



ESCUELA SUPERIOR POLITÉCNICA DE CHIMBORAZO

DESARROLLO DE UN REGULADOR NEURODIFUSO ADAPTATIVO PARA EL CONTROL DE UNA PLANTA DE VUELO VERTICAL DE NATIONAL INSTRUMENT

ANDRÉS FERNANDO MOROCHO CAIZA

Trabajo de Titulación modalidad: Proyectos de Investigación y Desarrollo, presentado ante el Instituto de Posgrado y Educación Continua de la ESPOCH como requisito parcial para la obtención del grado de:

**MAGÍSTER EN SISTEMAS DE CONTROL Y AUTOMATIZACIÓN
INDUSTRIAL**

Riobamba-Ecuador

Enero 2018



ESCUELA SUPERIOR POLITÉCNICA DE CHIMBORAZO

CERTIFICACIÓN:

EL TRIBUNAL DEL TRABAJO DE TITULACIÓN CERTIFICA QUE:

El trabajo de titulación modalidad proyectos de Investigación y Desarrollo, titulado: “DESARROLLO DE UN REGULADOR NEURODIFUSO ADAPTATIVO PARA EL CONTROL DE UNA PLANTA DE VUELO VERTICAL DE NATIONAL INSTRUMENT”, de responsabilidad del señor Andrés Fernando Morocho Caiza, ha sido prolijamente revisado y se autoriza su presentación.

Ing. Oswaldo Martínez Mgs.

PRESIDENTE

Ing. Jesús Alberto Rodríguez Flores PhD.

DIRECTOR

Ing. Jorge Luis Hernández Ambato PhD.

MIEMBRO

Ing. Paúl Moreno Avilés PhD.

MIEMBRO

Riobamba, Enero de 2018

DERECHOS INTELECTUALES

Yo, ANDRÉS FERNANDO MOROCHO CAIZA, declaro que soy responsable de las ideas, doctrinas y resultados expuestos en el presente Trabajo de Titulación modalidad Proyectos de Investigación y Desarrollo, y que el patrimonio intelectual generado por la misma pertenece exclusivamente a la Escuela Superior Politécnica de Chimborazo.

ANDRÉS FERNANDO MOROCHO CAIZA

No. Cédula: 0604201467

©2018, Andrés Fernando Morocho Caiza

Se autoriza la reproducción total o parcial, con fines académicos, por cualquier medio o procedimiento, incluyendo la cita bibliográfica del documento, siempre y cuando se reconozca el Derecho de Autor.

DECLARACIÓN DE AUTENTICIDAD

Yo, Andrés Fernando Morocho Caiza, declaro que el presente proyecto de investigación, es de mi autoría y que los resultados del mismo son auténticos y originales. Los textos constantes en el documento que provienen de otras fuentes están debidamente citados y referenciados.

Como autor, asumo la responsabilidad legal y académica de los contenidos de este Trabajo de Titulación de Maestría.

ANDRÉS FERNANDO MOROCHO CAIZA

No. Cédula: 0604201467

DEDICATORIA

Toda esta etapa académica inició desde mi hogar donde llegué a tener buenas raíces para seguir escalando en mi vida profesional y humana, y es por esa razón que dedico este trabajo a las personas que han estado desde temprana edad a mi lado y que se han convertido en mi familia.

Andrés

AGRADECIMIENTO

Agradezco en primer lugar a Dios, quien me ha puesto en este mundo para ir superando cada uno de los obstáculos que se me han ido presentando y al mismo tiempo junto a él los he vencido, llegando a cumplir muchos objetivos en mi vida espiritual, académica y profesional. También quiero extender mi agradecimiento a todos mis maestros en mi trayectoria educativa porque cada uno de ellos compartió sus conocimientos y experiencias y es esto lo que me ha permitido llegar hasta aquí. De igual manera agradezco a mi familia que me ha sabido acompañar en cada paso y que me han brindado apoyo en todas las formas posibles.

Andrés

ÍNDICE DE CONTENIDO

RESUMEN	xii
SUMMARY	xiii

CAPÍTULO I

1. INTRODUCCIÓN	1
1.1. Situación Problemática	1
1.2. Formulación del Problema.....	3
1.3. Preguntas Directrices	3
1.4. Justificación de la Investigación	4
1.5. Objetivos de la Investigación.....	5
1.5.1. <i>Objetivo General</i>	5
1.5.2. <i>Objetivos Específicos</i>	5
1.6. Hipótesis	6

CAPÍTULO II

2. MARCO TEÓRICO	7
2.1. Antecedentes del Problema.....	7
2.2. Bases Teóricas	8
2.2.1. <i>Control PID</i>	8
2.2.2. <i>Sistemas de Inferencia Difuso (FIS)</i>	13
2.2.3. <i>Sistema Neuro Difuso con Inferencia TSK</i>	18
2.2.4. <i>Arquitectura del Regulador Neuro Difuso</i>	19
2.2.5. <i>Redes Neuronales</i>	17
2.2.6. <i>Aplicaciones del Control Inteligente</i>	22

CAPÍTULO III

3.	METODOLOGÍA DE INVESTIGACIÓN	24
3.1.	Identificación de la Planta	24
3.1.1.	<i>Hardware del Sistema de la Planta</i>	24
3.1.2.	<i>Torques que actúan sobre el QNET VTOL</i>	27
3.1.3.	<i>Ecuación de Movimiento</i>	28
3.1.4.	<i>Función de Transferencia del Proceso</i>	31
3.2.	Diseño del controlador PID	37
3.3.	Controlador PID con ecuaciones en diferencia.....	40
3.4.	Diseño del Regulador Neuro Difuso.....	43

CAPÍTULO IV

4.	RESULTADOS Y DISCUSIÓN	47
4.1.	Análisis de Resultados del Controlador PID	47
4.1.1.	<i>Respuesta de la planta ante el controlador PID sin perturbación</i>	47
4.1.2.	<i>Respuesta de la planta ante el controlador PID con perturbación</i>	49
4.2.	Análisis de Resultados del Regulador Neurodifuso.....	50
4.2.1.	<i>Respuesta de la planta ante el controlador Neurodifuso sin perturbación</i>	50
4.2.2.	<i>Respuesta de la planta ante el controlador Neurodifuso con perturbación</i>	51
4.3.	Comprobación de la Hipótesis.....	54

CAPÍTULO V

5.	PROPUESTA	59
5.1.	Conclusiones.....	59
5.2.	Recomendaciones	60
5.3.	Respuesta a la formulación del Problema.....	60
5.4.	Respuesta a las Preguntas Directrices.....	61

BIBLIOGRAFÍA

ANEXOS

ÍNDICE DE TABLAS

Tabla 1-2: Valores de sintonización para el primer método	10
Tabla 2-2: Valores de sintonización para el segundo método.....	12
Tabla 1-3: Datos del sistema QNET VTOL.....	26
Tabla 1-4: Registro del tiempo de estabilización.....	50
Tabla 2-4: Registro del tiempo de estabilización con el Regulador Neurodifuso.....	53
Tabla 3-4: Muestras de los Controladores para la Distribución T de Student.....	57
Tabla 4-4: Distribución T de Student para las muestras de los Controladores.	57

ÍNDICE DE FIGURAS

Figura 1-2: Curva experimental para los parámetros de Ziegler-Nichols.....	10
Figura 2-2: Respuesta de un sistema con factor de decaimiento de un cuarto.....	11
Figura 3-2: Oscilación sostenida ante un período crítico.....	12
Figura 4-2: Gráfica de las Funciones de Membresía.	16
Figura 5-2: Ejemplo de una red neuronal totalmente conectada.....	17
Figura 6-2: Estructura del Sistema Neuro Difuso.....	20
Figura 1-3: Quanser QNET 2.0 Vertical Take-Off and Landing Board para el NI ELVIS II.	25
Figura 2-3: Tarjeta Shield L298N.....	26
Figura 3-3: Diagrama de cuerpo libre del QNET VTOL.....	27
Figura 4-3: Programación para la adquisición de datos.	32
Figura 5-3: Gráfica entre los datos adquiridos (línea roja) y el modelo encontrado (línea azul). ...	34
Figura 6-3: Variación de la función de costo.....	34
Figura 7-3: Importación de datos al System Identification.....	35
Figura 8-3: Estimación de la cantidad de polos y ceros del sistema a modelar.....	36
Figura 9-3: Función de transferencia obtenida en el System Identification	36
Figura 10-3: Ajuste para el diseño del PID.....	38
Figura 11-3: Respuesta del sistema con el controlador PID	39
Figura 12-3: Diagrama de bloques del PID	40
Figura 13-3: Diagrama de bloques en Simulink de Euler en adelanto.....	41
Figura 14-3: Controlador PID con ecuaciones en diferencias.	42
Figura 15-3: Diagrama de bloques de un PID de Ganancias Difusas.....	43
Figura 16-3: Modelo del regulador Neuro Difuso Adaptativo.	45
Figura 17-3: Respuesta del sistema con el regulador Neurodifuso.....	45
Figura 18-3: Programación del algoritmo Neurodifuso.....	46
Figura 1-4: Control PID subiendo de un SP de 5 a 24 grados.	48
Figura 2-4: Control PID bajando de un SP de 24 a 5 grados.....	48
Figura 3-4: Control PID colocando sobrepeso cuando se encuentra en un SP de 24 grados.....	49
Figura 4-4: Control PID retirando sobrepeso en un SP de 24 grados.	49

Figura 5-4: Control Neurodifuso subiendo de un SP de 5 a 24 grados.....	51
Figura 6-4: Control Neurodifuso bajando de un SP de 24 a 5 grados	51
Figura 7-4: Control Neurodifuso colocando sobrepeso cuando se encuentra en un SP de 24 grados.	52
Figura 8-4: Control Neurodifuso retirando sobrepeso cuando se encuentra en un SP de 24 grados.	52
Figura 9-4: Gráfica de barras de los Tiempos de Estabilización de los Controladores	54
Figura 10-4: Diagrama de barras del ISE para las cuatro pruebas.....	55

RESUMEN

Se desarrolló un regulador neurodifuso adaptativo, para el control de una planta de vuelo vertical de National Instrument, mediante un controlador de ganancias programadas o también llamado PID de ganancias programadas con una inferencia borrosa del tipo Takagi Sugeno Kang de orden cero que por medio de su estructura recoge las ventajas de las redes neuronales y la lógica difusa. Se empezó con la modelación de la planta mediante la respuesta del sistema ante una entrada escalón, llegando a obtenerse una función de transferencia de segundo orden y que luego fue ajustada con la técnica del gradiente decreciente. Se diseñó un controlador clásico para observar el comportamiento de la planta. Luego optimizó con técnicas de control inteligente. Antes de llegar a implementar, se simuló el sistema con los controladores para verificar el comportamiento de la planta y si es el adecuado proceder a la etapa de implementación. Los algoritmos del control PID clásico y del Neurodifuso se programó en el software de Labview, donde es la computadora la encargada de realizar todo el proceso para luego enviar mediante puerto de comunicación serial al Arduino Uno. Éste se encarga de recibir la información de PWM para transmitirlo al driver del motor de la planta de vuelo vertical. El lazo se cierra cuando el sensor de la posición angular envía a la tarjeta de adquisición de datos y ésta regresa la información a la PC. Los datos obtenidos fueron evaluados mediante el criterio integral del cuadrado del error (ISE) y comparados entre sí, donde el regulador Neurodifuso responde tres veces más rápido con el PID. Tener muy en cuenta en el tiempo de muestreo para la adquisición de datos para diseñar los controladores.

Palabras claves: <TECNOLOGÍA Y CIENCIAS DE LA INGENIERÍA>, <CONTROL AUTOMÁTICO>, <NEURODIFUSO>, <TAKAGI SUGENO KANG (MÉTODO)>, <CONTROL DE GANANCIAS PROGRAMADAS>, <PID DE GANANCIAS PROGRAMADAS>.

ABSTRACT

An adaptive neuro-diffuse regulator was developed, for the control of a vertical flight plant of National Instrument, by means of a controller of programmed gains or also called PID of gains programs with a fuzzy inference of the Takagi Sugeno Kang type of zero order that through its structure picks up the advantages of neural networks and fuzzy logic. The plant modeling was started by means of the response of the system to a step input, obtaining a second order transfer function and which was then adjusted with the decreasing gradient technique. A classic controller was designed to observe the behavior of the plant. Then optimized with intelligent control techniques. Before getting to implement, the system was simulated with the controllers to verify the behavior of the plant and if it is appropriate to proceed to the implementation stage. The algorithms of the classic PID control and the Neuro-diffuse were programmed in the Lab view software, where the computer is responsible for carrying out the entire process and then send via serial communication port to the Arduino Uno. . This is responsible for receiving the PWM information to transmit it to the driver of the vertical flight plant engine. The loop closes when the angular position sensor sends the data acquisition card and it returns the information to the PC. The data obtained were evaluated using the integral criterion of the square of the error (ISE) and compared to each other, where the Neuro-diffuse regulator responds three times faster with the PID. Take into account in the sampling time for the acquisition of data to design the controllers.

Keywords: <TECHNOLOGY AND ENGINEERING SCIENCES>, <AUTOMATIC CONTROL, <NEURO-DIFFUSE >, <TAKAGI SUGENO KANG (METHOD)>, <CONTROL OF PROGRAMMED PROFITS S>, <PID OF PROGRAMMED PROFITS>.

INDICE DE ABREVIATURAS

FIS: Sistema de Inferencia Difusa (Fuzzy Inference System)

IAE: Integral del Error Absoluto (Integral Absolute Error)

ISE: Integral del Error Cuadrático (Integral Squared Error)

J: función de costo

Kd: Constante Derivativa

Ki: Constante Integral

Kp: Constante Proporcional

NI: National Instrument

PD: Proporcional Derivativo

PI: Proporcional Integral

PID: Proporcional, Integral y Derivativo

RN: Red Neuronal

RND: Red Neuronal Difusa

Td: Tiempo derivativo

Ti: Tiempo Integral

TSK: Takagi Sugeno Kang

VTOL: Vuelo y aterrizaje vertical (Vertical Take-Off and Landing)

CAPÍTULO I

1. INTRODUCCIÓN

1.1. Situación Problemática

El avance de la ciencia en el sector tecnológico a nivel mundial ha tenido un gran desarrollo, al igual que la automatización y, por ende, las diferentes estrategias de control. Es muy común escuchar acerca del control clásico, el mismo que ha sido muy utilizado para el control de procesos en el sector industrial y que incluso se lo continúa utilizando dentro de la industria ecuatoriana

La sociedad requiere nuevos enfoques para los problemas actuales de control. Debido a la complejidad de algunos procesos, se tiene una incipiente automatización y una gran carga de mando manual. Aun cuando las tareas de control, que se asignen a un controlador humano, se realicen de manera adecuada, su desempeño exitoso depende del grado de especialización que alcanzan los operadores, su estado de ánimo y de los distintos operarios. Por tanto, se hace necesario proveer controles automáticos adecuados. Por esta razón se requiere un esquema de control que posea características inteligentes, con el cual sea posible controlar estos procesos en un grado mucho mayor que el actual y con las mismas o mejores prestaciones con las que lo hace el operador humano.

En los últimos años, ha venido creciendo un interés hacia técnicas no convencionales para resolver las no linealidades y la variancia en el tiempo.

En ayuda de las técnicas clásicas aparecieron los sistemas apoyados en Inteligencia Artificial para poder dotar a los controladores de habilidades casi humanas como la generalización y el aprendizaje, pero muchas veces al costo de grandes plataformas computacionales, como las de los sistemas expertos tan conocidos por la Ingeniería de Computación. (García, 2005, p 01)

Hoy en día se presenta una estrategia de control que ya ha venido siendo estudiada por algunos personajes, en la cual se demuestra las ventajas que brinda el poder combinar las redes neuronales

con la lógica difusa, llegando así a escucharse la terminología control neurodifuso. Donde busca que sea capaz de manejar sistemas tan enormes como los Sistemas Expertos, pero a un costo computacionalmente más económico y de una manera más simple que puede ser interpretada por el lenguaje natural.

Como dispositivos de vuelo vertical, actualmente, existen los drones que son utilizados para filmar eventos como partidos de fútbol, pueden ocuparse para entrega de paquetes a domicilio, son útiles para avisos de alerta de emergencia, y también empleados para realizar monitoreo. Análogo a los drones se tiene los vehículos aéreos no tripulados (UAV) que de igual manera tienen múltiples funcionalidades y su vuelo es diferente.

Estos dispositivos, por la dinámica de vuelo, son sistemas no lineales en los que se dificulta realizar un control convencional o, al menos este tipo de controladores carecen de precisión y tiempos de respuesta rápidos. Por esta razón, con este trabajo de titulación se busca lograr alcanzar estos dos parámetros muy importantes, en base a una combinación de redes neuronales y control borroso, donde se aprovechará las ventajas de cada método para alcanzar una mejor estrategia de control.

Los controladores para vuelo vienen ya prefabricados donde el usuario se olvida de la parte de control y únicamente se centra en enviar los datos de los sensores y las órdenes, llegando a presentarse mayor facilidad al momento de fabricar un equipo de vuelo de estas características. Esto significa que, en dichos proyectos ya no se aplican estrategias en el diseño de controladores y además estos equipos ya fabricados presentan un alto costo, donde se puede implementar por software un control para el vuelo, aplicando los recursos que presenta el control inteligente.

La aplicación de este trabajo de titulación permite dar a conocer la manera de ejecutar un regulador neurodifuso adaptativo para la estabilización de un dispositivo de vuelo vertical como es la planta vertical take-off and landing board (VTOL) de National Instrument, con el cual se podrán realizar todas las pruebas correspondientes y analizar las ventajas de las técnicas de control inteligente sobre la convencional.

1.2. Formulación del Problema

¿Cómo mejora un regulador neurodifuso adaptativo el desempeño en el tiempo de estabilización, mediante técnicas de control inteligente, de la planta de vuelo vertical de National Instrument con relación a un control convencional?

1.3. Preguntas Directrices

¿Qué relación existe entre la estructura neuronal dada por capas y las diferentes fases asociadas a la inferencia borrosa, tales como, fuzzificación de la variable, grados de verdad y agregación de las reglas?

¿Cuáles son las variables que deben ser consideradas para crear una función de costo que permita evaluar el desempeño de la planta bajo los diferentes esquemas de regulación?

¿Cuál es el procedimiento para implementar la técnica de Takagi Sugeno Kang de orden cero para desarrollar la caracterización de la variable de control (Y_c)?

¿Cómo se puede evaluar el desempeño del regulador neurodifuso adaptativo sobre la planta que simula el control de vuelo vertical?

1.4. Justificación de la Investigación

Este trabajo de titulación abrirá las puertas para tener un mayor dominio en la aplicación de técnicas de control inteligente y tomar como una opción la implementación de algoritmos de controladores neurodifusos para automatizar los procesos industriales, logrando un mejor control en la dinámica de los sistemas complejos.

Al realizar este desarrollo se pretende tener un mejor control en el vuelo de dispositivos voladores, como son los drones, incluyendo de igual manera un menor consumo computacional y de energía. Se debe tener muy en claro que la aplicación se la realizará en una planta vertical take-off and landing board de National Instrument, dicha planta simula el vuelo sobre un motor de un dron. Donde más adelante se puede ampliar su uso para los cuatro motores que tienen los drones, esta aplicación se la deja para próximas investigaciones.

La presente investigación es importante ya que permite mostrar la aplicación de nuevas técnicas de control inteligente, las ventajas que tiene sobre técnicas convencionales sobre sistemas complejos que no presentan una linealidad y cuyos modelos de procesos son desconocidos. Además, permite integrar las redes neuronales con la lógica difusa para generar un modelo neurodifuso adaptativo fusionando las ventajas de cada técnica de control.

Cada estudio o aplicación que se realiza, donde la investigación es un componente fundamental siempre será un aporte para ampliar el conocimiento y el avance tecnológico dentro de los países en vías de desarrollo, porque es necesario producir y dejar de ser consumistas para ir generando mayor economía e independencia tecnológica.

1.5. Objetivos de la Investigación

1.5.1. Objetivo General

Desarrollar un regulador neurodifuso adaptativo en una planta de vuelo vertical de National Instrument, mediante técnicas de control inteligente, para el mejoramiento del desempeño en el tiempo de estabilización, en relación a un control convencional.

1.5.2. Objetivos Específicos

- Plantear la relación existente entre la estructura neuronal dada por capas y las diferentes fases asociadas a la inferencia borrosa, tales como, fuzzificación de la variable, grados de verdad y agregación de las reglas, en base al estado del arte.
- Identificar las variables que deben ser consideradas para la realización de una función de costo que evalúe el desempeño de la planta bajo los diferentes esquemas de regulación.
- Implementar la técnica de Takagi Sugeno Kang de orden cero para el desarrollo de la caracterización de la variable de control (Y_c).
- Comparar los resultados de estabilidad entre las técnicas de control inteligente y control convencional, en la planta de vuelo vertical de National Instrument.

1.6. Hipótesis

El desarrollo de un regulador neurodifuso adaptativo, mediante técnicas de control inteligente, para el control de la panta de vuelo vertical de National Instrument mejorará el desempeño en el tiempo de estabilización con relación a un control convencional.

CAPÍTULO II

2. MARCO TEÓRICO

2.1. Antecedentes del Problema

Las técnicas de control inteligente son muy utilizadas en otros países, como en España, donde se registra un artículo “Control Neuroborroso en Red. Aplicación al Proceso de Taladrado de Alto Rendimiento”, desarrollado por Agustín Gajate y Rodolfo Ernesto, en el Instituto de Automática Industrial. Los autores pretenden alcanzar un alto rendimiento buscando mayores tasas de arranque de material y mejorar el aprovechamiento de la vida útil de las brocas con la aplicación de técnicas de control inteligente.

En la Universidad Federal de Rio de Janeiro publicaron un artículo en la IEEE, donde realizaron la “Aplicación de Control Inteligente en el control del torque en motores eléctricos como los de reluctancia conmutados (SMR)”, actuado sobre la presencia de rizado en la forma de onda de torque. Dicho inconveniente puede ser minimizado controlando adecuadamente la forma de onda de corriente. Para esto han propuesto utilizar un compensador neurodifuso en serie con un controlador PI convencional, dentro de un lazo de control de velocidad. Los resultados obtenidos mostraron las potencialidades de la incorporación de esta señal de compensación, y el efecto de la variación en la forma de las funciones de membresía para la reducción de rizado y armónicos. (Henriques, 1999)

En Arizona, en la Universidad de Tennessee, se aplicaron técnicas de control inteligente que fueron aplicadas en motores de inducción controlados por PWM, donde el esquema desarrollado se denominó “Control Neuro Difuso de Torque Directo” y utiliza un ANFIS (Adaptative Network-based Fuzzy Inference System) para conseguir un control de alto desempeño de flujo y torque. (Grabowski, 2000)

En un estudio en el 2002, en la Universidad de Sheffield, Linkens desarrolló un sistema inteligente para la administración de anestesia que utiliza lecturas electro-encefalográficas, medidas de los latidos del corazón y de la presión sanguínea. (Linkens, 2002).

En el Ecuador, la Escuela Politécnica Nacional desarrolló un algoritmo de programación de un sistema neurodifuso ANFIS para aplicarlo en procesos de modelamiento y control sobre un sistema aerodinámico TRMS (Twin Rotor MIMO System). Esta tesis de maestría desarrollada por Junior Figueroa, él mismo que busca aplicar el algoritmo sobre una planta que simula el comportamiento de un helicóptero. (Figueroa, 2016)

Se necesitan de sistemas neurodifusos totalmente adaptables para encarar los problemas del mundo real del futuro. La mayoría de los modelos neurodifusos existentes, se basan en los parámetros de red especificados por el usuario, pero para que el sistema sea completamente adaptable, su desempeño debe ser independiente de estos parámetros. Es por esta razón que se propone plantear este trabajo de titulación.

2.2. Bases Teóricas

2.2.1. Control PID

Un controlador del tipo PID en el dominio del tiempo viene definido de la siguiente manera:

$$u(t) = K_p e(t) + K_i \int_0^t e(\tau) d\tau + K_d \frac{de(t)}{dt} \quad (2.1)$$

Donde:

- u : es la señal de control.
- e : es el error de control.
- K_p : ganancia proporcional.
- K_i : ganancia integral.
- K_d : ganancia derivativa.

La ecuación 2.1 puede ser representada con las constantes de tiempo integral y derivativo como se puede observar a continuación:

$$u(t) = K_p \left(e(t) + \frac{1}{T_i} \int_0^t e(\tau) d\tau + T_d \frac{de(t)}{dt} \right) \quad (2.2)$$

Donde:

- T_i : tiempo integral.
- T_d : tiempo derivativo.

Si en la ecuación 2.2 se aplica la transformada de Laplace la función de transferencia del controlador queda representada de la siguiente manera:

$$\frac{U(s)}{E(s)} = K_p \left[1 + \frac{1}{T_i s} + T_d s \right] \quad (2.3)$$

Como se puede observar en la ecuación 2.1 este tipo de control trabaja directamente con la señal de error, la misma que es la diferencia entre el punto deseado (set point) y la salida del proceso.

El controlador PID genera a su salida una señal que es proporcional a la magnitud, a la duración y a la variación del error. Esto lo logra, combinando las ventajas de cada una de las tres acciones de control que presenta.

La aplicación de este sistema produce que se busquen maneras o métodos de calcular las constantes como la ganancia proporcional, tiempo de integración y derivación. Para ello se presenta el método, comúnmente utilizado, de Ziegler-Nichols.

Método 1 de Ziegler-Nichols

También conocido como el método de la respuesta al escalón, el mismo que es aplicado para sistemas que no son altamente integrales. Según Astrom, en su libro control PID avanzado, menciona que se puede obtener información de un proceso con la respuesta al escalón en lazo abierto. Por ende, el proceso se caracteriza por dos parámetros el tiempo de atraso L y la constante de tiempo T . (Astrom, 2009)

Para obtener estos dos parámetros, en primer lugar, se traza una recta tangente en el punto donde la pendiente de la respuesta a un escalón tiene su máximo. La intersección con el eje del tiempo y con el valor final de la amplitud forma las distancias L y T. En la siguiente figura se puede observar estos parámetros:

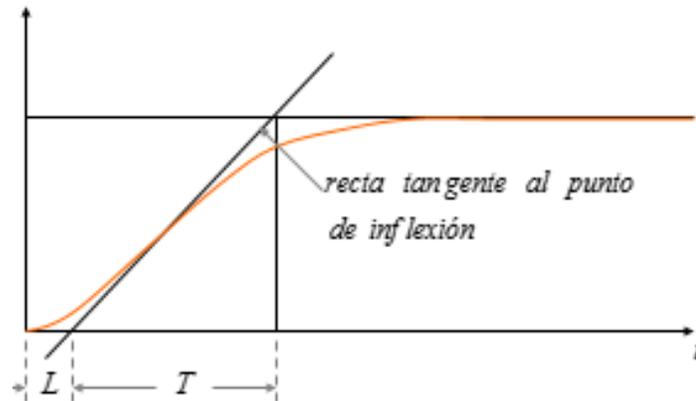


Figura 1-2: Curva experimental para los parámetros de Ziegler-Nichols.

Fuente: (Astrom & Hagglund, 2009)

En la Tabla 1-2 se define los valores para las constantes de un controlador PID de acuerdo al primer método de Ziegler-Nichols.

Tabla 1-2: Valores de sintonización para el primer método de Ziegler-Nichols.

Tipo controlador	K_p	T_i	T_d
P	$\frac{T}{L}$	∞	0
PI	$0.9 \frac{T}{L}$	$\frac{L}{0.3}$	0
PID	$1.2 \frac{T}{L}$	$2L$	$\frac{L}{2}$

Realizado por: Morocho, Andrés, 2018

Método 2 de Ziegler-Nichols

También conocido como el método de la respuesta en frecuencia o asentamiento de un cuarto o ganancia límite, que es utilizado para sistemas que son altamente integrales o de tipo uno en adelante. Al igual que el anterior, se trata de un método experimental. Ante una entrada a escalón unitario se presenta una respuesta como la siguiente:

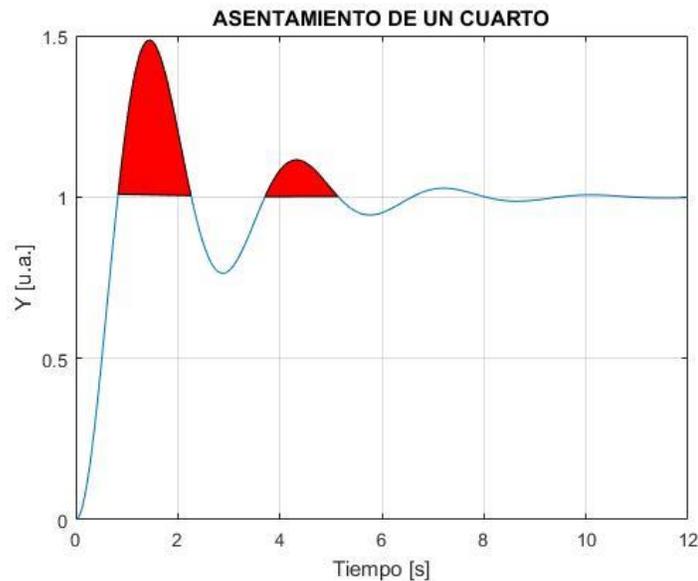


Figura 2-2: Respuesta de un sistema con factor de decaimiento de un cuarto.

Realizado por: Morocho, Andrés, 2018

Si se considera al primer sobre impulso como A y al segundo sobre impulso B, entonces la relación de decadencia:

- $B/A < 1$ produce una respuesta estable.
- $B/A > 1$ produce una respuesta inestable.

Cuanto más se aproxime la relación a 1, la respuesta será más rápida, pero más oscilante; mientras más se aleje de 1, la respuesta será poco oscilante, pero muy lenta. Entonces, de acuerdo a Ziegler-Nichols, se llega a la conclusión que la relación $B/A=1/4$ proporciona un buen compromiso entre estabilidad y rapidez.

Para realizar este método, en primer lugar, se busca eliminar los efectos de la parte integral y derivativa; para luego utilizar la ganancia proporcional K_p y hacer que el sistema presente oscilaciones sostenidas. El valor de la ganancia que logre esto se llama ganancia crítica K_{cr} , que corresponde a un período crítico P_{cr} medido desde un pico de la señal a otro pico.

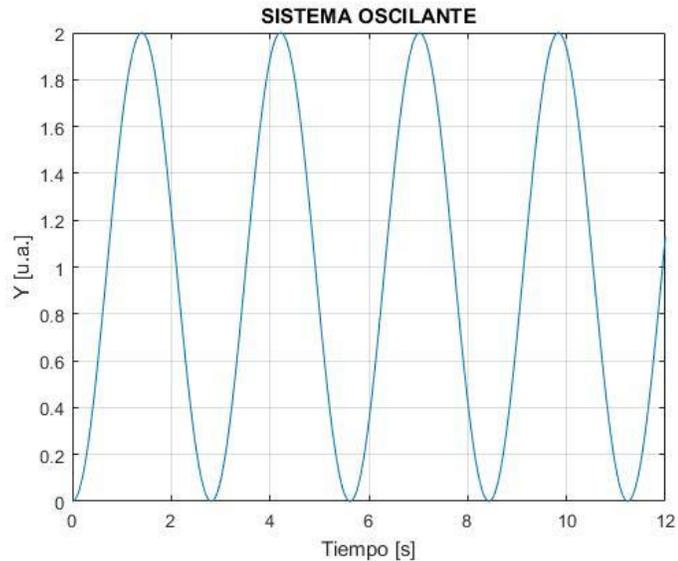


Figura 3-2: Oscilación sostenida ante un período crítico.
Realizado por: Morocho, Andrés, 2018

Una forma sencilla de determinar la ganancia crítica y su correspondiente período es mediante el método de Routh-Hurwitz. Luego de encontrar estos valores se procede a utilizar la siguiente tabla:

Tabla 2-2: Valores de sintonización para el segundo método de Ziegler-Nichols.

Tipo controlador	K_p	T_i	T_d
P	$0.5 K_{cr}$	∞	0
PI	$0.45 K_{cr}$	$\frac{P_{cr}}{1.2}$	0
PID	$0.6 K_{cr}$	$\frac{P_{cr}}{2}$	$\frac{P_{cr}}{8}$

Realizado por: Morocho, Andrés, 2018

Según Valdivia en su libro “Sistemas de Control Continuos y Discretos” resalta que Ziegler-Nichols manifiestan que el T_d es cuatro veces menor al T_i , como se puede observar en las dos tablas anteriores, porque el sistema debe ser causal de modo que el cero del derivador esté muy cercano al $-\infty$. (Valdivia, 2012, p. 158)

2.2.2. *Sistemas de Inferencia Difuso (FIS)*

Debido a su naturaleza multidisciplinaria, los sistemas de inferencia difusos también son conocidos como sistemas basados en reglas difusas, sistemas expertos difusos, modelos difusos, memorias asociativas difusas (FAM), controladores difusos (cuando se utilizan como controladores) o simplemente sistemas difusos. (Figueroa, 2016)

Se llaman dispositivos de inferencia borrosa a los sistemas que interpretan las reglas de tipo IF-THEN de una base de reglas, con el fin de obtener los valores de salida a partir de los actuales valores de las variables lingüísticas de entrada al sistema. (Toxqui, 2003)

Un sistema de inferencia difusa presenta los siguientes elementos:

- **Fuzzificación:** esta etapa es la encargada de transformar los valores de la entrada en valores difusos, estableciendo una relación entre puntos de entrada no difusas al sistema y sus correspondientes conjuntos difusos.
- **Defuzzificación:** es la etapa encargada de convertir un conjunto borroso, que por lo general es de la salida de un dispositivo de inferencia borrosa, en un valor real (no borroso). Según Rigoberto Toxqui, en su tesis Redes neuronales difusas dinámicas para identificación y control adaptable, da a conocer los siguientes métodos para esta etapa: desborrosificador por máximo, desborrosificador por medida de centros y desborrosificador por centro de área.

Los modelos borrosos basados en reglas utilizan la siguiente relación **SI** antecedente **ENTONCES** consecuente; donde la proposición del antecedente es del tipo “x es A”, donde “x” es una variable lingüística y “A” es un término lingüístico constante. El consecuente se puede presentar de dos tipos (Díez, 2003):

- **Modelos lingüísticos (Mamdani):** tanto el antecedente como el consecuente son modelos borrosos.
- **Modelo de Takagi-Sugeno:** en los que el antecedente es una proposición borrosa y el consecuente es una función real.

De acuerdo a lo expuesto, se puede decir que un modelo borroso Takagi-Sugeno se diferencia del modelo lingüístico en que tiene funciones reales en su consecuente en lugar de una proposición borrosa.

Para emplear un sistema de inferencia difusa es necesario conocer los siguientes términos que se indican a continuación:

Función de costo: es una expresión matemática, empleada como un indicador ya sea para evaluar el error, la desviación, etc. Respecto a un parámetro o conjunto de datos, también es utilizada para evaluar el desempeño, tal como, la velocidad de ajuste.

Se intenta que esta función sea aditiva y que no se auto compense. Razón por la cual, se suele emplear una función par, tal como, la función cuadrática o el valor absoluto, sin embargo, puede ser cualquier otra. Comúnmente se la denomina con la letra J.

Gradiente decreciente: también conocido como gradiente descendente, es un método numérico que pretende determinar la dirección de variación de los parámetros que definen una función de costo y hacerle disminuir hasta alcanzar un mínimo global de derivada o pendiente cero.

El gradiente decreciente viene definido de la siguiente manera:

$$a_n = a_{n-1} - \alpha \frac{\partial J(a)}{\partial a} \quad (2.4)$$

Donde:

- J(a): función de costo.
- a: parámetro a ser minimizado.
- α : factor de aprendizaje.

La derivada de la función de costo con respecto a su parámetro de minimización se la puede aproximar, como se indica a continuación:

$$\frac{\partial J(a)}{\partial a} \cong \Delta J(a)$$

La ecuación 2.10 quedaría de la siguiente manera:

$$a_n = a_{n-1} - \alpha \Delta J(a) \quad (2.5)$$

De donde la variación de la función de costo se la calcula con la siguiente ecuación:

$$\Delta J(a) = J(a + \varepsilon) - J(a - \varepsilon)$$

Donde:

- ε : incremento por lo general pequeño e igual al aprendizaje.
- $J(a + \varepsilon)$: función de costo en incremento.
- $J(a - \varepsilon)$: función de costo en decremento.

Función de Membresía: también conocidas como funciones de pertenencia, son gráficas que permiten conocer el grado de pertenencia que tiene un elemento dentro de un conjunto difuso. Permiten realizar el proceso de fuzzificación.

Las diferentes funciones de membresía que suelen emplearse para el proceso de fuzzificación son las siguientes:

- **Función de pertenencia triangular:** se especifica mediante tres parámetros $\{a, b, c\}$ que representan los vértices de la función. Por lo general, es muy empleada en control inteligente.

$$\mu_{a,b,c}(x) = \begin{cases} 0, & \text{si } x < a \\ \frac{x-a}{b-a}, & \text{si } a \leq x \leq b \\ \frac{c-x}{c-b}, & \text{si } b \leq x \leq c \\ 0, & \text{si } c < x \end{cases} \quad (2.6)$$

- **Función de pertenencia trapezoidal:** para ser definida necesita de cuatro parámetros {a, b, c, d}, los mismos que representan los vértices de la función.

$$\mu_{a,b,c,d}(x) = \begin{cases} 0, & \text{si } x \leq a \\ \frac{x-a}{b-a}, & \text{si } a \leq x \leq b \\ 1, & \text{si } b \leq x \leq c \\ \frac{d-x}{d-c}, & \text{si } c \leq x \leq d \\ 0, & \text{si } d \leq x \end{cases}$$

- **Función de pertenencia bell-shaped:** se define mediante tres parámetros {a, b, c}, donde su forma es como una campana.

$$\mu_{a,b,c,d}(x) = \frac{1}{1 + \left| \frac{x-c}{a} \right|^{2b}}$$

- **Función de pertenencia sigmoideal:** se define mediante dos parámetros {a, c}

$$\mu_{a,c}(x) = \frac{1}{1 + e^{[-a(x-c)]}}$$

A continuación, en la Figura 4-2 se presenta las cuatro funciones de membresía que se mencionaron anteriormente:

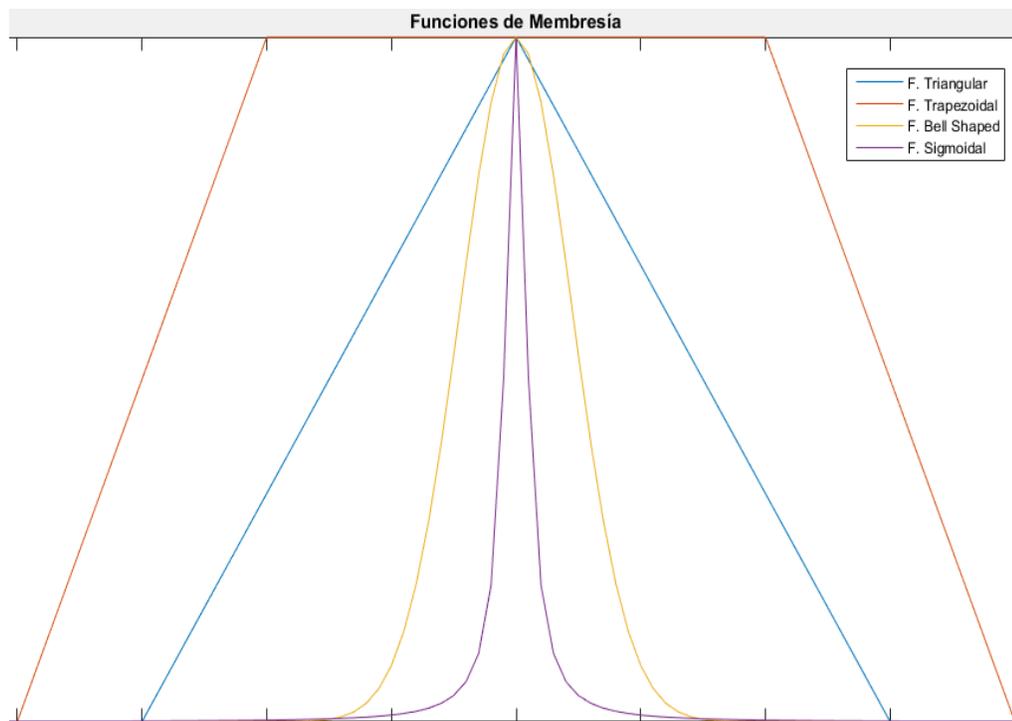


Figura 4-2: Gráfica de las Funciones de Membresía.

Realizado por: Morocho, Andrés, 2018

Existe una gran clase de problemas para los que la inteligencia humana es más rápida y eficiente que el procesamiento de la mejor computadora actual. Sin embargo, tratando de atacar estas deficiencias en la forma de resolver problemas tradicionales surgieron áreas como Lógica difusa, redes neuronales artificiales, la combinación de las dos y otras herramientas que se suelen agrupar en el concepto de Inteligencia Artificial. (Alvarado & Villamar, 2010).

2.2.3. *Redes Neuronales*

Widrow define a las redes neuronales como un sistema con entradas y salidas que está compuesta de muchos elementos de procesamiento similares. Cada elemento de procesamiento tiene un número de pesos sinápticos o simplemente pesos. Ajustando los pesos de un elemento se puede cambiar el comportamiento del mismo y, por lo tanto, puede también alterar el comportamiento total de la red para alcanzar la relación de entrada-salida deseada. Este último proceso es conocido como entrenamiento de la red (Nguyen & Widrow, 1990). En la Figura 5-2 se puede observar un esquema de una red neuronal.

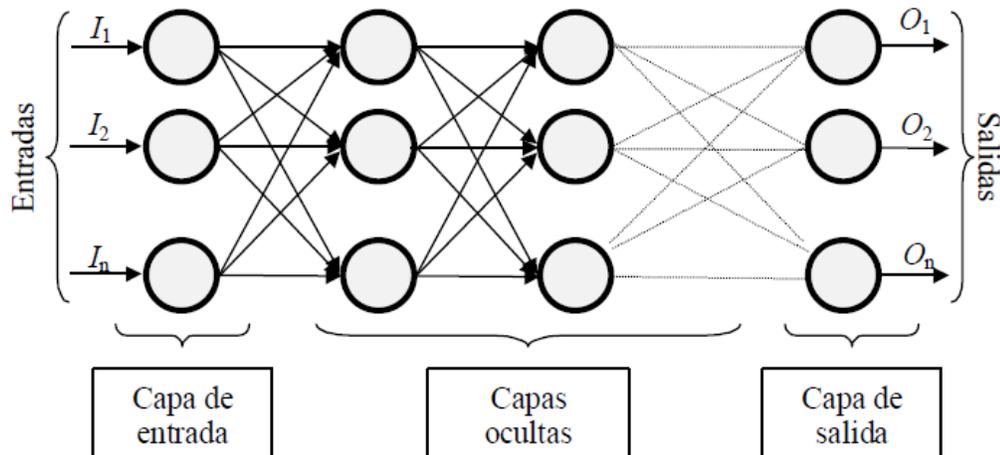


Figura 5-2: Ejemplo de una red neuronal totalmente conectada.

Realizado por: Morocho, Andrés, 2018

Una red neuronal artificial (RNA) está constituida por neuronas interconectadas y arregladas en tres capas (esto último puede variar). Los datos ingresan por medio de la “capa de entrada”, pasan a través de la “capa oculta” y salen por la “capa de salida”. Cabe mencionar que la capa oculta puede estar constituida por varias capas. (Ruiz, 2001)

Existen dos tipos fundamentales de RNA: Redes Estáticas o Feed Forward (RNFF) y Redes Recurrentes o Dinámicas (RNR). En las RNFF, todas las señales neuronales se propagan hacia adelante. No existen conexiones hacia atrás y normalmente tampoco autorrecurrentes, ni laterales y son especialmente útiles en tareas de reconocimiento o clasificación de patrones. (Hilera & Martínez, 1995)

2.2.4. Sistema Neuro Difuso con Inferencia TSK

Conocido también como modelo difuso TSK, que fue propuesto por Takagi, Sugeno y Kang, tiene la forma:

$$\mathbf{IF\ x\ es\ A\ AND\ y\ es\ B\ THEN\ z = f(x,y)}$$

Donde:

- A, B: es un conjunto difuso en la parte del antecedente.
- $z = f(x,y)$: es una función en la parte del consecuente.
- x,y: variables de entrada.

Normalmente $f(x,y)$ es un polinomio cualquiera que describe apropiadamente la salida del modelo dentro de la región difusa especificada por el antecedente de la regla. Si f es una constante, entonces se tiene un “Modelo Difuso Sugeno de orden cero”; si este polinomio es de primer orden, el sistema de inferencia difuso resultante es llamado “Modelo Difuso Sugeno de primer orden”.

Sugeno establece, en lugar de usar funciones, emplear un valor para cada regla; estos valores se conocen como singletons y su dominio está sobre el dominio de la variable de salida. (Takagi & Sugeno, 1985)

En este tipo de sistemas no existe la defuzzificación porque los singletons tienen valores determinados, así que la etapa de agregación solo se realiza mediante el promedio ponderado de las reglas con los singletons. (Retana & Vargas, 2000)

$$\text{salida} = \frac{\sum_{i=1}^N w_i c_i}{\sum_{i=1}^N w_i} \quad (2.7)$$

Donde:

- w_i : es la evaluación de la regla (pesos).
- c_i : es el valor del singleton.
- N : número de reglas.

Por lo tanto, el número de singletons es igual al número de reglas definidas. El uso de singletons es muy conveniente para implementar un sistema difuso en un microcontrolador porque no se requiere hacer un procesamiento fuerte. (Retana & Vargas, 2000)

Los controladores difusos TSK usualmente necesitan un menor número de reglas porque su salida ya es una función lineal de las entradas en vez de un conjunto difuso constante. La base de reglas difusas usualmente se construye manualmente o mediante técnicas de adaptación automática. (García & Villamizar, 2005)

Por otro lado, es muy común la aplicación del método de Mamdani porque se presta más a la representación de conocimiento experto, descrito de una forma intuitiva. Sin embargo, el principal inconveniente es su alto coste computacional, por lo que para aplicaciones de control y problemas de optimización se emplea más frecuentemente el método de inferencia TSK.

2.2.5. Arquitectura del Regulador Neuro Difuso

En la Figura 6-2 se puede observar la estructura de este regulador para un sistema de dos variables de entrada “X” e “Y” y una salida “Z”.

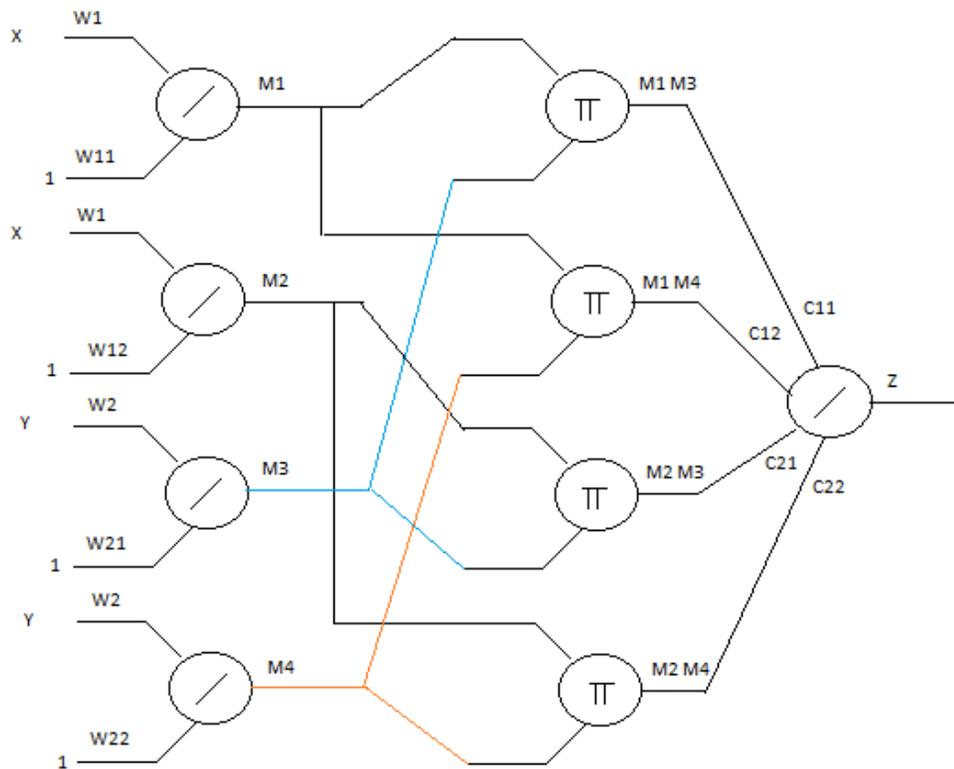


Figura 6-2: Estructura del Sistema Neuro Difuso.
 Realizado por: Morocho, Andrés, 2018

Se puede observar en la Figura 6-2 una capa de entrada que conlleva a obtener la fuzzificación y el grado de verdad respecto a cada función de pertenencia implementando neuronas lineales. Es decir, esa primera capa permite vincularlo para seguir utilizando las ventajas de las redes neuronales en una aplicación estructurada en otra capa asociada, llamada productoria. Ésta da paso al grado de verdad de cada una de las reglas, las mismas que obtienen un ponderado de los diferentes pesos de la capa de salida (capa lineal), constituida por una neurona que son, precisamente, los singletones de un sistema difuso.

Cabe destacar que la parte adaptativa de este sistema neuronal, que reproduce el comportamiento de un sistema difuso, se da en la fase de aprendizaje ya sea con cualquier técnica de minimización del error cuadrático como es, en este caso, el gradiente decreciente, para que los singletones se ajusten en función del desempeño deseado. Finalmente, una vez logrado todo esto, los pesos de la estructura neuronal no varían solamente las entradas y salidas que responden a una realidad del entorno del regulador.

Un modelo Takagi Sugeno Kang de orden cero viene definido en la ecuación (2.7) y al aplicar un solapamiento de dos funciones de pertenencia, se reduce a la siguiente forma:

$$Y_c = \sum_{i=1}^N w_i C_i \quad (2.8)$$

Para el caso de dos entradas, la ecuación (2.8) se abre de la siguiente manera:

$$Y_c = w_1 w_3 C_{11} + w_1 w_4 C_{12} + w_2 w_3 C_{21} + w_2 w_4 C_{22} \quad (2.9)$$

La ecuación (2.9) representa la salida de la tercera capa (lineal), la misma que define a la salida del sistema neurodifuso y que en la Figura 6-2 se denomina con la letra Z.

Los factores de pertenencia están definidos de la siguiente manera:

$$M_1 = \frac{X_{\max} - X}{X_{\max} - X_{\min}} ; M_2 = \frac{X - X_{\min}}{X_{\max} - X_{\min}} ; M_3 = \frac{Y_{\max} - Y}{Y_{\max} - Y_{\min}} ; M_4 = \frac{Y - Y_{\min}}{Y_{\max} - Y_{\min}}$$

Para los pesos de la entrada de la primera capa se definen a continuación:

$$W_1 = \frac{1}{X_{\max} - X_{\min}} ; W_{11} = \frac{X_{\max}}{X_{\max} - X_{\min}} ; W_{12} = \frac{X_{\min}}{X_{\max} - X_{\min}}$$

$$W_2 = \frac{1}{Y_{\max} - Y_{\min}} ; W_{21} = \frac{Y_{\max}}{Y_{\max} - Y_{\min}} ; W_{22} = \frac{Y_{\min}}{Y_{\max} - Y_{\min}}$$

En la primera capa (llamada lineal) se realizan las operaciones necesarias para calcular los factores de pertenencia. En la segunda capa (llamada productoria) se realiza la multiplicación entre los factores de pertenencia con los singletons correspondientes al sistema difuso.

2.2.6. *Aplicaciones del Control Inteligente*

En un artículo presentado por Santos, “Aplicaciones Exitosas de Control Inteligente a Casos Reales”, da a conocer seis trabajos reconocidos, donde se aplican las técnicas de redes neuronales con la lógica difusa, los cuales se mencionan a continuación (Santos, 2011):

- **Control inteligente de un criostato:** esta aplicación fue realizada en la University of Oxford, donde se busca controlar la temperatura de un criostato, un dispositivo que trabaja con helio y permite observar propiedades ópticas de diversos materiales. El trabajo consiste en realizar una estructura de control utilizando un controlador borroso de ganancia programada y para las distintas regiones de operación un controlador PID para cada zona de altas temperaturas. Continuando con las investigaciones finalmente aplicaron a este sistema un control neuro difuso adaptativo, en este caso el controlador aprende la entrada a la planta mediante un algoritmo de aprendizaje para seguir la trayectoria predefinida.
- **Control inteligente de las aceleraciones verticales de un ferry:** el proyecto se basa en reducir las aceleraciones verticales de un buque de alta velocidad ya que son principales causantes de la fatiga y el mareo. Para realizar el modelado se han aplicado técnicas de inferencia borrosa con aprendizaje. Finalmente, para la parte de control utilizaron un controlador PID borroso tipo Sugeno; además, se adaptó el control con ganancias no constantes, ajustado mediante algoritmos genéticos.
- **Control inteligente de un cuatri-rotor:** el objetivo de este proyecto es que, el helicóptero de cuatro rotores, autónomo aterrice y despegue desde una plataforma móvil, un barco, para tareas de vigilancia, búsqueda y rescate en el mar. Se ha diseñado cuatro controladores PID borrosos para la altura y los tres ángulos que definen la trayectoria. Además, han desarrollado un bloque agregador mediante lógica borrosa para que promedie la fuerza de cada motor.
- **Control inteligente de satélites en los puntos de Lagrange:** se ha desarrollado el control de posición de satélites en los cinco puntos de libración de Lagrange del sistema Tierra-Luna mediante reguladores P y PD borrosos.

- **Control inteligente en agricultura de precisión:** se trata del ajuste adecuado de la dosis de fitosanitario que requiere el desarrollo de un sistema en tiempo real, acoplado al tractor que lo va derramando. Para lo cual desarrollaron un sistema de visión artificial para la apertura y cierre de las distintas secciones de la barra del tractor por la que sale el líquido.
- **Control inteligente de un puente grúa:** consiste en el control de posición de una grúa pórtico o puente grúa para lo que utilizaron las estrategias de la inteligencia artificial como son las redes neuronales. En el modelamiento aplicaron linealización por realimentación del sistema usando redes neuronales como Layered Digital Dynamic Network, que son redes de tipo perceptrón multicapa con una línea de retardos para que sean dinámicas.

CAPÍTULO III

3. METODOLOGÍA DE INVESTIGACIÓN

En el presente capítulo se describe cada uno de los pasos a seguir para la realización de la investigación, en el cual se desarrolla el modelo matemático para la modelación del sistema a controlar, el diseño del regulador neurodifuso adaptativo y su correspondiente diagrama de flujo en vista de cumplir con los objetivos planteados al inicio de este trabajo de titulación para más adelante demostrar la hipótesis planteada.

3.1. Identificación de la Planta

Para realizar el modelo de la planta, Quanser QNET 2.0 Vertical Take-Off and Landing Board, será necesario conocer cómo se encuentra compuesta y los sensores que serán tomados en cuenta para la elaboración del regulador.

3.1.1. *Hardware del Sistema de la Planta*

La Quanser QNET 2.0 Vertical Take-Off and Landing Board (VTOL), que se presenta en la Figura 1-3. Ésta es un sistema versátil diseñado para enseñar y demostrar una variedad de experimentos. La planta consta con un ventilador de corriente continua de alto flujo de aire y un encóder rotacional digital que es utilizado para medir la posición angular.



Figura 1-3: Quanser QNET 2.0 Vertical Take-Off and Landing Board para el NI ELVIS II.
Fuente: (NI Quanser, 2014)

Las características principales de QNET VTOL son:

- Sistema compacto y completo de despegue y aterrizaje vertical.
- Ventilador DC de alto flujo de aire.
- Encóder óptico de alta resolución montado en el pivote.
- Amplificador PWM incorporado.

Generalmente, la planta funciona interconectada con el NI ELVIS II, pero en el presente trabajo de titulación sólo se empleará la estructura física que simula el vuelo vertical y se construirá la electrónica necesaria para la adaptación de la señal del encóder y el driver del motor.

El QNET VTOL incluye un ventilador de 24 V y 11000 rpm, modelo “Sanyo Denki SanAce 60 G” con serie “9G0624P4S00(0011)”.

El encóder de eje óptico es usado para medir la posición angular del brazo QNET VTOL, el mismo es de 2048 conteos por revolución en modo cuadratura y su modelo es “US Digital E8P-512-118”.

Para el driver del motor se utiliza un Shield L298N propio para Arduino, el cual mediante PWM simula una variación de voltaje en un rango entre 0 y 23 V. En la siguiente imagen se presenta este componente:

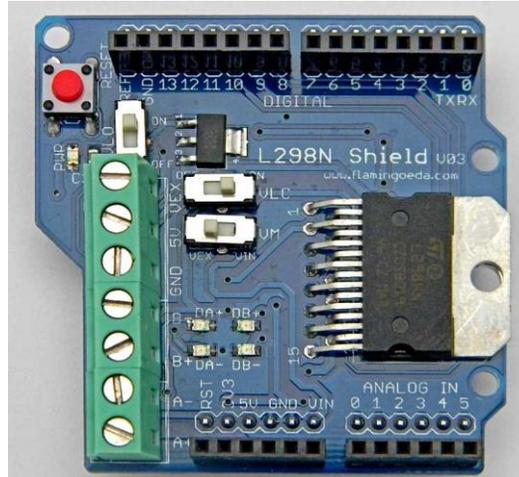


Figura 2-3: Tarjeta Shield L298N.
Realizado por: Morocho, Andrés, 2018

Los datos necesarios de la QNET VTOL para realizar una modelación matemática mediante ecuaciones diferenciales, se presenta en la siguiente tabla:

Tabla 1-3: Datos del sistema QNET VTOL

SÍMBOLO	DESCRIPCIÓN	VALOR
Montaje VTOL		
m_1	Masa del montaje del ventilador.	127 g
m_2	Masa de contrapeso.	258 g
m_3	Masa de la pieza de unión del contrapeso con el ventilador (link body).	60 g
l_1	Longitud desde el pivote hasta el centro del ventilador.	155 mm
l_2	Longitud desde el pivote hasta el centro del contrapeso.	72.5 mm
l_3	Longitud desde el pivote hasta el centro del link body.	7 mm
B	Estimación del amortiguamiento viscoso del pivote.	0.002 Nm/(rad/s)
Encóder del pivote		
Conteo de línea del encóder		512 líneas/rev
Conteo de línea del encóder en cuadratura		2048 líneas/rev
Resolución del encóder (en cuadratura)		0.176 deg/count

Realizado por: Morocho, Andrés, 2018

3.1.2. Torques que actúan sobre el QNET VTOL

El diagrama de cuerpo libre de la Quanser QNET 2.0 VTOL Board, que gira alrededor de su propio eje, se muestra en la siguiente imagen.

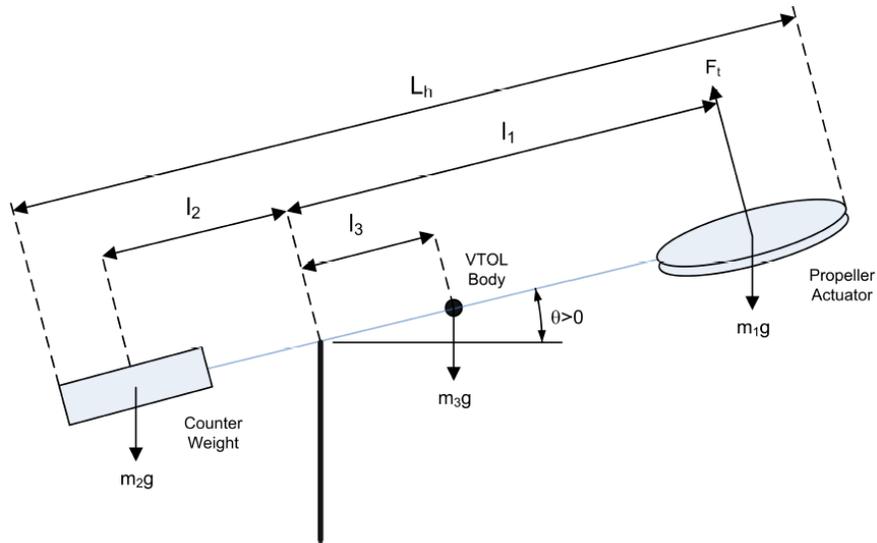


Figura 3-3: Diagrama de cuerpo libre del QNET VTOL.
Fuente: (NI Quanser, 2014)

Como se puede deducir de la Figura 3-3, el torque resultante (τ) sobre el sistema puede ser descrito por la siguiente ecuación:

$$\tau_t + m_2gl_2 \sin \theta - m_1gl_1 \sin \theta - m_3gl_3 \sin \theta = \tau \quad (3.1)$$

La fuerza de empuje F_t , es generada por la hélice y actúa perpendicular al conjunto del ventilador. El par de empuje está dado por:

$$\tau_t = F_t l_1$$

La ecuación (3.1) quedaría de la siguiente manera:

$$F_t l_1 + m_2gl_2 \sin \theta - m_1gl_1 \sin \theta - m_3gl_3 \sin \theta = \tau \quad (3.2)$$

Como se puede ver en la ecuación (3.2) el par de empuje generado por la hélice y el par gravitacional del contrapeso actúan en la misma dirección y se oponen a los pares gravitacionales del link body (barra horizontal) y el peso del ventilador.

Por lo tanto, reemplazando los datos de la tabla (3-1) en la ecuación (3.2)

$$0.155F_t + 0.258(9.8)(0.0725) \sin \theta - 0.127(9.8)(0.155) \sin \theta - 0.06(9.8)(0.007) \sin \theta = \tau$$

$$\tau = 0.155F_t + 0.183309 \sin \theta - 0.192913 \sin \theta - 0.004116 \sin \theta \quad (3.3)$$

3.1.3. Ecuación de Movimiento

Los movimientos angulares del QNET VTOL con respecto al torque de empuje τ_t se expresa con la ecuación:

$$\sum \tau - B\dot{\theta} = I\alpha \quad (3.4)$$

Donde:

- θ : es el ángulo de inclinación.
- I: es equivalente al momento de inercia rotacional actuando alrededor del eje.
- B: es el amortiguamiento viscoso.
- τ : es el torque resultante
- α : es la aceleración angular.

Como la aceleración angular es la doble derivada de la posición angular “ θ ”, por lo tanto, la expresión (3.4) se la puede definir de la siguiente manera:

$$\sum \tau - B\dot{\theta} = I\ddot{\theta} \quad (3.5)$$

Para encontrar el momento de inercia del sistema será necesario encontrarlo por partes. Primero se calculará la I del ventilador y del contrapeso considerando como masas puntuales, para ello será necesario emplear la siguiente ecuación:

$$I = \sum_{i=1}^n m_i r_i^2 \quad (3.6)$$

Donde:

- m: es la masa.
- r: es la posición.

Entonces el momento de inercia del ventilador quedaría definido de la siguiente manera:

$$I_v = 0.127(0.155)^2 = 305.118 \times 10^{-5} \text{ [kg m}^2\text{]}$$

El momento de inercia del contrapeso se lo calcula a continuación:

$$I_c = 0.258(0.0725)^2 = 135.611 \times 10^{-5} \text{ [kg m}^2\text{]}$$

Para la barra horizontal, el momento de inercia se calcula como un sistema continuo mediante la siguiente integral:

$$I_b = \int r^2 dm \quad (3.7)$$

Donde:

- r: es la posición.
- dm: es un diferencial de masa.

El momento de inercia de una barra rectangular con su eje de rotación desplazado de su centro se puede calcular con la ecuación (3.7), la misma que se reduce a continuación:

$$I_b = \frac{1}{12} M(a^2 + b^2) + Mx^2 \quad (3.8)$$

Donde:

- M: es la masa del objeto.
- a: es el largo.
- b: es el ancho.

- x : es la distancia que se desplaza desde el centro del objeto a cualquier otro punto.

Como se puede notar no es necesario el grosor de la barra horizontal para calcular el momento de inercia. Las medidas de largo, ancho y profundidad de la barra horizontal tienen las siguientes dimensiones, $a=21.4$ cm, $b=2$ cm y $c=3.2$ mm, respectivamente. Es necesario tener muy en cuenta que el eje de rotación está desplazado 1.7 cm del centro de la barra, la masa de la barra se ubica en la tabla (3.1). Con estos datos la ecuación (3.8) se reduce a continuación:

$$I_b = \frac{1}{12} 0.06(0.214^2 + 0.02^2) + 0.06(0.017^2) = 24.832 \times 10^{-5} \text{ [kg m}^2\text{]}$$

Por lo tanto, la inercia de todo el sistema se calcula sumando cada una de las anteriores

$$I = 305.118 \times 10^{-5} + 135.611 \times 10^{-5} + 24.832 \times 10^{-5} = 465.561 \times 10^{-5} \text{ [kg m}^2\text{]} \quad (3.9)$$

Reemplazando las ecuaciones (3.3) y (3.9) en la ecuación (3.5):

$$0.155F_t + 0.183309 \sin \theta - 0.192913 \sin \theta - 0.004116 \sin \theta - 0.002\ddot{\theta} = 465.561 \times 10^{-5} \ddot{\theta}$$

Ordenando los elementos la ecuación de movimiento se define de la siguiente manera:

$$465.561 \times 10^{-5} \ddot{\theta} + 0.002\dot{\theta} + 0.004116 \sin \theta + 0.192913 \sin \theta - 0.183309 \sin \theta = 0.155 F_t \quad (3.10)$$

Para linealizar se la realizará con series de Taylor en un punto de equilibrio ($\theta = 66$). Este valor es adquirido de acuerdo al reposo que presenta el QNET VTOL cuando no recibe energía eléctrica.

$$\Delta f = \frac{\partial f}{\partial \ddot{\theta}} \Delta \ddot{\theta} + \frac{\partial f}{\partial \dot{\theta}} \Delta \dot{\theta} + \frac{\partial f}{\partial \theta} \Delta \theta - \frac{\partial f}{\partial F_t} \Delta F_t = 0$$

Aplicando la linealización a la ecuación (3.10)

$$\Delta f = 465.561 \times 10^{-5} \Delta \ddot{\theta} + 0.002 \Delta \dot{\theta} + [0.004116 \cos(66) + 0.192913 \cos(66) - 0.183309 \cos(66)] \Delta \theta - 0.155 \Delta F_t$$

Reduciendo los términos, la ecuación linealizada quedará:

$$465.561 \times 10^{-5} \Delta \ddot{\theta} + 0.002 \Delta \dot{\theta} + 558.0426(10^{-5}) \Delta \theta = 0.0725 \Delta F_t \quad (3.11)$$

3.1.4. Función de Transferencia del Proceso

La función de transferencia, que representa a la posición con respecto a la fuerza de empuje, de la ecuación (3.11) del QNET VTOL es:

$$G(s) = \frac{\Delta \theta}{F_t} = \frac{0.0725}{465.561 \times 10^{-5} s^2 + 0.002 s + 558.0426(10^{-5})} \quad (3.12)$$

Simplificando la ecuación (3.12) queda:

$$G(s) = \frac{7250}{465.561 s^2 + 200 s + 558.0426}$$

$$G(s) = \frac{15.57}{s^2 + 0.43 s + 1.2} \quad (3.13)$$

Se puede observar que la ecuación (3.13) representa a un modelo de segundo orden y del tipo cero. Por ende, el denominador tiene la siguiente forma:

$$s^2 + 2\zeta\omega_n s + \omega_n^2 \quad (3.14)$$

Donde:

- ζ : es el coeficiente de amortiguamiento.
- ω_n : es la frecuencia natural.

Por lo tanto, es posible encontrar la frecuencia natural del sistema identificado:

$$\omega_n = \sqrt{1.2} = 1.095 \text{ rad} \quad (3.15)$$

Mientras que el coeficiente de amortiguamiento del sistema quedará:

Una vez adquiridos los datos en un archivo de Excel se los procesa en Matlab. De acuerdo a lo que dice la Teoría de Control para sistemas de segundo orden es muy común emplear un margen de error del $\pm 2\%$ para determinar el tiempo de estabilización de la planta en lazo abierto; con este criterio el sistema es estable a los 7.77 segundos (s). La sobre oscilación (M_p) se encuentra restando el máximo valor de la respuesta del sistema (Y) y el valor de la respuesta del sistema en estado estacionario, que en este caso es de 0.5.

Es necesario aclarar que en esta ocasión no fue necesario aplicar un filtro para el procesamiento de los datos adquiridos del encóder porque es un dispositivo digital y no analógico.

Con este valor de sobre oscilación se puede calcular el coeficiente de amortiguamiento, como se indica a continuación:

$$\xi = \frac{|\ln M_p|}{\sqrt{\pi^2 + (\ln M_p)^2}} = \frac{|\ln 0.5|}{\sqrt{\pi^2 + (\ln 0.5)^2}} = 0.2155$$

Como se puede observar se trata de una planta subamortiguada y al considerar el criterio del 2%, se emplea la siguiente fórmula para calcular la frecuencia natural del sistema:

$$\omega_n = \frac{4}{\xi t_{ss}} = \frac{4}{(0.2155)(7.77)} = 2.3894$$

Una vez obtenido estos dos parámetros se puede construir un modelo inicial de la planta que se desea controlar:

$$G(s) = \frac{K}{s^2 + 2\xi\omega_n s + (\omega_n)^2} = \frac{5.709}{s^2 + 1.029 s + 5.709}$$

Como ya se tiene el modelo inicial se puede continuar con el algoritmo que se programó para mejorarlo mediante la técnica del gradiente decreciente, tomando como función de costo el valor

absoluto del error y se lo presenta en el ANEXO A. En el momento de ejecutarlo muestra el siguiente gráfico donde se puede visualizar los datos adquiridos y el modelo obtenido:

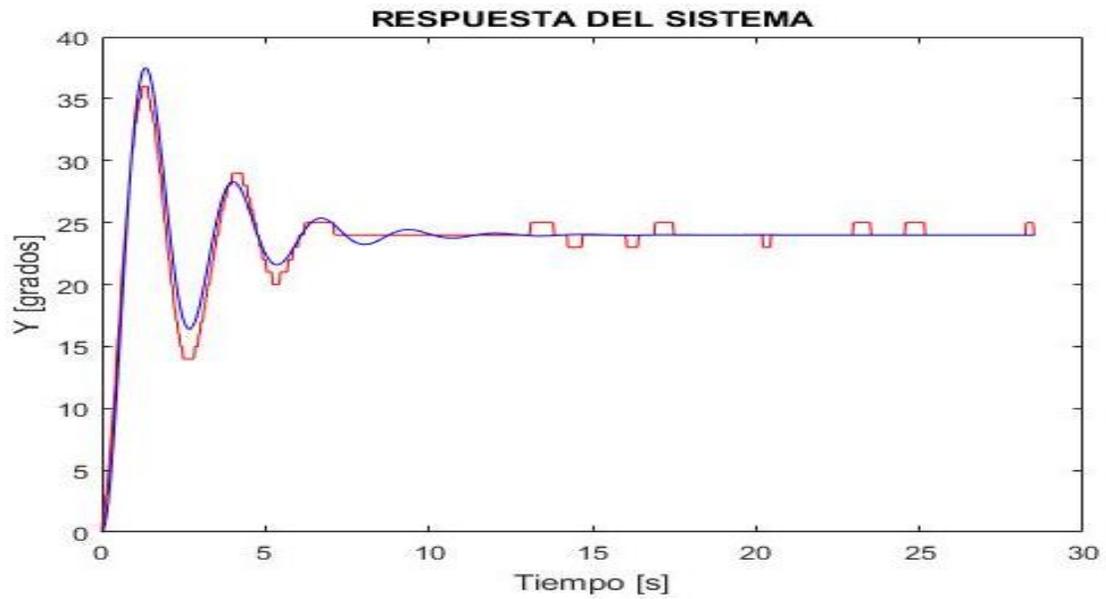


Figura 5-3: Gráfica entre los datos adquiridos (línea roja) y el modelo encontrado (línea azul).
Realizado por: Morocho, Andrés, 2018

La evolución de la función de costo se la puede observar en el siguiente gráfico:

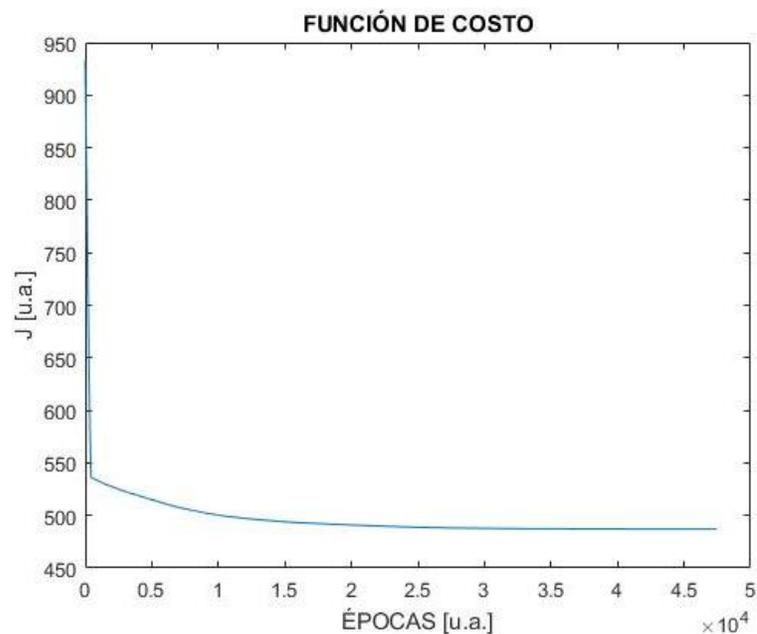


Figura 6-3: Variación de la función de costo.
Realizado por: Morocho, Andrés, 2018

Dicho algoritmo de identificación presenta la siguiente función de transferencia, que relaciona la posición del elemento terminal con el PWM de aplicación al motor; presentándose un error cuadrático medio, MSE=0.79:

$$g = \frac{2.355}{s^2 + 0.858 s + 5.692}$$

De igual manera para modelar un sistema se puede ayudar con las herramientas que presenta el software de Matlab, como es el *System Identification*. Donde es necesario ingresar el valor del escalón de la entrada, en este caso 60 (PWM), y la respuesta de la planta junto con el tiempo de muestreo, que para este caso de estudio fue el mismo tiempo de delay de espera de la tarjeta de adquisición, 0.03 segundos. En Figura 7-3 se presenta la configuración de los parámetros mencionados anteriormente:

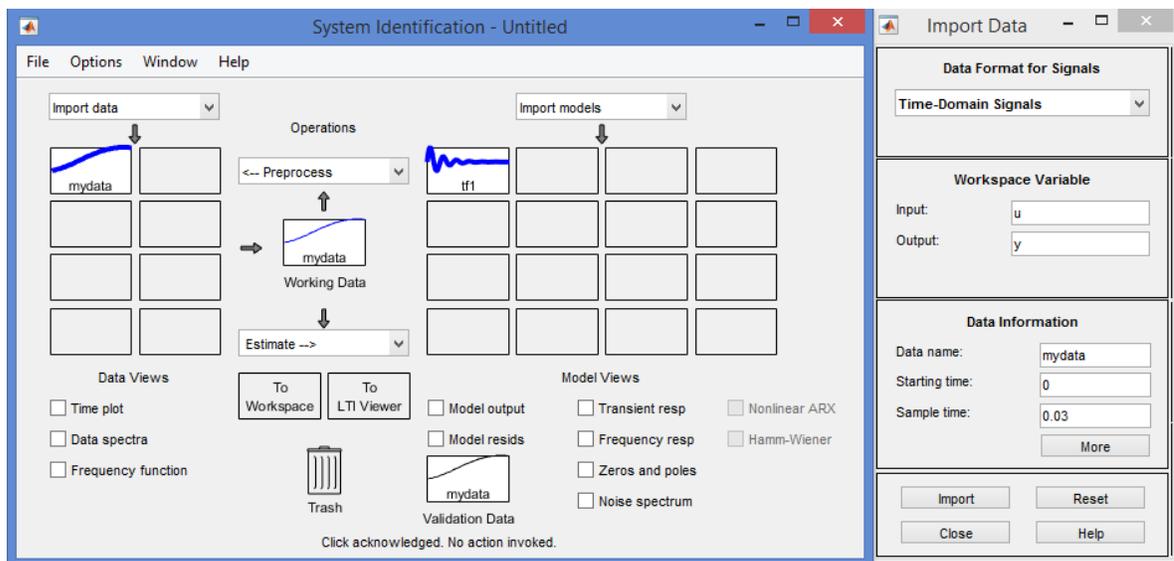


Figura 7-3: Importación de datos al System Identification
Realizado por: Morocho, Andrés, 2018

Al momento de modelar el mismo software le permite escoger cuantos polos y ceros desea que tenga el sistema a identificarse. Anteriormente, en este estudio se dedujo que el modelo debe constar de dos polos porque se trata de un sistema de segundo orden.

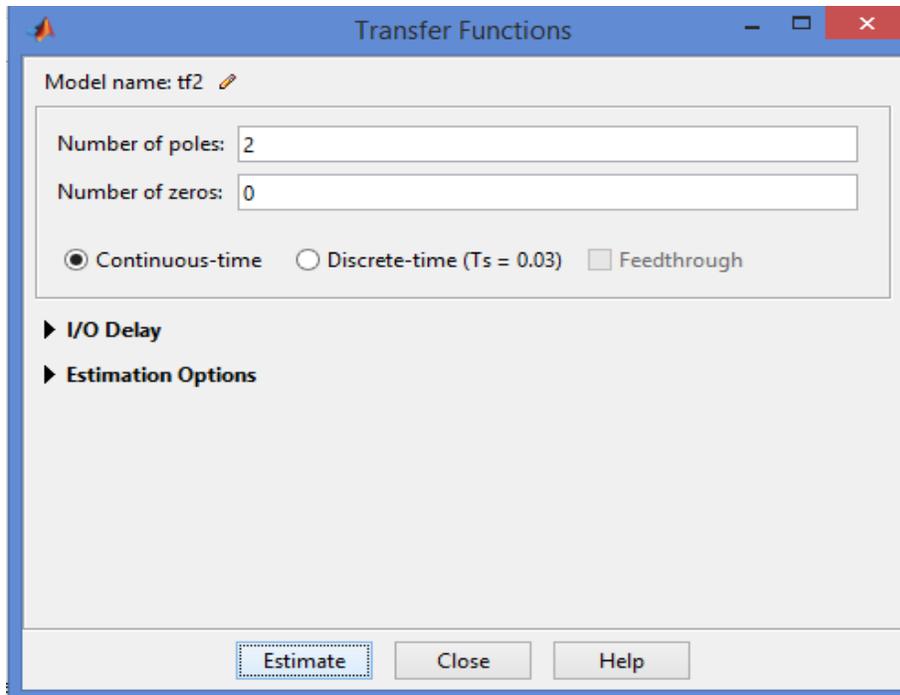


Figura 8-3: Estimación de la cantidad de polos y ceros del sistema a modelar.
 Realizado por: Morocho, Andrés, 2018

El propio Matlab entrega la siguiente función de transferencia, indicando que tiene un error cuadrático medio de 0.56.

```

From input "u1" to output "y1":
      2.256
-----
s^2 + 0.7406 s + 5.489

Name: tf1
Continuous-time identified transfer function.

Parameterization:
  Number of poles: 2   Number of zeros: 0
  Number of free coefficients: 3
  Use "tfdata", "getpvec", "getcov" for parameters and their uncertainties.

Status:
Estimated using TFEST on time domain data "mydata".
Fit to estimation data: 79.09% (stability enforced)
FPE: 0.5673, MSE: 0.5613

```

Figura 9-3: Función de transferencia obtenida en el System Identification
 Realizado por: Morocho, Andrés, 2018

Se puede comparar entre las dos funciones de transferencia y notar que no presenta mayor diferencia entre ellas. Aunque para el diseño del controlador se utilizará el modelo presentado por el System Identification porque presenta un menor error cuadrático medio.

3.2. Diseño del controlador PID

Para realizar el diseño del controlador se empleará el modelo de la planta con menor error cuadrático medio. Como el sistema no tiene una respuesta suave como una “S” en lazo abierto no se puede utilizar el primer método de Ziegler-Nichols “Respuesta al escalón”.

Tampoco se puede emplear el segundo método “Ganancia límite” porque la planta no se puede oscilar debido al término de primer orden que tiene en el denominador de su función de transferencia, el mismo que se presenta por el amortiguamiento viscoso del pivote.

Por esa razón se aplicará un autotuning para el diseño del controlador clásico. Una vez que ya se posee la función de transferencia, que representa la dinámica del QNET, se utilizará el “SISOTOOL” para el cálculo de las constantes que son necesarias para el PID.

En la siguiente imagen se puede observar el ajuste que se realiza para el diseño del controlador:

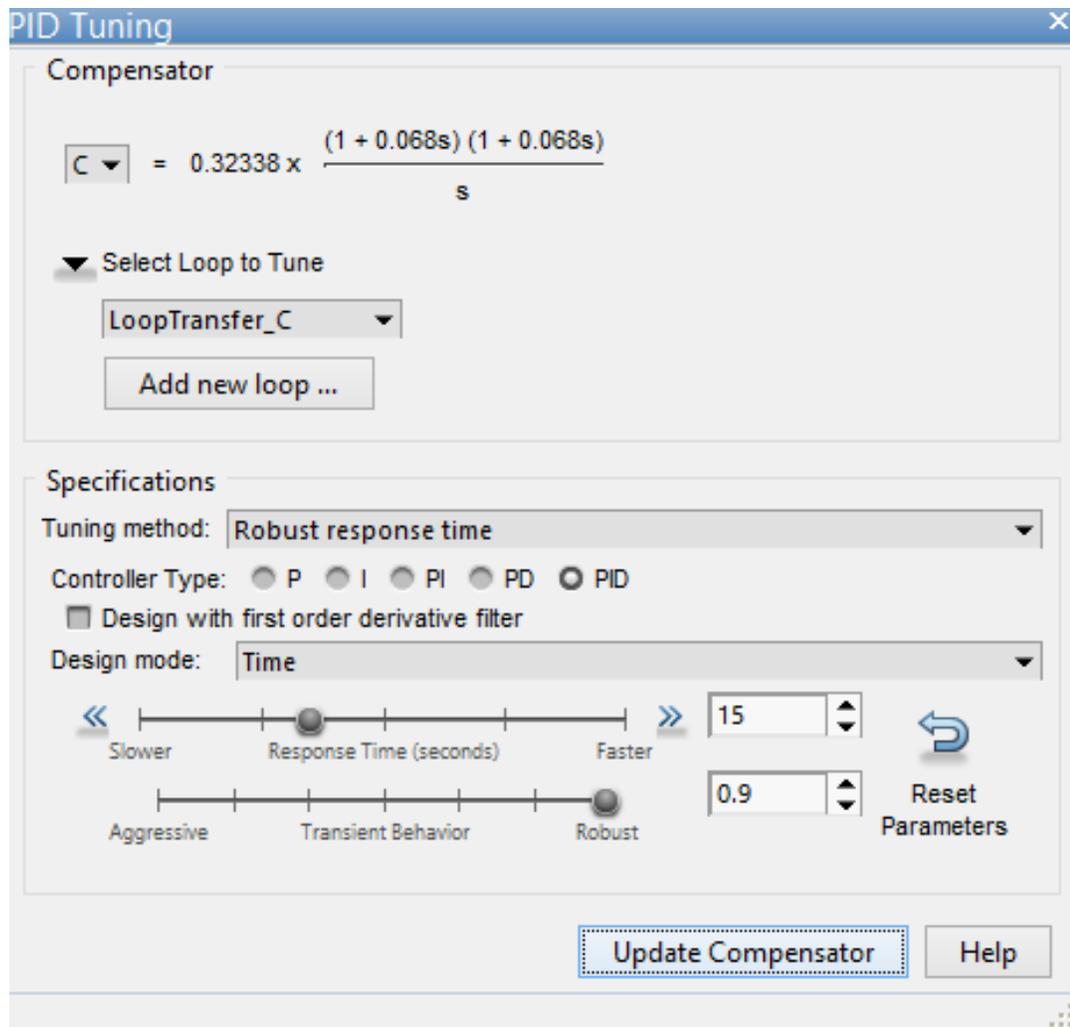


Figura 10-3: Ajuste para el diseño del PID
 Realizado por: Morocho, Andrés, 2018

En la Figura 10-3 se puede extraer el valor de las constantes para implementar el controlador PID.

$$C = 0.32338 \frac{(1 + 0.068s)(1 + 0.068s)}{s} \quad (3.17)$$

La ecuación 3.17 representa la función de transferencia del controlador PID que se puede reducir, presentándose de la siguiente forma:

$$C = 0.0014811 \frac{(s + 14.78)^2}{s} \quad (3.18)$$

La ecuación 3.18 se la puede representar en la misma forma de la ecuación 2.3 del capítulo dos.

$$C = 0.044 \left(1 + \frac{1}{0.14s} + 0.034s \right) \quad (3.19)$$

De la ecuación 3.19 se puede obtener de forma directa las tres constantes del controlador PID:

$$k_p = 0.044 ; T_i(\text{seg}) = 0.14 ; T_d(\text{seg}) = 0.034$$

En la siguiente figura se puede observar que el sistema reduce las oscilaciones en su etapa trasciente y el tiempo de estabilización es de 20 segundos aproximadamente. Y si se compara con el tiempo en lazo abierto pues se ve que ha incrementado, pero responde bastante bien ante perturbaciones.

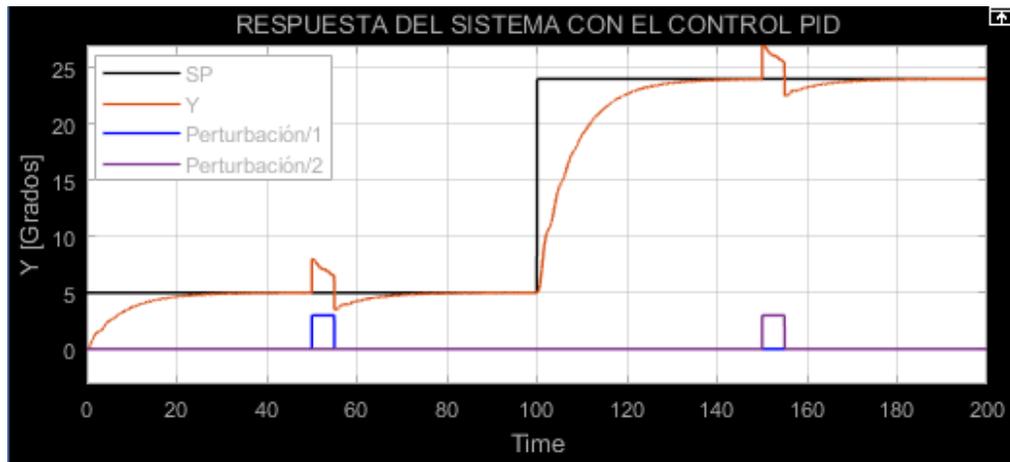


Figura 11-3: Respuesta del sistema con el controlador PID
Realizado por: Morocho, Andrés, 2018

Cabe indicar que inicialmente se aplica un set point de 5 grados, luego a los 50 segundos se aplica una perturbación de amplitud 3 con una duración de 5 segundos, después a los 100 segundos se emplea una referencia de 24 grados y, por último, se introduce una perturbación a los 150 segundos con una amplitud de 3 unidades y una duración de 5 segundos.

El diagrama de bloques del controlador PID clásico se lo presenta en la Figura 12-3, incluyendo las perturbaciones:

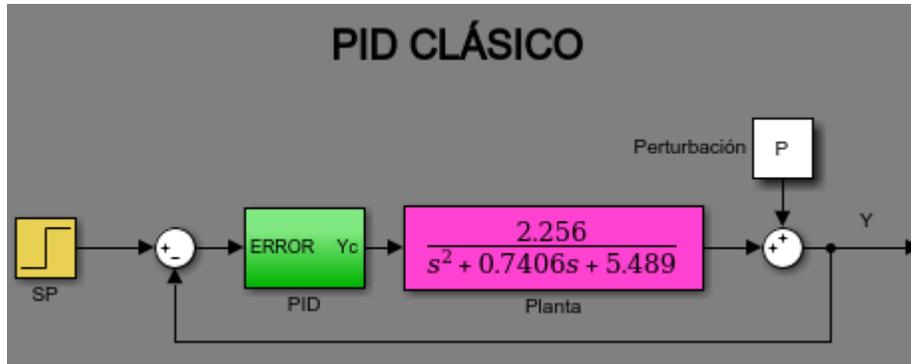


Figura 12-3: Diagrama de bloques del PID
 Realizado por: Morocho, Andrés, 2018

3.3. Controlador PID con ecuaciones en diferencia

El controlador PID clásico en el dominio del tiempo viene representado de la siguiente manera, como se presentó en el capítulo anterior:

$$u(t) = K_p \left[e(t) + \frac{1}{T_i} \int e(t)dt + T_d \frac{de(t)}{dt} \right] \quad (3.20)$$

Si a la ecuación (3.20) se le lleva al dominio de la frecuencia con la ayuda de la transformada de Laplace, quedaría de la siguiente manera:

$$U(s) = K_p \left[E(s) + \frac{1}{T_i} \frac{1}{s} E(s) + T_d s E(s) \right] \quad (3.21)$$

Para discretizar la ecuación (3.21) es necesario utilizar la transformada Z en forma matemática o también se puede emplear Euler en adelante, donde la derivada se expresa como la muestra actual menos la anterior dividida entre el tiempo de muestreo (T), llevando a ecuación se la representa de la siguiente manera:

$$s = \frac{1 - z^{-1}}{T} \quad (3.22)$$

El diagrama de bloques en Simulink de la discretización de la derivada de una señal con el método de Euler en adelante es la siguiente:

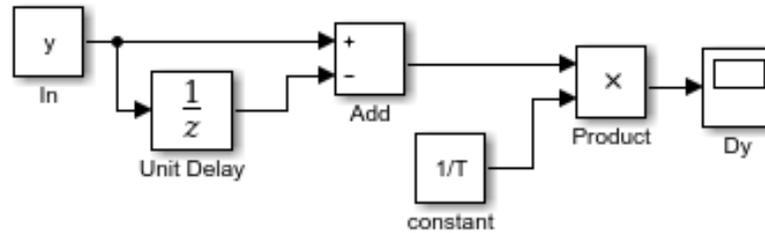


Figura 13-3: Diagrama de bloques en Simulink de Euler en adelante
Realizado por: Morocho, Andrés, 2018

Utilizando la ecuación (3.22) en (3.21), la ecuación del PID discretizada se la representa de la siguiente manera:

$$U(z) = K_p \left[E(z) + \frac{T}{T_i} \frac{E(z)}{1 - z^{-1}} + \frac{T_d}{T} (1 - z^{-1}) E(z) \right] \quad (3.23)$$

Si se continúa reduciendo la ecuación anterior:

$$U(z)(1 - z^{-1}) = K_p \left[E(z)(1 - z^{-1}) + \frac{T}{T_i} E(z) + \frac{T_d}{T} (1 - z^{-1})^2 E(z) \right]$$

Por último, se la puede dejar expresado de la siguiente manera:

$$U(z) - z^{-1}U(z) = K_p \left[E(z) - z^{-1} E(z) + \frac{T}{T_i} E(z) + \frac{T_d}{T} (1 - 2z^{-1} + z^{-2}) E(z) \right] \quad (3.24)$$

Para poder programar en cualquier lenguaje de programación es necesario llevar a una ecuación en diferencias, por lo tanto, es necesario aplicar la transformada z inversa:

$$u_k = u_{k-1} + K_p \left[e_k - e_{k-1} + \frac{T}{T_i} e_k + \frac{T_d}{T} (e_k - 2e_{k-1} + e_{k-2}) \right] \quad (3.25)$$

Como se puede observar en la ecuación anterior es necesario tener como entrada los siguientes parámetros:

- u_{k-1} : salida anterior del controlador.
- e_k : el error actual.
- e_{k-1} : el error anterior.
- e_{k-2} : el error hace dos muestras.

Una vez obtenida la ecuación en diferencias se procede a programar el controlador PID para la planta QNET VTOL, en este trabajo de titulación se utilizó el software de Labview que será el encargado de realizar toda la parte de control y el Arduino Uno se encargará únicamente de enviar el dato del sensor, mediante comunicación serial.

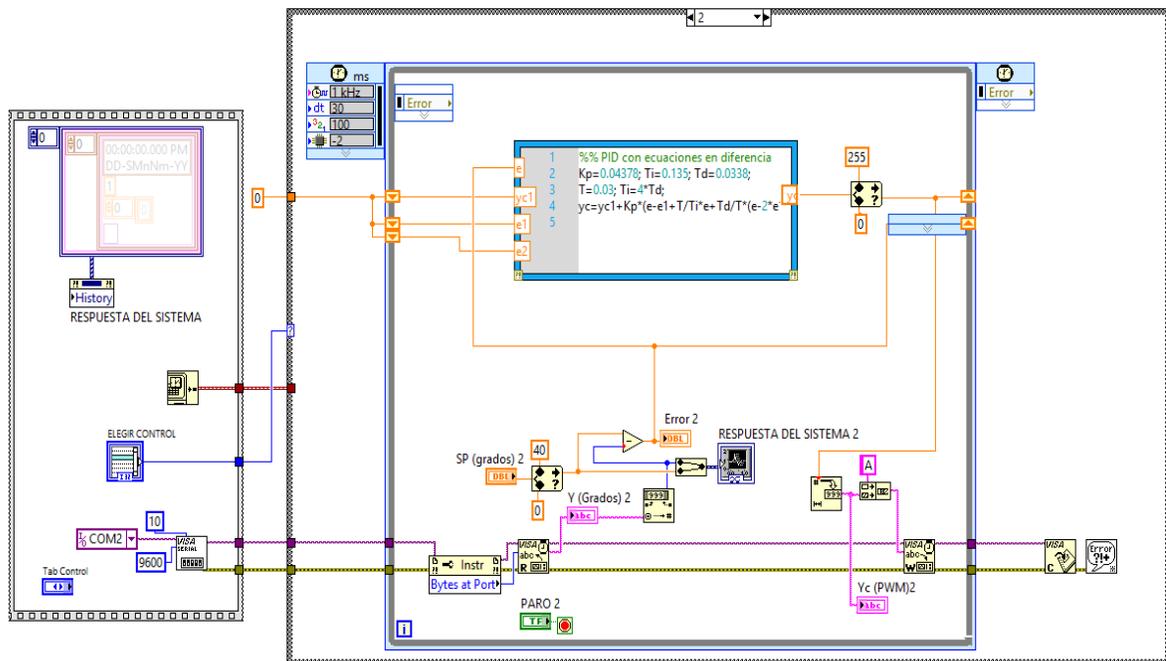


Figura 14-3: Controlador PID con ecuaciones en diferencias.
 Realizado por: Morochó, Andrés, 2018

3.4. Diseño del Regulador Neuro Difuso

Para el presente trabajo de titulación se pretende realizar, en primera instancia, el sistema neurodifuso con una inferencia borrosa del tipo Takagi Sugeno Kang orden cero. Ya que presenta una estructura de una red neuronal, de acuerdo a lo que se detalló en el capítulo 2, debido a que consta de capas y cada una de ellas con sus respectivas vías y pesos, para luego emplear el proceso de adaptabilidad en el aprendizaje y así encontrar el valor óptimo para cada uno de los singletons.

El modelo que se realiza es el PID de Ganancias Difusas o también llamado Control de Ganancias Programadas. Se basa en la inferencia borrosa TSK orden cero que se encarga de encontrar los valores óptimos de las constantes del controlador clásico y así lograr un mejor desempeño en el tiempo de estabilización de la planta de vuelo vertical. Su diagrama de bloques se lo presenta a continuación:

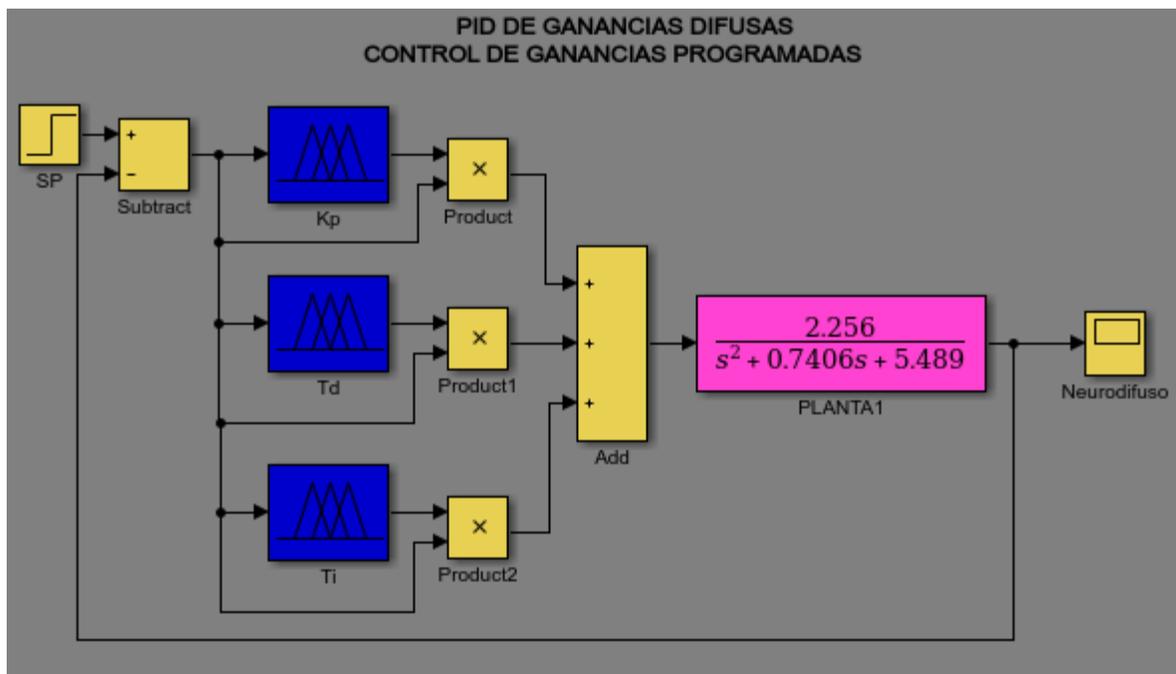


Figura 15-3: Diagrama de bloques de un PID de Ganancias Difusas

Realizado por: Morocho, Andrés, 2018

Entonces para diseñar el regulador neuro difuso, en primer lugar, se debe empezar identificando el universo de discurso del error. Como la planta tiene un rango de posición ([0 a 40] grados); por ende, el error tendrá un universo de discurso de [-40 a 40]. Este rango se lo define en este intervalo porque

al inicio cuando la planta está a cero grados y se pone un set point de la máxima posición, se tendría un error de cuarenta grados; en cambio cuando en esta posición se pone una referencia de cero grados, el error sería de menos cuarenta grados. Lo que se acaba de mencionar viene definido mediante la siguiente expresión:

$$\text{error} = \text{referencia} - \text{salida del sistema}$$

Luego es necesario encontrar los singletons para la constante K_p y T_d , donde se iniciará a partir de los valores de cada una de las variables del PID realizado en Matlab, para que después sea optimizado con el regulador Neurodifuso y empleando una función de costo que para este caso de estudio será el valor absoluto del error y la técnica del gradiente decreciente.

Las funciones de membresía utilizadas son funciones triangulares porque presentan un menor procesamiento computacional al momento de realizar operaciones matemáticas que incluyen, únicamente, sumas y multiplicaciones. Además, para el presente trabajo se utilizaron 10 funciones de membresía donde se obtuvo un mejor desempeño de la planta y que también si se aumentaba a partir de este valor no se presentaba ninguna diferencia en la respuesta del sistema, comportándose prácticamente igual.

Cabe recalcar que el mismo número de funciones de membresía corresponden al número de singletons, lo que de una forma abstracta representa el número de reglas utilizadas.

Para el presente estudio se utilizó el neurodifuso para la constante K_p y T_d ya que el T_i debe ser cuatro veces mayor que el tiempo derivativo, según Ziegler-Nichols y de acuerdo a como se indicó en el capítulo dos; además que permite tener un menor consumo computacional. Por esta razón se necesita los valores de los singletons para la constante proporcional y derivativa.

Entonces, se partió desde los valores iniciales de las constantes del controlador PID, calculados en el diseño del mismo. Luego se realiza una optimización de estos valores con la técnica del gradiente decreciente teniendo como función de costo, el valor absoluto del error. Por lo cual, con este procedimiento se trabajará con los siguientes rangos de valores:

$$0.01 \leq K_p \leq 0.25$$

$$0.1 \geq K_d \geq 0.001$$

Para implementar en la planta de vuelo vertical, es necesario simularlo para lo cual se utilizó Simulink y su diagrama de bloques de un PID de Ganancias Difusas se lo reduce como se muestra en la Figura 16-3:

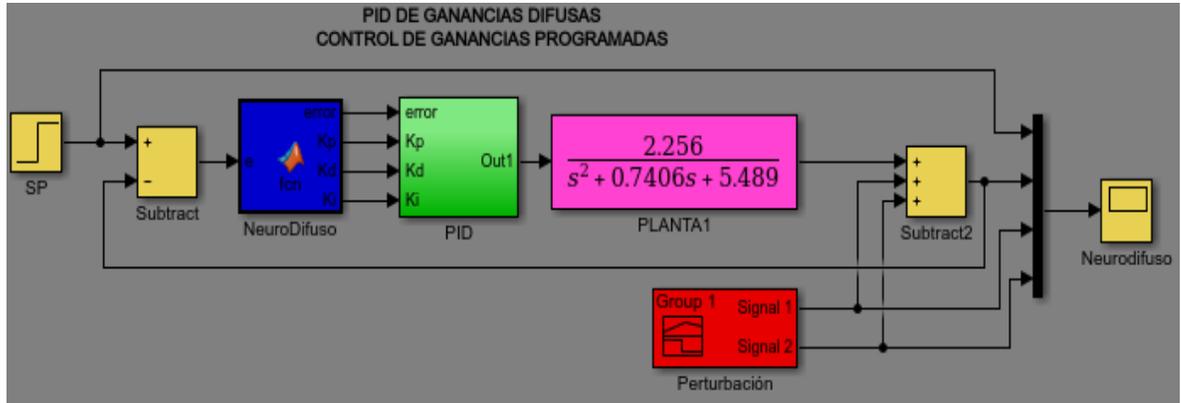


Figura 16-3: Modelo del regulador Neuro Difuso Adaptativo.
Realizado por: Morocho, Andrés, 2018

Como se puede observar en la imagen el algoritmo TSK de orden cero envía las constantes K_p , K_i y K_d al controlador clásico.

A continuación, en la Figura 17-3 se muestra la respuesta del sistema ante el controlador neurodifuso con las mismas perturbaciones que se aplicaron en el controlador PID.

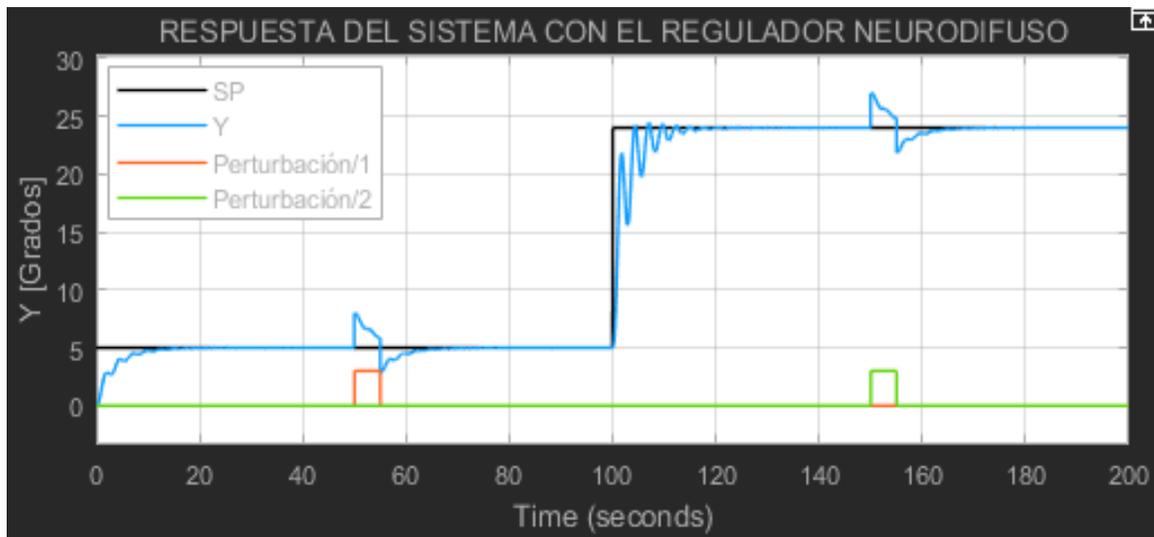


Figura 17-3: Respuesta del sistema con el regulador Neurodifuso.
Realizado por: Morocho, Andrés, 2018

Como se puede observar en la figura anterior el controlador Neurodifuso tiene un mejor tiempo de respuesta con relación al PID clásico. En el capítulo siguiente se presentarán la respuesta del sistema ante los dos reguladores implementados y ante perturbaciones reales.

El algoritmo para la realización del control neurodifuso se lo presenta en el ANEXO B y a continuación se muestra la programación en Labview para su implementación:

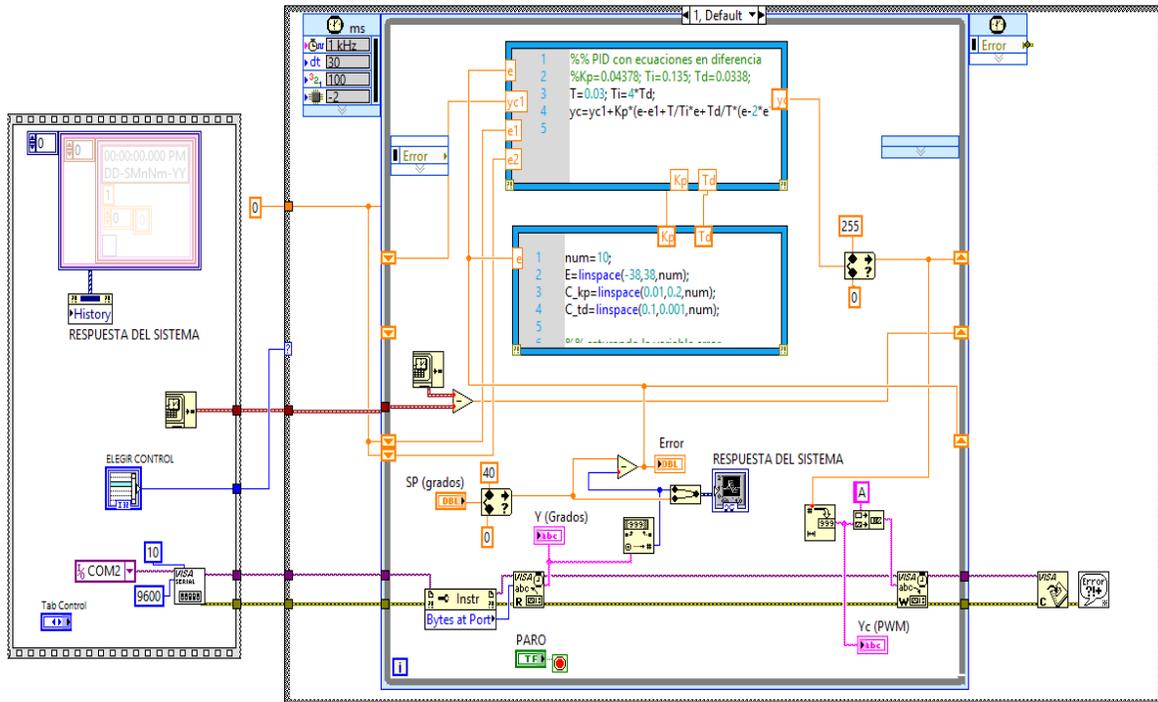


Figura 18-3: Programación del algoritmo Neurodifuso.
 Realizado por: Morocho, Andrés, 2018

CAPÍTULO IV

4. RESULTADOS Y DISCUSIÓN

Una vez terminada la implementación de los reguladores de la planta de vuelo vertical, se continúa, en el presente capítulo, con la puntualización de los resultados que se obtuvieron con el diseño de los dos controladores y del comportamiento ante perturbaciones para llegar a la comprobación de la hipótesis, donde se definirá cuál de los controladores logra un mejor desempeño con la dinámica del sistema.

4.1. Análisis de Resultados del Controlador PID

Una vez que se hizo la implementación del control clásico sobre la planta de vuelo vertical de National Instrument; se realizan las siguientes pruebas para registrar el tiempo de estabilización y evaluar con el criterio integral del cuadrado del error.

Todas las pruebas se realizaron aplicando un escalón y ocasionando una perturbación con un peso pequeño para registrar el comportamiento de la planta.

4.1.1. *Respuesta de la planta ante el controlador PID sin perturbación*

En la primera prueba se aplicó un set point desde 5 hasta 24 grados, como se muestra en la Figura 1-4, donde es evidente que el tiempo que la planta tarda en estabilizarse es de 17 segundos aproximadamente. Este valor es bastante bueno para ser un controlador clásico y además evita que la planta presente sobre-oscilaciones.

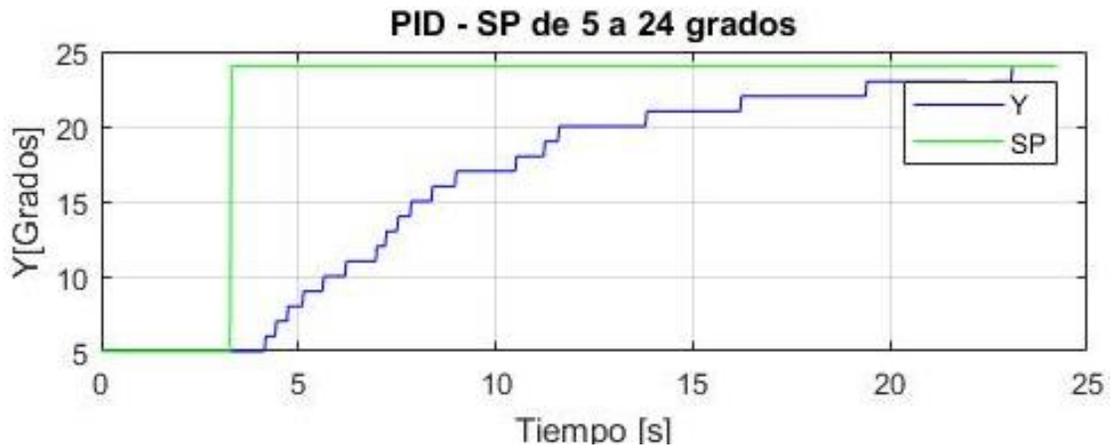


Figura 1-4: Control PID subiendo de un SP de 5 a 24 grados.
 Realizado por: Morocho, Andrés, 2018

En la figura 2-4 los resultados de una siguiente prueba son mostrados para observar el comportamiento de la planta de vuelo vertical cuando se baja de un set point de 24 a 5 grados. Es necesario indicar que el tiempo de estabilización para este caso es de 15 segundos y tampoco presenta sobre-oscilación. Lo que se da a entender que tanto la modelación como el diseño del controlador están bien realizados.

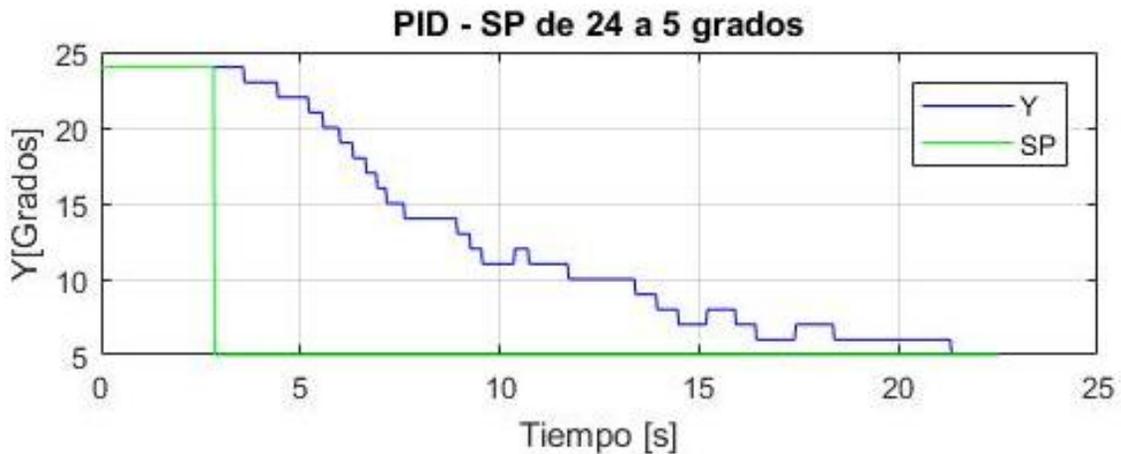


Figura 2-4: Control PID bajando de un SP de 24 a 5 grados
 Realizado por: Morocho, Andrés, 2018

4.1.2. Respuesta de la planta ante el controlador PID con perturbación

La siguiente prueba se realizó estando la planta en equilibrio con un set point de 24 grados y en ese momento añadiendo un pequeño objeto de 10 gramos en la parte del contrapeso, que actuará como una perturbación. El comportamiento de la planta se la puede observar en la siguiente figura:



Figura 3-4: Control PID colocando sobrepeso cuando se encuentra en un SP de 24 grados.
Realizado por: Morocho, Andrés, 2018

El tiempo de estabilización es de 16 segundos de acuerdo como se indica en la Figura 3-4. Por último, una vez que se encuentra en equilibrio con el peso adicional se procedió a retirarlo, tal como se evidencia en la Figura 4-4, y presenta un tiempo de estabilización de 12 segundos.

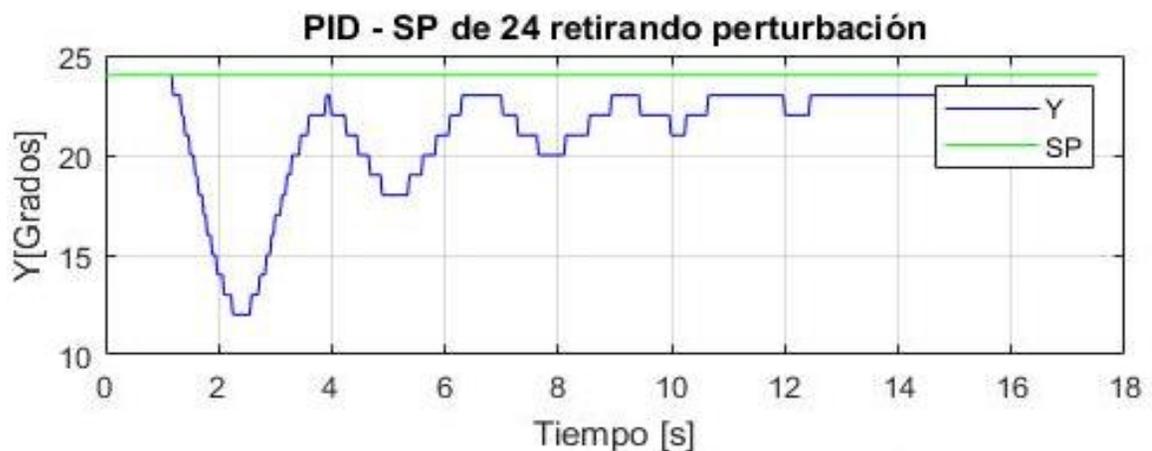


Figura 4-4: Control PID retirando sobrepeso en un SP de 24 grados.
Realizado por: Morocho, Andrés, 2018

En la Tabla 1-4 se resumen los datos obtenidos, para luego poder hacer una comparación, en el siguiente apartado, con el regulador neurodifuso.

Tabla 1-4: Registro del tiempo de estabilización.

Pruebas	Tiempo de estabilización [s]
1) Subiendo el set point	17
2) Bajando el set point	15
3) Añadiendo peso estando en equilibrio	16
4) Retirando peso estando en equilibrio	12

Realizado por: Morocho, Andrés, 2018

El controlador clásico presenta los tiempos mostrados en la Tabla 1-4 pero pueden ser mejorados con la implementación del regulador neurodifuso. En caso que no se desee mejorar el tiempo de estabilización el controlador PID es aplicable.

4.2. Análisis de Resultados del Regulador Neurodifuso

Luego de implementar el controlador neurodifuso y aplicarlo a la planta de vuelo vertical se realizaron las siguientes pruebas similares a las anteriores para observar el comportamiento del sistema dinámico.

4.2.1. Respuesta de la planta ante el controlador Neurodifuso sin perturbación

Primero se subió el set point de 5° a 24° , donde se puede observar en la siguiente imagen que el tiempo de estabilización es de 5 segundos.



Figura 5-4: Control Neurodifuso subiendo de un SP de 5 a 24 grados.
 Realizado por: Morocho, Andrés, 2018

La siguiente prueba es bajar el set point de 24 a 5 grados, donde en la siguiente figura se observa un tiempo de estabilización de 12 segundos.



Figura 6-4: Control Neurodifuso bajando de un SP de 24 a 5 grados
 Realizado por: Morocho, Andrés, 2018

4.2.2. Respuesta de la planta ante el controlador Neurodifuso con perturbación

La siguiente prueba será manteniendo la planta en equilibrio en un set point de 24 grados y en ese momento aplicando una perturbación instantánea, colocando un objeto de 10 gramos. En la Figura 7.4 se muestra que el tiempo de estabilización es de 8 segundos.



Figura 7-4: Control Neurodifuso colocando sobrepeso cuando se encuentra en un SP de 24 grados.
Realizado por: Morocho, Andrés, 2018

Finalmente, retirando el sobre peso estando en un set point de 24 grados. En la figura siguiente se registra un tiempo de establecimiento de 7 segundos.



Figura 8-4: Control Neurodifuso retirando sobrepeso cuando se encuentra en un SP de 24 grados.
Realizado por: Morocho, Andrés, 2018

En la Tabla 2-4 donde se resumen cada una de las pruebas realizadas con el controlador neurodifuso, ante la presencia y ausencia de perturbaciones.

Tabla 2-4: Registro del tiempo de estabilización con el Regulador Neurodifuso

Pruebas	Tiempo de estabilización [s]
1) Subiendo el set point	5
2) Bajando el set point	12
3) Añadiendo peso estando en equilibrio	8
4) Retirando peso estando en equilibrio	7

Realizado por: Morocho, Andrés, 2018

Como se puede observar el controlador neurodifuso mejoró el tiempo de estabilización, llegando a reducirlo de 17 segundos a 5 segundos, siendo aproximadamente tres veces más rápido en comparación con el PID clásico. Y no solamente mejoró con respecto a la primera prueba sino con todos los casos llegando a tener tiempos óptimos.

Se pudo mejorar el regulador PID clásico gracias a las ventajas del neurodifuso basado en un control de ganancias programadas con inferencia borrosa del tipo Takagi Sugeno Kang orden cero. Esto se puede evidenciar al comparar la Tabla 4-1 y la Tabla 4-2 para cada uno de los casos, presentándose con y sin perturbaciones.

En la Figura 9-4 se visualiza una gráfica de barras elaborada mediante la información recopilada de la Tabla 1-4 y la Tabla 2-4 para comparar los tiempos de estabilización entre los dos controladores.

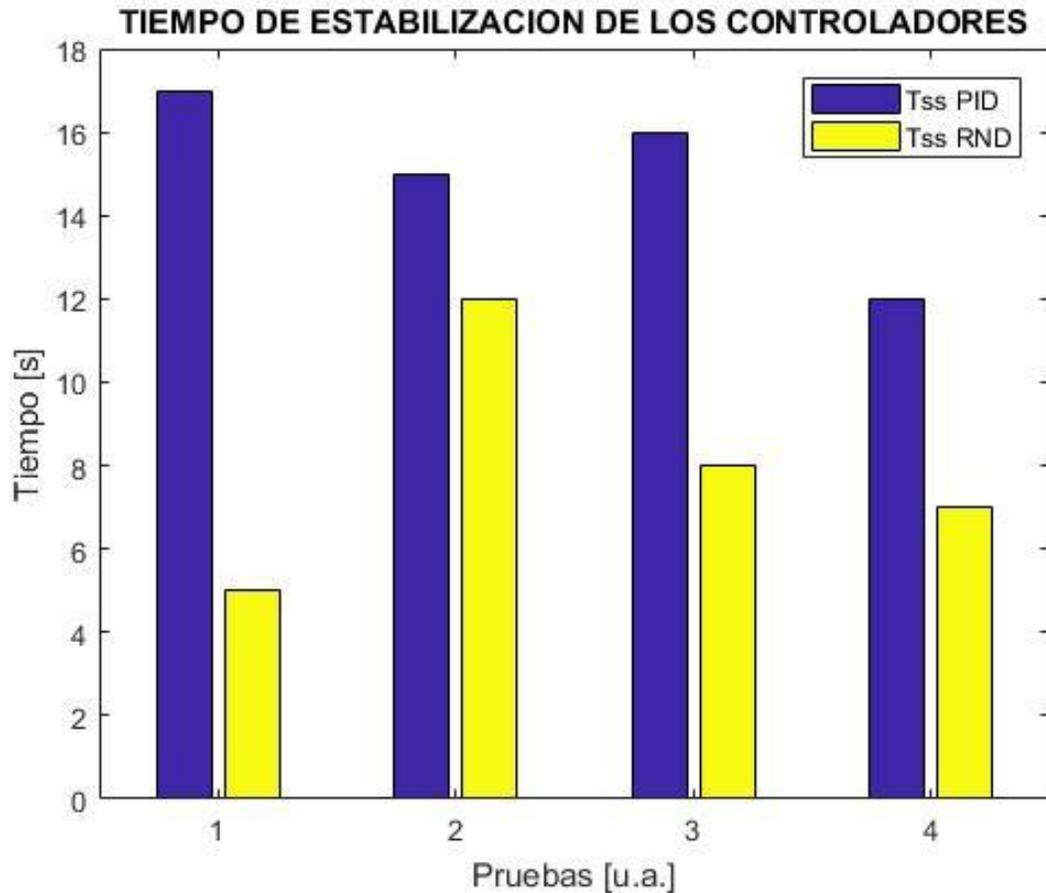


Figura 9-4: Gráfica de barras de los Tiempos de Estabilización de los Controladores
 Realizado por: Morocho, Andrés, 2018

4.3. Comprobación de la Hipótesis

Para evaluar el comportamiento del sistema con los dos controladores diseñados e implementados se utilizará una función de costo, que para este trabajo será el criterio integral del cuadrado del error (ISE), el mismo que permitirá evaluar para cada una de las pruebas. Se escogió la variable error porque quien menos error tenga mejor tiempo de estabilización tendrá, ya que alcanzará más rápido el set point.

En primer lugar, se necesitan extraer los datos de cada una de las pruebas con los dos reguladores desarrollados. Luego para el procesamiento de los datos se utilizará la fórmula del ISE.

$$ISE = \int_0^{\infty} e^2(t) dt \quad (4.1)$$

La ecuación (4.1) se reduce a una sumatoria del total de datos adquiridos propiamente desde la planta:

$$ISE = \sum_{i=1}^n e_i^2 \quad (4.2)$$

En el ANEXO C se puede observar el procesamiento de los datos de cada una de las pruebas realizadas para evaluar el criterio integral de las mismas. A continuación, se presenta en la siguiente figura un diagrama de barras de los resultados obtenidos:

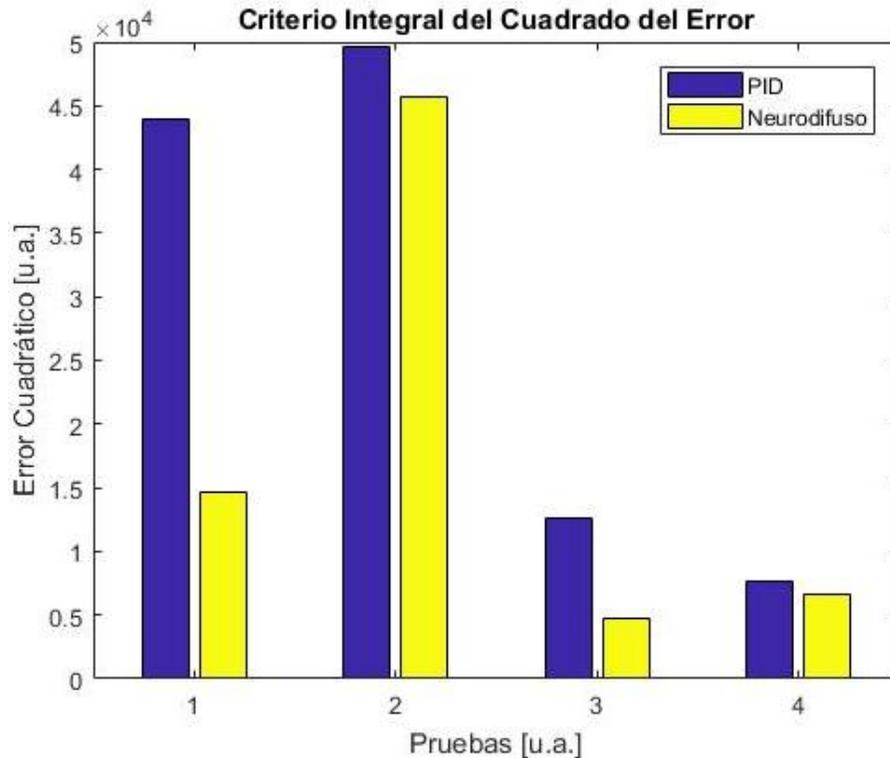


Figura 10-4: Diagrama de barras del ISE para las cuatro pruebas.
Realizado por: Morocho, Andrés, 2018

En la Figura 10-4 se puede observar que, para las cuatro pruebas realizadas bajo las mismas condiciones, con el mismo tiempo de adquisición de datos, el regulador neurodifuso presenta un menor valor en la función de costo del criterio integral del cuadrado del error. A nivel de sistemas de control existen diferentes criterios y se escogió esta función porque penaliza a los errores grandes. Si

la planta hubiese llegado a dar lugar a oscilaciones constantes en su estado estacionario se debía trabajar con otro criterio que penalice estos pequeños errores oscilatorios.

Bajo este criterio integral a nivel de sistemas de control se puede llegar a demostrar la hipótesis planteada, donde el desarrollo de un regulador neurodifuso adaptativo, mediante técnicas de control inteligente, para el control de la planta de vuelo vertical de National Instrument mejoró el desempeño en el tiempo de estabilización con relación a un control convencional.

4.3.1. Distribución T de Student

La prueba de hipótesis para medias usando Distribución T de Student se usa cuando se cumplen las siguientes dos condiciones:

- Es posible calcular la media y la desviación estándar a partir de la muestra.
- El tamaño de la muestra es menor a 30.

Los datos que se obtuvieron fue a partir de varias entradas escalón partiendo desde 0° hasta el valor indicado en la Tabla 3-4 y calculando el error cuadrático medio de la respuesta del sistema para cada set point.

Ahora se define la Hipótesis Alternativa (H_i), esto define lo que se quiere comprobar, en este caso: El regulador Neurodifuso tiene menor valor de error cuadrático medio y por ende un menor tiempo de estabilización.

La Hipótesis Nula (H_o) se refiere a lo contrario de la hipótesis alternativa, para este caso de estudio es: El Regulador Neurodifuso no tiene un menor valor de error cuadrático medio y por ende un mayor tiempo de estabilización.

Tabla 3-4:Muestras de los Controladores para la Distribución T de Student

ID	Set Point (Grados)	Control PID (error cuadrático medio)	Neurodifuso (error cuadrático medio)
1	2	34.9231	6.2317
2	4	36.2319	8.4321
3	6	40.3287	9.2378
4	8	45.2122	10.2789
5	10	46.7089	11.3023
6	12	47.1178	11.9132
7	14	48.1098	12.2078
8	16	49.9781	13.4198
9	18	50.2341	15.4321
10	20	51.2712	16.0834
11	22	53.2708	17.2341
12	24	54.3601	18.1795

Realizado por: Morocho, Andrés, 2018

El estadístico T se lo calculó utilizando Excel donde se insertó los datos de la Tabla 3-4 y el valor de significancia del 5%. El programa entregó el siguiente resultado:

Tabla 4-4: Distribución T de Student para las muestras de los Controladores.

Prueba t para dos muestras suponiendo varianzas desiguales		
	PID	RND
Media	46.47889167	12.49605833
Varianza	39.87665687	13.65736949
Observaciones	12	12
Diferencia hipotética de las medias	0	
Grados de libertad	18	
Estadístico t	16.08922979	
P(T<=t) una cola	1.98339E-12	
Valor crítico de t (una cola)	1.734063607	
P(T<=t) dos colas	3.96678E-12	
Valor crítico de t (dos colas)	2.10092204	

Realizado por: Morocho, Andrés, 2018

De acuerdo a la Distribución T de Student indica lo siguiente:

- Valor $P \leq$ Nivel Significancia, se rechaza la hipótesis nula.
- Valor $P >$ Nivel Significancia, se acepta hipótesis nula.

En la Tabla 4-4 se observa que los valores de P, resaltados de color verde, son menores al valor de significancia de 0.05. Se concluye que se rechaza la hipótesis nula y por ende se acepta la hipótesis alternativa.

CAPÍTULO V

5. PROPUESTA

- Desarrollar un regulador neurodifuso con un modelo de PID de ganancias difusas con inferencia borrosa del tipo Takagi Sugeno Kang de orden uno y dos para observar y comparar el desempeño que tiene la planta de vuelo vertical de National Instrument.
- Desarrollar un regulador neurodifuso mediante una caracterización de las constantes del control clásico en base al error y a su derivada, para conseguir un PID difuso, con una inferencia borrosa del tipo TSK y así evaluar el desempeño de la planta.

5.1. Conclusiones

- El número de singletons en un sistema neuro difuso es muy importante para un sistema neurodifuso con inferencia borrosa del tipo Takagi Sugeno Kang de orden cero porque viene relacionado de acuerdo a la cantidad de funciones de membresía que definen el universo de discurso de la variable de proceso.
- Un modelo de segundo orden no siempre puede ser modelado únicamente por su tiempo de estabilización y la sobre oscilación, como fue en el caso del presente trabajo de titulación que se necesitó ajustar el modelo inicial de la planta mediante la técnica del gradiente decreciente.
- Para diseñar un regulador neurodifuso no es necesario tener un modelo de la planta que se desea controlar, por el contrario, lo que se necesita es conocer bien el sistema para plasmar ese conocimiento del experto en el universo de discurso, en los singletons y las reglas para el diseño del controlador.
- La implementación de un PID de Ganancias Difusas mejora el rendimiento del controlador clásico, llegando a tener una respuesta de tres veces más rápida de la planta. Con lo cual ha provocado que mejore el tiempo de estabilización en lazo abierto reduciéndolo en dos unidades aproximadamente.

- La combinación del control clásico con el inteligente llega a alcanzar un mejor rendimiento de la planta que se desee controlar; como se observa en el presente trabajo de titulación la unificación de las ventajas tanto del PID como del neurodifuso.

5.2. Recomendaciones

- Cuando se presente una lectura muy repetida del encóder en una misma ubicación se puede aplicar un filtro de Savitzky-Golay o también se puede aumentar el tiempo de muestreo hasta lograr disminuir la repetición de la lectura del sensor.
- Escoger bien el rango del universo del error y los valores de los singletons porque el algoritmo presenta dificultades al momento de procesar y tiende a colapsar al software y obviamente la planta no va a responder a lo deseado.
- Para implementar un controlador clásico como el PID es necesario llevarlo del dominio del tiempo a ecuaciones en diferencia, con la ayuda de las herramientas matemáticas, para poder construirlo en cualquier software de programación.
- Si el control del driver del motor DC se lo realiza mediante PWM es muy importante manejar altas frecuencias y es por esa razón que en el presente trabajo se manejó un valor de 30KHz, modificando el Timer dos del Arduino Uno y que se relaciona con los pines digitales 9 y 10 del microcontrolador, los mismo que se conectan con el L298N (puente H).

5.3. Respuesta a la formulación del Problema

El regulador neurodifuso adaptativo mejoró su desempeño en el tiempo de estabilización mediante la técnica de inferencia borrosa Takagi Sugeno Kang de orden cero con la combinación de las técnicas del control inteligente y convencional llegando a tener un regulador optimizado.

5.4. Respuesta a las Preguntas Directrices

¿Qué relación existe entre la estructura neuronal dada por capas y las diferentes fases asociadas a la inferencia borrosa, tales como, fuzzificación de la variable, grados de verdad y agregación de las reglas?

Un modelo de inferencia borrosa del tipo TSK de cualquier orden presenta una estructura similar a una red neuronal ya que se encuentra basado en capas, tiene los pesos, el Bías, las funciones operacionales y su salida. En el capítulo dos se explica cómo calcular cada uno de estos parámetros.

¿Cuáles son las variables que deben ser consideradas para crear una función de costo que permita evaluar el desempeño de la planta bajo los diferentes esquemas de regulación?

La variable que se consideró en el presente trabajo de titulación fue el error que involucra a la referencia (set point) y la respuesta del sistema tanto para el controlador PID clásico como para el Neurodifuso.

¿Cuál es el procedimiento para implementar la técnica de Takagi Sugeno Kang de orden cero para desarrollar la caracterización de la variable de control (Y_c)?

En primer lugar, se partió desarrollando un control clásico para luego optimizarlo mediante un PID de ganancias difusas o también conocido como Controlador de Ganancias Programadas. Y de ahí se implementó la inferencia borrosa del tipo Takagi Sugeno Kang de orden cero.

¿Cómo se puede evaluar el desempeño del regulador neurodifuso adaptativo sobre la planta que simula el control de vuelo vertical?

Para evaluar el desempeño del regulador neurodifuso, sobre la planta de vuelo vertical, se utilizó una función de costo que es el Criterio Integral del Cuadrado del Error (ISE); la misma que fue utilizada en los dos controladores para definir cuál es el mejor.

BIBLIOGRAFÍA

- Abraham, A. (2005). Adaptation of fuzzy inference system using neural learning. *Fuzzy Systems Engineering*, 83. Retrieved from <https://doi.org/10.1007/b102051>
- Alvarado, C., & Villamar, C. (2010). *Aplicación del modelo anfis a la sintetización de notas musicales y señales de voz*, 7. Retrieved from <http://www.dspace.espol.edu.ec/handle/123456789/16119>
- Díez, J. (2003). *Técnicas de agrupamiento para identificación y control por modelos locales*. Universidad Politécnica de Valencia. Retrieved from <https://riunet.upv.es/bitstream/handle/10251/2684/tesisUPV1703.pdf>
- Domínguez, S., Campoy, P., Sebastián, J., & Jiménez, A. (2006). *Control en el Espacio de Estado*. (P. E. S:A., Ed.) (Segunda). Madrid.
- Figuerola, J. (2016). *Desarrollo e Implementación del algoritmo de un controlador Neuro Difuso tipo ANFIS aplicado a un sistema aerodinámico TRMS (Twin Rotor MIMO System)*. Escuela Politécnica Nacional. Retrieved from <http://bibdigital.epn.edu.ec/bitstream/15000/16986/1/CD-7564.pdf>
- García, B., & Villamizar, E. (2005). *Sistemas Neuro Difusos aplicados al control automático*. Universidad Tecnológica de Bolívar. Retrieved from <http://biblioteca.unitecnologica.edu.co/notas/tesis/0030354.pdf>
- Maroto, R. (2007). *Ecuaciones para la sintonización de controladores PID con acción derivativa aplicada a la señal realimentada*. Universidad de Costa Rica. Retrieved from <http://eie.ucr.ac.cr/uploads/file/proybach/pb0714t.pdf>
- Monzón, J., & Pisarello, M. (2004). *Identificación de Latidos Cardíacos Anómalos con Redes Neuronales Difusas*, 6. Retrieved from <http://www.unne.edu.ar/unnevieja/Web/cyt/com2004/8>
- Nauck, D. (1995). *Beyond Neuro-Fuzzy: Perspectives And Directions*, 7. Retrieved from <https://pdfs.semanticscholar.org/b643/7ab63482b0131e6db78424e1e4315645110f.pdf>
- Ogata, K. (2010). *Ingeniería de Control Moderna*. *Journal of Chemical Information and*

Modeling (5th ed., Vol. 53). Madrid: PEARSON EDUCACIÓN, S.A.
<https://doi.org/10.1017/CBO9781107415324.004>

Retana, D., & Vargas, A. (2000). *Estabilización de un helicóptero a escala mediante sistemas neuro-difusos*. Universidad Nacional Autónoma de México. Retrieved from <http://www.ptolomeo.unam.mx:8080/xmlui/bitstream/handle/132.248.52.100/1341/Completo.pdf?>

Santos, M. (2011). Aplicaciones Exitosas de Control Inteligente a Casos Reales. *Revista Iberoamericana de Automática E Informática Industrial*, 0, pp.1–8. Retrieved from http://intranet.ceautomatica.es/sites/default/files/upload/955/files/VII_Simposio_de_Control_Inteligente-2011/07_ponencia2_Santos.pdf

Sanz, R. (1990). *Arquitectura de Control Inteligente de Procesos*. Autonomous Systems Laboratory. Retrieved from <http://tierra.aslab.upm.es/~sanz/documents/Sanz-1990-PhD.pdf>

Takagi, T., & Sugeno, M. (1985). *Fuzzy Identification of Systems and Its Applications to Modeling and Control*. Retrieved from <https://doi.org/0.1109/ICSMC.2001.969870>

Toxqui, R. (2003). *Redes neuronales difusas dinámicas para identificación y control adaptable*. Instituto Politécnico Nacional. Retrieved from <http://www.ctrl.cinvestav.mx/~yuw/pdf/MaTesRT.pdf>

Nguyen, D. & Widrow, B. (1990). Neural Networks for Self-Learning Control Systems. *IEEE Control Systems Magazine*, 10, pp. 18-23.

Hilera, J. & Martínez V. (1995). *Redes Neuronales Artificiales. Fundamentos Modelos y Aplicaciones*, Ed. RA-MA.

ANEXOS

ANEXO A: Modelación mediante la técnica del gradiente decreciente.

```
clear all; clc;
%% cargando los datos leídos de la planta
u=xlsread('datosex',1,'B67:B1018');
y=xlsread('datosex',1,'C67:C1018');

ts=0.03; % tiempo de muestreo en segundos
tss=7.77; % tiempo de estabilización 7.77
mp=max(y)/24-1; % calculando la sobre oscilacion Mp con un valor de 24 en estado
estacionario
ti=ts*length(y)-ts;
t=[0:ts:ti]';

%% Parámetros de la planta inicial
chi=abs(log(mp))/sqrt(pi^2+log(mp)^2);
wn=4/(tss*chi);
k=2.3;

PARAM=[k 2*chi*wn wn^2];
g=tf([PARAM(1)],[1 PARAM(2) PARAM(3)]);
ym=lsim(g,u,t);
plot(t,y,'r',t,ym,'b-'); title('Respuesta al escalón'); legend('Real',
'Modelado');
grid on

%% DEFINIENDO LA FUNCIÓN DE COSTO

J= sum(abs(y-ym),1);

%% APLICANDO EL MÉTODO DEL GRADIENTE DECRECIENTE PARA OBTENER A "PARAM"
BUSCAR=1;
APRENDIZAJE=1/1e4;
DELTA=1/1e4;

CONTADOR=1;
LIMITE=70000;

J_INC=zeros(size(PARAM));
J_DEC=zeros(size(PARAM));
DJ=zeros(size(PARAM));

EPOCAS=0;
FUNCION_COSTO=J;

figure;
while ((CONTADOR<LIMITE) && (BUSCAR==1))
    % DETERMINANDO A J EN INCREMENTO
    for i=1:length(PARAM)
        PARAM1=PARAM;
        PARAM1(i)=PARAM(i)+DELTA;
        g=tf([PARAM1(1)],[1 PARAM1(2) PARAM1(3)]);
        ym =lsim(g,u,t);

        J_INC(i)= sum(abs(y-ym),1);
    end
end
```

```

% DETERMINANDO A J EN DECREMENTO
for i=1:length(PARAM)
    PARAM1=PARAM;
    PARAM1(i)=PARAM(i)-DELTA;
    g=tf([PARAM1(1)], [1 PARAM1(2) PARAM1(3)]);
    ym =lsim(g,u,t);

    J_DEC(i)= sum(abs(y-ym),1);
end

% OBTENIENDO EL DIFERENCIAL DE DJ
DJ=J_INC-J_DEC;

% VERIFICANDO AJUSTE
PARAM1=PARAM-APRENDIZAJE*DJ;
g=tf([PARAM1(1)], [1 PARAM1(2) PARAM1(3)]);
ym =lsim(g,u,t);

J_VERIFICACION= sum(abs(y-ym),1);

if J_VERIFICACION<J
    PARAM=PARAM1;
    J=J_VERIFICACION;

    EPOCAS=[EPOCAS,CONTADOR];
    FUNCION_COSTO=[FUNCION_COSTO;J];
    CONTADOR=CONTADOR+1;
    if mod(CONTADOR,5)==0
        plot(t,y,'r-',t,ym,'b-');
        pause(0.05);
    end

else
    BUSCAR=0;
end
end

%% cálculo de los parámetros de la función modelada
g=tf([PARAM(1)], [1 PARAM(2) PARAM(3)]);
ym =lsim(g,u,t);
wn_m=sqrt(PARAM(3)); k_m=PARAM(1)/wn_m; chi_m=PARAM(2)/(2*wn_m);
mp_m=max(ym)/24-1;
figure; plot(EPOCAS,FUNCION_COSTO)

%% cálculo del error cuadrático medio MSE
MSE=zeros(size(y));
for i=1:length(y)
    MSE(i)=(y(i)-ym(i))^2;
end
MSE=sum(MSE)/length(y)

```

ANEXO B: Código de programación del Regulador Difuso con Inferencia Borrosa del tipo Takagi Sugeno Kang orden cero.

```
function [error,Kp,Kd,Ki] = fcn(e)
    num=10;
    E=linspace(-38,38,num);
    C_kp=linspace(0.01,0.25,num);
    C_td=linspace(0.1,0.001,num);
    Kp=TSK0(e,E,C_kp); Td=TSK0(e,E,C_td); Ti=4*Td;
    Kd=Kp*Td; Ki=Kp/Ti; error=e;
end

function yc=TSK0(e,E,C)
%% saturando la variable error
    e=min(max(e,min(E)),max(E));

    %% encontrando el índice máximo
    ind=find(E>=e);
    ind_max=ind(1);

    %% encontrando el índice mínimo
    ind=find(E<=e);
    ind_min=ind(end);

    %% encontrando el rango en el universo de discurso y en los singletones
    E_max=E(ind_max);
    E_min=E(ind_min);
    C1=C(ind_min);
    C2=C(ind_max);

    if ind_max==ind_min
        w1=1;
        w2=0;
    else
        w1 = (E_max-e)/(E_max-E_min);
        w2 = (e-E_min)/(E_max-E_min);
    end
    yc = w1*C1+w2*C2
end
```

ANEXO C: Programa para evaluar los datos de la planta de acuerdo al criterio integral del cuadrado del error.

```
clear all; clc;
%% ISE para el PID
% calculando el ISE para la subida de 5 a 24 grados PID
y1=xlsread('PID5a24',1,'A2:A809');
sp1=xlsread('PID5a24',1,'B2:B809');
T=0.03;
t1=0:T:(length(y1)-T)*T;

e1=zeros(size(y1));

for i=1:length(y1)
    e1(i)=(sp1(i)-y1(i))^2;
end
ISE1=sum(e1);

% calculando el ISE para un SP de 24 a 5 grados PID
y2=xlsread('PID24a5',1,'A2:A752');
sp2=xlsread('PID24a5',1,'B2:B752');
T=0.03;
t2=0:T:(length(y2)-T)*T;

e2=zeros(size(y2));

for i=1:length(y2)
    e2(i)=(sp2(i)-y2(i))^2;
end
ISE2=sum(e2);

% calculando el ISE para un SP de 24 colocando perturbacion PID
y3=xlsread('PID24coloper',1,'A2:A907');
sp3=xlsread('PID24coloper',1,'B2:B907');
T=0.03;
t3=0:T:(length(y3)-T)*T;

e3=zeros(size(y3));

for i=1:length(y3)
    e3(i)=(sp3(i)-y3(i))^2;
end
ISE3=sum(e3);

% calculando el ISE para un SP de 24 retirando perturbacion PID
y4=xlsread('PID24retiper',1,'A2:A586');
sp4=xlsread('PID24retiper',1,'B2:B586');
T=0.03;
t4=0:T:(length(y4)-T)*T;

e4=zeros(size(y4));

for i=1:length(y4)
    e4(i)=(sp4(i)-y4(i))^2;
end
ISE4=sum(e4);

%% ISE para el Neurodifuso
```

```

% calculando el ISE para la subida de 5 a 24 grados
y11=xlsread('RND5a24',1,'A2:A809');
sp11=xlsread('RND5a24',1,'B2:B809');
T=0.03;
t11=0:T:(length(y11)-T)*T;

e11=zeros(size(y11));

for i=1:length(y11)
    e11(i)=(sp11(i)-y11(i))^2;
end
ISE11=sum(e11);

% calculando el ISE para un SP de 24 a 5 grados
y22=xlsread('RND24a5',1,'A2:A752');
sp22=xlsread('RND24a5',1,'B2:B752');
T=0.03;
t22=0:T:(length(y22)-T)*T;

e22=zeros(size(y22));

for i=1:length(y22)
    e22(i)=(sp22(i)-y22(i))^2;
end
ISE22=sum(e22);

% calculando el ISE para un SP de 24 colocando perturbacion
y33=xlsread('RND24coloper',1,'A2:A907');
sp33=xlsread('RND24coloper',1,'B2:B907');
T=0.03;
t33=0:T:(length(y33)-T)*T;

e33=zeros(size(y33));

for i=1:length(y33)
    e33(i)=(sp33(i)-y33(i))^2;
end
ISE33=sum(e33);

% calculando el ISE para un SP de 24 retirando perturbacion PID
y44=xlsread('RND24retiper',1,'A2:A586');
sp44=xlsread('RND24retiper',1,'B2:B586');
T=0.03;
t44=0:T:(length(y44)-T)*T;

e44=zeros(size(y44));

for i=1:length(y44)
    e44(i)=(sp44(i)-y44(i))^2;
end
ISE44=sum(e44);

%% gráfica de los ISE

bar([ISE1 ISE11; ISE2 ISE22; ISE3 ISE33; ISE4
ISE44]);legend('PID','Neurodifuso'); title('Criterio Integral del Cuadrado del
Error')

```