figura 3.15 se muestra cómo reacciona el sistema ante perturbaciones en el flujo de la corriente ácida generando así un sobre pico de valor similar para los 3 controladores, en cuanto al tiempo de establecimiento se observa que es menor para el sistema de control PID Neuronal y mayor para el PID Clásico, denotando así las limitaciones a las cuales está sujeto el PID clásico, ya que al no tener la capacidad de reajustar las constantes que lo conforman (K_p , K_i , K_d) no es capaz de adaptarse a las dinámicas variables del sistema no lineal.

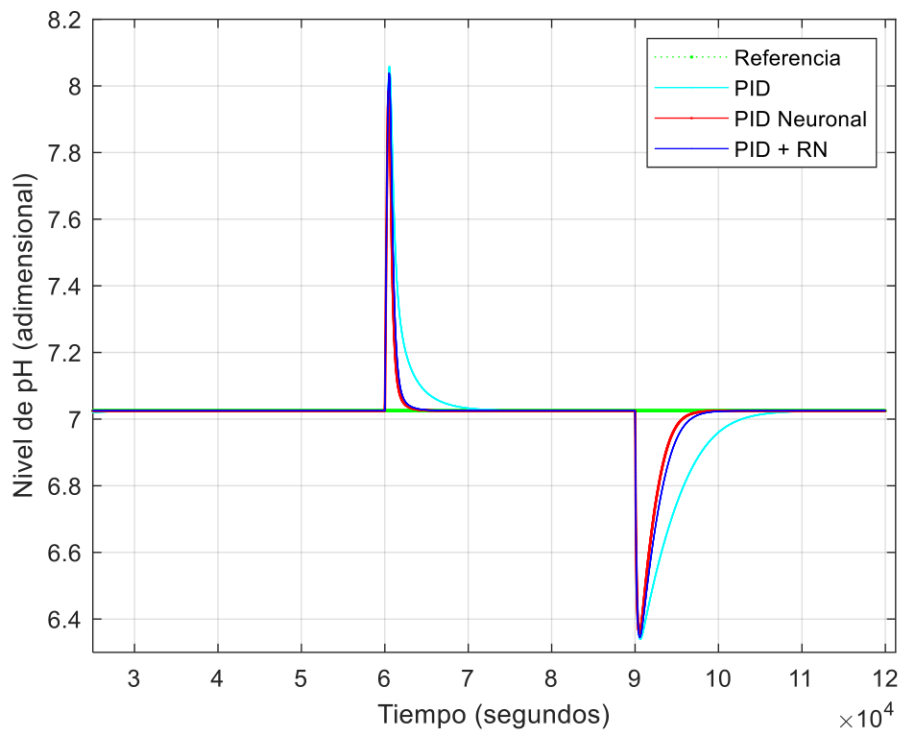


Figura 3.15 Comparación de la respuesta del sistema con los esquemas de control propuestos (perturbaciones en flujo de corriente ácida $q_1(t)$).

3.1.5 COMPARACIÓN DE LAS ACCIONES DE CONTROL GENERADAS POR LOS CONTROLADORES Y DE LOS ÍNDICES ISE Y TVU

En esta sección se va a comparar cuantitativamente el rendimiento de los controladores haciendo uso de los parámetros ISE y TVu, que como se había dicho anteriormente, toman en cuenta el error existente entre la señal de referencia y la salida del sistema; y también el esfuerzo que realizan los controladores para llevar al sistema a los valores de referencia deseados respectivamente.

En la Figura 3.16 se presenta la señal de control generada por cada esquema de control propuesto en este trabajo de titulación, se observa que ante los cambios de referencia ascendentes la acción de control más agresiva resulta ser la generada por el controlador PID + RN, razón por la cual este presenta un sobrepico de valor elevado, aun con esta condición se ve que es capaz de estabilizarse en un tiempo menor al del PID Clásico el cual cabe mencionar posee el tiempo de establecimiento más alto en todos los cambios de referencia, también se puede ver que conforme la referencia se aleja del punto de operación inicial del sistema el controlador comienza a presentar pequeñas oscilaciones las cuales si bien no son de valor elevado con el tiempo pueden llegar a ser perjudiciales

para el elemento de control ya que se estará activando continuamente hasta que las oscilaciones finalicen.

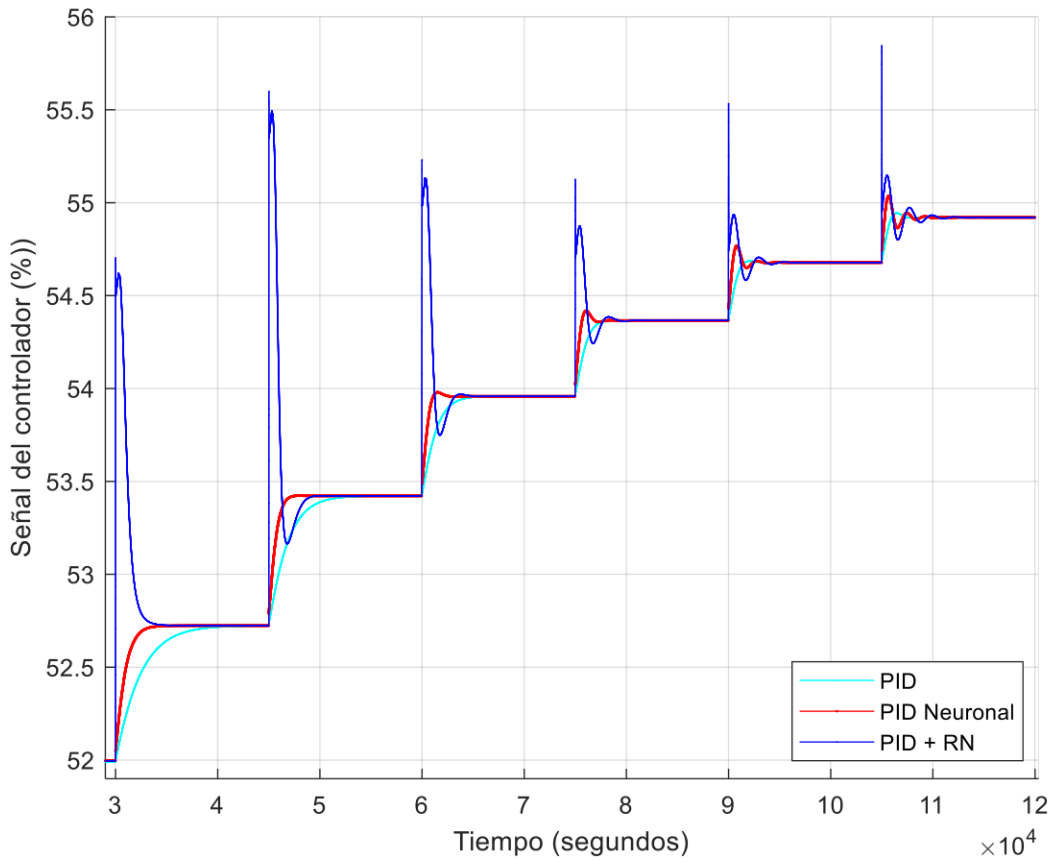


Figura 3.16 Señal de los controladores en la prueba de seguimiento con cambios de referencia ascendentes.




Figura 3.17 Comparación del índice ISE alcanzado por los esquemas de control.

En la Figura 3.17 se indican los valores del índice ISE alcanzado por los controladores donde se observa que el ISE de menor valor es el del controlador PID neuronal, el cual es aproximadamente 10 veces menor que el obtenido con el PID + RN y aproximadamente la mitad del alcanzado con el PID Clásico.

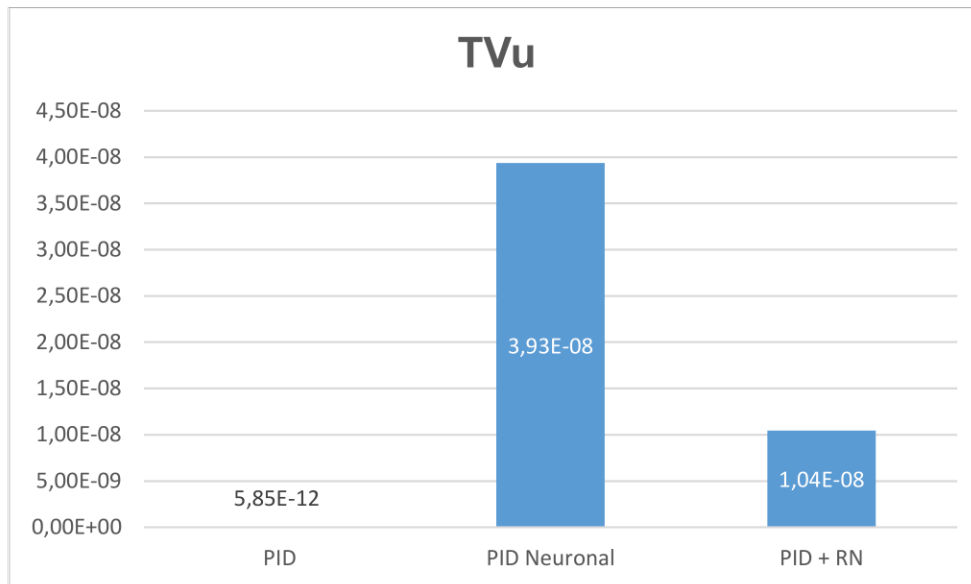


Figura 3.18 Comparación del índice TVu alcanzado por los esquemas de control.

En la Figura 3.18 se muestra el valor del índice TVu alcanzado por cada controlador donde se observa que el controlador PID Neuronal obtiene un mejor desempeño a costa de generar un esfuerzo mayor en el elemento final de control, en contraste a esto el PID Clásico es el que supondría un menor esfuerzo para dicho elemento, pero con la penalización de que sus tiempos de establecimiento son demasiado elevados.

En la Figura 3.19 se muestra la señal de control generada por cada esquema de control propuesto en este trabajo de titulación, se puede ver que ante cambios de referencia descendentes una vez más la acción de control más agresiva resulta ser la generada por el controlador PID + RN, aunque esto ya no es general para todas las variaciones de referencia propuesta para esta prueba, este comportamiento podría deberse a la característica de la función de activación presente en la red neuronal que genera la señal compensatoria añadida al PID Clásico dentro del esquema PID + RN, lo que causaría que la acción de control presente sobrepicos en ciertos puntos de operación del sistema, aun con esta condición se ve que es capaz de estabilizarse en un tiempo menor al del PID Clásico el cual cabe mencionar posee el tiempo de establecimiento más alto en todos los cambios de referencia, también se puede ver que conforme la referencia se aleja del punto de operación inicial del sistema los controladores comienzan a presentar pequeñas

oscilaciones que como se había dicho anteriormente con el tiempo pueden llegar a ser perjudiciales para el elemento de control.

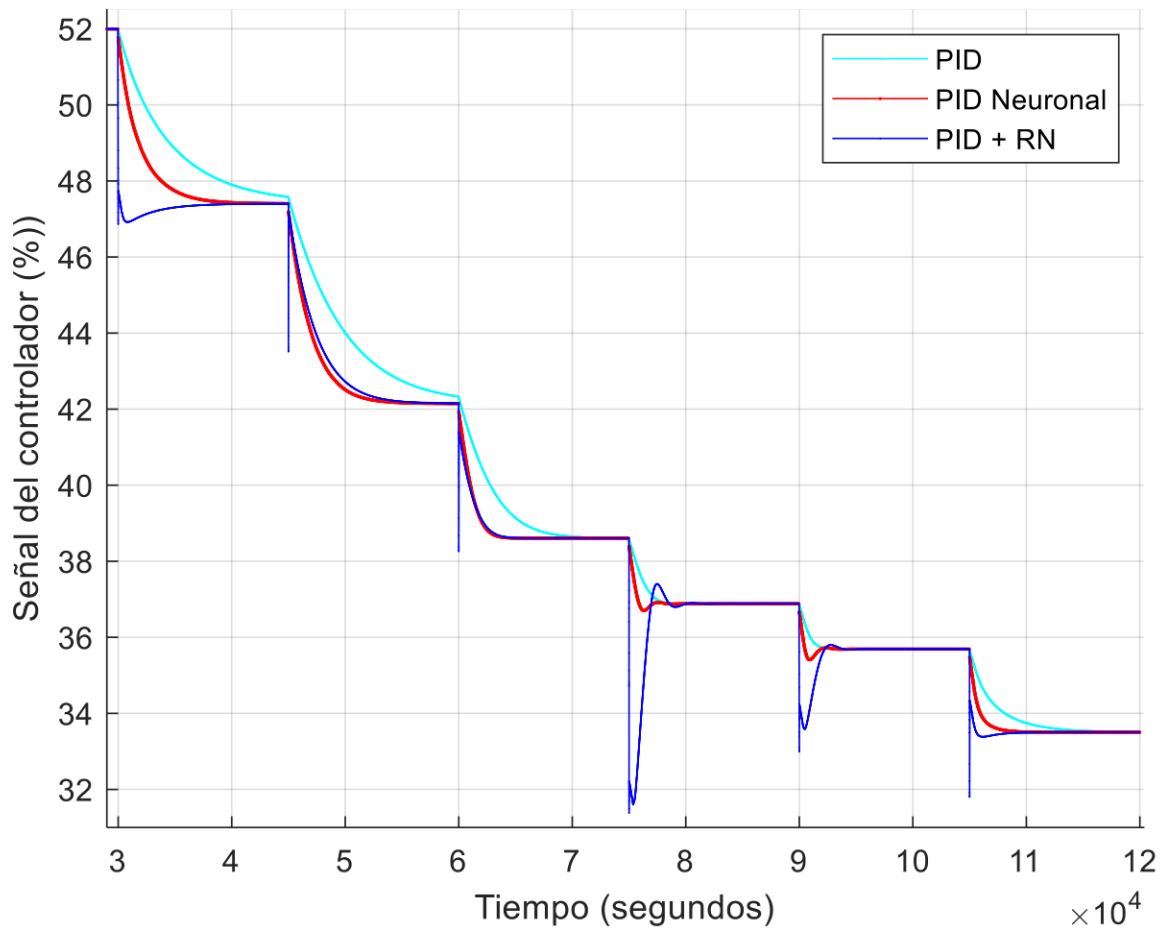


Figura 3.19 Señal de los controladores en la prueba de seguimiento con cambios de referencia descendentes.

En la Figura 3.20 se indican los valores del índice ISE alcanzado por los controladores donde se observa una vez más que el ISE de menor valor es el del controlador PID Neuronal, el cual tiene aproximadamente la mitad del valor de los índices por los otros controladores.




Figura 3.20 Comparación del índice ISE alcanzado por los esquemas de control.




Figura 3.21 Comparación del índice TVu alcanzado por los esquemas de control.

En la Figura 3.21 se muestra el valor del índice TVu alcanzado por cada controlador donde se observa que el controlador PID + RN tiene un menor valor con lo cual se puede decir que a pesar de generar sobrepicos de valor elevado, en conjunto en los diferentes cambios de referencia es el que menos esfuerzo genera al elemento final de control, en contraste a esto el PID Clásico es el que supondría un mayor esfuerzo para dicho elemento, además de penalizar en los tiempos de establecimiento los cuales son demasiado elevados.

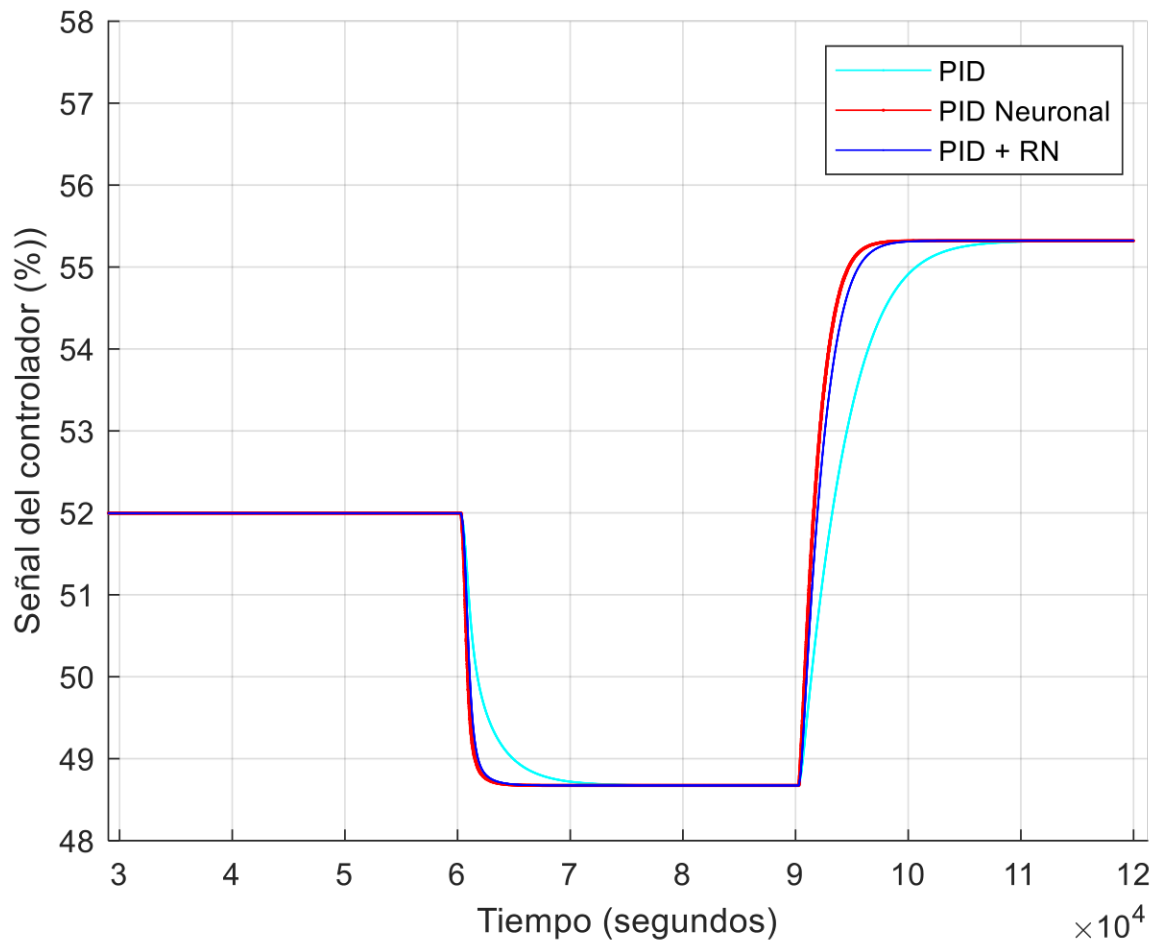


Figura 3.22 Señal de los controladores en la prueba regulación.

En la Figura 3.22 se muestra la señal de control generada por los controladores ante la prueba de regulación, se puede ver que ante perturbaciones el controlador que mejor reacción tiene es el controlador PID Neuronal, además se observa que ninguno de los controladores presenta sobrepicos lo que no denota un mayor esfuerzo por parte de los controladores para regresar al sistema al punto de operación deseado, además los tiempos de establecimiento para los controladores PID Neuronal y PID + RN son semejantes mientras que el del PID es el más elevado, cosa que se refleja en la respuesta del sistema.

En la Figura 3.23 se indican los valores del índice ISE alcanzado por los controladores donde se observa una vez más que el ISE de menor valor es el del controlador PID Neuronal.




Figura 3.23 Comparación del índice ISE alcanzado por los esquemas de control.

En la Figura 3.24 se muestra el valor del índice TVu alcanzado por los controladores ante las perturbaciones ingresadas al sistema, se observa que el controlador PID Neuronal tiene el menor valor de los tres, lo cual indica que es el mejor controlador para rechazar perturbaciones, en contraste a esto el PID Clásico penaliza una vez más en el tiempo de establecimiento ya que siguen siendo demasiado elevados en comparación a los obtenidos por los otros esquemas de control propuestos.

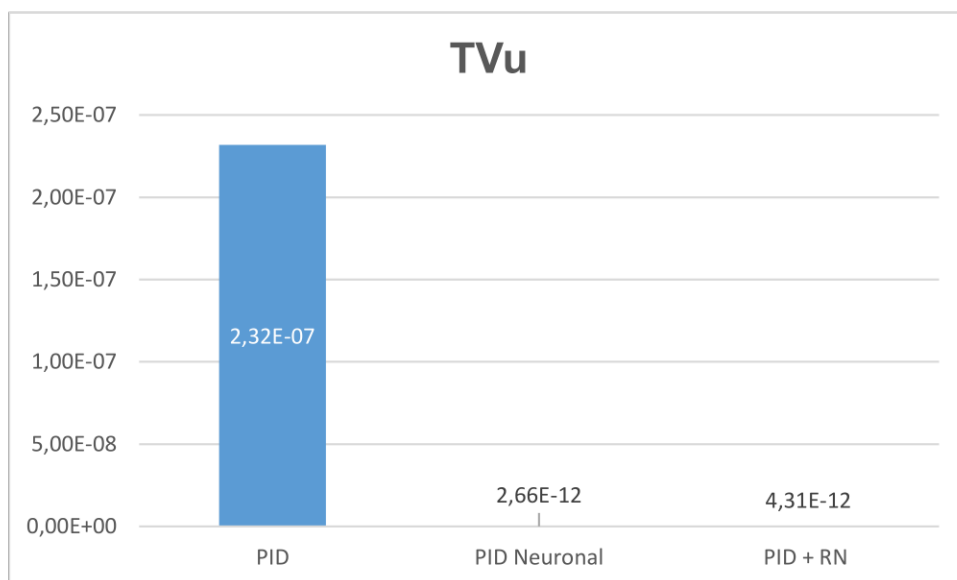


Figura 3.24 Comparación del índice TVu alcanzado por los esquemas de control.

Teniendo en cuenta los resultados anteriormente mostrados se puede concluir que para las tres pruebas propuestas el controlador con mejor rendimiento en general es el PID Neuronal, mientras que el PID + RN y el PID Clásico se comportan mejor dependiendo la

prueba a las que sean sometidos, teniendo así que en la prueba de seguimiento con variaciones de referencia ascendentes el PID Clásico presenta un mejor rendimiento que el PID + RN mientras que en las pruebas de seguimiento con variaciones de referencia descendentes y regulación ocurre lo contrario.

Por lo dicho anteriormente se puede decir Esto indica que este controlador es el que mejor se adapta a las características de funcionamiento variable propias del reactor de neutralización de pH que como se indicó en el capítulo 2 es un sistema no lineal ya que logra determinar la ley de control para llevar al sistema al punto de referencia en el que se desea trabajar.

3.2 CONCLUSIONES

- Haciendo uso del método de Smith y Corripio el cual se basa en la curva de reacción del sistema, se obtuvo los modelos FOPDT del sistema en distintos puntos de operación; al obtener dichos modelos se pudo ver que los parámetros de estos variaban según el punto de operación en el que eran calculados, denotando así el comportamiento no lineal del reactor de neutralización de pH. En base a los modelos obtenidos y haciendo uso de las ecuaciones para sintonización de PID de Dahlin se diseñó un controlador tipo PID Clásico para cada modelo obtenido cuyos parámetros fueron promediados y usados como base de desarrollo para los esquemas de control PID Neuronal y PID + RN escogidos en base al estudio bibliográfico realizado acerca de las redes neuronales aplicables a los sistemas de control cuyo objetivo era mejorar la respuesta de un controlador PID clásico ante los efectos inherentes a la dinámica no lineal del reactor de neutralización de pH.
- Se desarrollaron y simularon los esquemas de control propuestos en este trabajo de titulación aplicándolos al reactor de neutralización de pH haciendo uso del software de simulación Simulink de Matlab, se realizaron pruebas de regulación y seguimiento donde se pudo comprobar y comparar el funcionamiento de estos mediante los índices ISE y TVu.
- Con los valores de los índices ISE y TVu junto con el análisis de la respuesta del sistema se puede concluir que el esquema de control PID Neuronal es el que mejor desempeño tiene tanto en las pruebas de seguimiento como de regulación ya que es el que menor valor presenta en índices mencionados, además de que es el que más rápido logra llevar al sistema a la referencia deseada y en general es el que menor sobrepico presenta en los distintos puntos de operación propuestos en la señal de referencia, también se mostró que aunque el esquema PID Clásico presenta una señal de control más suave tarda mucho en estabilizar al sistema, esto comparándolo con los tiempos de establecimiento alcanzados por los otros esquemas de control.
- En cuanto al esquema PID + RN se puede concluir que, si bien es capaz de llevar al sistema a los puntos de operación deseados, presenta valores de sobrepico bastante elevados lo cual puede llegar a ser perjudicial para los elementos finales de control, cabe mencionar que este comportamiento solo está presente en la

prueba de seguimiento con variaciones ascendentes, en las otras pruebas el comportamiento de este esquema mejora, pero no llega a obtener los resultados del PID Neuronal. Por otra parte, los resultados obtenidos con el PID Clásico muestran que este no es capaz de adaptarse a la dinámica variable del sistema ya que pierde capacidad de llevar al sistema a los puntos de operación deseados conforme este cambia, lo cual concuerda con las características propias de un esquema de control tipo PID Clásico.

3.3 RECOMENDACIONES

- Los esquemas de control desarrollados en este trabajo de titulación se podrían aplicar a distintos sistemas de control donde se necesite tomar como base el funcionamiento o parámetros de un PID Clásico, tomando como referencia la metodología y resultados presentados en este trabajo de titulación.
- Los controladores desarrollados en este trabajo de titulación tienen características adaptativas lo cual los hace altamente recomendables para sistemas de dinámica variable.
- Para la implementación de este tipo de neuro controladores se debe tener en cuenta la gran carga computacional que estos generan en su funcionamiento, además de que es necesario que el procesador del sistema embebido en el que vaya a ser implementado deberá tener la capacidad de realizar procesamiento paralelo.

4 REFERENCIAS BIBLIOGRÁFICAS

- [1] H. Khalil, *Nonlinear Systems*, 2da ed. Estados Unidos de América: Prentice Hall, 1996.
- [2] E. C. Rodríguez, B. M. González, A. Juárez, and J. M. Arteaga, “Modelado de un Sistema de Control de pH,” p. 6, 2003.
- [3] J. E. Normey-Rico and E. F. Camacho, *Control of dead-time processes*. London: Springer, 2007.
- [4] E. Vázquez and T. Rojas, *pH: Teoría y 232 Problemas.pdf*, 1ra ed. México D.F.: UNIVERSIDAD AUTONOMA METROPOLITANA, 2016.
- [5] E. Anchitipan, “Diseño, simulación y comparación de esquemas de control adaptativo aplicados a plantas no lineales de parámetros variables y retardo de tiempo dominante,” Aug. 2020, Accessed: Aug. 10, 2021. [Online]. Available: <http://bibdigital.epn.edu.ec/handle/15000/21075>
- [6] E. Anchitipan and O. Camacho, “Processes with Variable Parameters and Dominant Time Delay: A Fuzzy Adaptive Control Approaches Comparison,” 2021, pp. 181–195. doi: 10.1007/978-3-030-72208-1_14.
- [7] O. Regalón, V. Rodríguez, M. Díez, and R. Báez, “Aplicación de algoritmos de control clásico, adaptable y robusto a sistemas dinámicos de parámetros variables,” *Ingeniería Energética*, vol. 33, no. 3, pp. 184–195, Dec. 2012.
- [8] K. Patiño, D. Chávez, and O. Camacho, “Application of Particle Swarm optimization for Tuning a Dynamic Sliding Mode Control for System With Inverse Response.,” in *2019 IEEE 4th Colombian Conference on Automatic Control (CCAC)*, Oct. 2019, pp. 1–6. doi: 10.1109/CCAC.2019.8921192.
- [9] J. D. R. Antolines, D. F. C. Quiroga, and M. Á. P. Pachón, “Implementación de neurocontroladores en línea: tres configuraciones, tres plantas,” *Ingeniería y universidad*, vol. 16, no. 1, pp. 163–182, 2012.
- [10] H. Cheng, Y. Zhang, L. Kong, and X. Meng, “The application of neural network PID controller to control the light gasoline etherification,” *IOP Conf. Ser.: Earth Environ. Sci.*, vol. 69, p. 012045, Jun. 2017, doi: 10.1088/1755-1315/69/1/012045.
- [11] A. Marino and F. Neri, “PID Tuning with Neural Networks,” 2019, pp. 476–487. doi: 10.1007/978-3-030-14799-0_41.
- [12] M. E. Salgado, J. I. Yuz, and R. A. Rojas, “ANA´LISIS DE SISTEMAS LINEALES,” *1era Edición Corregida*, p. 525, Aug. 2014.
- [13] C. A. Smith and A. B. Corripio, *Principles and practice of automatic process control*, 2nd ed. New York: J. Wiley, 1997.
- [14] I. O. Benítez-González and R. Rivas-Pérez, “Predictor de Smith: revisión y desafíos,” *Ingeniería Electrónica, Automática y Comunicaciones*, vol. 38, no. 1, pp. 33–47, Apr. 2017.
- [15] M. F. Golnaraghi, B. C. Kuo, and M. F. Golnaraghi, *Automatic control systems*, 9th ed. Hoboken, NJ: Wiley, 2010.

- [16] P. J. Fleming and R. C. Purshouse, "Evolutionary algorithms in control systems engineering: a survey," *Control Engineering Practice*, vol. 10, no. 11, pp. 1223–1241, Nov. 2002, doi: 10.1016/S0967-0661(02)00081-3.
- [17] L. F. Lozano-Valencia, L. F. Rodríguez-García, and D. Giraldo-Buitrago, "Diseño, implementación y validación de un controlador PID autosintonizado," *TecnoL.*, no. 28, p. 33, Jun. 2012, doi: 10.22430/22565337.12.
- [18] M. Kano and M. Ogawa, "The State of the Art in Advanced Chemical Process Control in Japan," *IFAC Proceedings Volumes*, vol. 42, no. 11, pp. 10–25, Jan. 2009, doi: 10.3182/20090712-4-TR-2008.00005.
- [19] M. Roman, *Control Digital, Teoría y Práctica 2Ed- Luis Eduardo García Jaimes.pdf*. Accessed: Jan. 05, 2022. [Online]. Available: https://www.academia.edu/35306915/Control_Digital_Teor%C3%ADa_y_Pr%C3%A1ctica_2Ed_Luis_Eduardo_Garc%C3%ADa_Jaimes_pdf
- [20] G. Zaidner, S. Korotkin, E. Shteimberg, A. Ellenbogen, M. Arad, and Y. Cohen, "Non linear PID and its application in process control," in *2010 IEEE 26-th Convention of Electrical and Electronics Engineers in Israel*, Nov. 2010, pp. 000574–000577. doi: 10.1109/EEEI.2010.5662155.
- [21] S. S. Haykin and S. S. Haykin, *Neural networks and learning machines*, 3rd ed. New York: Prentice Hall, 2009.
- [22] J. Vásquez, "La redes neuronales artificiales feedforward como identificadoras de asociaciones espurias entre caminatas aleatorias," 2008. <https://1library.co/document/lzgg1m7z-neuronales-artificiales-feedforward-identificadoras-asociaciones-espurias-caminatas-aleatorias.html> (accessed Jan. 07, 2022).
- [23] R. Sarkar, S. Julai, S. Hossain, W. T. Chong, and M. Rahman, "A Comparative Study of Activation Functions of NAR and NARX Neural Network for Long-Term Wind Speed Forecasting in Malaysia," *Mathematical Problems in Engineering*, vol. 2019, pp. 1–14, Mar. 2019, doi: 10.1155/2019/6403081.
- [24] K. W. Wang, C. Deng, J. P. Li, Y. Y. Zhang, X. Y. Li, and M. C. Wu, "Hybrid methodology for tuberculosis incidence time-series forecasting based on ARIMA and a NAR neural network," *Epidemiology & Infection*, vol. 145, no. 6, pp. 1118–1129, Apr. 2017, doi: 10.1017/S0950268816003216.
- [25] *Data Mining: Practical Machine Learning Tools and Techniques*. Elsevier, 2011. doi: 10.1016/C2009-0-19715-5.
- [26] C. K. Mishra, J. S. Jebakumar, and B. K. Mishra, "CONTROLLER SELECTION AND SENSITIVITY CHECK ON THE BASIS OF PERFORMANCE INDEX CALCULATION," vol. 2, no. 1, p. 3.
- [27] V. M. Alfaro and R. Vilanova, "Robust tuning of 2DoF five-parameter PID controllers for inverse response controlled processes," *Journal of Process Control*, vol. 23, no. 4, pp. 453–462, Apr. 2013, doi: 10.1016/j.jprocont.2013.01.005.

5 ANEXOS

El contenido de este capítulo se encuentra disponible en el tomo II.