

Tecnológico Nacional de México

Centro Nacional de Investigación
y Desarrollo Tecnológico

Tesis de Maestría

Esquema de control basado en una red neuronal
artificial de bajo orden

presentada por

Ing. Gregorio Pérez Del Ángel

como requisito para la obtención del grado
de

**Maestro en Ciencias en Ingeniería
Electrónica**

Director de tesis

Dr. Víctor Manuel Alvarado Martínez

Codirector de tesis

Dr. José Francisco Gómez Aguilar

Cuernavaca, Morelos, México. Abril de 2019.



SEP
SECRETARÍA DE
EDUCACIÓN PÚBLICA



TECNOLÓGICO NACIONAL DE MÉXICO

Centro Nacional de Investigación y Desarrollo Tecnológico

"2019, Año del Caudillo del Sur, Emiliano Zapata"

Cuernavaca, Mor., 4 de abril de 2019.

OFICIO No. DIE/073/2019

Asunto: Aceptación de documento de tesis

DR. GERARDO VICENTE GUERRERO RAMÍREZ
SUBDIRECTOR ACADÉMICO
PRESENTE

Por este conducto, los integrantes de Comité Tutorial del **C. Gregorio Pérez del Ángel**, con número de control **M16CE045** de la Maestría en Ciencias en Ingeniería Electrónica, le informamos que hemos revisado el trabajo de tesis profesional titulado **"Esquema de Control Basado en una Red Neuronal Artificial de Bajo Orden"** y hemos encontrado que se han realizado todas las correcciones y observaciones que se le indicaron, por lo que hemos acordado aceptar el documento de tesis y le solicitamos la autorización de impresión definitiva.

DIRECTOR DE TESIS

Dr. Víctor Manuel Alvarado Martínez
Doctor en Ciencias en Ingeniería Electrónica
Cédula profesional 8031070

CODIRECTOR DE TESIS

Dr. José Francisco Gómez Aguilar
Doctor en Física
Cédula profesional 9124781

REVISOR 1

Dra. Ma. Guadalupe López López
Doctora en Ciencias en Ingeniería Química
Cédula profesional 7980045

REVISOR 2

Dr. Juan Reyes Reyes
Doctor en Ciencias en la Especialidad de Control Automático
Cédula profesional 4214833

C.p. M.T.I. María Elena-Gómez Torres- Jefa del Departamento de Servicios Escolares

Estudiante
Expediente
RFEJ/lrr.



SEP
SECRETARÍA DE
EDUCACIÓN PÚBLICA



TECNOLÓGICO NACIONAL DE MÉXICO

Centro Nacional de Investigación y Desarrollo Tecnológico

"2019, Año del Caudillo del Sur, Emiliano Zapata"

Cuernavaca, Morelos, **5/abril/2019**

OFICIO No. SAC/176/2019

Asunto: Autorización de impresión de tesis

ING. GREGORIO PÉREZ DEL ÁNGEL
CANDIDATO AL GRADO DE MAESTRO EN CIENCIAS
EN INGENIERÍA ELECTRÓNICA
PRESENTE

Por este conducto, tengo el agrado de comunicarle que el Comité Tutorial asignado a su trabajo de tesis titulado "Esquema de Control Basado en una Red Neuronal Artificial de Bajo Orden", ha informado a esta Subdirección Académica, que están de acuerdo con el trabajo presentado. Por lo anterior, se le autoriza a que proceda con la impresión definitiva de su trabajo de tesis.

Esperando que el logro del mismo sea acorde con sus aspiraciones profesionales, reciba un cordial saludo

ATENTAMENTE

Excelencia en Educación Tecnológica®
"Conocimiento y tecnología al servicio de México"

DR. GERARDO VICENTE GUERRERO RAMÍREZ
SUBDIRECTOR ACADÉMICO


SEP TecNM
CENTRO NACIONAL
DE INVESTIGACIÓN
Y DESARROLLO
TECNOLÓGICO
SUBDIRECCIÓN
ACADÉMICA

C.p. M.T.I. María Elena Gómez Torres- Jefa del Departamento de Servicios Escolares.
Expediente

GVGR/mcr

cenidet[®]
Centro Nacional de Investigación
y Desarrollo Tecnológico

Interior Internado Palmira S/N, Col. Palmira, C. P. 62490, Cuernavaca, Morelos.
Tel. (01) 777 3 62 77 70, ext. 4106, e-mail: dir_cenidet@tecnm.mx

www.tecnm.mx | www.cenidet.edu.mx



Dedicado a mi mamá:

Protacia Pérez

A mi novia:

Gaby

Agradecimientos

Primeramente, agradezco a Dios por todo lo que me ha dado a lo largo de mi vida y darme la oportunidad de poder concluir una meta mas de mi vida.

Agradezco a mi mamá, y a mi hermano Santos, por todo el apoyo y amor que me han brindado a lo largo de toda mi vida.

Al Dr. Víctor M. Alvarado y al Dr. José Francisco, agradezco su amistad, su confianza, paciencia y por haberme guiado a lo largo del desarrollo de este trabajo. ¡Gracias!

Al comité revisor: Dra. Guadalupe López López y Dr. Juan Reyes Reyes, por sus valiosas observaciones que realizaron para poder mejorar este trabajo.

A mis profesores que se vieron involucrados en mi formación a lo largo de mi estancia en cenidet: Dr. Victor Manuel, Dr. José Francisco, Dra. Guadalupe, Dr. Carlos Daniel, Dr. Juan Reyes, Dr. Enrique Quintero, Dr. Manuel Astorga y Dr. Gerardo Vela, gracias por todas sus valiosas enseñanzas, que hasta el día de hoy han sido de mucha ayuda.

A mi Gaby que a estado a mi lado, apoyándome en todo momento de mi estancia y ahora.

A la familia Reyes: Ignacia, Eli, Vero y José por el apoyo a lo largo de todo este camino, su hospitalidad y sus atenciones, por el apoyo impulsándome a seguir adelante.

A mis amigos Roy, Lis y May, les agradezco su amistad y apoyo desde el inicio de la maestría.

A Lic. Lorena Ruiz, por su atención, muy buenos consejos recibidor por ella, su apoyo y trato amable con los trámites de titulación, ¡muchas gracias!

Al Cenidet, por haberme dado la oportunidad de continuar con mi formación

académica.

Al Consejo Nacional de Ciencia y Tecnología (CONACYT) por el apoyo económico proporcionado para el desarrollo de este trabajo.

Resumen

En esta tesis se propone el uso de una Red Neuronal Artificial (RNA) para estimar la dinámica de una columna de destilación y poder controlar indirectamente la pureza de la composición (% mol). Para ello se implementan bajo simulación los esquemas de control inverso directo (CID) y control por modelo inverso (CMI), con el objetivo de poder analizar e interpretar los resultados. Con base a este análisis se desarrolla un esquema de control que tendrá la finalidad de regularizar la temperatura en un plato específico de la columna de destilación.

En los esquemas de control utilizados se implementaron Redes Neuronales Artificiales estáticas para la regulación de la temperatura para en esta forma poder mantener a 98 % mol la pureza del propano considerando una perturbación en el flujo de entrada que se presenta en el plato 15 de la torre de destilación.

También, se presenta el esquema de control por modelo interno con compensador (CMIC) desarrollado para la regulación de temperatura y finalmente se comparan los resultados obtenidos con un controlador PI.

Abstract

This thesis proposes the use of an Artificial Neural Network (ANN) to estimate the dynamics of a distillation column and to indirectly control the purity of the composition (% mol). For this purpose, the direct inverse control (CID) and inverse control model (CMI) schemes are implemented under simulation, with the aim of analyzing and interpreting the results. Based on this analysis, a control scheme is developed that will serve the purpose to regularize the temperature in a specific dish of the distillation column.

In the control schemes used, static Artificial Neural Networks were implemented to regulate the temperature in order to maintain the purity of the propane at 98 % mol considering a disturbance in the input flow that occurs in plate 15 of the distillation tower.

Also, the control scheme by internal model with compensator (CMIC) developed for temperature regulation is presented and finally we compared the results obtained with a PI controller.

Índice general

Lista de Abreviaturas	1
1. Introducción	1
1.1. Planteamiento del problema	2
1.2. Objetivos	3
1.2.1. Objetivo general	3
1.2.2. Objetivos específicos	3
1.3. Justificación	4
1.3.1. Alcances	5
1.4. Estado del arte	5
2. Marco teórico	8
2.1. Columna de Destilación	8
2.2. Una Red Neuronal Artificial (RNA)	10
2.2.1. Características de las RNA	10
2.2.2. Estructura básica de una Red Neuronal (RN)	11
2.2.3. La neurona artificial NA	12
2.3. Redes Neuronales Supervisadas y No Supervisadas	13
2.3.1. Reglas de entrenamiento Supervisado	13
2.3.2. Reglas de Entrenamiento No Supervisado	14
2.4. Funciones de Base y Activación	15

2.4.1.	Función Base (Función de Red)	16
2.4.2.	Función de Activación (Función de neurona)	16
2.5.	Algoritmo de aprendizaje de una Red Neuronal Artificial	17
2.5.1.	Técnica de optimización	17
2.6.	Secuencias binarias pseudoaleatorias (PRBS)	21
2.6.1.	Dimensionamiento de un PRBS	23
2.6.2.	Identificación de sistemas	24
2.6.3.	Esquemas de control con RNA	27
3.	Resultados de investigación	30
3.1.	Columna de destilación	30
3.2.	Ubicación de la sensibilidad de cambio de temperatura en cada plato de la Columna de Destilación	32
3.3.	Red Neuronal Artificial (RNA)	33
3.3.1.	Estructura de modelo de la RNA	33
3.3.2.	Orden de la estructura de modelo de la RNA	33
3.3.3.	Entrenamiento de la RNA	36
4.	Simulaciones	40
4.1.	Simulación 1: Esquema de Control Inverso Directo (CID) con RNA	40
4.1.1.	Planteamiento del problema	40
4.1.2.	Objetivo de la simulación	41
4.1.3.	Desarrollo de la simulación	41
4.2.	Simulación 2: Esquema de Control por Modelo Interno (CMI) con RNA	43
4.2.1.	Planteamiento del problema	43
4.2.2.	Objetivo de la simulación	44
4.2.3.	Desarrollo de la simulación	45
4.3.	Simulación 3: Comparación de los resultados de los controladores con RNA y PI	46

4.3.1.	Planteamiento del problema	46
4.3.2.	Objetivo de la simulación	47
4.3.3.	Desarrollo de la simulación	47
4.4.	Simulación 4: Esquema de Control por Modelo Interno con Compensador (CMIC) con RNA	49
4.4.1.	Planteamiento del problema	49
4.4.2.	Objetivo de la simulación	51
4.4.3.	Desarrollo de la simulación	51
5.	Conclusiones	54
	Trabajos Futuros	56
	Bibliografía	56
	[L] [R]	

Índice de figuras

2.1. Columna de destilación.	9
2.2. Esquema de una Red Neuronal.	11
2.3. Cuatro elementos Funcionales de una NA	12
2.4. Esquema de entrenamiento supervisado.	14
2.5. Esquema de entrenamiento no supervisado.	15
2.6. Diagrama de la RNA.	19
2.7. Generación de una PRBS de longitud $2^5 - 1 = 31$ periodos de muestreo.	22
2.8. Elección de la duración máxima de un pulso en una PRBS	23
2.9. Pasos para la identificación de sistemas.	24
2.10. Esquema de la obtención de datos.	25
2.11. Control Interno Directo (CID).	27
2.12. Características de la planta y del modelo inverso.	28
2.13. Control por Modelo Interno (CMI).	29
3.1. Diagrama de flujo de un separador.	31
3.2. En la gráfica superior muestra la sensibilidad de temperatura en cada plato y en la inferior se muestra la diferencia de temperatura.	32
3.3. Estructura de modelo ARX.	33
3.4. Grado para $n_k = 1$	34
3.5. Grado para $n_a = 3$	35
3.6. Grado para $n_b = 1$	36

3.7. Datos de entrenamiento (9 bits) donde la superior indica la entrada de calor en el rehervidor de la columna y la inferior la temperatura de acuerdo al calor agregado.	37
3.8. Datos de validación (5 bits) donde la superior indica la entrada de calor en el rehervidor de la columna y la inferior la temperatura de acuerdo al calor agregado.	38
3.9. Dinámica del error de entrenamiento de la RNA.	38
3.10. Estimación de $u[k]$ (datos de entrenamiento).	39
3.11. Estimación de $u[k]$ (datos de validación).	39
4.1. Esquema de CID.	40
4.2. Comparación de la ley de control $u[k]$ de CID vs PI.	42
4.3. Comparación de Temperatura °C de CID (cyan) vs PI (rojo).	43
4.4. Esquema de CMI.	44
4.5. Comparación de la ley de control $u[k]$ de CMI vs PI.	45
4.6. Comparación de Temperatura °C de CMI (cyan) vs PI (rojo).	46
4.7. Comparación de la ley de control $u[k]$ de CID vs CMI vs PI.	48
4.8. Comparación de Temperatura F de CID vs CMI vs PI.	49
4.9. Esquema de Control por Modelo Interno.	50
4.10. Esquema de Control por Modelo Interno con Compensador $u(k)$ para el CMIC desarrollado.	50
4.11. Perturbación en el flujo de entrada.	51
4.12. Comparativa de Temperatura con el esquema de CMIC vs PI.	52
4.13. Comparativa de la dinámica del destilado (en % de propano) con los esquemas de CMIC contra PI contra CID y contra CMI.	53

Índice de tablas

2.1. Generación de longitud maxima de una PRBS	22
3.1. Característica de la PRBS	36
3.2. FIT de la RNA	37
5.1. ECM de los resultados de los controles de temperatura y de la composición	55

[L] [C] [R]

Lista de simbolos

Símbolo	Descripción
y_i	es el dato de salida del proceso
my_i	es la salida de la RNA
$F(k)$	función de costo
NT_s	N es el número de celdas y T_s es el período de muestreo

Lista de Abreviaturas

Acrónimos	Descripción
CID	Control Inverso Directo
CMI	Control por Modelo Interno
ARX	AutoRegresivo entrada eXterna
RNA	Red Neuronal Artificial
PI	Proporcional Integral
RP	RetroPropagación
NARX	No lineal AutoRegresivo entrada eXterna
MSF	MultiStage Flash
BP	BlackPropagation
ANN	Artificial Neural Networks
M	Membrana
C	Citoplasma
N	Núcleo
D	Dendritas
F	Fibras
A	Axón
PRBS	Secuencias binarias pseudoaleatorias
ECM	error cuadrático medio

Capítulo 1

Introducción

En esta memoria primero se presentan conceptos sobre los cuales se sustentan los resultados de investigación. A lo largo de este documento se presenta el esquema de control inverso directo (CID) y control por modelo interno (CMI) con redes neuronales artificiales. Estos esquemas de control son implementados en una columna de destilación a nivel simulación con el objetivo de desarrollar una idea para el diseño de un nuevo esquema de control neuronal. La estructura utilizada para la red neuronal es la desarrollada por Ljung, y se denomina ARX (AutoRegresivo, entrada eXterna), en donde los errores de modelado se incluyen, a diferencia de otros métodos de estimación en el término del error, a este término se le asocia una serie de variables aleatorias independientes uniformemente distribuidas.

El algoritmo gradiente descendente es utilizado para el entrenamiento de la red neuronal artificial (RNA), el cual consiste en iteraciones de optimización que permiten encontrar los pesos sináptico y umbrales de la RNA a través de valores mínimos en todo su dominio.

La implementación de los esquemas de control se llevó a cabo para el desarrollo de un nuevo diseño de controlador, los tipos CID y CMI construidos con RNA para el

control de temperatura. Para ambos casos se pretende asignar cambios de referencias de temperatura, con el fin de observar y analizar los resultados de acuerdo al comportamiento dinámico del sistema. La idea de realizar las pruebas mencionadas son las que marcan la pauta para la construcción del esquema propuesto para este trabajo de investigación denominado esquema de control basado en una red neuronal artificial de bajo orden.

1.1. Planteamiento del problema

El control de procesos industriales es un campo de la ingeniería en el que la integración de tecnologías se enfoca en la optimización de procesos que el sector productivo requiere. Dentro de la industria, los procesos presentan un comportamiento dinámico altamente no lineal debido al fuerte acoplamiento que existe entre sus variables, por este motivo el análisis matemático es extremadamente complejo y por lo tanto el diseño de un controlador también lo es. Un claro ejemplo de este tipo de problemas se presenta en columnas de destilación, intercambiadores de calor, tanques de mezclado, reactores químicos, etc. La importancia de control de procesos se ha incrementado con la necesidad de ofrecer soluciones de optimización de procesos productivos con la capacidad de garantizar la confiabilidad de los mismos, Hoy en día aún se utilizan técnicas de control clásico, para un punto de operación o en una región muy cercana al punto de operación.

Se desea controlar la pureza del propano de una columna de destilación. El control se realiza indirectamente mediante la temperatura en el plato 7, la alimentación del proceso es de $100 \frac{lb-mol}{h}$ de una mezcla de propano (30 % *mol*), isobutano (40 % *mol*) y n-butano (30 % *mol*) a $90^{\circ}F$. El problema en este trabajo de investigación es mantener estable al 98 % *mol* la pureza del propano durante el destilado. Es altamente complejo lograr este porcentaje de salida, debido al tipo de variable de proceso a controlar, en un proceso real este tipo de control no se podría aplicar de manera directa, es decir,

tener un sensor en el flujo de destilado sería prácticamente imposible ya que el costo de este tipo de sensores de composición es muy alto, también se podría extraer una muestra y analizarla en el laboratorio para observar el porcentaje del propano, esto implica invertir mucho tiempo lo que a su vez se deriva en costo económico.

El esquema de control que se propone posee la característica de bajo orden, esto se hace con el fin de aprovechar diferentes aspectos tales como; el menor número de parámetros posibles, la obtención de un modelo de manera simple del controlador, un número pequeño de pesos sinápticos, entrenar una RNA de forma sencilla y, pensando a trabajos futuros; implementar los esquemas junto con el controlador en el sistema real.

1.2. Objetivos

1.2.1. Objetivo general

Desarrollar un esquema de control para una columna de destilación (bajo simulación), utilizando una RNA de bajo orden.

1.2.2. Objetivos específicos

- Implementar el esquema de Control Inverso Directo (CID). Para el lazo de control seleccionado en la columna de destilación.
- Implementar el esquema de Control por Modelo Interno (CMI). Para el lazo de control seleccionado en la columna de destilación.
- Análisis dinámico de las pruebas con los esquemas implementados.
- Obtener de un modelo basado en RNA de la columna de destilación.

- Desarrollar un controlador con RNA que mejore el desempeño de los dos anteriores.
- Implementar el control en la columna de destilación en el simulador de procesos Aspen Plus Dynamics.
- Comparación de resultados del esquema desarrollado vs el PI.

1.3. Justificación

En este trabajo de investigación se realizara un esquema de control con RNA cuyo objetivo será mejorar la respuesta de un controlador PI, esto se hace debido a que una de las características de las RNAs es la capacidad de estimar procesos altamente no lineales y de orden superior, un ejemplo de ello es la columna de destilación, otro de los aspectos importantes en este trabajo es que se utilizara una RNA de bajo orden.

El uso de técnicas de control clásico para sistemas no lineales consisten en linealizar alrededor de un punto de operación exclusivamente, el sistema funciona dentro de ese rango, de tal forma que, si se necesita realizar un cambio en el punto de operación inevitablemente se deben ajustar nuevamente las ganancias del controlador.

En la literatura se ha comprobado que el control con RNA presenta una mejor respuesta a procesos no lineales, esto orienta a realizar una nueva búsqueda de una técnica de control que pueda resolver el problema que se tiene, por lo tanto, en base en los antecedentes se proponen esquemas de control con Redes Neuronales Artificiales (RNA), que ya han sido aplicados y probados en diferentes sistemas no lineales de los cuales se han obtenido mejores resultados.

1.3.1. Alcances

- Desarrollo de un esquema de control a inspirado en los controles CID y CMI.
- Simulación del esquema de control desarrollado de la columna de destilación en Aspen Plus.
- Comparación de los resultados del controlador propuesto contra el PI disponible en Aspen.

1.4. Estado del arte

En la industria de procesos es muy común encontrar procesos multivariables, procesos interconectados, procesos con múltiples interacciones de variables o sin interacción de variables.

En [1], se utiliza el esquema Control Inverso Directo (CID) basado en la Red Neuronal Artificial (RNA), se probó en un sistema de tanque cónico que muestra la convergencia estable y el mejor rendimiento del sistema. El entrenamiento de la RNA se realizó mediante el algoritmo de retropropagación de Levenberg Marquardt. A partir de los resultados se observó que el CID realiza un buen comportamiento dinámico de los sistemas de tanques cónicos interactivos y no interactivos.

En [3], se controla con RNA a un inversor de almacenamiento de energía monofásico, donde la calidad de forma de onda del voltaje de salida es un índice de medición importante, la RNA se entrena con el algoritmo de aprendizaje retropropagación (RP). Propusieron dos esquemas de control para obtener un voltaje con una buena calidad de forma de onda, el primero consiste en poner en paralelo y sumar las salidas de los controladores (ley de control (u_1 y u_2)) de la RNA y el controlador PI. El otro esquema propuesto es tener en serie el controlador PI con la RNA. A partir de los esquemas

propuestos logran obtener una buena calidad de forma de onda en el voltaje de salida.

En [4], se describe el desarrollo de estrategias de control basadas en modelos neuronales para la optimización de un proceso industrial de molienda. La velocidad de eliminación de la muela varía considerablemente a lo largo de la vida de una piedra y es una función altamente no lineal de las variables de proceso. El entrenamiento de la RNA se realiza con los datos recopilados directamente del proceso y se entrenó la RNA con la estructura de modelo NARX. Los esquemas de control que aplicó para el control, fue el esquema de CID y el CMI. Con respecto a la estructura del modelo que utilizó NARX para la RNA, se concluye que su respuesta produjo buenas aproximaciones.

En [5], se presenta una técnica de control directo inverso (DIC) utilizando una red neuronal artificial aplicado al problema del desplazamiento autónomo de un helicóptero UAV cuadrotor, ya que se requiere evaluar que tan robusta es la técnica de control ante la incertidumbre y el cambio en la dinámica no lineal. Y como resultado se tuvo que el DIC es capaz de mantener en flotación el cuadrotor.

En [6], es utilizado un controlador neuronal entrenado para modelar el inverso experimental de las vibraciones de un sistema mecánico. El modelo inverso de la planta se obtiene mediante datos experimentales de entrada y salida. Después del entrenamiento, la red neuronal se utiliza como un controlador hacia adelante. La eficiencia y robustez del controlador se muestran a través de pruebas experimentales. A través de esta investigación se demostró que se puede hacer uso de controladores basados en redes neuronales artificiales sin tener un previo conocimiento de las ecuaciones del sistema a analizar y que también se obtuvo una respuesta satisfactoria del sistema, aún en condiciones extremas.

En [7], se utiliza un controlador inverso directo de red neuronal para controlar el

sistema de dirección de las cuatro ruedas de una moto que tiene dos grados de libertad, esto se realiza a través de la identificación fuera de línea. La diferencia que se encontró con otros métodos de control, es que el control inverso directo de la red neuronal es más eficaz para controlar el ángulo de giro de la rueda trasera para actualizar la minimización del ángulo de deslizamiento y mejorar la estabilidad a altas velocidades, por lo tanto, mejora el rendimiento del vehículo.

En [8], se propone una estrategia de control de modelo inverso no lineal basado en una red neuronal para la planta de desalinización MultiStage Flash (MSF). Cabe mencionar que la selección del número de neuronas ocultas es importante en el diseño de la red neuronal, por lo que en este estudio se obtiene el número de neuronas en la capa oculta mediante el método del Error Medio Cuadrático. La ventaja de esta estructura de control es que se necesita una formulación matemática muy simple para los cálculos de control. Los resultados obtenidos indican que la estrategia propuesta es una herramienta prometedora para planta de MSF y que se puede implementar en otras plantas no lineales.

En [9], se propone una estrategia de control de modelo inverso del inversor en el campo del filtrado de potencia activa, introduciendo una red neuronal BP, esto para aproximar el modelo inverso. Se llevaron a cabo varias simulaciones con diferentes condiciones y el resultado fue favorable. En comparación con el control de histéresis, este método tiene una frecuencia de conmutación estable; Comparándolo con la modulación de onda triangular, este método no contiene un componente armónico que sea igual a la onda de modulación en la frecuencia.

En [10], se presenta los tipos de estructuras de modelos con las que se puede realizar el entrenamiento de una red neuronal artificial, donde se presenta estructuras de modelos lineales y no lineales.

Capítulo 2

Marco teórico

2.1. Columna de Destilación

En la Figura 2.1, se muestra el diagrama de flujo de la columna de destilación a la que se le aplicará el control con RNA, para obtener una calidad de destilación esperada por el operador.

De acuerdo con [10], las refinerías de petróleo usan la destilación extensamente. Una de las separaciones de condensación es la purificación de propano para su uso en GLP. La columna de destilación que realiza esta tarea se denomina "despropanizador".

El agua típica de la torre de enfriamiento es de aproximadamente $90^{\circ}F$ ($32^{\circ}C$) en condiciones de verano en el peor de los casos, por lo que muchas columnas funcionan a una presión lo suficientemente alta para dar una temperatura de $110^{\circ}F$ ($43^{\circ}C$) en el tambor de reflujo. Esto proporciona diferenciales de temperatura razonables para la transferencia de calor y el área razonable del condensador. Es una compensación entre el costo de energía del rehervidor y la inversión de capital en el área del intercambiador de calor del condensador.

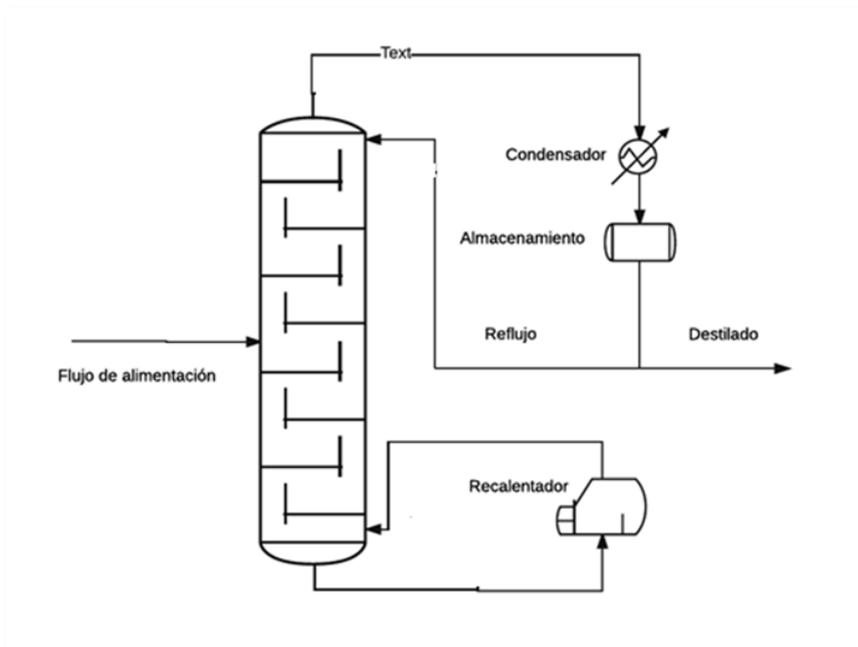


Figura 2.1: Columna de destilación.

2.2. Una Red Neuronal Artificial (RNA)

2.2.1. Características de las RNA

En esta sección se trata de las características de una RNA de acuerdo con la referencia [12].

Las Redes Neuronales Artificiales, ANN (Artificial Neural Networks) están inspiradas en las redes neuronales biológicas del cerebro humano. Están constituidas por elementos que se comportan de forma similar a la neurona biológica en sus funciones más comunes. Estos elementos están organizados de una forma parecida a la que presenta el cerebro humano.

Las ANN al margen de “parecerse” al cerebro presentan una serie de características propias del cerebro. Por ejemplo las ANN aprenden de la experiencia, generalizan de ejemplos previos a ejemplos nuevos y abstraen las características principales de una serie de datos.

Aprender: adquirir el conocimiento de una cosa por medio del estudio, ejercicio o experiencia. Las ANN pueden cambiar su comportamiento en función del entorno. Se les muestra un conjunto de entradas y ellas mismas se ajustan para producir unas salidas consistentes.

Generalizar: extender o ampliar una cosa. Las ANN generalizan automáticamente debido a su propia estructura y naturaleza. Estas redes pueden ofrecer, dentro de un margen, respuestas correctas a entradas que presentan pequeñas variaciones debido a los efectos de ruido o distorsión.

Abstraer: aislar mentalmente o considerar por separado las cualidades de un ob-

jeto. Algunas ANN son capaces de abstraer la esencia de un conjunto de entradas que aparentemente no presentan aspectos comunes o relativos.

2.2.2. Estructura básica de una Red Neuronal (RN)

En la siguiente sección se presenta la estructura básica de una RN de acuerdo a la referencia [11].

La neurona, como toda célula, consta de una membrana exterior M, que la limita y le sirve de órgano de intercambio con el medio exterior, de un citoplasma C, que es el cuerpo principal de la célula donde radica el grueso de sus funciones y de un núcleo N, que contiene el material genético de la célula Figura 2.2.

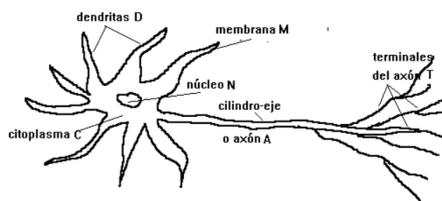


Figura 2.2: Esquema de una Red Neuronal.

El citoplasma presenta unos alargamientos D, llamados dendritas, que son órganos de recepción. En las dendritas termina un gran número de fibras F que son conductores que llevan la señal o impulso nervioso de los receptores o de otras neuronas hacia la neurona. Estas fibras terminan en un pequeño corpúsculo llamado sinapsis, que constituye un relevador bioquímico y que sirve para transferir la señal de una neurona a otra.

Existen dos clases de sinapsis: actuadoras, que favorecen el disparo de la neurona receptora e inhibidora, que dificultan éste. Cuando se presenta un cierto desbalance entre las sinapsis actuadoras y las inhibidoras activas, la neurona dispara un impulso

de salida, que constituye la respuesta de la neurona. Este impulso nervioso de salida es conducido por una prolongación cilíndrica alargada (hasta de varios decímetros de largo) de la neurona, que se llama cilindro eje o axón A, que en su extremo se divide en varias fibras para comunicarse con otras neuronas o con órganos efectores o motores como glándulas o músculos.

El citoplasma de las neuronas forma la masa gris de los centros nerviosos y el conjunto de cilindros ejes forma la masa blanca de aquéllos.

2.2.3. La neurona artificial NA

En [11] se dice que una neurona artificial es una unidad procesadora con cuatro elementos funcionales Figura 2.3

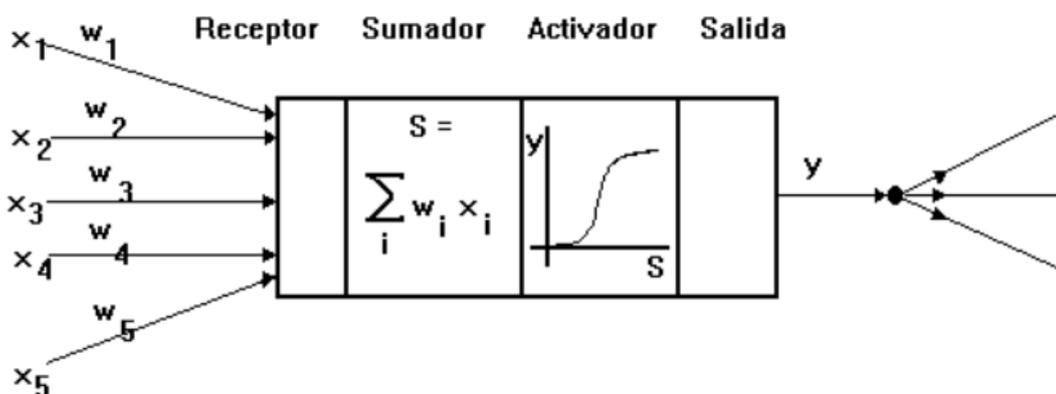


Figura 2.3: Cuatro elementos Funcionales de una NA

- El elemento receptor, a donde llegan una o varias señales de entrada x_i , que generalmente provienen de otras neuronas y que son atenuadas o amplificadas cada una de ellas con arreglo a un factor de peso w_i que constituye la conectividad entre la neurona fuente de donde provienen y la neurona de destino en cuestión.

- El elemento sumador, que efectúa la suma algebraica ponderada de las señales de entrada, ponderándolas de acuerdo con su peso, aplicando la siguiente expresión:

$$S = \sum w_i \cdot x_i. \quad (2.1)$$

- El elemento de función activadora, que aplica una función no lineal de umbral (que frecuentemente es una función escalón o una curva logística) a la salida del sumador para decidir si la neurona se activa, disparando una salida o no.
- El elemento de salida que es el que produce la señal, de acuerdo con el elemento anterior, que constituye la salida de la neurona.

Este modelo neuronal es el utilizado en casi todas las Redes Neuronales artificiales, variando únicamente el tipo de función activadora.

2.3. Redes Neuronales Supervisadas y No Supervisadas

Las redes neuronales se clasifican comúnmente en términos de sus correspondientes algoritmos o métodos de entrenamiento: redes de pesos fijos, redes no supervisadas, y redes de entrenamiento supervisado. Para las redes de pesos fijos no existe ningún tipo de entrenamiento.

2.3.1. Reglas de entrenamiento Supervisado

Las redes neuronales de entrenamiento supervisado son las más populares. Los datos para el entrenamiento están constituidos por varios pares de patrones de entrenamiento

de entrada y de salida. El hecho de conocer la salida implica que el entrenamiento se beneficia de la supervisión de un maestro. Dado un nuevo patrón de entrenamiento, en la etapa $(m + 1)$ –ésima, los pesos se adaptan de la siguiente forma:

$$w_{ij}^{m+1} = w_{ij}^m + \Delta w_{ij}^m. \quad (2.2)$$

Se puede ver un diagrama esquemático de un sistema de entrenamiento supervisado en la Figura 2.4:

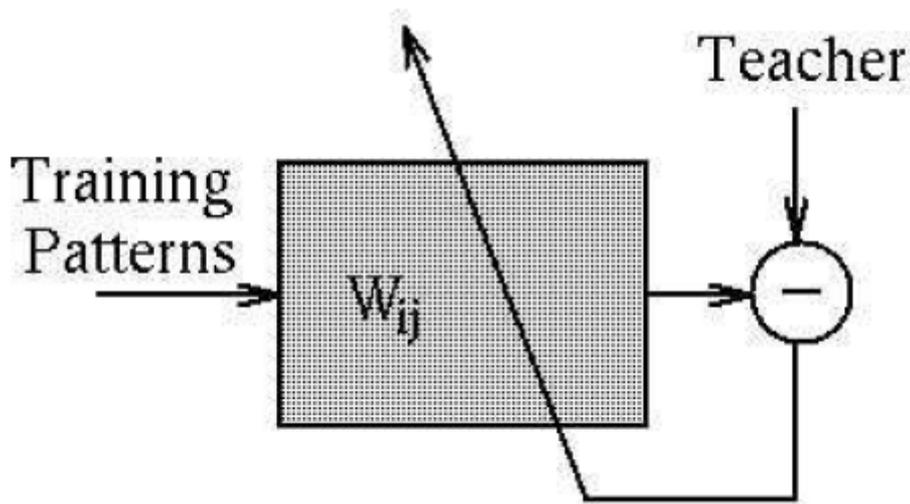


Figura 2.4: Esquema de entrenamiento supervisado.

2.3.2. Reglas de Entrenamiento No Supervisado

Para los modelos de entrenamiento no supervisado, el conjunto de datos de entrenamiento consiste sólo en los patrones de entrada. Por lo tanto, la red es entrenada sin el beneficio de un maestro. La red aprende a adaptarse basada en las experiencias recogidas de los patrones de entrenamiento anteriores. Un esquema típico de un sistema No Supervisado se presenta en la Figura 2.5:

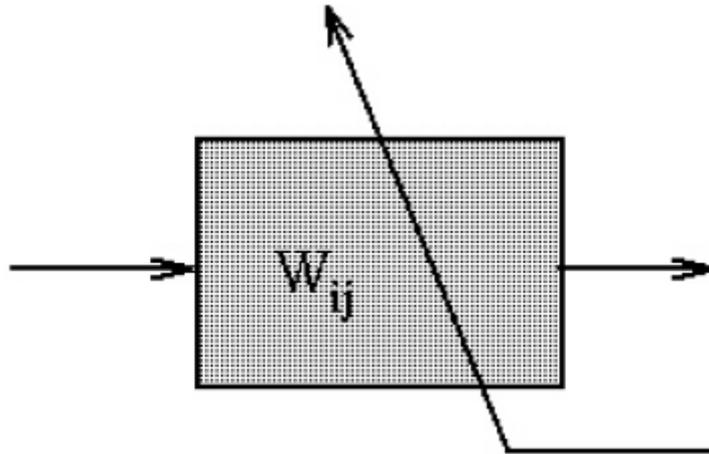


Figura 2.5: Esquema de entrenamiento no supervisado.

Ejemplos típicos de estos esquemas son: la Regla de Aprendizaje de Hebb y la Regla de Aprendizaje Competitivo. Un ejemplo del primero consiste en reforzar el peso que conecta dos nodos que se excitan simultáneamente.

En el aprendizaje competitivo, si un patrón nuevo pertenece a una clase reconocida previamente, entonces la inclusión de este nuevo patrón a esta clase matizará la representación de la misma. Si el nuevo patrón no pertenece a ninguna de las clases reconocidas anteriormente, entonces la estructura y los pesos de la red neuronal serán ajustados para reconocer a la nueva clase.

2.4. Funciones de Base y Activación

Una red neuronal típica se puede caracterizar por la función de base y la función de activación.

Cada nodo (unidad de proceso), suministra un valor y_j a su salida. Este valor se propaga a través de la red mediante conexiones unidireccionales hacia otros nodos de la red. Asociada a cada conexión hay un peso sináptico denominado $\{w_{ij}\}$, que determina el efecto del nodo j –ésimo sobre el nodo i –ésimo.

Las entradas al nodo i – *ésimo* que provienen de los otros nodos son acumuladas junto con el valor umbral θ_i , y se aplica la función base f , obteniendo u_i . La salida final y_i se obtiene aplicando la función de activación sobre u_i .

2.4.1. Función Base (Función de Red)

La función de base tiene dos formas típicas:

- Función lineal de tipo hiperplano: El valor de red es una combinación lineal de las entradas

$$u_i(w, x) = \sum_{j=1}^n w_{ij}x_j. \quad (2.3)$$

- Función radial de tipo hiperesférico: es una función de base de segundo orden no lineal. El valor de red representa la distancia a un determinado patrón de referencia,

$$f(u_i) = (w, x) = \sum_{j=1}^n (x_j - w_{ij}). \quad (2.4)$$

2.4.2. Función de Activación (Función de neurona)

El valor de red, expresado por la función de base, $u(w, x)$, se transforma mediante una función de activación no lineal. Las funciones de activación más comunes son la función sigmoidea y gaussiana:

- Función sigmoidea.

$$f(u_i) = \frac{1}{1 + \exp(-\frac{u_i}{\Phi^2})}. \quad (2.5)$$

- Función Gaussiana.

$$f(u_i) = C * \exp(\frac{u_i}{\Phi^2}). \quad (2.6)$$

2.5. Algoritmo de aprendizaje de una Red Neuronal Artificial

2.5.1. Técnica de optimización

En la referencia [14], se mencionan tres diferentes maneras de optimizar un modelo dependiendo de la cantidad de información requerida sobre la dinámica del modelo, que enseguida se muestra:

- Aprendizaje supervisado.
- Aprendizaje reforzado.
- Aprendizaje no supervisado.

El **aprendizaje supervisado** se basa en el conocimiento de los datos de entrada y salida del proceso. Este método consiste en minimizar el error de la salida del proceso contra la salida del modelo, es para encontrar un modelo que se asemeje mas al proceso.

El **aprendizaje reforzado** se dispone de la información de la calidad del modelo, sin conocer los datos de salida que corresponde a una entrada.

Por último, el **aprendizaje no supervisado** es un método que solo utiliza datos de entrada, este método se utiliza mas en el procesamiento de datos.

En este trabajo se utilizara el método de **aprendizaje supervisado**, por que tenemos los datos de entrada y salida del proceso a controlar.

La técnica de **aprendizaje supervisado** se puede dividir. A continuación se muestra

el criterio que se utiliza para realizar la optimización

$$F(k) = \sum_{i=1}^N e^2(i), \quad (2.7)$$

donde $e(i) = y(i) - {}^m y_i$, y_i es el dato de salida del proceso y ${}^m y_i$ es la salida de la RNA y $F(k)$ es la función de costo.

El entrenamiento se realizará mediante el método de gradiente descendiente. Definiendo el algoritmo de aprendizaje para actualizar los pesos sinápticos y bias de la RNA, con la siguiente función de costo

$$F(k) = \frac{1}{2}(e(k))^2. \quad (2.8)$$

De acuerdo a la RNA que se implementó se sustituye su salida en el error como sigue $e(k) = y(i) - {}^{II} y_i$, con base a esto se reescribe la función de costo

$$F(k) = \frac{1}{2}(y(i) - {}^{II} y_i)^2. \quad (2.9)$$

Ahora bien, para el ajuste de los pesos sinápticos ${}^m w_{ij}$ y el umbral ${}^m \theta_i$ de la RNA, como se mencionó antes, se utilizará el algoritmo de **gradiente descendiente** para minimizar el error.

$$\begin{aligned} {}^m w_{ij}(k+1) &= {}^m w_{ij}(k) - \eta \frac{\partial F(k)}{\partial {}^m w_{ij}(k)}, \\ {}^m \theta_i(k+1) &= {}^m \theta_i(k) - \eta \frac{\partial F(k)}{\partial {}^m \theta_i(k)}, \end{aligned} \quad (2.10)$$

donde,

$$\begin{aligned} \frac{\partial F(k)}{\partial {}^m w_{ij}(k)} &= \frac{\partial F(k)}{\partial e(k)} \frac{\partial e(k)}{\partial {}^m y_i} \frac{\partial {}^m y_i}{\partial {}^m v_i} \frac{\partial {}^m v_i}{\partial {}^m w_{ij}}, \\ \frac{\partial F(k)}{\partial {}^m \theta_i(k)} &= \frac{\partial F(k)}{\partial e(k)} \frac{\partial e(k)}{\partial {}^m y_i} \frac{\partial {}^m y_i}{\partial {}^m v_i} \frac{\partial {}^m v_i}{\partial {}^m \theta_i}. \end{aligned} \quad (2.11)$$

De la ecuación (2.8) se obtiene $\frac{\partial F(k)}{\partial e(k)} = e(k)$, si $e(k) = y(i) - {}^{II} y_i$ entonces $\frac{\partial e(k)}{\partial {}^m y_i} = -1$,

para la $\frac{\partial^m y_i}{\partial^m v_i} = f(v)$, $\frac{\partial^m v_i}{\partial^m w_{ij}} = x_i$ y para el bias $\frac{\partial^m v_i}{\partial^m \theta_i} = 1$.

De acuerdo a esto la ecuación (2.10) queda de la siguiente manera:

$$\begin{aligned} {}^m w_{ij}(k+1) &= {}^m w_{ij}(k) - \eta e(k)(-1)f(v)x_i = {}^m w_{ij}(k) + \eta e(k)f(v)x_i \\ {}^m \theta_i(k+1) &= {}^m \theta_i(k) - \eta e(k)(-1)f(v)(1) = {}^m \theta_i(k) + \eta e(k)f(v) \end{aligned} \quad (2.12)$$

De acuerdo a la ecuación (2.12) se realiza el cálculo de los pesos sináptico y bias de la RNA de la Figura 2.6.

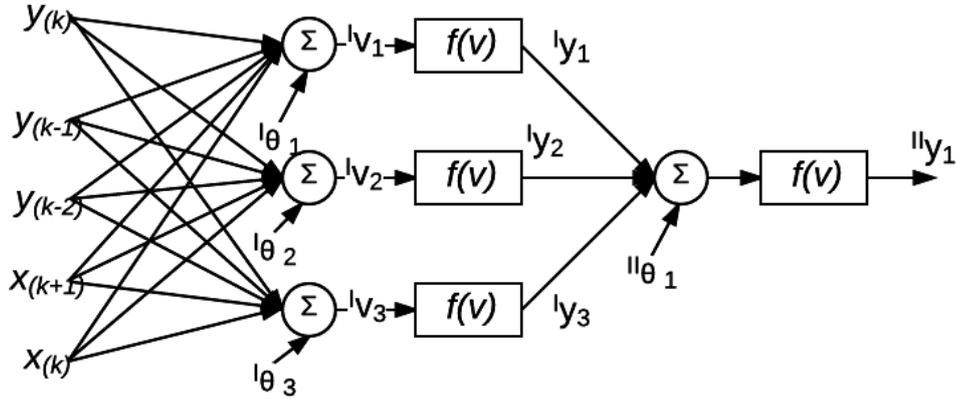


Figura 2.6: Diagrama de la RNA.

$${}^m v_j(k) = \sum_{i=1}^n {}^m w_{ij}(k)u_i(k) + {}^m \theta_j, j = 1, 2, \dots, p \quad NA. \quad (2.13)$$

Dada la matriz de entrada $U \in \mathfrak{R}^{5 \times 1}$ y ${}^m W \in \mathfrak{R}^{n \times 1}$, m indica la capa correspondiente a la RNA, ${}^m V, {}^m \Theta \in \mathfrak{R}^n$.

$$U = \begin{bmatrix} u_1 \\ u_2 \\ u_3 \\ u_4 \\ u_5 \end{bmatrix} = \begin{bmatrix} y(k) \\ y(k-1) \\ y(k-2) \\ u(k) \\ u(k+1) \end{bmatrix}. \quad (2.14)$$

$${}^I W = \begin{bmatrix} {}^I w_{11} & {}^I w_{21} & {}^I w_{31} & {}^I w_{41} & {}^I w_{51} \\ {}^I w_{12} & {}^I w_{22} & {}^I w_{32} & {}^I w_{42} & {}^I w_{52} \\ {}^I w_{13} & {}^I w_{23} & {}^I w_{33} & {}^I w_{43} & {}^I w_{53} \end{bmatrix} = \begin{bmatrix} {}^I W_1 \\ {}^I W_2 \\ {}^I W_3 \end{bmatrix}, \quad (2.15)$$

$${}^{II} W = \begin{bmatrix} {}^{II} w_{11} & {}^{II} w_{12} & {}^{II} w_{13} \end{bmatrix}, \quad (2.16)$$

$${}^I \Theta = \begin{bmatrix} {}^I \theta_1 \\ {}^I \theta_2 \\ {}^I \theta_3 \end{bmatrix}, \quad (2.17)$$

$${}^I V = \begin{bmatrix} {}^I v_1 \\ {}^I v_2 \\ {}^I v_3 \end{bmatrix} = {}^I W U + {}^I \Theta, \quad (2.18)$$

$${}^m Y = f({}^m V), \quad (2.19)$$

$${}^I Y = f({}^I W U + {}^I \Theta), \quad (2.20)$$

$${}^{II} V = {}^{II} W {}^I Y + {}^{II} \theta, \quad (2.21)$$

$${}^{II} Y = f({}^{II} V), \quad (2.22)$$

$${}^{II} Y = f({}^{II} W {}^I Y + {}^{II} \theta).$$

Algoritmo de aprendizaje **gradiente descendiente**

$$\begin{aligned} {}^m w_{ij}(k+1) &= {}^m w_{ij}(k) - \eta \frac{\partial F(k)}{\partial {}^m w_{ij}(k)}, \\ {}^m \theta_i(k+1) &= {}^m \theta_i(k) - \eta \frac{\partial F(k)}{\partial {}^m \theta_i(k)}. \end{aligned} \quad (2.23)$$

Si

$$\begin{aligned}
\frac{\partial F(k)}{\partial e(k)} &= e(k), \\
e(k) &= y(i) -^{II} y_1, \\
\frac{\partial e(k)}{\partial^m y_i} &= -1, \\
\frac{\partial^m y_i}{\partial^m v_i} &= f(v), \\
\frac{\partial^m v_i}{\partial^m w_{ij}} &= x_i, \\
\frac{\partial^m v_i}{\partial^m \theta_i} &= 1.
\end{aligned} \tag{2.24}$$

2.6. Secuencias binarias pseudoaleatorias (PRBS)

Considerando el trabajo descrito en [15] obtenemos las características que se deben tomar en cuenta para la generación de una PRBS de tamaño 1 a 10 bits.

La PRBS es una secuencia de pulsos rectangulares, de ancho modulado, que se aproximan a un ruido blanco de tiempo discreto, por lo tanto, tienen un contenido espectral rico en frecuencias.

Deben su nombre pseudoaleatorio al hecho de que se caracterizan por una longitud de secuencia dentro de la cual las variaciones en el ancho del pulso varían aleatoriamente, pero que, en un tiempo finito son periódicas, definiéndose el período por la longitud del secuencia.

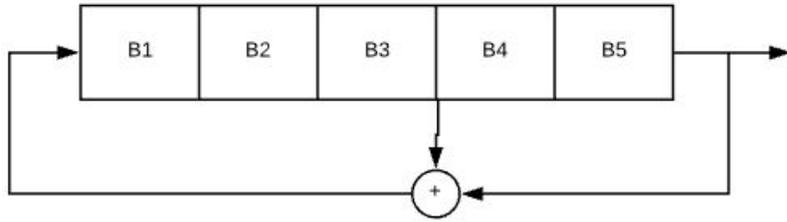


Figura 2.7: Generación de una PRBS de longitud $2^5 - 1 = 31$ periodos de muestreo.

Los PRBS se generan por medio de registros de desplazamiento con retroalimentación (implementados en hardware o software). La longitud máxima de una secuencia es $2^N - 1$ en la que N es el número de celdas del registro de desplazamiento. En la Figura 2.7 se presenta la generación de una PRBS de longitud $31 = 2^5 - 1$ obtenida mediante un registro de desplazamiento de cinco celdas. Tenga en cuenta que al menos una de las N celdas del registro de desplazamiento debe tener un valor lógico inicial diferente de cero (una toma generalmente todos los valores iniciales de las N celdas iguales al valor lógico 1).

Tabla 2.1: Generación de longitud maxima de una PRBS

Número de celdas N	Longitud de secuencia $L = 2^N - 1$	Bits añadidos B_i y B_j
2	3	1 y 2
3	7	1 y 3
4	15	3 y 4
5	31	3 y 5
6	63	5 y 6
7	127	4 y 7
8	255	2, 3, 4 y 8
9	511	5 y 9
10	1023	7 y 10

En la Tabla (2.1) se proporciona para diferentes números de celdas la estructura que permite la generación de PRBS de longitud máxima. En el sitio web del libro se puede encontrar un programa en C++ y una función MATLAB® (prbs.m) para la

generación de secuencias binarias pseudoaleatorias.

Se debe tomar en cuenta también un elemento característico muy importante de la PRBS: la duración máxima de un pulso PRBS (t_{im}) es igual a NT_s (donde N es el número de celdas y T_s es el período de muestreo). Esta propiedad debe considerarse al elegir un PRBS para la identificación del sistema.

2.6.1. Dimensionamiento de un PRBS

Para identificar correctamente la ganancia de estado estable del modelo dinámico de la planta, la duración de al menos, uno de los pulsos (por ejemplo, la duración máxima del pulso) debe ser mayor que el tiempo de aumento t_R de la planta (incluido el retardo de tiempo). La duración máxima de un pulso es NT_s , obteniendo la siguiente condición

$$t_{im} = NT_s > t_R, \quad (2.25)$$

como se muestra en la Figura 2.8.

De la ecuación (2.25), se deriva N y por lo tanto, la longitud de la secuencia es $2^N - 1$.

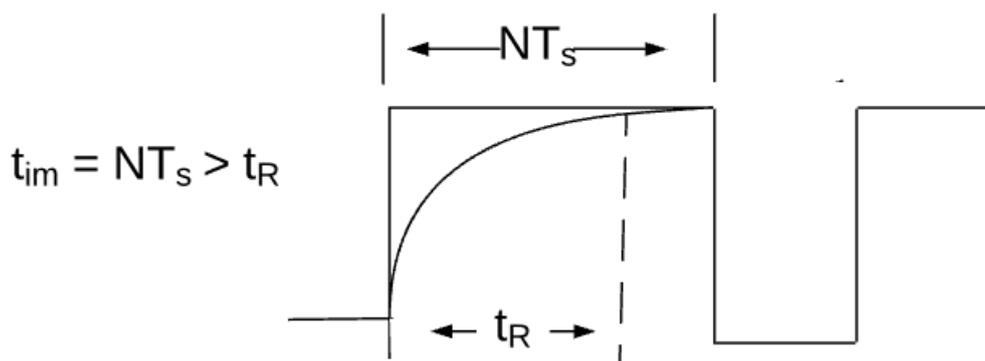


Figura 2.8: Elección de la duración máxima de un pulso en una PRBS

Además, para cubrir todo el espectro de frecuencia generado por un PRBS particular, la duración de una prueba debe ser al menos igual a la longitud de la secuencia. En un gran número de casos, la duración de la prueba (L) se elige igual a la longitud de la secuencia. Si se especifica la duración de la prueba, se debe garantizar que

$$2^{N-1}T_s > L, \quad (2.26)$$

donde L representa la duración de la prueba.

2.6.2. Identificación de sistemas

Para realizar una identificación de sistema es necesario seguir los siguientes pasos, ver Figura 2.9.

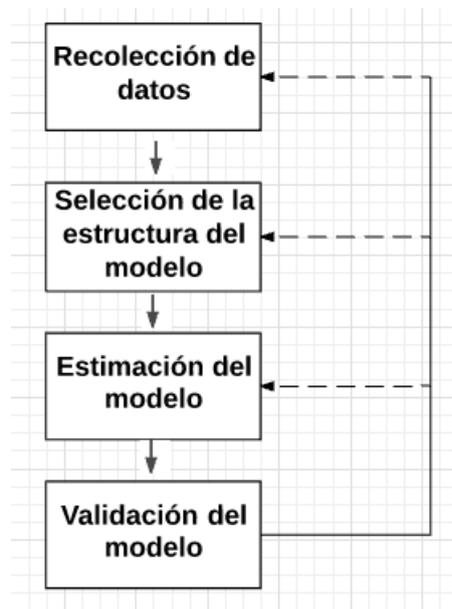


Figura 2.9: Pasos para la identificación de sistemas.

Recolección de datos. Se realiza la recolección de datos entrada y salida de proceso a identificar, como se muestra en la Figura 2.10.

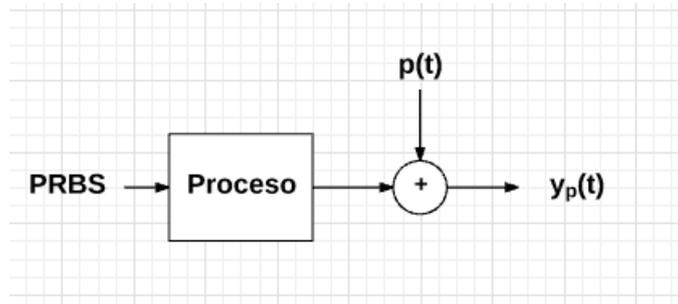


Figura 2.10: Esquema de la obtención de datos.

Selección de estructura del modelo. Consiste en tener varios modelos candidatos para estimar la planta a identificar, existen estructuras de modelos lineales y no lineales, a continuación se muestra algunas estructuras.

- Estructura de modelo ARX

$$A(q)y(t) = B(q)u(t - nk) + e(t). \quad (2.27)$$

- Estructura de modelo ARMAX

$$A(q)y(t) = B(q)u(t - nk) + \frac{C(q)}{(1 - q^{-1})}e(t). \quad (2.28)$$

- Estructura de modelo OE

$$y(t) = \frac{B(q)}{F(q)}u(t - nk) + e(t). \quad (2.29)$$

- Estructura de modelo BJ

$$y(t) = \frac{B(q)}{F(q)}u(t - nk) + \frac{C(q)}{D(q)}e(t), \quad (2.30)$$

donde:

▪

$$A(q) = 1 + a_1q^{-1} + \dots + a_{n_a}q^{-n_a}, \quad (2.31)$$

▪

$$B(q) = b_1q^{-1} + \dots + b_{n_b}q^{-n_b}, \quad (2.32)$$

▪

$$C(q) = 1 + c_1q^{-1} + \dots + c_{n_c}q^{-n_c}, \quad (2.33)$$

▪

$$D(q) = 1 + d_1q^{-1} + \dots + d_{n_d}q^{-n_d}, \quad (2.34)$$

▪

$$F(q) = 1 + f_1q^{-1} + \dots + f_{n_f}q^{-n_f}, \quad (2.35)$$

- $e(t)$ es una simple perturbación al sistema.

2.6.3. Esquemas de control con RNA

En la presente sección se muestra algunos tipos de esquemas de control basado en redes neuronales [5].

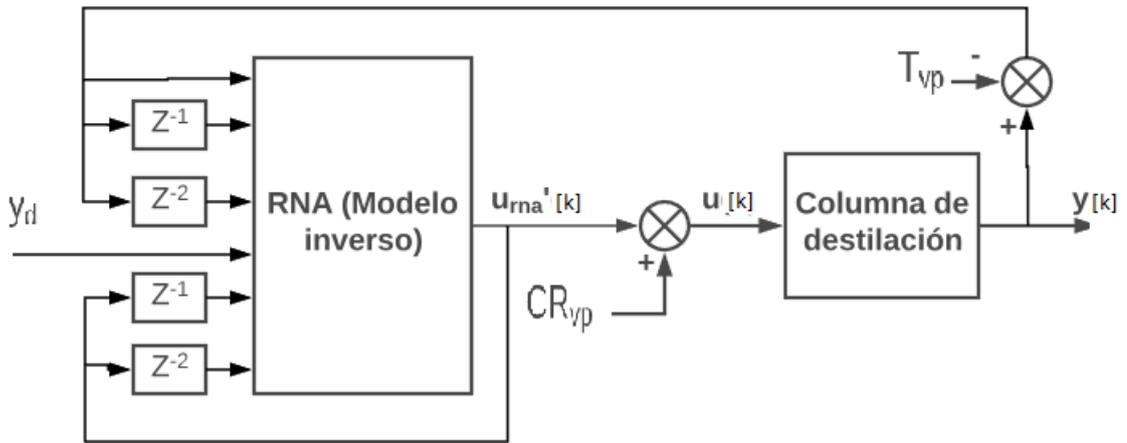


Figura 2.11: Control Interno Directo (CID).

El esquema de la Figura 2.11 muestra la estructura del control interno directo, es la más sencilla, de acuerdo a la estructura se tiene la planta (Proceso Industrial) y la señal de control $u(t)$ es la salida de una RNA.

La característica principal del CID es obtener un modelo inverso con la dinámica del proceso original con una RNA para poder alcanzar la referencia $r(k + 1)$ deseada del proceso. Esta característica de control se logra utilizando las salidas pasadas y presentes que se usan para obtener la salida deseada.

La función de transferencia que representa el sistema es la siguiente

$$y = \frac{n(q)}{d(q)} u, \quad (2.36)$$

donde u es la entrada del proceso, y la salida del proceso, $n(q)$ el numerador y $d(q)$ el denominador de la función de transferencia, de acuerdo a la función de transferencia entonces el modelo inverso queda de la siguiente forma.

$$u = \frac{d(q)}{n(q)}y. \quad (2.37)$$

Las características de la planta y del modelo inverso se muestran en la Figura 2.12 de acuerdo con [1].

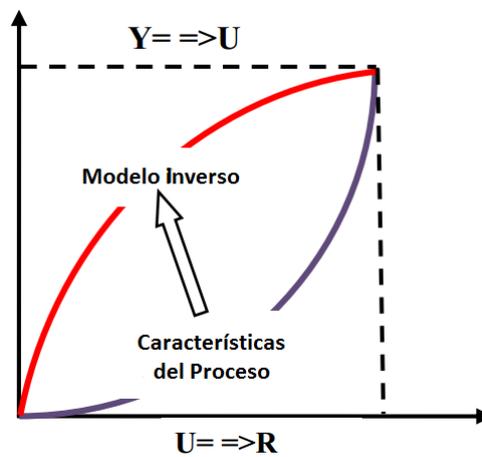


Figura 2.12: Características de la planta y del modelo inverso.

En la Figura 2.13 se muestra el esquema de **Control por Modelo Interno (CMI)**.

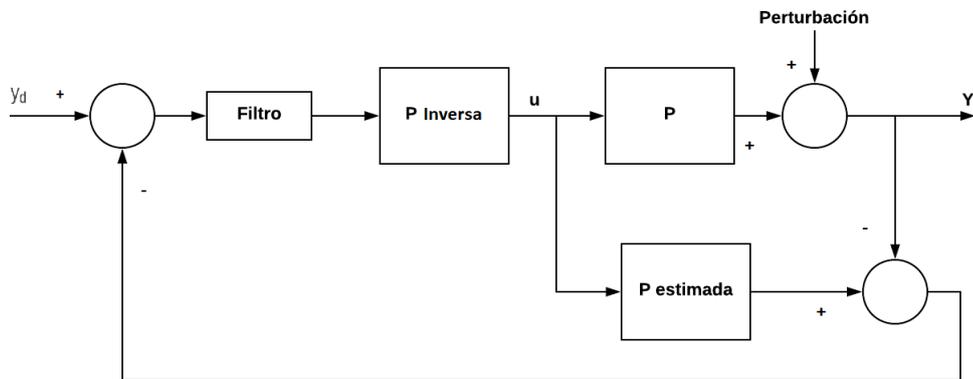


Figura 2.13: Control por Modelo Interno (CMI).

Como se observa en el esquema, parece que tiene características del CID, es decir, también utiliza el modelo inverso y las salidas pasadas y presente, pero esta estructura lo que hace diferente al CID es porque utiliza un modelo estimado del proceso a controlar.

El modelo estimado es simplemente un modelo que tiene las mismas características del proceso que se desea controlar, donde el modelo estimado ayuda a aproximar la perturbación que se presenta, para poder encontrar el error $e(k)$ para que el controlador con modelo inverso actúe al respecto.

Capítulo 3

Resultados de investigación

En este capítulo se presentan las pruebas obtenidas a lo largo de esta investigación, inicialmente se identifica la ubicación de la sensibilidad de cambio de temperatura en cada plato de la columna de destilación.

Posteriormente se simuló el CID y CMI, para ello se realiza el control de temperatura con cambio de referencia.

3.1. Columna de destilación

La columna de destilación que se consideró en esta tesis obtiene un producto destilado que es 98% *mol* en la pureza del propano. A 110°F la presión de vapor del propano es ligeramente superior a 200 psi. Por lo tanto, se seleccionó la presión de funcionamiento con un valor de 200 psi en el condensador. Por otra parte la presión del rehervidor se calcula asumiendo una caída de presión sobre cada plato de 5 in de líquido en alta-presión de la columna. La densidad del líquido de este sistema de hidrocarburos es de aproximadamente $30 \frac{lb}{ft^3}$. La columna tiene 30 platos y se alimenta

en el plato 15, por lo tanto, la presión en el calderín es:

$$P_{base} = P_{condensador} + (N_{platos})(\Delta P_{platos}),$$

$$P_{base} = 200 \text{ psia} + (30)(5in)\left(\frac{ft}{12in}\right)\left(30\frac{lb}{ft^3}\right)\left(\frac{ft^2}{144in^2}\right) = 202,6 \text{ psia.} \quad (3.1)$$

La columna se alimenta con $100\frac{lb-mol}{h}$ de una mezcla de propano (30 % mol), isobutano (40 % mol) y n-butano (30 % mol) a $90^\circ F$. La pureza especificada del destilado es 98 % mol de propano, la impureza especificada de propano en los fondos es 1 % mol. La relación de reflujo es 3.22 y la entrada de calor de rehervidor de diseño es $1,02 \times 10^6\frac{Btu}{h}$. La Figura 3.1 muestra el diagrama de flujo.

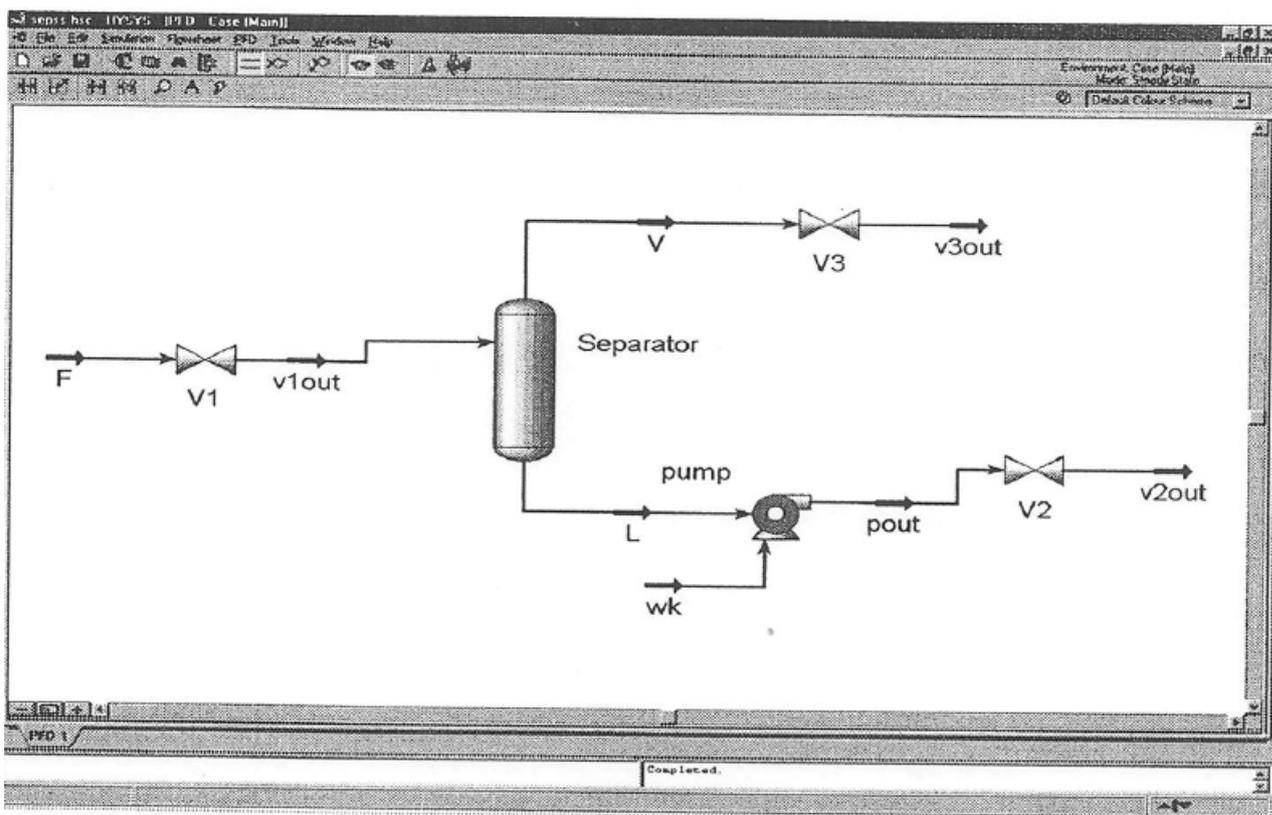


Figura 3.1: Diagrama de flujo de un separador.

3.2. Ubicación de la sensibilidad de cambio de temperatura en cada plato de la Columna de Destilación

Para deducir en que plato es recomendable aplicar el control de temperatura, se realiza un análisis de sensibilidad de temperatura en cada plato como se muestra en la Figura 3.2.

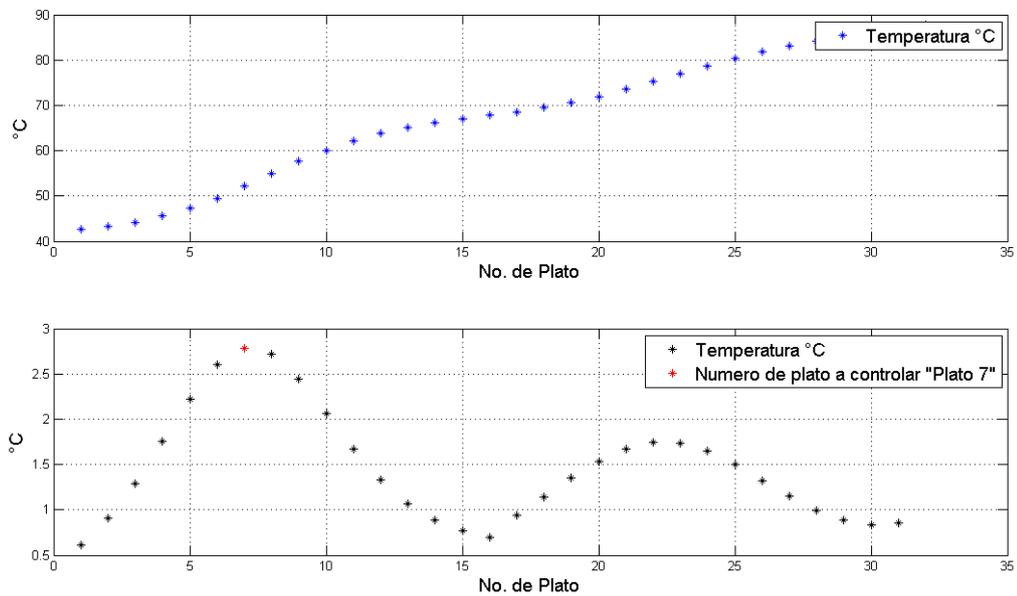


Figura 3.2: En la gráfica superior muestra la sensibilidad de temperatura en cada plato y en la inferior se muestra la diferencia de temperatura.

De acuerdo al análisis de sensibilidad de temperatura, en la Figura 3.2 se observa el comportamiento de la temperatura en cada plato, al obtener la diferencia de un plato a otro, el plato número 7 es el que presenta una variación más importante de temperatura; de tal manera, la temperatura a controlar es la que se encuentra en el plato 7.

3.3. Red Neuronal Artificial (RNA)

3.3.1. Estructura de modelo de la RNA

En la Figura 3.3 se presenta la estructura del modelo ARX (AutoRegresivo, entrada eXterna) utilizada para la RNA, para los esquema de control: CID, CMI y para el esquema de control desarrollado Control por Modelo Interno con Compensador CMIC.

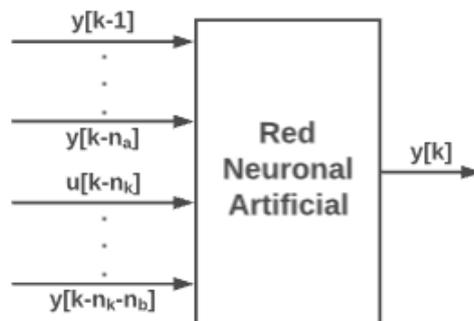


Figura 3.3: Estructura de modelo ARX.

Donde **na** indica el número de veces de retardo de la señal **y**, **nb** indica el número de veces de retardo de la señal **u** y **nk** indica el retardo natural del sistema.

3.3.2. Orden de la estructura de modelo de la RNA

Para que se cumpla con el objetivo de una RNA de bajo orden, se utilizó el método propuesto en [11].

A continuación se presenta los pasos a seguir para calcular el orden de la RNA en donde se seleccionaron valores de n_a y $n_b = 10$ y se realizó el cálculo de 10 modelos con valores de $n_k = 1, 2, 3, \dots, 10$, en donde se obtuvo el Error Cuadrático Medio (ECM)

de cada modelo, para ello se seleccionó un valor para n_k de acuerdo al valor menor correspondiente del ECM, ver Figura 3.4.

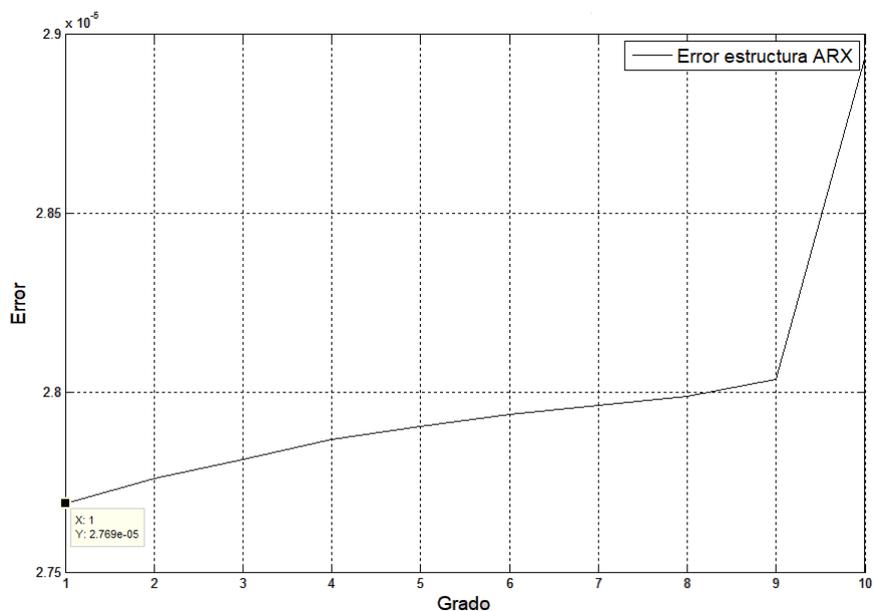


Figura 3.4: Grado para $n_k = 1$.

Posteriormente, luego de haber seleccionado el valor de n_k , el siguiente paso es seleccionar un valor de $n_b = 10$ y se realiza el cálculo de 10 modelos con $n_a = 1, 2, 3, \dots, 10$, obteniendo el ECM de cada modelo, de igual forma se seleccionaron valores de n_b de acuerdo al valor menor del ECM correspondiente, ver Figura 3.5.

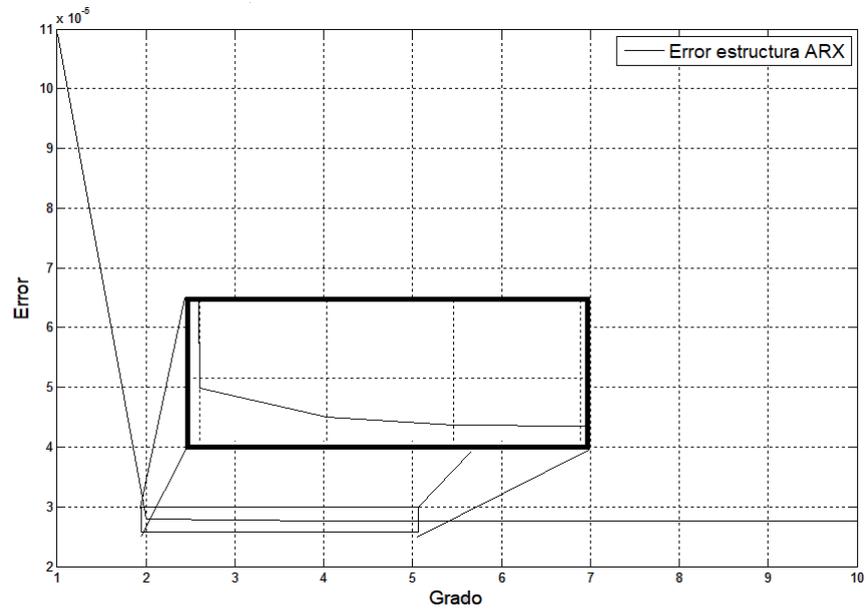


Figura 3.5: Grado para $n_a = 3$.

Después de haber seleccionado n_k y n_a , es necesario realizar el cálculo de los modelos con $n_b = 1, 2, 3, \dots, 10$, obteniendo el ECM para seleccionar el valor de n_a de acuerdo al ECM, ver Figura 3.6.

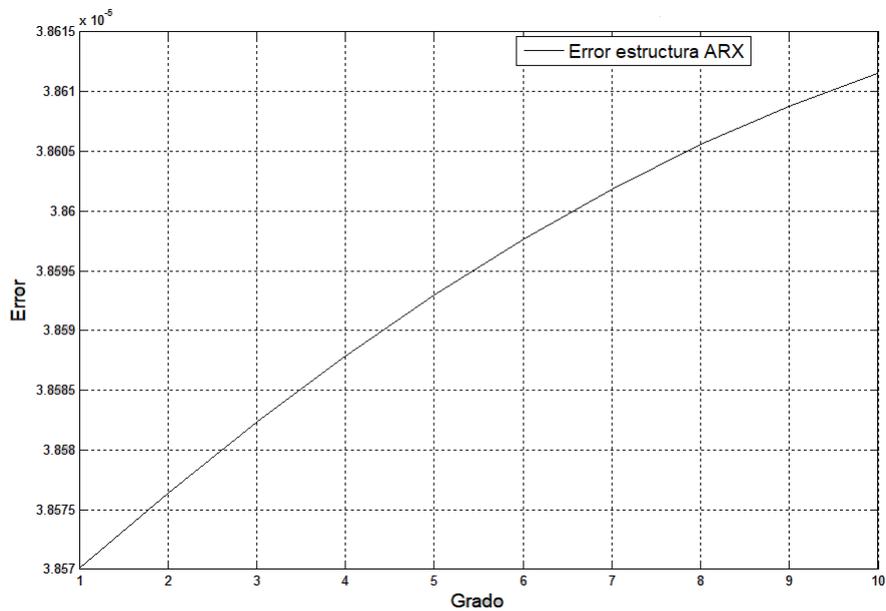


Figura 3.6: Grado para $n_b = 1$.

El orden de la RNA fue de $n_a = 3$, $n_b = 1$ y $n_k = 1$.

3.3.3. Entrenamiento de la RNA

Para el entrenamiento de la RNA se utilizó una PRBS de 9 bits como entrada, de tal forma se obtiene la salida con la finalidad de obtener mas datos de entrenamiento. La característica de la PRBS se muestra en la Tabla (3.1).

Tabla 3.1: Característica de la PRBS

BITS	Datos
5	31
9	511

Los datos de entrenamiento, los cuales se utilizan para el entrenamiento de la RNA fuera de línea y los datos de validación, que son aquellos datos totalmente nuevos para la RNA y que deciden si la estimación con la RNA se encuentra lo mas cercano al 100 %, los resultados de estimación se muestran en la Tabla 3.2.

Tabla 3.2: FIT de la RNA

Datos	FIT %
Datos de entrenamiento	98.1831 %
Datos de validación	96.9183 %

En la Figura 3.7 se aprecian los datos de entrenamiento y en la Figura 3.10 la validación de la misma, además los datos de validación se muestran en la Figura 3.8 y en la Figura 3.11 se muestra la validación.

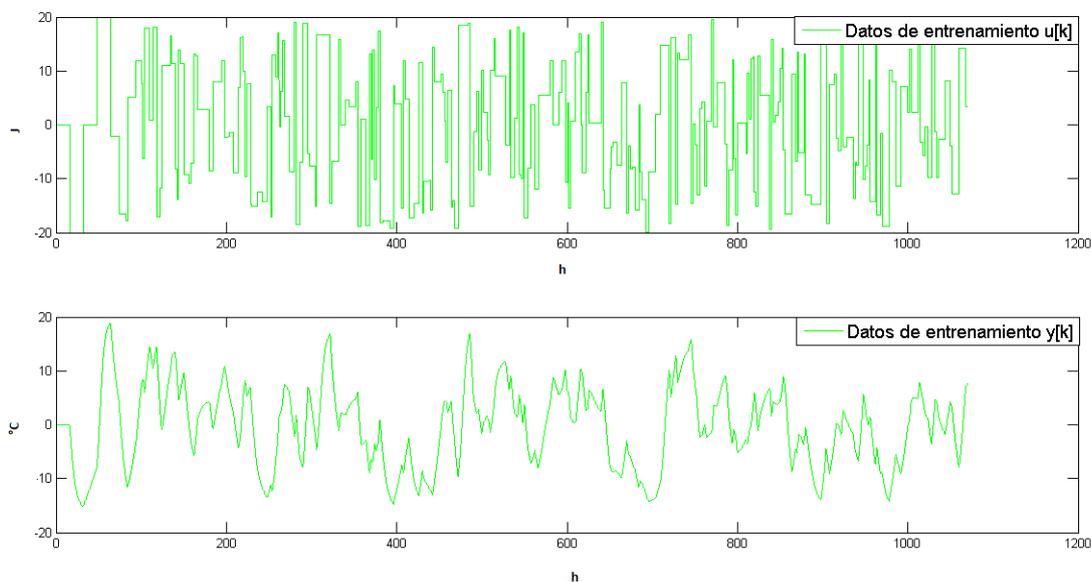


Figura 3.7: Datos de entrenamiento (9 bits) donde la superior indica la entrada de calor en el rehervidor de la columna y la inferior la temperatura de acuerdo al calor agregado.

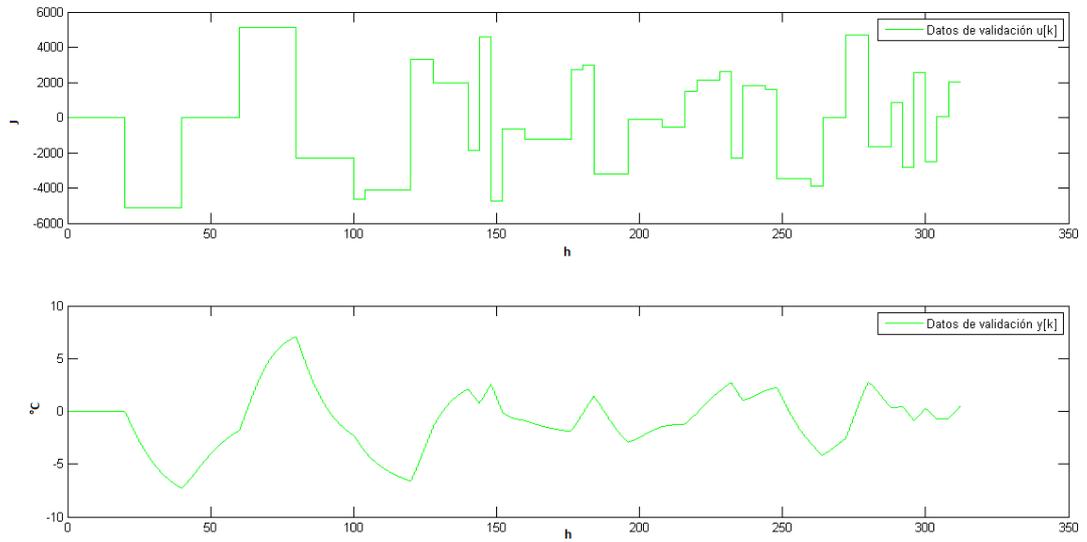


Figura 3.8: Datos de validación (5 bits) donde la superior indica la entrada de calor en el rehervidor de la columna y la inferior la temperatura de acuerdo al calor agregado.

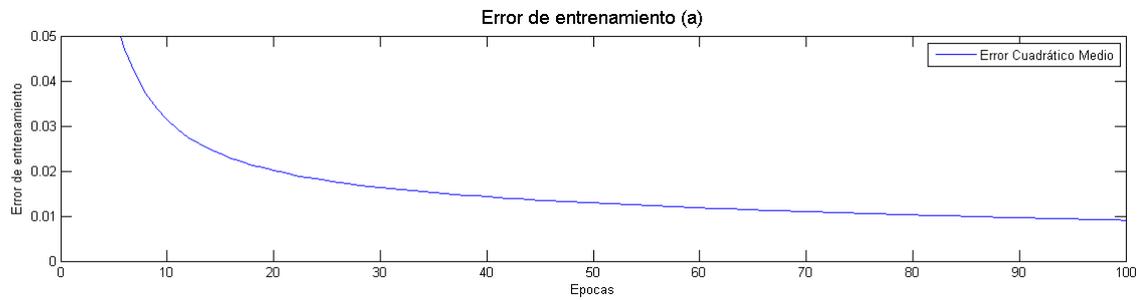


Figura 3.9: Dinámica del error de entrenamiento de la RNA.

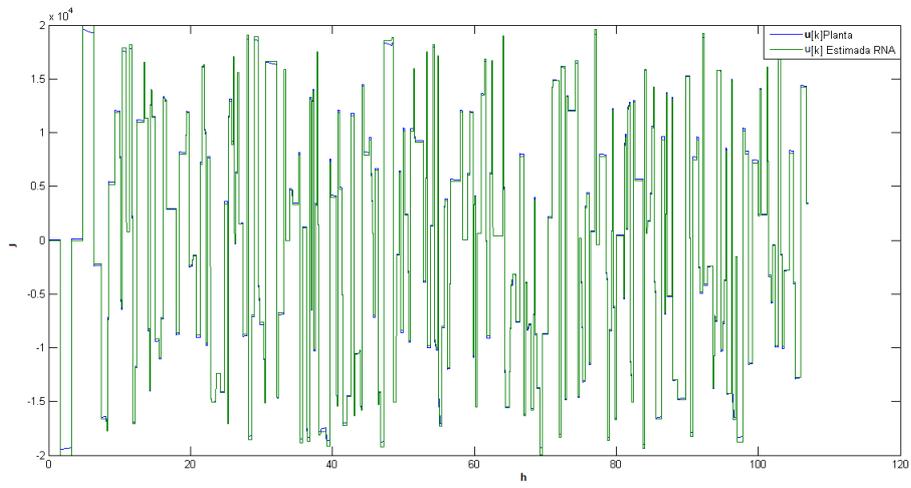


Figura 3.10: Estimación de $u[k]$ (datos de entrenamiento).

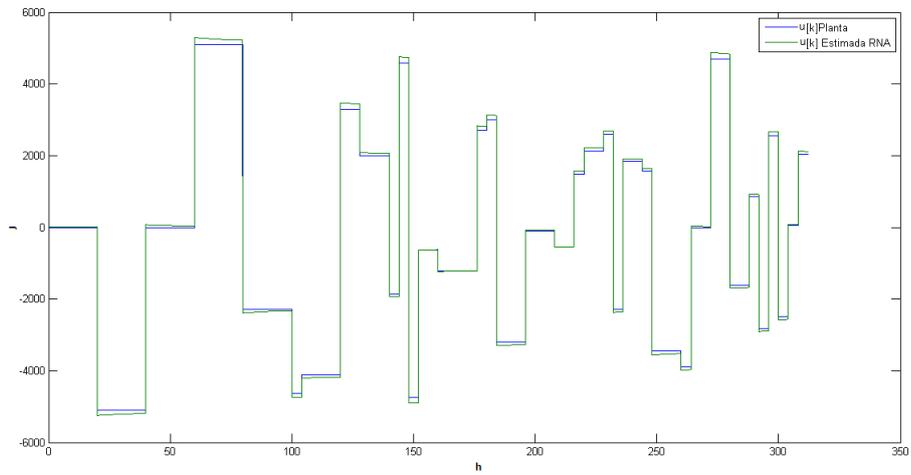


Figura 3.11: Estimación de $u[k]$ (datos de validación).

Capítulo 4

Simulaciones

4.1. Simulación 1: Esquema de Control Inverso Directo (CID) con RNA

4.1.1. Planteamiento del problema

En la Figura 4.1 se presenta el esquema CID para el control de regulación de temperatura de la columna de destilación en el plato 7, se utiliza una RNA con la característica inversa de la planta, ver Figura 4.1.

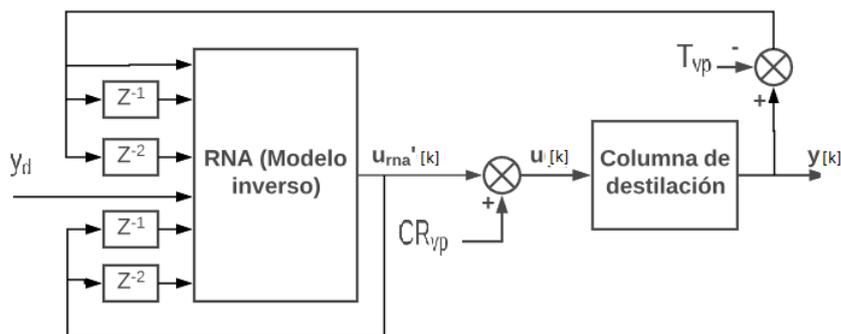


Figura 4.1: Esquema de CID.

En la figura anterior, y_d es la referencia, CR_{vp} es el calor en el rehervidor en

variable de proceso, $y[k]$ es la temperatura en el plato 7, T_{vd} es la temperatura en el plato 7 (variable de proceso) y $u[k]$ representa la cantidad de calor que se le agrega en el rehervidor.

4.1.2. Objetivo de la simulación

La simulación tiene como objetivos:

1. Analizar el comportamiento de la ley de control $u[k]$ y la dinámica de la temperatura $y[k]$ con respecto al cambio de referencia que se le aplica en el tiempo 1 h.
2. Comparar los resultados obtenidos con resultados de un controlador PI.

4.1.3. Desarrollo de la simulación

De acuerdo al esquema CID se aplica control de regulación de la temperatura en variable de desviación. Para ello se realiza cambio de referencia en el tiempo 1 h, de 0 a 2.4 °C. De acuerdo a este cambio, en la Figura 4.5 se puede observar la ley de control que se obtuvo con el esquema CID y controlador PI.

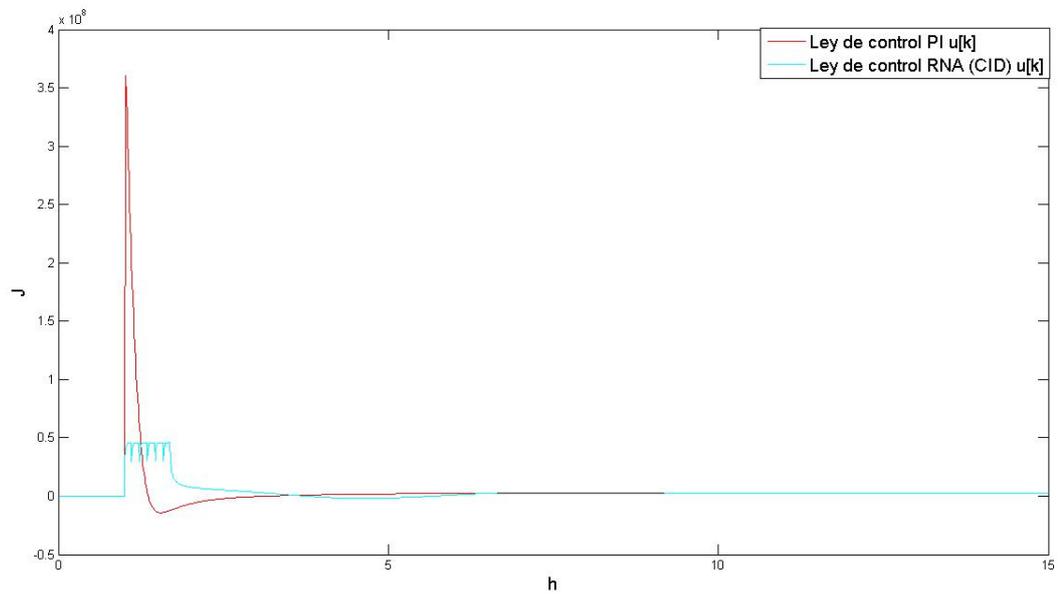


Figura 4.2: Comparación de la ley de control $u[k]$ de CID vs PI.

En la figura anterior se presenta la comparación de la ley de control, donde: la gráfica de color rojo representa la ley de control del PI y la de color cian la ley de control de la RNA.

En la Figura 4.6, se observa el comportamiento de la temperatura que adquiere de acuerdo a la ley de control CID y PI.

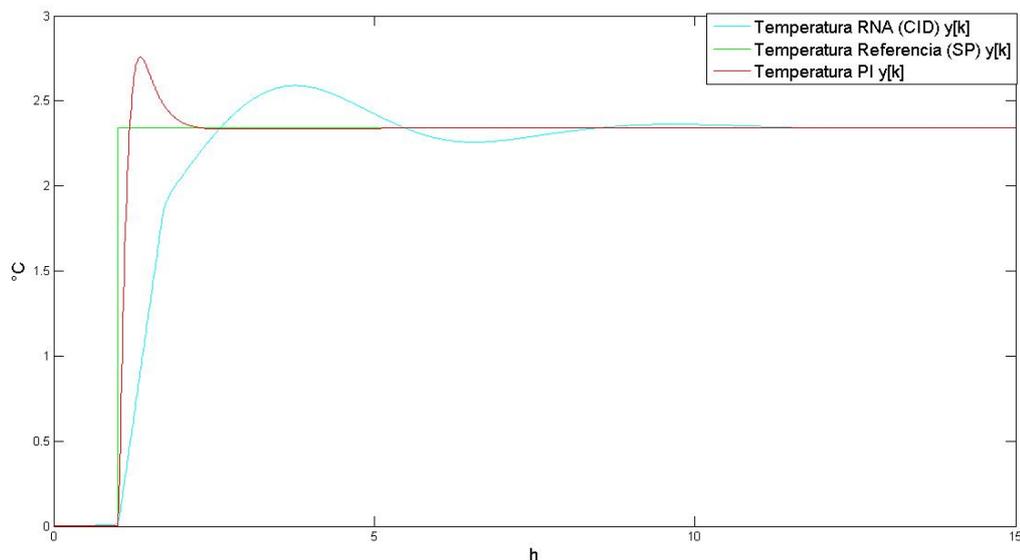


Figura 4.3: Comparación de Temperatura °C de CID (cyan) vs PI (rojo).

Se observa que la dinámica de la temperatura que presenta utilizando el esquema CID su tiempo de transitorio es aproximadamente 6.5 h, mientras que el tiempo de transitorio utilizando un PI es de 2 h., pero observando la ley de control del PI tiene un sobretiro muy elevado y la ley de control de la RNA presenta una U[k] con menos sobretiro provocando un mayor tiempo transitorio en la temperatura.

4.2. Simulación 2: Esquema de Control por Modelo Interno (CMI) con RNA

4.2.1. Planteamiento del problema

En la Figura 4.4 se presenta el esquema CMI para el control de regulación de temperatura de la columna de destilación en el plato 7, se utiliza una RNA con la

característica inversa de la planta, en este esquema también tiene una RNA que tiene característica de estimar la temperatura de la planta con el fin de eliminar la perturbación que exista en la salida.

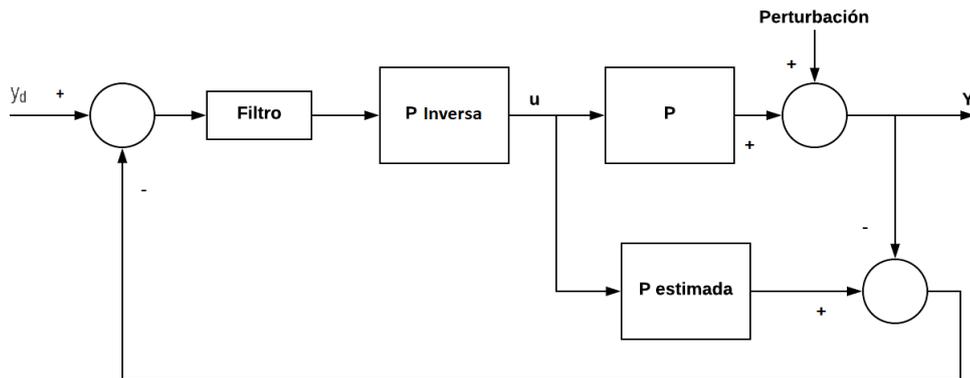


Figura 4.4: Esquema de CMI.

En la figura anterior, y_d es la referencia, CR_{vp} es el calor en el rehervidor en variable de proceso, $y[k]$ es la temperatura en el plato 7, T_{vd} es la temperatura en el plato 7 (variable de proceso) y $u[k]$ representa la cantidad de calor que se le agrega en el rehervidor.

4.2.2. Objetivo de la simulación

La simulación tiene como objetivos:

1. Analizar el comportamiento de la ley de control $u[k]$ y la dinámica de la temperatura $y[k]$ con respecto al cambio de referencia que se le aplica en el tiempo 1 h.
2. Comparar los resultados obtenidos con la implementación de un controlador PI.

4.2.3. Desarrollo de la simulación

De acuerdo al esquema CID se aplica control de regulación de la temperatura en variable de desviación. Se realiza cambio de referencia en el tiempo 1 h, de 0 a 2.4 °C. De acuerdo a este cambio, en la Figura 4.5 se puede observar la ley de control que se obtuvo con el esquema CID y controlador PI.

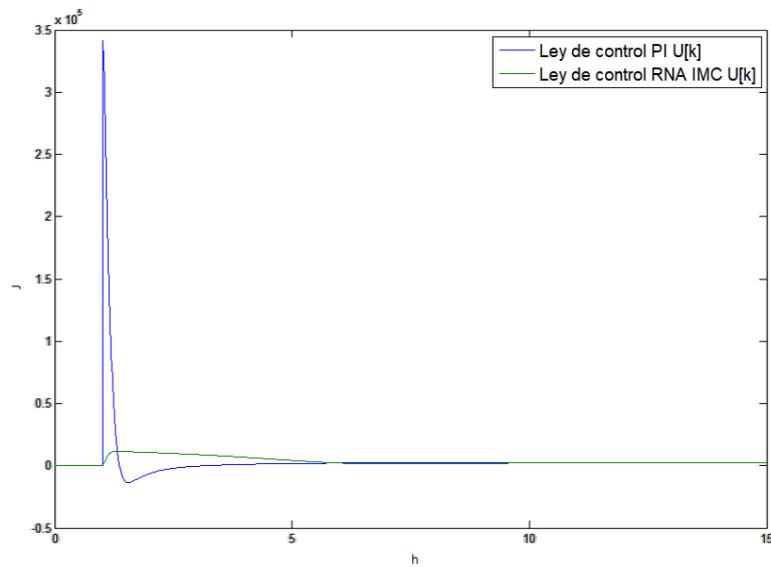


Figura 4.5: Comparación de la ley de control $u[k]$ de CMI vs PI.

En la figura anterior se presenta la comparación de la ley de control, donde: la gráfica de color rojo representa la ley de control del PI y la de color cian la ley de control de la RNA.

En la Figura 4.6, se observa el comportamiento de la temperatura con respecto a la ley de control CMI y PI.

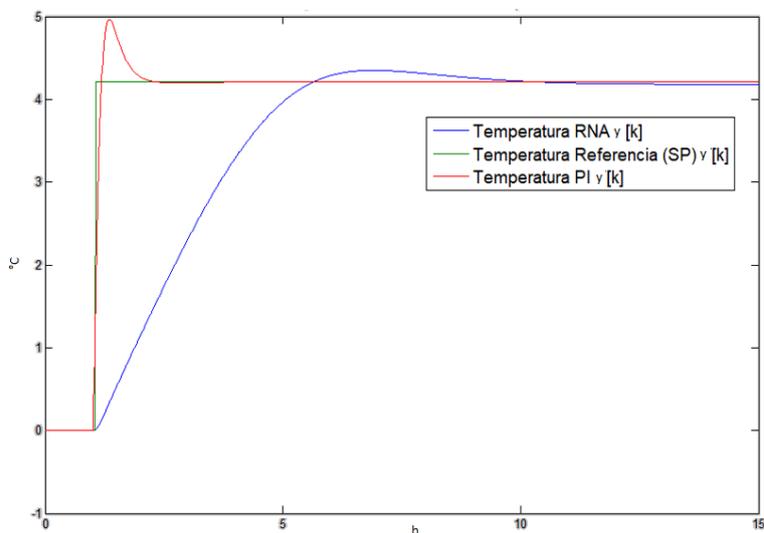


Figura 4.6: Comparación de Temperatura $^{\circ}\text{C}$ de CMI (cyan) vs PI (rojo).

Se observa que la dinámica de la temperatura que presenta utilizando el esquema CMI su tiempo transitorio es aproximadamente 6.5 h, mientras que el tiempo de transitorio utilizando un PI es de 2 h, pero observando la ley de control la del PI tiene un sobretiro muy elevado y la ley de control de la RNA presenta una $U[k]$ con menos sobretiro generando un mayor tiempo de transitorio en la temperatura.

4.3. Simulación 3: Comparación de los resultados de los controladores con RNA y PI

4.3.1. Planteamiento del problema

Se realiza una comparativa involucrando la temperatura y ley de control para visualizar los comportamientos de cada controlador.

4.3.2. Objetivo de la simulación

La simulación tiene como objetivos:

1. Analizar el comportamiento de la ley de control $u[k]$ con respecto a cada uno de los controladores y la dinámica de la temperatura $y[k]$ con respecto al cambio de referencia que se le aplica en el tiempo 1 h.
2. Comparar los resultados de cada control obtenido contra los resultados de un PI.

4.3.3. Desarrollo de la simulación

De acuerdo a los esquemas CID y CMI se aplica control de regulación de la temperatura en variable de desviación. Se realiza cambio de referencia en el tiempo 1 h, de 0 a 2.4 °C. De acuerdo a la integración de gráficas que se muestra en la Figura 4.7 se puede observar la ley de control que se obtuvo con los esquemas CID, CMI y controlador PI.

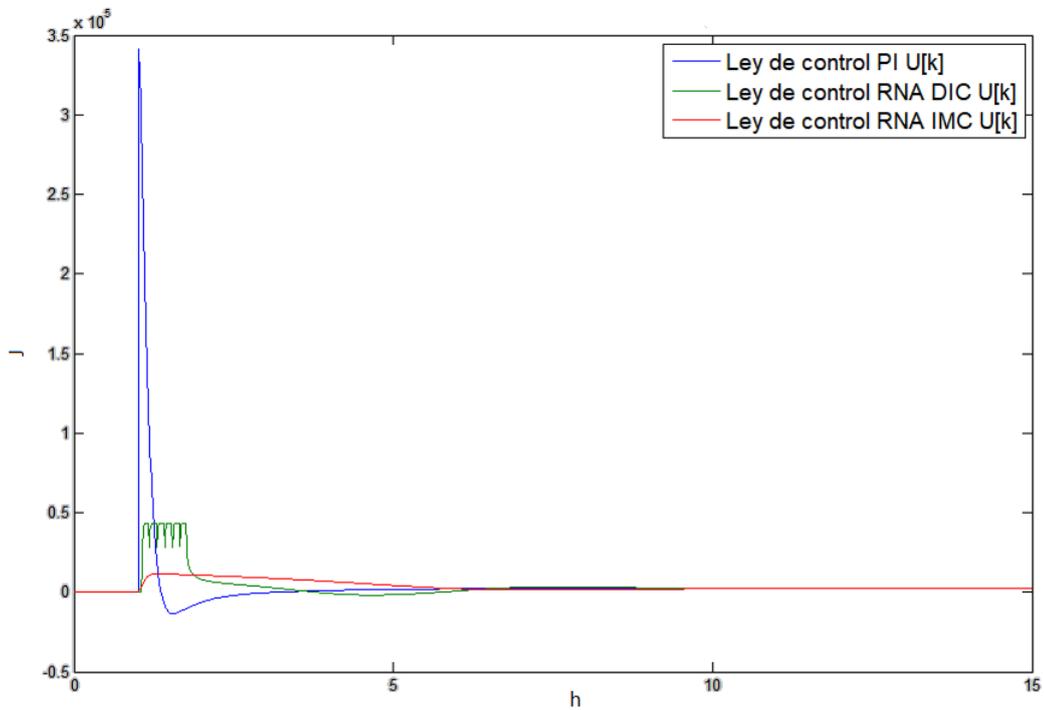


Figura 4.7: Comparación de la ley de control $u[k]$ de CID vs CMI vs PI.

En la figura anterior se muestra la comparación de la ley de control, donde: la gráfica de color azul representa la ley de control del PI, la de color verde la ley de control de la RNA (CID) y la de rojo es la de CMI. Se aprecia que la dinámica generada por el controlador PI muestra un sobretiro elevado y la CID presenta una oscilación suave, asociada a la RNA del esquema CMI.

En la Figura 4.6, se observa el comportamiento de la temperatura que adquiere con los diferentes controles pertenecientes a la RNA y al PI.

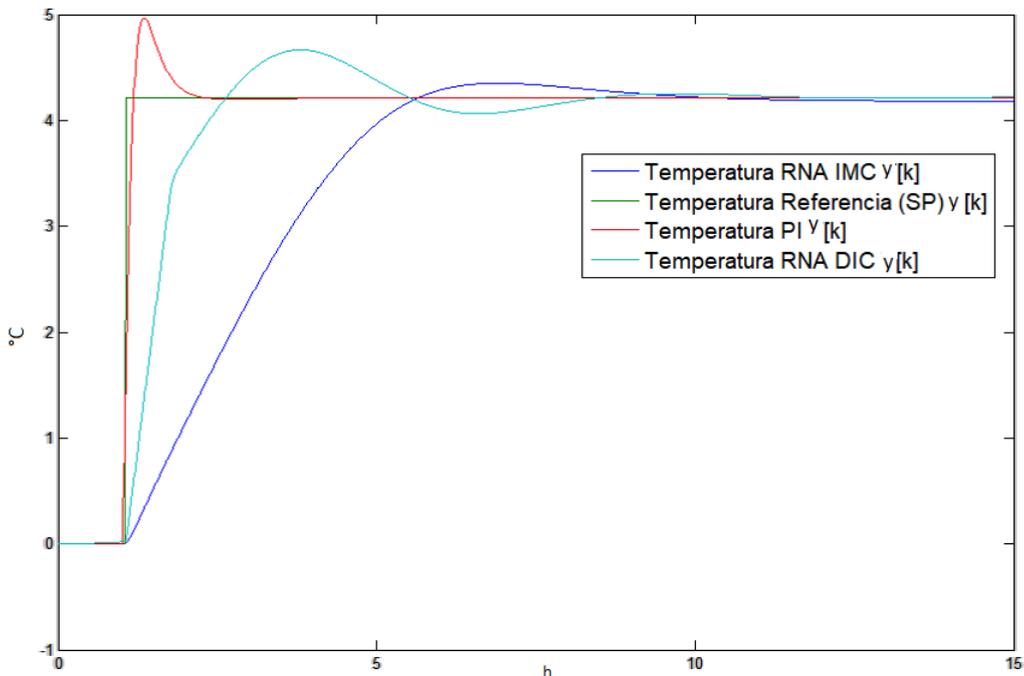


Figura 4.8: Comparación de Temperatura F de CID vs CMI vs PI.

Se observa que la temperatura deseada se alcanza con un menor tiempo transitorio, pero el esfuerzo de la ley de control es muy grande, sin embargo el esquema CMI muestra una ley de control suave con un transitorio más que grande que la del PI.

4.4. Simulación 4: Esquema de Control por Modelo Interno con Compensador (CMIC) con RNA

4.4.1. Planteamiento del problema

El esquema CMI contiene una RNA que tiene característica inversa de la planta y una RNA como modelo estimado de la planta como se puede observar en la Figura 4.9.

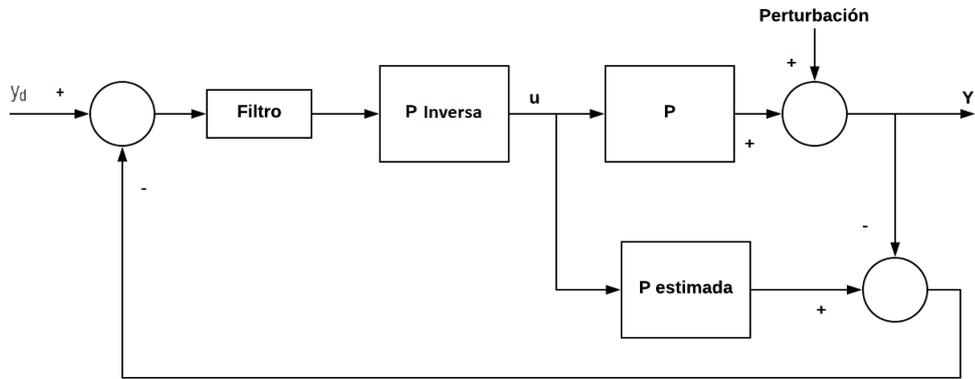


Figura 4.9: Esquema de Control por Modelo Interno.

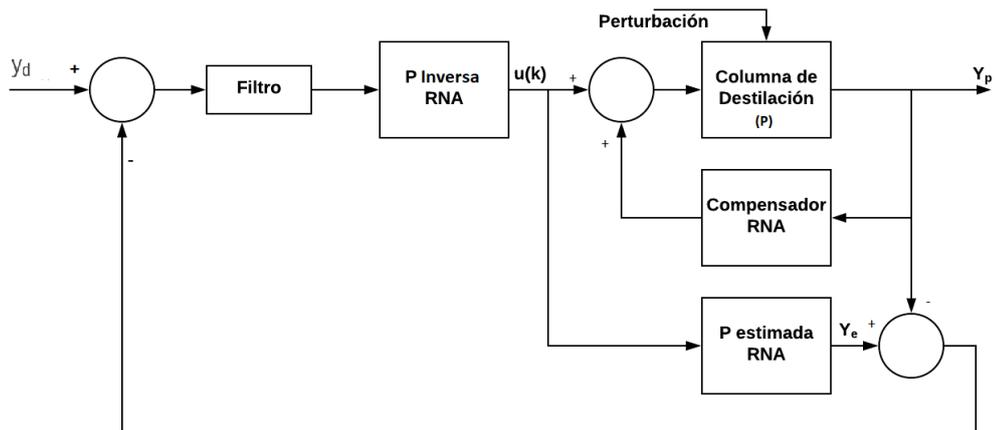


Figura 4.10: Esquema de Control por Modelo Interno con Compensador $u(k)$ para el CMIC desarrollado.

En la figura anterior y_d es la referencia, CR_{vp} es el calor en el rehervidor en variable de proceso, $y[k]$ es la temperatura en el plato 7, T_{vd} es la temperatura en el plato 7 (variable de proceso) y $u[k]$ representa la cantidad de calor que se le agrega en el rehervidor.

4.4.2. Objetivo de la simulación

La simulación tiene como objetivos:

1. Visualizar el comportamiento del resultado de que se obtuvo con los dos esquemas anteriormente pero presentando el esquema desallodado CMIC.
2. Comparar los resultados obtenidos con resultados de un PI, generando una perturbación en el flujo de entrada.

4.4.3. Desarrollo de la simulación

De acuerdo al esquema CID, CMI, PI y CMIC se controla la temperatura, generando una perturbación en el flujo de entrada como se muestra en la Figura 4.11.

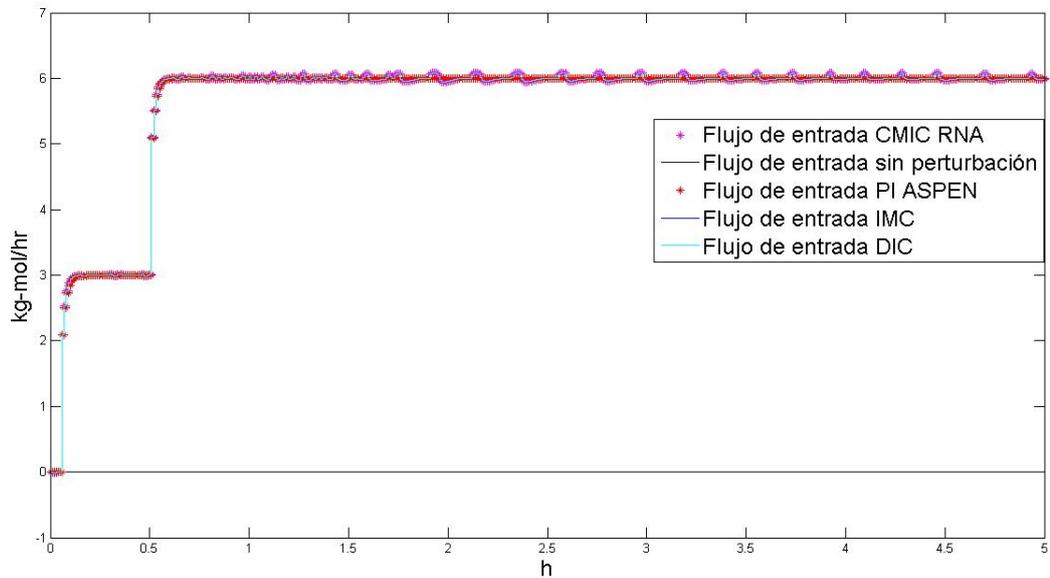


Figura 4.11: Perturbación en el flujo de entrada.

Este cambio de flujo de entrada en el plato 7 se considera como perturbación.

En la Figura 4.12, se observa el comportamiento de la temperatura que adquiere de acuerdo al cambio de flujo de entrada como se muestra en la Figura 4.11.

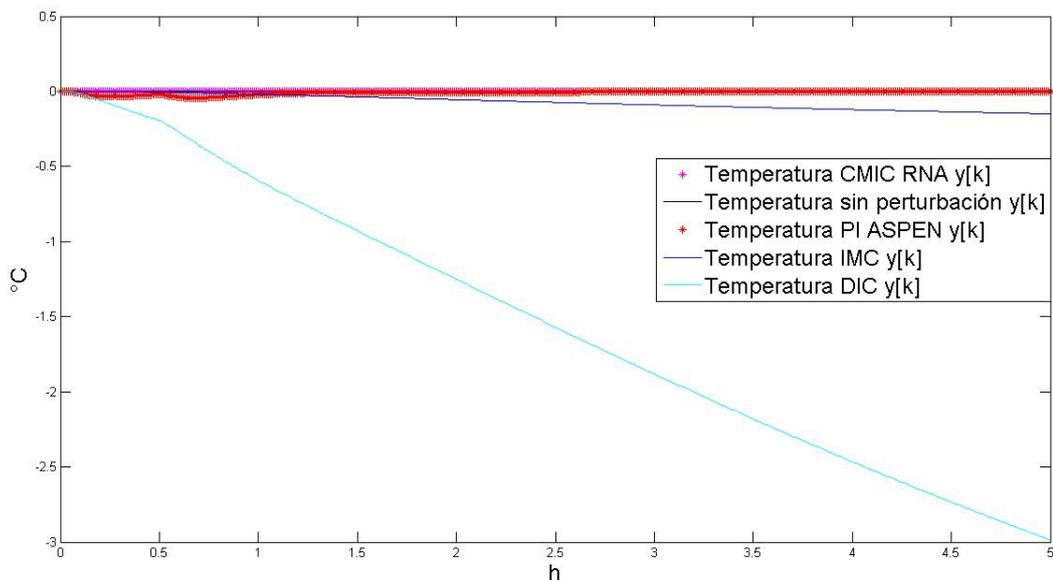


Figura 4.12: Comparativa de Temperatura con el esquema de CMIC vs PI.

En la figura anterior se observa que en los esquemas de control CID Y CMI la temperatura se desvia sin poder ser controlada, esto sucede por que el esquema CID no permite realizar el control de perturbaciones, mientras que la CMI si puede controlar una perturbación siempre que la perturbación este presente en la salida y no como en este caso que la perturbación esta presente dentro del proceso.

La composición se esta controlando indirectamente mediante la dinámica de la temperatura, el comportamiento de la composición se muestra en la Figura 4.13, cumpliendo con el objetivo de mantener la composición a un 98% mol.

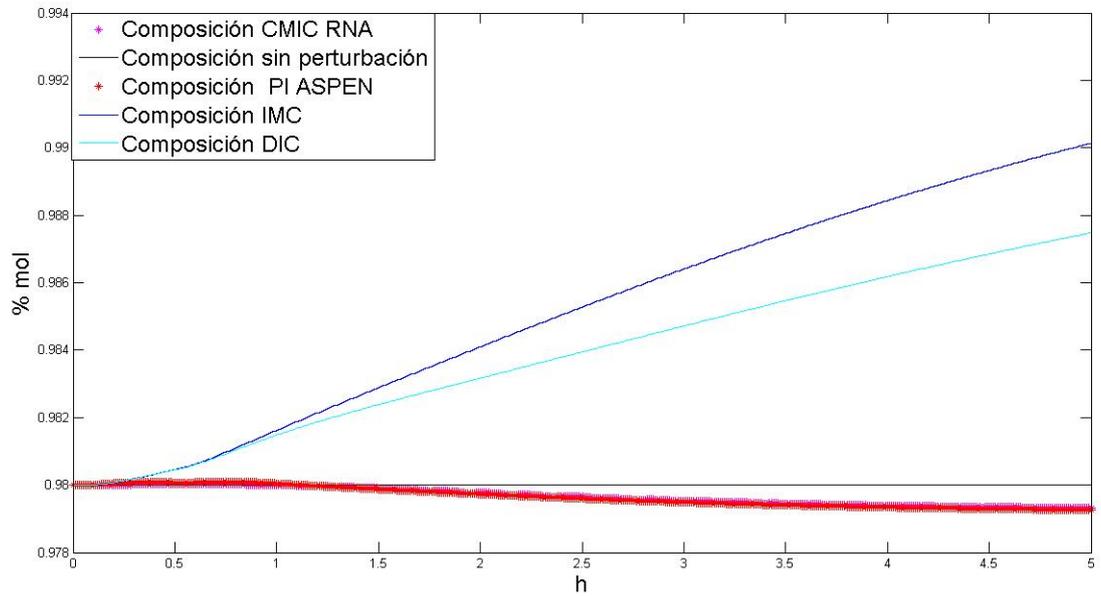


Figura 4.13: Comparativa de la dinámica del destilado (en % de propano) con los esquemas de CMIC contra PI contra CID y contra CMI.

De igual forma los esquemas CID y CMI no son capaces de mantener la concentración cerca del 98 % mol de propano.

Capítulo 5

Conclusiones

Como conclusiones de esta tesis podemos describir las siguientes:

Primero se utilizó como señal de excitación una PRBS de 5 bits, se dedujo que los datos que se obtuvieron eran insuficientes para la caracterización de la RNA para la realización del control deseado. De acuerdo a este análisis se entreno una red neuronal artificial con 9 bits y con base a estos datos obtenidos se concluyó que se obtiene una mejor respuesta de control.

Analizando la respuesta del controlador propuesto se observa que el tiempo de establecimiento en la temperatura es un poco lento, pero esto se logra a un bajo costo ya que la exigencia de la ley de control es menor. Con esto se ve que la eficiencia del esquema propuesto es mejor.

A partir del análisis de los resultados obtenidos de los esquemas implementados, se desarrolló una propuesta de control por modelo interno compensado (CMIC), el cual se aplico a la columna de destilación, obteniendo una mejora en el porcentaje de error con respecto a las otras estrategias de control: PI, CMIC, CID y CMI, ver Tabla (5.1). Además se comprobó que presenta un comportamiento más óptimo (ley de control) que

los esquemas CMI y CID de acuerdo al resultado obtenido en cambio de referencia.

Tabla 5.1: ECM de los resultados de los controles de temperatura y de la composición

Error cuadrático medio	Temperatura	Composición
Control desarrollado CMIC	0.0217 %	0.0075 %
Control Aspen Plus Dynamics <i>PI</i>	0.3461 %	0.0079 %
Control IMC	2.8860 %	0.1143 %
Control DIC	61.2585 %	0.0852 %

De acuerdo al cálculo de error cuadrático medio que se presenta en la tabla anterior, se observa que en el porcentaje de la temperatura se obtiene un mejor resultado con el esquema de control CMIC contra el controlador PI.

Trabajos Futuros

- Implementar el esquema CMIC en otros procesos considerando perturbaciones dentro de los procesos.
- Diseñar e implementar una red neuronal artificial dinámica para el esquema CMIC y realizar simulaciones considerando cambios en algunos parámetros del proceso, asociándolos como posibles perturbaciones.

Bibliografía

- [1] R.J. Rajesh, R. Preethi, P. Mehata, B. Jaganatha Pandian. Artificial Neural Network based Inverse Model Control of a Nonlinear Process, 2015. IEEE International Conference on Computer, Communication and Control (IC4-2015).
- [2] Takayuki Yamada. Discussion of Stability of Learning Type Neural Network Direct Controller and Its Folding Behavior. SICE Annual Conference, 2012.
- [3] Weiliang Liu, Haining Zhang, Changliang Liu, Yongjun Lin, Liangyu Ma, Wenying Chen. Energy Storage Inverter Control Based on Neural Network Inverse Model, Proceeding of the 2015. IEEE International Conference on Information and Automation Lijiang, China, August 2015.
- [4] Subhash Gupta, L. Rajaji y S. Kalika Modelling of Nonlinear Superheated temperature control Process using Neural Networks. IET, Tiruchengode, Tamilnadu, India, 2012.
- [5] M. Norgaard, O. Ravn, N. K. Poulsen y L. K. Hansen. Neural Networks for Modelling and Control of Dynamic Systems. Editorial Springer, 2000.
- [6] Petr Dolezel, Pavel Rozsival, Martirn Mariska. Piecewise-Linear Neural Network: a Tool for Modelling of the Processes to be Controlled. International Conference on Computational Science and and Computayional Intelligence, 2014.

- [7] M. Norgaard, O. Ravn, N. K. Poulsen. NNSYSID and NNCTRL Tools for system identification and control with neural networks, 2001. Computing & Control Engineering Journal, February 2001.
- [8] Carlos Jesús Zúñiga Aguilar. Estimador M de Huber para la Identificación de un Modelo en Red Neuronal. Tesis de maestría en ciencias Ingeniería Electrónica, CENIDET, Cuernavaca, Morelos, México, 2014.
- [9] César Octavio Márquez Aguirre. Neuro-Identificación de Sistemas Dinámicos No Lineales Afines con la Entrada con Incertidumbre en la Retroalimentación. Tesis de maestría en ciencias Ingeniería Electrónica, CENIDET, Cuernavaca, Morelos, México, 2016.
- [10] W.L. Luyben. Plantwide Dynamic Simulators in Chemical Processing and Control. Nueva York, EEUU: Marcel Dekker, 2002.
- [11] L. Ljung. System identification toolbox: User's guide. MathWorks Incorporated, 1995.
- [12] L. Felipe. Fundamentos de redes neuronales artificiales. Laboratorio de cibernética aplicada, Centro de instrumentación UNAM, 2000.
- [13] Germán Álvarez Alba. Diseño de redes neuronales artificiales no supervisadas orientadas a la inteligencia de negocio. Laboratorio de cibernética aplicada, Centro de instrumentación UNAM, 2000.
- [14] Oliver Nelles. Nonlinear System Identification. Springer, Berlin, 2001.
- [15] Ioan D. Landau and Gianluca Zito. Digital Control Systems (Design, Identification and Implementation) Springer, 2005.