

**UNIVERSIDAD SAN FRANCISCO DE QUITO USFQ**

**Colegio de Ciencias e Ingenierías**

**Desarrollo de un Controlador Adaptativo Neuro-Fuzzy PID: Una  
Validación Experimental**

**Gabriel Eduardo Salazar Navarrete**

**Ingeniería en Electrónica y Automatización**

Trabajo de fin de carrera presentado como requisito  
para la obtención del título de  
Ingeniero en Electrónica

Quito, 13 de mayo de 2022

**UNIVERSIDAD SAN FRANCISCO DE QUITO USFQ**

**Colegio de Ciencias e Ingenierías**

**HOJA DE CALIFICACIÓN  
DE TRABAJO DE FIN DE CARRERA**

**Desarrollo de un Controlador Adaptativo Neuro-Fuzzy PID: Una  
Validación Experimental**

**Gabriel Eduardo Salazar Navarrete**

**Nombre del profesor, Título académico**

**Oscar Camacho, Ph.D.**

Quito, 13 de mayo de 2022

## © DERECHOS DE AUTOR

Por medio del presente documento certifico que he leído todas las Políticas y Manuales de la Universidad San Francisco de Quito USFQ, incluyendo la Política de Propiedad Intelectual USFQ, y estoy de acuerdo con su contenido, por lo que los derechos de propiedad intelectual del presente trabajo quedan sujetos a lo dispuesto en esas Políticas.

Asimismo, autorizo a la USFQ para que realice la digitalización y publicación de este trabajo en el repositorio virtual, de conformidad a lo dispuesto en la Ley Orgánica de Educación Superior del Ecuador.

Nombres y apellidos: Gabriel Eduardo Salazar Navarrete

Código: 00201363

Cédula de identidad: 1718365115

Lugar y fecha: Quito, 13 de mayo de 2022

## **ACLARACIÓN PARA PUBLICACIÓN**

**Nota:** El presente trabajo, en su totalidad o cualquiera de sus partes, no debe ser considerado como una publicación, incluso a pesar de estar disponible sin restricciones a través de un repositorio institucional. Esta declaración se alinea con las prácticas y recomendaciones presentadas por el Committee on Publication Ethics COPE descritas por Barbour et al. (2017) Discussion document on best practice for issues around theses publishing, disponible en <http://bit.ly/COPETHeses>.

## **UNPUBLISHED DOCUMENT**

**Note:** The following capstone project is available through Universidad San Francisco de Quito USFQ institutional repository. Nonetheless, this project – in whole or in part – should not be considered a publication. This statement follows the recommendations presented by the Committee on Publication Ethics COPE described by Barbour et al. (2017) Discussion document on best practice for issues around theses publishing available on <http://bit.ly/COPETHeses>.

## RESUMEN

Aplicación de control automático basado en redes neuronales para modelado de sistema, mediante un aprendizaje supervisado que pueda definir el desgaste y perturbaciones de un sistema de calentamiento físico (TCLab). Mediante el error de modelado se adapta la sintonización de un PID. La adaptación de la sintonización está hecha mediante lógica difusa.

Principalmente, en base a los experimentos realizados sobre el dispositivo nos demuestran que se pueden distinguir claros efectos sobre la implementación en comparación con un PID normal, se tiene un tiempo de estabilización más bajo y un mayor rechazo a las perturbaciones.

**Palabras clave:** Control Automático, Control difuso, adaptativo, redes neuronales, NARX, neuro-fuzzy, adaptive neuro-fuzzy.

## ABSTRACT

Automatic control application based on neural networks for system modelling, through supervised learning so that the wear and disturbances could be defined in a physical heating system (TCLab). Through the modelling error the sintonization of a PID controller is adapted. The adaptation of the sintonization is made through fuzzy logic.

Principally the effects of this implementation compared to a typical PID controller are easily noticeable, the settling time is lower and there is a better disturbance rejection.

**Key words:** Automatic Control, Fuzzy Control, adaptive, neural networks, NARX, neuro-fuzzy, adaptive neuro-fuzzy.

**TABLA DE CONTENIDO**

<b>Introducción .....</b>	<b>10</b>
<b>Control automático .....</b>	<b>10</b>
<b>Lógica difusa.....</b>	<b>16</b>
<b>Control difuso.....</b>	<b>17</b>
<b>Redes neuronales.....</b>	<b>18</b>
Red narx.....	18
<b>Control adaptativo .....</b>	<b>19</b>
<b>Temperature Control Lab.....</b>	<b>21</b>
<b>Desarrollo del Tema.....</b>	<b>23</b>
<b>Identificación y arquitectura de la red.....</b>	<b>24</b>
<b>Adaptación difusa .....</b>	<b>26</b>
<b>Resultados.....</b>	<b>27</b>
<b>Conclusiones .....</b>	<b>32</b>
<b>Referencias bibliográficas .....</b>	<b>33</b>
<b>Anexo A: ARCHIVOS UTILIZADOS.....</b>	<b>35</b>

## ÍNDICE DE TABLAS

Tabla 1: Parámetros de Sintonización por Z&N.....	14
Tabla 2: Parámetros de Sintonización por Dahlin .....	15
Tabla 3: Reglas de lógica de sintonización automática difusa .....	26



## ÍNDICE DE FIGURAS

Figura 1: Modelo Propuesto.....	11
Figura 2: Controlador PID de parámetros constantes .....	15
Figura 3: Topología de la Red NARX .....	19
Figura 4: Modelo propuesto implementado en Simulink .....	23
Figura 5: Datos para entrenamiento de la Red Neuronal .....	24
Figura 6: Prueba de la Red Neuronal para un cambio de referencia aleatorio .....	25
Figura 7: Respuesta a cambio de referencia .....	28
Figura 8: Respuesta a cambio de referencia con desgaste simulado .....	28
Figura 9: ISE para condiciones nominales.....	29
Figura 10: Respuesta a perturbaciones .....	29
Figura 11: Respuesta a perturbaciones con desgaste simulado .....	30
Figura 12: ISE con desgaste simulado .....	30

## INTRODUCCIÓN

El presente trabajo comienza con una introducción a cada uno de los conceptos y principios que se utilizan en la implementación física. Se comienza con una breve introducción histórica de control automático, una descripción de la solución propuesta, continuada por las secciones de definición de los conceptos dentro del área de control. Posteriormente, tenemos los métodos de identificación más conocidos para realizar la sintonización de controladores por diferentes estrategias. Se sigue explicando los conceptos primarios dentro de la lógica y control difuso, redes neuronales, la topología de red utilizada en la identificación y finalmente una descripción del sistema físico en el que se implementa el controlador.

Dentro de la sección de desarrollo se describe el papel que juega cada uno de los conceptos explicados en la introducción dentro del esquema propuesto, los resultados de la implementación y los datos para realizar la comparación.

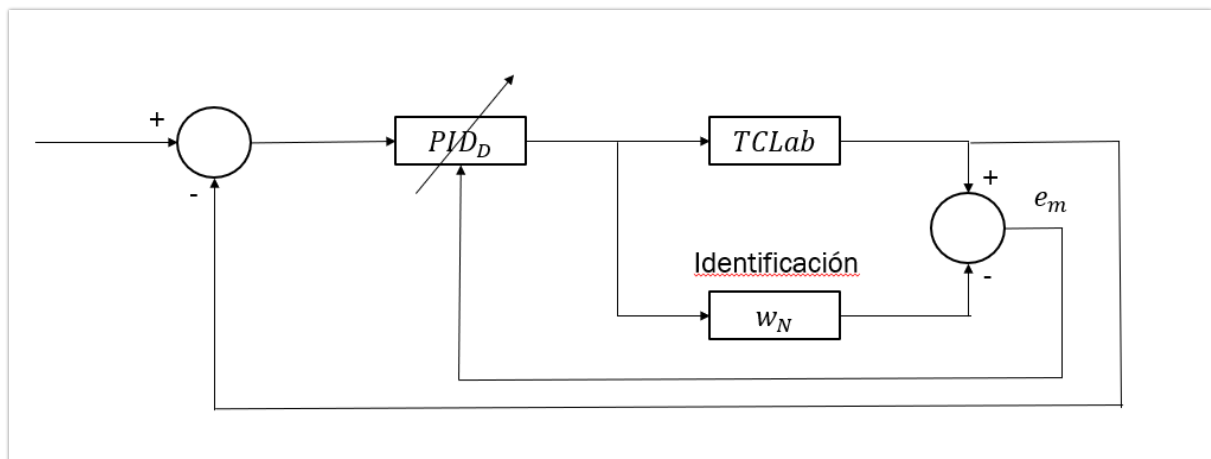
Finalmente, en las conclusiones se analizan los resultados obtenidos y se describen parámetros que pueden darnos una mejor respuesta en el esquema.

### **Control automático**

El control automático se basa en estrategias de manipulación de sistemas para que estos sean estables en el tiempo, aunque existan variaciones externas. La retroalimentación es uno de los principales conceptos por los cuales se puede realizar un esquema de control. Al momento que tenemos una referencia y una respuesta del sistema podemos ver un error entre lo que se desea y lo que se obtiene. Bajo esta premisa, el ser humano ha creado sistemas de control con retroalimentación desde 300 a.C. hasta el 1200 d.C., como un primer periodo en el que los árabes y helenos utilizaban válvulas flotantes reguladoras para medir tiempos con precisión (Siddique, 2014).

Esto ha ido evolucionando con los años, y ahora tenemos varias técnicas de control, unas más complejas que otras y que funcionan en diferentes magnitudes para diferentes sistemas a controlar.

Los problemas dentro del control automático radican en los modelos que se comportan de manera no lineal. Estos procesos hacen que los métodos de compensación de controladores sean específicos a un punto de operación de una planta o a la linealización de los mismos. La linealización y la operación en un punto de operación generan limitaciones, por lo que una propuesta adaptativa es deseada. En el presente trabajo vamos a desarrollar un esquema de control adaptativo basado en redes neuronales y control de lógica difusa con el siguiente esquemático teórico.



*Figura 1: Modelo Propuesto*

Donde:

- $PID_D$  es el controlador PID Adaptativo Neuro-Fuzzy.
- TCLab es la Planta que vamos a controlar.
- $w_N$  es la Red Neuronal encargada de la identificación del modelo.
- $e_m$  es el error de modelado.

Mediante la identificación de la Planta adaptamos los parámetros de un PID mediante lógica difusa para mantener la dinámica de la planta.

Los aportes de esta investigación se pueden resumir de la siguiente manera:

- Identificación del modelo mediante redes neuronales.
- Uso del error de modelado para realizar sintonización automática difusa de un controlador PID.
- Implementación del esquema de control en un sistema físico de calentamiento.

Cabe recalcar que dentro de la investigación del estado del arte, no se encontró un esquema similar, por lo que el alcance del presente estudio en cuanto a la aplicación es innovador en el sentido de que la sintonización automática corrige errores debido a desgaste al igual que un rechazo a perturbaciones dinámico.

Se explican los conceptos fundamentales para entender la aplicación propuesta, junto con la manera general en las que se aplican. Posteriormente se verá cómo cada concepto se utiliza dentro de la aplicación final.

Se llama Planta a cualquier sistema de entradas y salidas que realice un proceso. En este caso llamamos Planta al sistema que vamos a controlar.

En definitiva, el objetivo de un sistema de control automático es tomar la señal de referencia, compararla con la señal de salida y producir una señal en la entrada del sistema para compensar el error. El controlador es la estructura que se encarga de tomar los datos de la salida, los compara con la referencia y produce una señal de compensación. Existen varios tipos de controladores, y dependiendo de la planta se puede utilizar un esquema de control más específico. En las industrias, el esquema de control más común es un Proporcional, Integral y Derivativo, mejor conocido como un PID (Camacho, Rosales, & Rivas, 2020). Este controlador

toma la señal de error entre la salida y la entrada, y bajo ponderaciones de este error se genera una señal de salida para compensar y mantenerla lo más cercano posible a la entrada. Estos parámetros de ajuste son ganancias proporcionales, integrales y derivativas.

Existen varias maneras de tomar estos parámetros, y la decisión o cálculo de los mismos ya sea por prueba y error o fórmulas se llama sintonización (Camacho, Rosales, & Rivas, 2020). Esta sintonización en la mayoría de los casos es estática, se toman los parámetros gracias a la respuesta de la planta, se definen las especificaciones y limitaciones para no dañarla y con esto se realiza la sintonización.

Los métodos más comunes de sintonización son los definidos por Ziegler & Nichols y Dahlin (Camacho, Rosales, & Rivas, 2020). Estos son métodos a lazo abierto, esto quiere decir que no existe una retroalimentación considerada en el sistema, previa a la sintonización. El primer paso para realizar este proceso es obtener los parámetros del sistema. Estos parámetros dependen de la respuesta de la planta frente a un cambio en la entrada. En la industria, la mayoría de procesos (especialmente los procesos químicos) se pueden caracterizar como modelos de Primer Orden Más Tiempo Muerto (POMTM) o por sus siglas en inglés FOPDT (First Order Plus Dead Time). Como es un modelo de primer orden tenemos un polo, una ganancia y un retardo temporal. La ganancia del sistema es el cambio de la salida en relación a la entrada. El polo viene determinado por la constante de tiempo del sistema. Esta constante de tiempo es un parámetro por el cual podemos determinar la “velocidad” del sistema, es decir, que tanto se demora en estabilizarse a su estado estacionario. Y el tiempo muerto es el tiempo que le toma al sistema en generar la respuesta desde que se realiza el cambio en la entrada (Camacho, Rosales, & Rivas, Control de Procesos, 2020).

$$K = \frac{\Delta Salida}{\Delta Entrada}$$

$$\tau = 1.5 \times (t_2 - t_1)$$

$$t_0 = t_2 - \tau$$

Donde los parámetros  $t_2$  y  $t_1$  corresponden a los tiempos en los que, para la variación de entrada, la salida llega al 63.2 % y al 28.3 % del valor de estado estable de la misma, correspondientemente.

La caracterización de sistemas por este método es utilizada para varias aplicaciones de modelos no lineales y es una gran aproximación para realizar la sintonización de controladores PID. Con esta aproximación se puede sintonizar el PID de la siguiente manera, con estos métodos propuestos.

*Tabla 1: Parámetros de Sintonización por Z&N*

Parámetros de Sintonización usando el método de Ziegler & Nichols		
Controlador	Parámetro de Ajuste	Ecuación
PID	$K_p$	$\frac{1.2}{K} \left( \frac{\tau}{t_0} \right)$
	$\tau_i$	$2 \times t_0$
	$\tau_d$	$\frac{t_0}{2}$

(Camacho, Rosales, & Rivas, Control de Procesos, 2020, pág. 108)

Tabla 2: Parámetros de Sintonización por Dahlin

Parámetros de Sintonización usando el método de Dahlin		
Controlador	Parámetro de Ajuste	Ecuación
PID	$K_p$	$\frac{1}{2K} \left( \frac{\tau}{t_0} \right)$
	$\tau_i$	$\tau$
	$\tau_d$	$\frac{t_0}{2}$

(Camacho, Rosales, & Rivas, Control de Procesos, 2020, p. 109)

Para realizar la comparación, obtener el error y cerrar el lazo para hacer la sintonización se debe seguir un modelo estándar como es el siguiente.




Figura 2: Controlador PID de parámetros constantes

Donde:

- $V_\alpha(s)$  es la referencia.
- $e(s)$  es la señal de error.
- $m(s)$  es la señal del controlador.
- $y(s)$  es la señal de salida de la planta.
- $o(s)$  es la señal de retroalimentación.
- $d(s)$  es la perturbación en el sistema.

- $c(s)$  es la salida de la planta con perturbaciones.

Esta estructura principal puede ser vista como un controlador que puede contener uno o más subsistemas donde se realiza el control y puede ser simple o incrementar en dificultad dependiendo de los resultados que se busquen.

### **Lógica difusa**

La mayoría de sistemas de decisión o de lógica matemática se basan en la lógica binaria. Esto se refiere a que existen proposiciones lógicas donde la entrada corresponde a sentencias o datos que únicamente pueden tomar valores de Verdadero o Falso, Alto o Bajo, Uno o Cero, entre otros. Esta lógica ha sido base para construir los dispositivos de sistemas digitales y programables más complejos y que utilizamos en la realidad (Camacho, Iglesias, Herrera, & Aboukheir, 2021).

Adicionalmente existe otra serie de reglas y lógica matemática que puede definir a la realidad de una manera más continua y real, esta siendo la lógica difusa. Cuando tenemos valores que no pueden ser caracterizados binariamente, podemos comenzar a definir rangos donde la operación puede ser descrita mediante otras variables. Un ejemplo puede ser la temperatura; algo puede ser caracterizado como caliente, frío o tibio, pero esto es un parámetro subjetivo en cuanto el encargado de realizar el juicio es el que decide. En definitiva, los rangos de temperatura deben definirse para que, dentro del universo de opciones de temperatura, podamos determinar que es frío, tibio o caliente.

Para nosotros definir estas opciones necesitamos generar rangos de operación en los cuales la variable toma valores que pertenecen a una semántica. Siguiendo el ejemplo de la temperatura, podríamos definir que en un rango de 0 °C a 100 °C en el que frío esta de 0 °C a 15 °C, tibio de 15 °C a 85 °C y caliente de 85 °C a 100 °C. Este es el primer diseño de las funciones de membresía.



Las funciones de membresía o MFs por sus siglas en inglés son funciones que determinan el grado de pertenencia de un número en un rango a una variable semántica. Es la base por la cual se puede hacer la lógica difusa. Las funciones pueden tener diferentes formas, siendo las más populares las funciones triangulares, gaussianas o trapezoidales. Existen también las sigmoidales y polinomiales.

En la literatura (M. Ali, Ali, & Sumait, 2015) se puede ver que la decisión sobre qué tipo de MF utilizar depende únicamente de la matemática involucrada. Si tenemos funciones simples, el tiempo de procesamiento será menor al tiempo de procesamiento de una función más compleja, mientras que los resultados de utilizar una MF u otra no influyen en la construcción final del sistema lógico involucrado. Pero a su vez, se puede ver que las funciones de membresía triangulares dan una mejor respuesta en sistemas de control.

### **Control difuso**

Ya teniendo estas nociones de MFs, se generan reglas para el control y toma de decisiones. Ya que estamos hablando de un sistema retroalimentado, tenemos datos del error. El error puede ser grande o pequeño, positivo o negativo y esto nos da información sobre la señal que debe dar el controlador a la salida para compensar y llegar a la referencia. Una vez que tenemos valores estimados de los parámetros del PID, podemos empezar con los mismos para construir un PID difuso.

El PID difuso necesita reglas para que las relaciones entre error y derivada de error se traduzcan en una acción de control que compense las perturbaciones. Lógicamente hablando, en cualquier sistema, si el error es alto y positivo quiere decir que la referencia se movió a un valor más alto, por lo que la entrada al sistema, en el caso de que este tenga una acción directa, tiene que ser alta para llegar a la referencia. Con esta lógica construimos un conjunto de reglas que se encargan de hacer el control de la planta.

Cuando estas reglas son definidas, junto con las MFs, lo que nos queda es definir los métodos de Fusificación y Defusificación. Estos métodos son los encargados de tomar un número de una variable de entrada, asignar el grado de pertenencia en las funciones de membresía, realizar la lógica de las reglas establecidas y asignar un valor numérico a la salida en base a los métodos y reglas definidas.

### **Redes neuronales**

Dentro de la rama de la Inteligencia Artificial tenemos a las Redes Neuronales; estas se conciben como una red artificial que se asemeja en funcionamiento a las conexiones cerebrales de impulsos eléctricos que sirven para tomar decisiones en base a estímulos. Estas funcionan mediante una serie de multiplicaciones matriciales donde los datos de entrada tienen que parecerse a los datos de salida, a una clasificación o un valor definido. Al momento en el que tenemos datos de entrada y sus correspondientes datos de salida hablamos de que la red va a ser entrenada bajo supervisión y el entrenamiento consiste en ver una estructura matricial de funciones lineales y no lineales que procesan los datos de entrada y mediante ponderaciones, minimizar una función de coste que se transforme en un sistema robusto que actúe según este aprendizaje.

Técnicamente una Red Neuronal puede hacer todo, sus aplicaciones a sistemas de control, clasificación, predicción y otros, son infinitas. Pero en este trabajo usamos una red neuronal para la identificación del sistema a controlar. Por lo que necesitamos una topología de red neuronal que tenga en cuenta parámetros temporales, que considere la salida como otra entrada y que pueda considerarse como un sistema SISO.

#### **Red narx.**

Entre las redes neuronales que se basan en series de tiempo, para considerar parámetros temporales, y que permiten considerar el estado de la salida para la entrada tenemos las redes

no lineales autorregresivas con entradas exógenas, mejor conocidas como redes NARX (Xie, Tang, & Liao, 2009).

Esta topología de red recurrente es utilizada para identificación de sistemas y se encarga bastante bien del manejo del ruido en el sistema. Consta de una línea de retardos a la entrada donde se almacenan los valores temporales que se utilizan como regresores, que junto con las capas ocultas captan la no-linealidad del sistema.




Figura 3: Topología de la Red NARX

### Control adaptativo

Muchos de los sistemas de control se basan en sintonizar controladores con parámetros constantes, esto define una dinámica que se mantendrá controlando el sistema. Pero si realizamos una autosintonía adaptativa dependiendo del error, podemos realizar un control con una mejor respuesta y rechazo a perturbaciones. Esto funciona gracias a tomar una decisión con base en el error y mediante una estructura adaptar los parámetros del controlador para rechazar la perturbación y devolverlos a la sintonización inicial cuando llegemos a un estado estable. Se refiere a una aplicación en la que la sintonización es automática. Esto nos ayuda en varios ámbitos. Energético, para no utilizar potencia innecesaria en amplificadores, solo

cuando se necesite; mejor respuesta, para tener una mayor robustez en el diseño de controladores; rechazo dinámico, para que las perturbaciones se corrijan lo más pronto posible.

Existen varios esquemas de control adaptativo, estos difieren principalmente en cómo se ajustan los parámetros del controlador. Los tres más populares son control adaptativo programado, control adaptativo por modelo de referencia y controlador auto sintonizado.

El control programado resulta de tener conocimiento previo de los cambios del sistema y programar el cambio de los parámetros. Este tipo de control adaptativo se conoce también como ganancia programada. En la práctica esto se reduce a una *look-up table* donde se programan los cambios y las ganancias correspondientes.

El control por modelo de referencia (MRAC) se basa en un modelo de cómo el proceso debería responder a un cambio de referencia. Puede ser simple, como una trayectoria de referencia o puede ser un modelo de lazo cerrado más detallado. El error de modelado es el que se encarga de adaptar los parámetros mediante un algoritmo de optimización.

Por último, está el control auto sintonizado. Este método de control se basa en tomar los datos de entrada y salida de la planta y estimar recursivamente de un modelo de proceso aproximado. Un cambio no lineal del proceso produce un modelo lineal aproximado que puede utilizarse para adaptar los parámetros de un PID o un controlador basado en modelo (Ogunnaike & Ray, 1994).

Para el presente trabajo se utiliza un control MRAC en principio. Ya que el modelado de la planta será hecho mediante una red neuronal y el error de modelado es el que adapta los parámetros de un PID mediante lógica difusa.

## Temperature Control Lab

El TCLab es un circuito impreso (PCB) que se conecta a un micro controlador Arduino. Tiene 2 transistores como calentadores y 2 termistores sensores de temperatura. El proceso se puede caracterizar con dinámicas de segundo orden y como son adyacentes se crea un sistema compacto multivariable. Los transistores calentadores son TIP31C BJT NPN. Estos transistores se utilizan comúnmente en audio, potencia y conmutación. Pero al momento de hacer el diseño se descubrió que podían ser utilizados como calentadores y como conmutadores PWM. De esta manera y para abaratar costos se utiliza el mismo. Los sensores de temperatura son termistores TMP36GZ estándar. Tienen una salida linealmente proporcional y no requieren calibración.

Este dispositivo es ideal en aplicaciones de control por temperatura ya que es compacto y económico. Para realizar control de un modelo no lineal es prácticamente una planta completa que nos brinda resultados reales dentro de un dispositivo pequeño (Park, Martin, Kelly, & Hedengren, 2020).

Considerando los conceptos anteriores definiremos un control adaptativo mediante lógica difusa con base al error producido entre la planta y el modelo de redes neuronales correspondiente a la planta. Dentro del contexto nacional, existen fábricas cuya automatización es importante, y el desgaste dentro de la industria es un problema real. En la manera que la producción se ve afectada en el caso de que algún proceso no funcione o cambie dentro del tiempo. Un ejemplo práctico en el que se podría aplicar este esquema de manera industrial es en las cámaras de fermentación que existen en las panificadoras industriales. Al momento en el que la masa tiene que realizar el leudado, se necesita una humedad y temperatura específica para el crecimiento del pan. Cuando existe un desgaste de los elementos, se necesita subir la temperatura manualmente para que se mantenga la producción normal y la dinámica del sistema cambia. En el caso de cambiar la receta, se necesita adaptar los parámetros y la

dinámica es importante para mantener los tiempos de producción, por lo que una implementación adaptativa que mantenga la dinámica del sistema es importante.

## DESARROLLO DEL TEMA

Si tenemos un modelo que se comporte igual a la planta, (condiciones iniciales) podemos ver como las perturbaciones o el deterioro de la planta provocan un error de desempeño. Este error puede servir de indicador de varios parámetros de la planta. En principio si tenemos un error constante podríamos determinar un cambio en la ganancia permanente de la planta, que indicaría un deterioro y un fallo en cuanto a la misma. Si la función de transferencia de la planta cambia, tendríamos que hacer una nueva sintonización del controlador para mantener la dinámica del sistema, por lo que, si podemos realizar la sintonización automáticamente considerando este deterioro, no necesitamos volver a sintonizar el controlador.

Para esto proponemos un modelo que, mediante el error de modelado, entre una red neuronal que imite el proceso, se pueda accionar un control de lógica difusa que adapte las señales  $K_p$ ,  $K_i$ , y  $K_d$  de un controlador PID. Bajo este funcionamiento nombramos un controlador Adaptative-NeuroFuzzy PID (ANFPID).





Figura 4: Modelo propuesto implementado en Simulink

El modelo está configurado en MATLAB, como se puede ver, el error de modelado viene de la diferencia entre el resultado entre la Planta y la Red Neuronal. El error de modelado entra al controlador difuso que adapta los parámetros del PID sintonizado por Dahlin.

## Identificación y arquitectura de la red

El primer paso es la identificación del sistema a lazo abierto, para esto obtenemos datos de la planta para una referencia aleatoria dentro del rango de operación, esperando a que esta se estabilice. Considerando que el proceso de calentamiento es lento, nuestra frecuencia para tomar datos es de 1 Hz. También por teoría de control sabemos que los sistemas se estabilizan en aproximadamente 3 a 5 veces su constante de tiempo, y gracias a estudios previos sabemos que la constante de tiempo de la planta es de aproximadamente 150 segundos. Se decide cambiar la referencia aleatoria cada 1000 segundos, para permitir que se estabilice. La aleatoriedad de la referencia está definida mediante una distribución uniforme entre 25% y 100% que es el rango de operación en el que funciona la planta.

Los resultados son los siguientes:




*Figura 5: Datos para entrenamiento de la Red Neuronal*

Estos datos son utilizados para entrenar la red y tuvimos resultados muy parecidos con la dinámica del sistema. El error cuadrático medio de la red neuronal es menor a al error cuadrático medio del modelo FOPDT por lo que se decide que se tiene una mejor aproximación



con la red neuronal. Se realiza también un entrenamiento con la dinámica de los datos en una escala de subida en pasos de 20 en 20, al entrenar la red con estos datos y realizar una prueba aleatoria, los resultados no se aproximan a la dinámica del sistema. Por lo que en ese caso decimos que la red memoriza el comportamiento, mas no puede aprender a extrapolar.

La topología de la red NARX es de una capa no lineal y una capa de activación. Consta de 9 neuronas de entrada con 3 regresores de salida y, de entrada. Estos parámetros fueron decididos mediante la experimentación. Si se aumenta regresores, los resultados se vuelven ruidosos, si se reducen tenemos menor capacidad de predicción. En cuanto al número de neuronas, se establecieron 10 para empezar y se modifica la cantidad para tener un valor de desempeño más bajo, cabe recalcar que un valor de rendimiento más bajo se relaciona con un mejor rendimiento.



*Figura 6: Prueba de la Red Neuronal para un cambio de referencia aleatorio*

Al momento de realizar los cambios de referencia con el modelo de la planta podemos ver que la Red se comporta de manera relativamente igual. Por lo que seguimos con este modelo de Red para realizar el control.

Otra estrategia que se toma es la normalización de los datos, para evitar riesgos de desbordamiento (Overflow) de memoria. Esto hace que el indicador de rendimiento baje, teniendo una mejor respuesta.

### Adaptación difusa

Como se va a realizar un lazo adaptativo en base al error de modelado, lo primero que se hace es obtener el error entre planta y modelo, y con ese error y derivada del error diseñamos las reglas difusas para establecer los parámetros de ajuste de los valores del PID. Los rangos de error y derivada de error que se manejan son de  $-100\text{ }^{\circ}\text{C}$  a  $100\text{ }^{\circ}\text{C}$ , ya que son los parámetros máximos de error que se puede tener físicamente dentro del rango de operación. Y la salida proviene de la guía de un esquema parecido al presente. Los rangos del ajuste de los parámetros del PID están entre  $-2$  y  $2$ , con las siguientes reglas de (Yahya, Al Tahtawi, Wijayanto, & Faizah, 2022).

Tabla 3: Reglas de lógica de sintonización automática difusa

dKp dKi dKd	de(t)					
		NB	NS	ZE	PS	PB
e(t)	NB	N	P	P	P	P
		P	N	N	N	Z
		P	Z	Z	Z	P
	NS	N	P	P	P	P
		P	N	N	Z	N
		Z	Z	Z	P	P
	ZE	N	P	Z	P	P
		N	P	Z	P	N
		Z	Z	Z	Z	Z
	PS	N	P	Z	P	P
		N	Z	N	N	P
		P	Z	Z	P	Z
	PB	N	P	Z	P	P
		Z	N	N	N	P
		P	Z	P	Z	Z

Ya teniendo el modelo en redes neuronales, las reglas y MFs difusas, los métodos de fusificación y defusificación, y el PID sintonizado con parámetros iniciales; procedemos a cerrar el lazo de control.

Ahora construimos ya el lazo de control con el modelo propuesto como proyecto, lo que queda hacer es poner el esquema a prueba para ver su respuesta a un cambio de referencia y su respuesta en cuanto a rechazo a perturbaciones. Realizamos la comparación con la respuesta de un controlador PID para un mismo cambio de referencia y perturbaciones similares.

Para realizar la prueba del controlador generamos un cambio de referencia dentro del rango de operación como ejemplo de una operación típica. El cambio de referencia se hace de 25 °C a 60 °C a los 500 [s] del inicio de la prueba con una función escalón. Lo que da cabida a que exista un equilibrio de señales en temperatura ambiente antes de hacer el cambio a 60 °C.

## **Resultados**

Se hacen las pruebas para dos grupos de resultados, con valores nominales y con un desgaste simulado por software, mediante una ganancia de 0.7. Primeramente se comparan los valores para cambio de referencia de condiciones nominales con el desgaste simulado y posteriormente la respuesta a rechazo de perturbaciones para los dos esquemas explicados anteriormente. Las perturbaciones se realizan a los 2000 [s] y a los 3560 [s].

El parámetro para comparar el desempeño es el ISE (Integrated Squared Error). Si comparamos estos valores podemos determinar cuál esquema tiene el menor error a lo largo del tiempo de ejecución.

Para los cambios de referencia tenemos las siguientes gráficas.

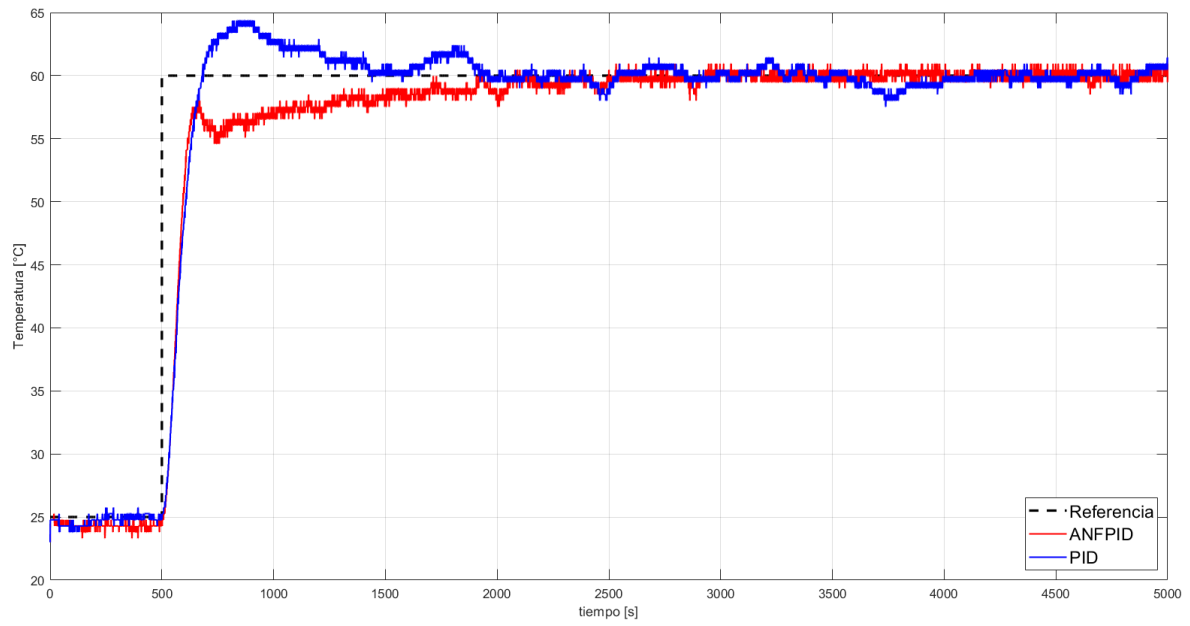


Figura 7: Respuesta a cambio de referencia




Figura 8: Respuesta a cambio de referencia con desgaste simulado

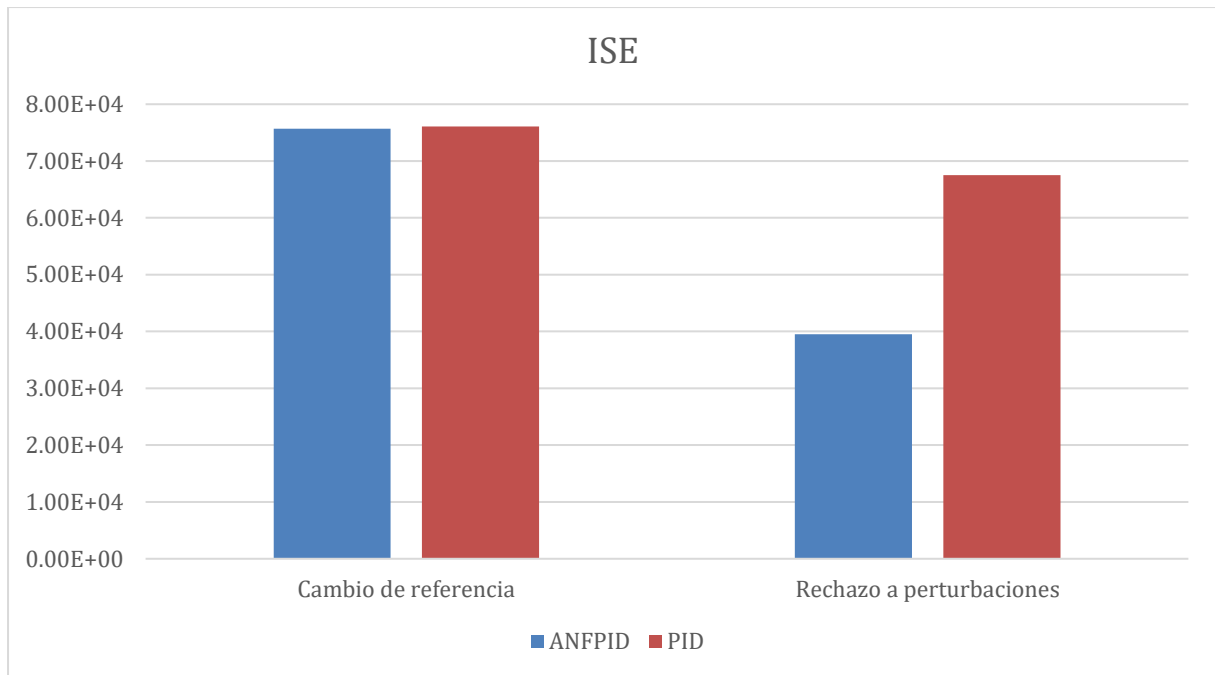


Figura 9: ISE para condiciones nominales

Para rechazo a perturbaciones con y sin desgaste simulado tenemos las siguientes gráficas.




Figura 10: Respuesta a perturbaciones

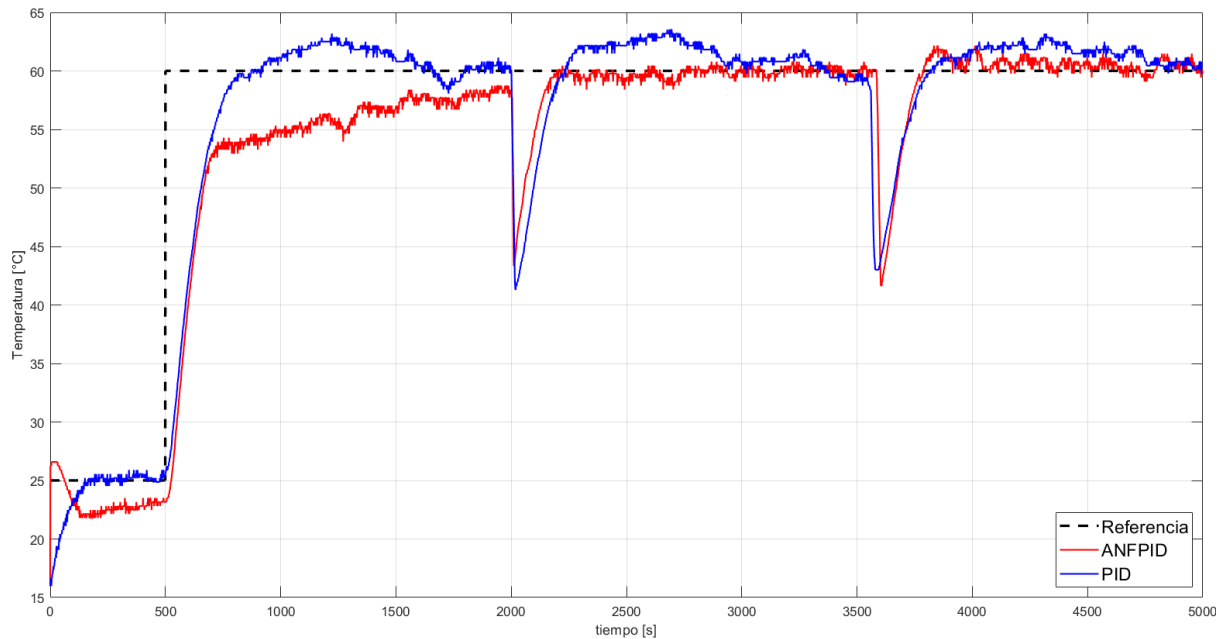


Figura 11: Respuesta a perturbaciones con desgaste simulado

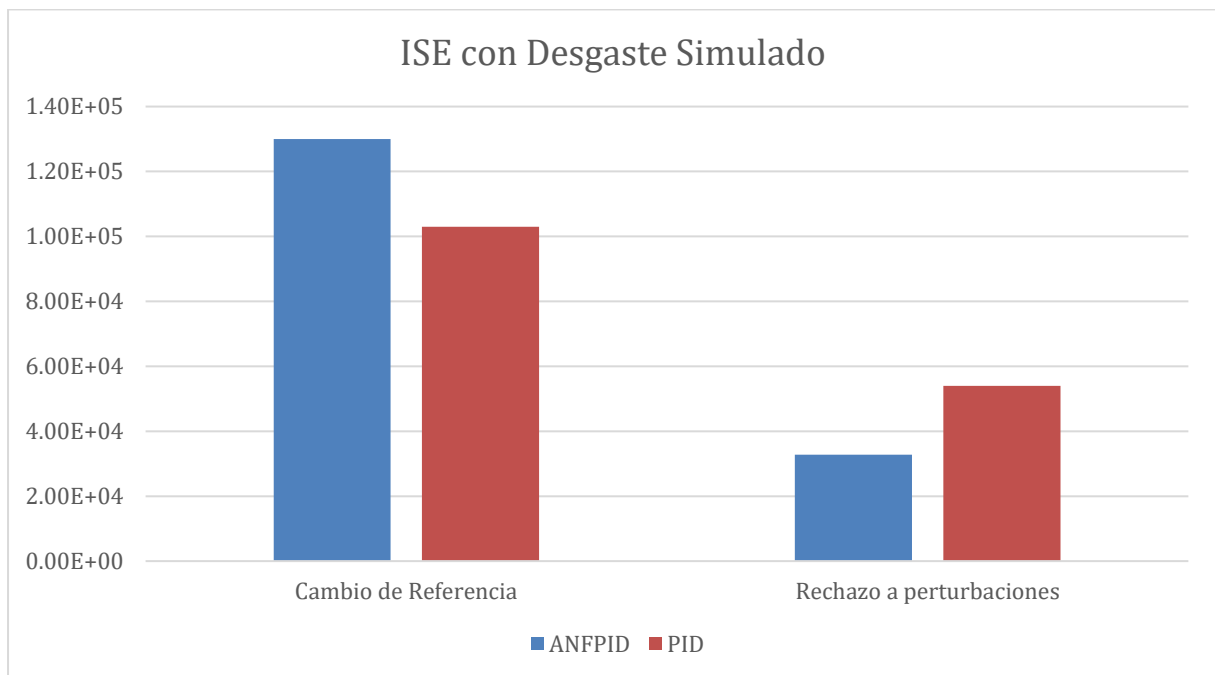


Figura 12: ISE con desgaste simulado

Se puede ver que la respuesta del esquema propuesto tiene un tiempo de estabilización menor al del PID normal, además el rechazo a perturbaciones es mucho más robusto con una estabilización mucho más rápida y un sobrepico considerablemente menor. Lo más importante dentro del proceso de control y que se puede ver en las gráficas es que el controlador Adaptive Neuro-Fuzzy mantiene la dinámica del sistema y el rechazo a perturbaciones con la misma

dinámica. Para obtener los resultados presentes con el controlador, podemos esperar un coste en otro factor de desempeño, en este caso, la señal de control. Para el controlador PID con parámetros fijos, la señal de control es relativamente baja a la del Adaptive Neuro-Fuzzy. Esto hace que, si se desea la respuesta al cambio definida por el modelo propuesto, se espera un mayor consumo en el controlador.

Se puede ver claramente que para condiciones normales el error resultante es menor en el caso del modelo ANFPID en comparación al PID normal. En el caso de rechazo a las perturbaciones, el modelo ANFPID tiene un menor error comparado con el PID normal. Cuando existe un desgaste simulado del sistema, el error del modelo ANFPID tiene un mayor error que el PID normal, pero aquí entra en consideración la dinámica del sistema que cambia para este caso y el error mayor resulta de mantener la dinámica del sistema. En el caso de perturbaciones en el sistema de desgaste simulado existe un menor margen de error entre el ANFPID y el PID normal que demuestra la robustez del controlador propuesto.

## CONCLUSIONES

Un esquema adaptativo en aplicaciones industriales es deseable, el presente trabajo realiza la comparación cualitativa de las respuestas para decidir la mejor opción de implementación. Se puede ver dentro de los resultados que el error varía mucho al momento en el que existen perturbaciones o desgaste. Para poder controlar esto y tener una respuesta estable, rápida, adaptada y robusta, el esquema propuesto nos da resultados esperados.

Los resultados esperados consisten en tener una mejor respuesta en todos los ámbitos para las pruebas realizadas. Se desea que la dinámica del sistema se mantenga por lo que los resultados en comparación al controlador PID con parámetros constantes representan una mejora clara. A su vez, en cuanto a la señal de control podemos ver que se mantiene constante para cada caso, por lo que la señal de control no va a dañar a la planta. El PID de parámetros constantes tiene una mayor variación, por lo que puede resultar en un mayor desgaste de la planta, generando más daño que el del modelo ANFPID propuesto.

Cabe recalcar que existen parámetros que se pueden modificar para poder tener respuestas diferentes y realizar una adaptación diferente, por lo que el controlador es enteramente personalizable. Como trabajo futuro se puede ver el efecto de cambiar las reglas o los rangos de las funciones de membresía.

En resumen, los resultados nos indican que el modelo propuesto sirve de la manera en la que estaba prevista, con la misma dinámica y con una mayor robusteza, haciéndolo mejor para adaptación de parámetros pero a un alto coste de señal de control



## REFERENCIAS BIBLIOGRÁFICAS

- Camacho, O., Iglesias, E., Herrera, M., & Aboukheir, H. (2021). Fuzzy logic-based control: From fundamentals to applications. *Novasinerгия*, 06-37.
- Camacho, O., Rosales, A., & Rivas, F. (2020). *Control de Procesos*. Quito: Escuela Politécnica Nacional.
- Carvajal, J., Chen, G., & Ogmen, H. (2000). Fuzzy PID controller: Design, performance, evaluation, and stability analysis. *Information Sciences* (pp. 249-270). Houston: Elsevier.
- de Moura Oliveira, P. B., Hedengren, J. D., & Rossiter, J. A. (2020). Introducing Digital Controllers to Undergraduate Students using the TCLab Arduino Kit. *21st IFAC World Congress: Berlin, Germany*, 17524-17529.
- Gobinath, S., & Madheswaran, M. (2020). Deep perceptron neural network with fuzzy PID controller for speed control and stability analysis of BLDC motor. *Soft Computing*, 10161–10180.
- M. Ali, O. A., Ali, A. Y., & Sumait, B. S. (2015). Comparison between the Effects of Different Types of Membership Functions on Fuzzy Logic Controller Performance . *International Journal of Emerging Engineering Research and Technology*, 76-83.
- Mejia, C., Salazar, E., & Camacho, O. (2022). A comparative experimental evaluation of various Smith predictor approaches for a thermal process with large dead time. *Alexandria Engineering Journal*, 9377-9394.
- Ogunnaike, B. A., & Ray, W. H. (1994). *Process Dynamics, Modeling, and Control* . New York: OXFORD UNIVERSITY PRESS.

- Park, J., Martin, R. A., Kelly, J. D., & Hedengren, J. D. (2020). Benchmark temperature microcontroller for process dynamics and control. *Computers and Chemical Engineering*.
- Siddique, N. (2014). *Intelligent Control: A Hybrid Approach Based on Fuzzy Logic, Neural Networks and Genetic Algorithms*. Springer.
- Xie, H., Tang, H., & Liao, Y. H. (2009). Time Series Prediction Based On NARX Neural Networks: An Advanced Approach. *Proceedings of the Eighth International Conference on Machine Learning and Cybernetics*, 1275-1279.
- Yahya, S., Al Tahtawi, A. R., Wijayanto, K., & Faizah, B. A. (2022). Adaptive Fuzzy-PID Controller for Liquid Flow Control in the Heating Tank System. *The International Journal of Integrated Engineering*, 173-180.  
doi:<https://doi.org/10.30880/ijie.14.01.015>

## **ANEXO A: ARCHIVOS UTILIZADOS**

En el siguiente enlace se encuentra el modelo propuesto con los archivos necesarios para la ejecución del código y la replicación del experimento.

[Enlace](#)