

PONTIFICIA UNIVERSIDAD CATÓLICA DEL PERÚ

ESCUELA DE POSGRADO

MAESTRÍA EN INGENIERÍA DE CONTROL Y AUTOMATIZACIÓN



**“DISEÑO DE UN SISTEMA DE CONTROL NEURAL PARA EL
MONITOREO Y CONTROL DE CALIDAD EN UNA COLUMNA DE
DESTILACIÓN MULTICOMPONENTES”**

Tesis para optar por el grado de Magíster en Ingeniería de Control y Automatización

Autor : Segundo Feliberto Dávila Tapia

Asesor de Tesis : Dr. Antonio Morán Cárdenas

PUCP – 2013

Dedicatoria

...Nada en el mundo puede tomar el lugar de la Persistencia; el Talento no lo hará; nada es más común que hombres fracasados con talento. La Genialidad no lo hará; genios sin recompensa es casi un proverbio. La Educación no lo hará; el mundo está lleno de vagabundos educados. La Persistencia y determinación solas son omnipotentes. La frase "Sigue Avanzando" siempre ha resuelto y siempre resolverá los problemas de la humanidad.... *Calvin Coolidge / 1872-1933.*

...El presente trabajo está dedicado a mi esposa, mis hijos y mis padres, por su infinita paciencia y continuo soporte, a lo largo de mis estudios; y durante el desarrollo del presente trabajo...

Agradecimiento

A mis profesores de la PUCP, por su continuo apoyo y consejos, a lo largo de los cursos y desarrollo del presente trabajo. A mi asesor, por su paciencia y orientación.

ÍNDICE

INTRODUCCIÓN.....	5
CAPÍTULO 1: ESTADO DEL ARTE	7
1.1.- Introducción	7
1.2.- Descripción del Proceso	11
1.2.1.- <i>La Industria del Gas Natural</i>	11
1.2.1.1.- <i>Factores que Definen la Tecnología del Tratamiento del Gas Natural.-</i>	11
1.2.1.2.- <i>Composiciones de Gas Típicas.-</i>	11
1.2.1.3.- <i>Especificaciones de Calidad de los Productos.-</i>	12
1.2.1.4.- <i>Terminología Utilizada para Identificar Líquidos del Gas Natural según su Composición.-</i> 13	13
1.2.2.- <i>Esquema Básico de un Sistema de Procesamiento de Gas Natural</i>	15
1.2.3.- <i>Los Sistemas de Estabilización de Condensado</i>	16
1.3.- Estado del Arte del Sistema de Control Neural para el Monitoreo y Control de	19
Calidad en una Columna de Destilación Multicomponentes.....	19
1.3.1.- <i>Estado del Arte de los Sistemas de Estabilización de Condensado en la Industria</i>	19
<i>del Gas Natural</i>	19
1.3.2.- <i>Estado del Arte de los Sistemas de Control en Columnas de Destilación</i>	22
1.3.3.- <i>Estado del Arte de los Sistemas de Control Inferencial</i>	24
1.4.- Objetivos de la Tesis	29
1.4.1.- <i>Objetivo General</i>	29
1.4.2.- <i>Objetivos Específicos</i>	29
CAPÍTULO 2: EL PROCESO DE ESTABILIZACIÓN DE CONDENSADOS DE GAS NATURAL COMO OBJETO DE CONTROL AUTOMÁTICO	30
2.1.- Introducción	30
2.2.- Análisis y Caracterización del Sistema	30
2.2.1.- <i>Esquema del Sistema de Estabilización de Condensado</i>	30
2.2.1.1.- <i>Descripción de los Equipos Principales y sus Características de Operación.-</i>	31
2.2.1.2.- <i>Descripción de las Estrategias de Control del Sistema.-</i>	33
2.2.1.3.- <i>Característica de las Corrientes de Alimentación y Productos del Sistema.-</i>	34
2.2.1.4.- <i>Especificaciones de Calidad a Controlar en los Productos del Sistema.-</i>	37
2.2.2.- <i>Comportamiento en Estado Estacionario del Sistema</i>	37
2.2.2.1.- <i>Simulación del Sistema en Estado Estacionario.-</i>	37
2.2.2.2.- <i>Comportamiento de la Calidad del Producto de Fondo de la Columna de Destilación.-</i> ...	39
2.2.2.3.- <i>Curvas de Operación de la columna.-</i>	40
2.2.3.- <i>Comportamiento Dinámico del Sistema</i>	44
2.2.3.1.- <i>Simulación Dinámica del Sistema de Estabilización de Condensado.-</i>	45

CAPÍTULO 3: DISEÑO DEL SISTEMA DE CONTROL BASADO EN REDES NEURONALES ARTIFICIALES PARA EL MONITOREO Y CONTROL DE CALIDAD DE LA COLUMNA DE DESTILACION MULTICOMPONENTES	47
3.1.- Introducción	47
3.2.- Construcción del Modelo de Red Neuronal Artificial para la Estimación de la Calidad del Producto de la Columna de Destilación Multicomponentes	48
3.2.1.- <i>Esquema General de un Sistema de Red Neuronal Artificial (RNA)</i>	48
3.2.1.1.- <i>Entrenamiento de la Red Neuronal Artificial (RNA).</i> -.....	50
3.2.1.2.- <i>Acondicionamiento de los Datos.</i> -.....	52
3.2.2.- <i>Modelamiento de Sistemas Mediante Red Neuronal Artificial (RNA) Dinámica</i>	52
3.2.3.- <i>Selección de Variables del Sistema de Estabilización de Condensado para el Modelamiento</i>	54
3.2.3.1.- <i>Esquema a Implementar en Matlab.</i> -.....	55
3.2.4.- <i>Generación de Datos para el Entrenamiento y Validación del Sistema de Red Neuronal Artificial (RNA) Dinámica</i>	57
3.3.- Entrenamiento y Validación de la Red Neuronal Artificial Dinámica del Sistema	60
3.3.1.- <i>Resultados de la Estimación de la Calidad del Producto de Fondo de la Columna de Destilación Multicomponentes Durante el Entrenamiento de la Red Neuronal Dinámica</i>	60
3.3.2.- <i>Validación de la Red Neuronal Artificial (RNA) Dinámica</i>	66
3.4.- Diseño del Sistema de Control Basado en la Estimación de Calidad por Red Neuronal Artificial Dinámica.....	71
3.4.1.- <i>Estructura del Controlador Inferencial de Calidad</i>	71
3.5.- Evaluación de la Performance del Sistema de Control a Implementar	73
3.5.1.- <i>Resultados del Comportamiento del Controlador Inferencial Basado en RNA Dinámica con Estructura en Cascada sobre el Flujo de Aceite Térmico a la Columna</i>	75
3.5.2.- <i>Resultados del Comportamiento del Controlador Inferencial Basado en RNA Dinámica con Estructura en Cascada sobre el Flujo de Aceite Térmico a la Columna y Override de Temperatura de Fondo de la Columna</i>	78
3.6.- Conclusiones Preliminares	83
 CAPÍTULO 4: IMPACTO EN LA PRODUCCIÓN Y BENEFICIO DE LA ESTRATEGIA DE CONTROL IMPLEMENTADA	 85
4.1.- Impacto de la Estrategia de Control en la Producción de Condensado de Fondo de Columna... ..	85
4.2.- Impacto de la Estrategia de Control en la Demanda de Aceite Térmico de los Reboiler de la Columna	88
4.3.- Conclusiones Preliminares	92
 CONCLUSIONES GENERALES.....	 94
Conclusión Principal.-.....	94
Conclusiones Secundarias.-.....	94
 RECOMENDACIONES	 96

REFERENCIAS BIBLIOGRÁFICAS..... 97

- Anexo 1.- Programa en Matlab para el Entrenamiento de la Red Neuronal Dinámica
- Anexo 2.- Programa en Matlab para la Validación de la Red Neuronal Dinámica
- Anexo 3.- Simulación Dinámica con el Esquema de Control Inferencial Implementado



INTRODUCCIÓN

Los sistemas de destilación, desde hace muchas décadas, vienen siendo ampliamente usados en la industria de procesos químicos, especialmente en refinerías y procesos de acondicionamiento y tratamiento de gas natural. Los objetivos típicos en estos sistemas están asociados al cumplimiento de especificaciones sobre la calidad de los productos, y para lo cual usualmente se cuenta con analizadores online para monitoreo de estas especificaciones como es el caso de cromatógrafos, así como análisis en laboratorio mediante técnicas específicas.

Sin embargo, el correcto funcionamiento de estos sistemas de medición online resultan susceptibles a una serie de factores como son: correcto diseño del sistema de acondicionamiento de la muestra a analizar (fast loop, calentamiento, control de presión, etc.), ensuciamiento del producto a analizar, complejidad del mantenimiento, problemas electrónicos, etc.,... que afectan la precisión de los datos reportados y generan altos tiempos de respuesta, así como altos costos del mantenimiento asociado a los mismos; y que los hacen poco atractivos para asociarse a algún esquema efectivo de control.

Debido a estas consideraciones, surge el interés en poder estimar mediante el uso de sensores por software (observadores o soft sensor como se les conoce típicamente) la calidad de los productos de estas columnas, para su uso en un esquema efectivo de control, tomando como caso específico de análisis una columna de destilación multicomponentes de un sistema de estabilización de condensado, que típicamente se encuentra en los procesos de acondicionamiento de gas natural.

En ese sentido, las técnicas basadas en redes neurales, resultan muy atractivas debido a su probada capacidad para el manejo de no linealidades, interacción y dependencia entre las variables de interés, así como su capacidad para del desarrollo de modelos robustos a efectos de ruido y perturbaciones en las señales.

De esta forma, se pretende diseñar un sistema de estimación y control inferencial basado en redes neuronales, como una alternativa frente a los esquemas tradicionales de monitoreo y control de calidad de productos de estas columnas, y que además sea factible de implementarse en un sistema de control distribuido (DCS); así como mostrar los beneficios asociados al mismo.

Es así que a lo largo del presente trabajo de Tesis, se desarrollan 4 capítulos que permitirán mostrar de forma detallada los pasos necesarios para el diseño del sistema de estimación basada en redes neuronales artificiales, así como el diseño del esquema de control inferencial y las variaciones que admite el mismo.

El Capítulo 1 inicia con la descripción del contexto sobre el cual se ubica el proceso que es materia de nuestro análisis y nos vamos adentrando progresivamente hacia los Estados del Arte de los Sistemas de Estabilización de Condensado, de los Sistemas de Control en Columnas de Destilación y de los Sistemas de Control Inferencial; para describir finalmente los Objetivos que se persiguen con el desarrollo del presente trabajo de Tesis.

El Capítulo 2 busca describir el proceso de Estabilización de Condensados de Gas Natural como Objeto de Control Automático, para lo cual se describen los equipos que conforman estos sistemas, los principios de funcionamiento de cada uno y se van mostrando las relaciones que existen entre las variables de proceso de cada uno, a fin de poder determinar más adelante aquellas que servirían para establecer el esquema de la red neuronal artificial que usaremos.

El Capítulo 3 cubre el Diseño del Sistema de Control basado en Redes Neuronales Artificiales para el Monitoreo y Control de Calidad de la Columna de Destilación Multicomponentes. En este capítulo se realiza la construcción del modelo de red neuronal artificial para la estimación de la calidad del

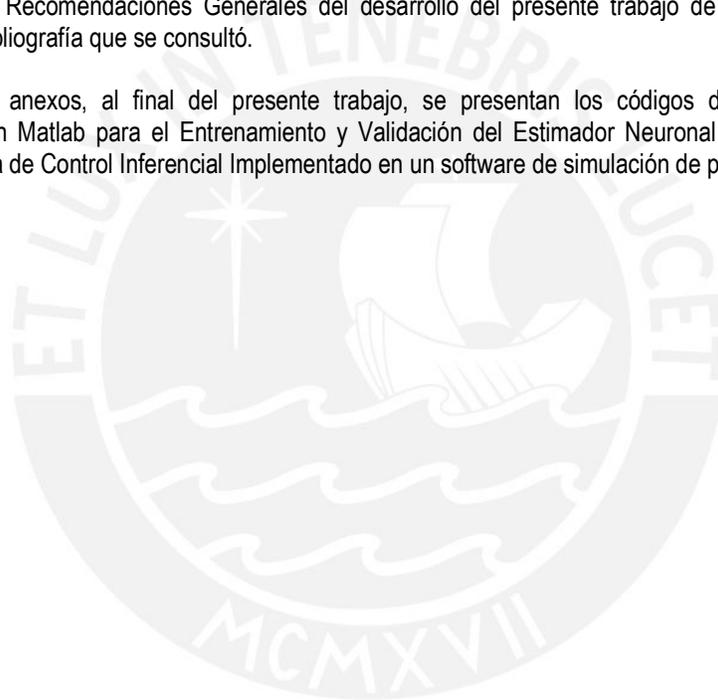
producto de fondo de la columna de destilación de multicomponentes; se muestran los resultados experimentales del entrenamiento y validación de la red neuronal creada.

Asimismo, luego de creada y probada la red neuronal para la estimación de la calidad del producto de fondo de la columna de destilación, se va creando la estructura de control cuya performance se desea evaluar. Para ello la incorporación de la estructura de control inferencial se realiza en dos etapas sobre el esquema tradicional de control, evaluándose cualitativa y cuantitativamente el comportamiento de cada esquema.

El Capítulo 4 analiza el Impacto en la Producción y el Beneficio de la Estrategia de Control Implementada; para lo cual se extrapola el comportamiento del lazo de control y su impacto sobre algunos parámetros operativos como son: caudal de producción de la columna de destilación y consumo de fluido de calentamiento en el fondo de la columna, a fin de asignar costos a estas variables y obtener una idea del beneficio extrapolado que se obtendría por el uso de este esquema de control propuesto.

Finalmente, se presentan, además de las conclusiones específicas de los capítulos 3 y 4; las Conclusiones y Recomendaciones Generales del desarrollo del presente trabajo de Tesis, para citar finalmente la Bibliografía que se consultó.

En los anexos, al final del presente trabajo, se presentan los códigos de los programas desarrollados en Matlab para el Entrenamiento y Validación del Estimador Neuronal desarrollado, así como el Sistema de Control Inferencial Implementado en un software de simulación de procesos.



CAPÍTULO 1: ESTADO DEL ARTE

1.1.- Introducción

El gas natural es una mezcla de gases combustibles subterráneos formados por la descomposición de materiales orgánicos en plantas y animales. Se encuentra generalmente en las zonas donde el petróleo está presente, aunque hay varios grandes yacimientos subterráneos de gas natural donde hay poco o nada de petróleo. El gas natural es ampliamente utilizado para una variedad de aplicaciones industriales y como fuente proveedora de energía en distintos países del mundo.

El gas natural sin tratamiento (gas natural crudo) tiene varios componentes: El principal componente es el metano. Otros componentes incluyen el etano, propano, butano, y muchos otros hidrocarburos combustibles. Este gas natural crudo puede contener vapor de agua, sulfuro de hidrógeno, dióxido de carbono, nitrógeno y helio. Durante el procesamiento de este gas natural, muchos de estos componentes se pueden quitar.

Algunos, tales como etano, propano, butano, sulfuro de hidrógeno y helio-pueden ser parcial o totalmente eliminadas para ser procesados y vendidos como productos separados. Otros componentes, como el vapor de agua, dióxido de carbono y nitrógeno se pueden retirar para mejorar la calidad del gas natural o para hacer más fácil el transporte del gas, a grandes distancias a través de gasoductos. El resultado de procesar el gas natural, es un gas que contiene principalmente metano y etano, aunque no existe una composición "típica" de gas natural. Algunos otros componentes se pueden agregar al gas a un tratamiento que le dan cualidades especiales. Por ejemplo, un producto químico conocido como mercaptano se añade para dar al gas un olor característico que advierte a la gente de una fuga.

Los métodos utilizados para extraer, procesar, transportar, almacenar y distribuir gas natural dependen de la ubicación y la composición del gas natural crudo, así como de la ubicación y la aplicación deseada para el gas por los usuarios finales. Un esquema que resume las distintas etapas de este proceso productivo del gas natural, se ilustra a continuación en la Fig. 1.1 :

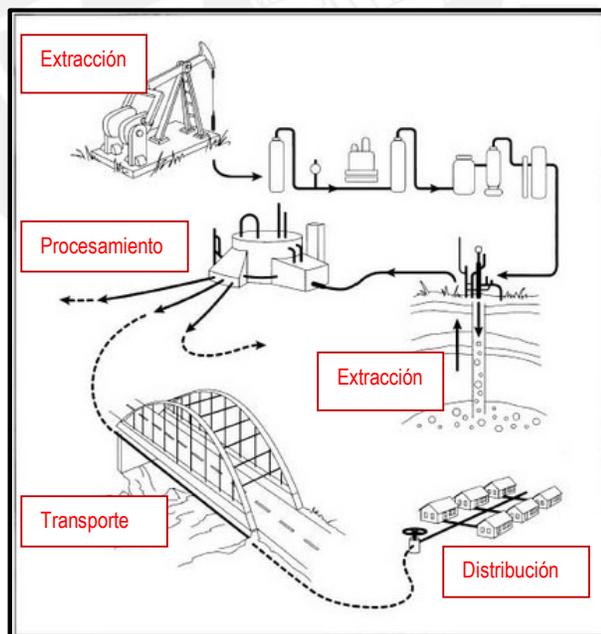


Fig. 1.1.- Etapas del Proceso Productivo de Gas Natural

Debido a que el gas natural es de combustión limpia, viene siendo usado como un combustible alternativo para vehículos de motor de tal forma que actualmente se usa el Gas natural comprimido

(GNC) que están en funcionamiento en muchas áreas. Las empresas que utilizan procesos industriales que requieren altas temperaturas también están recurriendo al gas natural en lugar de otros combustibles con el fin de reducir la contaminación atmosférica emitida por sus plantas. Esto incluye a las empresas que participan en la fabricación de acero, vidrio, cerámica, cemento, papel, productos químicos, aluminio, y los alimentos procesados. Asimismo, las empresas de generación eléctrica vienen usando tecnologías que aprovechan el gas natural en turbinas, especialmente acondicionadas, para convertir la energía de combustión en energía eléctrica.

Es así que la industria de gas natural se encuentra en estado de crecimiento, ya que representa, dentro del sector de hidrocarburos, una alternativa limpia y con procesos relativamente sencillos que permiten su interacción con distintas industrias energéticas o de servicios.

A continuación, en la Fig. 1.2, se muestra un cuadro estadístico que resume la evolución de la producción mundial y el consumo asociado a la industria del gas natural (tomado del “BP Statistical Review of World Energy - June 2012” de la British Petroleum Company) :

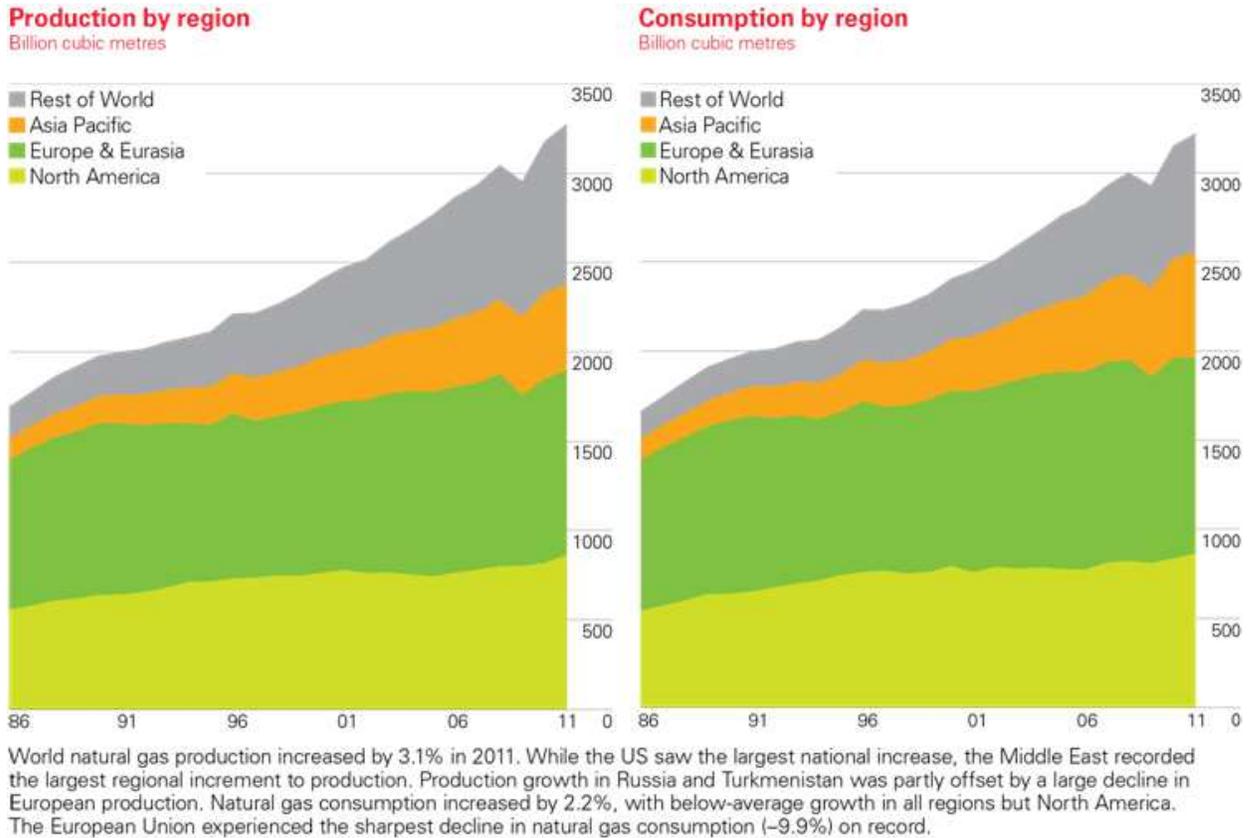


Fig. 1.2.- Evolución de la Producción y Consumo de Gas Natural a Nivel Mundial

Aquí se puede observar la tendencia creciente de la demanda gas natural en el mundo y que genera la búsqueda de mayor número de reservas, lo que viene acompañado por desarrollo de nuevas tecnologías para las distintas etapas del proceso productivo mencionadas anteriormente.

Sin embargo, si bien la demanda por el gas natural “tratado” se intensifica, del mismo modo crece la demanda por los productos líquidos que se obtienen en el procesamiento del gas, y entre los cuales se encuentran : GLP (Gas licuado de petróleo, conformado por distintas proporciones de propano y butanos y que principalmente se usa como fuente de energía para uso doméstico), Nafta que puede emplearse en el parque automotor o en la industria petroquímica, Diesel, que suele emplearse como combustible líquido y Turbo, como combustible líquidos para aviones, helicópteros, etc..

Y es en esta etapa del procesamiento, donde las columnas de destilación, cobran relevancia gracias a que permiten el fraccionamiento o separación de estos componentes debido a sus fundamentos de operación, y las particularidades tecnológicas con las que son diseñadas.

La destilación, es un método de separación de mezclas en base a las diferencias en los puntos de ebullición de los componentes de la misma. El punto de ebullición de un líquido, es la temperatura a la que la presión de vapor del líquido es igual a la presión en el líquido, lo que permite que se formen burbujas sin ser retenidas en su estado líquido original. La destilación es una operación unitaria o un proceso de separación física, y no una reacción química.

Comercialmente, la destilación tiene muchas aplicaciones: Se utiliza para separar el petróleo crudo en fracciones para usos más específicos, tales como la generación de energía, transporte y calefacción. El agua es destilada para eliminar las impurezas, tales como la sal del agua de mar. El aire es destilado para separar sus componentes, en particular el oxígeno, nitrógeno y argón para uso industrial. La destilación de soluciones fermentadas se ha utilizado desde tiempos antiguos para producir bebidas destiladas con un contenido de alcohol más alto.

La aplicación de técnicas de destilación puede hacerse a escala de laboratorio y a nivel industrial. La principal diferencia entre la destilación a escala de laboratorio y la destilación industrial radica en que a escala de laboratorio, se suele realizar por lotes (de forma "batch"), mientras que a nivel industrial a menudo se produce de forma continua. En la destilación por lotes, la composición del material de origen, los vapores de los compuestos de destilación y el producto destilado cambian durante el proceso. En la destilación continua, los materiales de base, los vapores, y el producto destilado se mantienen a una composición constante, cuidando la reposición del material de base y la eliminación de las fracciones de vapor y líquido en el sistema. Esto se traduce en un mejor control del proceso de separación.

Las aplicaciones a gran escala de destilación industrial incluyen tanto procesos por lotes (batch) así como procesos continuos, destilación al vacío, destilación azeotrópica, destilación extractiva, destilación reactiva, entre otras. La aplicación industrial más ampliamente utilizada de destilación continua en estado estacionario, se da en las refinerías de petróleo, plantas petroquímicas y químicas y en las plantas de procesamiento de gas.

La destilación industrial se realiza típicamente en grandes columnas, cilíndricas verticales conocidas como torres de destilación o columnas de destilación, con diámetros que van desde unos 65 centímetros a 16 metros y alturas que van desde unos 6 metros a 90 metros o más. Cuando la alimentación al proceso tiene una composición muy diversa, como en el caso de la destilación del petróleo crudo, se tienen salidas de líquidos en diferentes intervalos de la columna para retirar diferentes fracciones o productos que tengan diferentes puntos de ebullición o rangos de ebullición. Los "más ligeros" de los productos (los que tienen el punto de ebullición más bajo) salen desde la parte superior de las columnas y los "más pesados" de los productos (los que tienen el más alto punto de ebullición) salen por la parte inferior de la columna y son a menudo llamados los "productos de fondo".

En algunas de estas torres de uso industrial, se suele utilizar una corriente de reflujo para lograr una separación más completa de los productos. Este reflujo se refiere a una porción del producto de tope de la columna que ha condensado a partir de una torre de destilación o fraccionamiento y que se devuelve a la parte superior de la torre, como se muestra en el diagrama esquemático de la Fig. 1.3, de una torre típica.

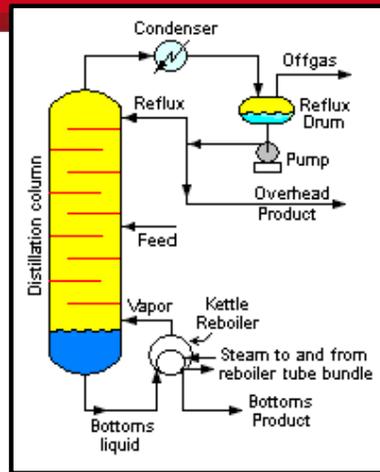


Fig. 1.3.- Esquema Típico de una Columna de Fraccionamiento / Destilación

Dentro de la torre, el líquido de reflujo descendente proporciona el enfriamiento y la condensación de los vapores ascendentes, aumentando así la eficiencia de la torre de destilación. El aumento del reflujo para un número de etapas de separación (número de etapas teóricas), condiciona la mejor separación de la torre de los materiales de menor punto de ebullición a partir de materiales de mayor punto de ebullición. Asimismo, a un mayor reflujo, para un nivel de separación deseada, condiciona a un menor número de etapas teóricas necesarias. En la práctica el número de etapas de separación (platos de separación) siempre es mayor al número de etapas teóricas, ya que la eficiencia de separación nunca es de 100%. Es en estas etapas o platos de separación donde se produce el contacto líquido-vapor y se produce la separación de los distintos componentes. A continuación, en la Fig. 1.4, se muestra un esquema típico de la forma que pueden tener estos platos de separación:

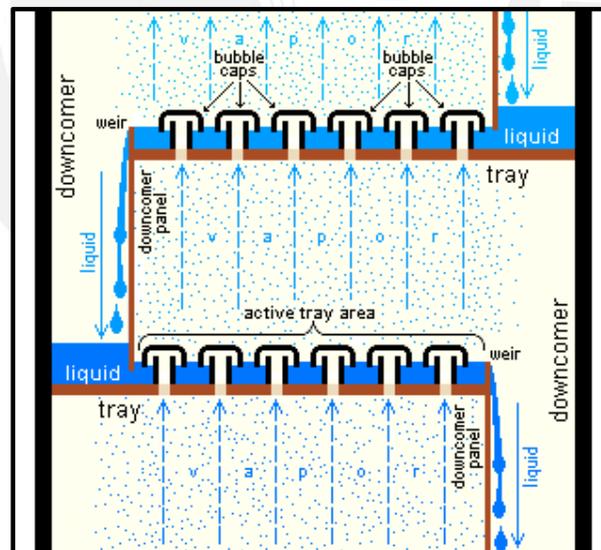


Fig. 1.4.- Esquema Típico de una Etapa (plato o bandeja) de Separación Líquido - Vapor

En general, el diseño y operación de una torre de destilación dependen de las características de la alimentación y los productos deseados, y así como se pueden considerar esquemas como el mostrado, también se suelen emplear “empaques” que son un material de embalaje que se utiliza en la columna en lugar de bandejas, especialmente cuando se requiere trabajar con bajas caídas de presión a través de la columna. Este material llamado “empaque” tiene una disposición tal que permite que los líquidos que descienden humedezcan la superficie del mismo y los vapores pasan a través de esta superficie mojada, donde se lleva a cabo la transferencia de masa que implica la separación de componentes.

1.2.- Descripción del Proceso

1.2.1.- La Industria del Gas Natural

1.2.1.1.- Factores que Definen la Tecnología del Tratamiento del Gas Natural.-

Como se ha mencionado anteriormente, el proceso productivo del gas natural consta de una serie de etapas generales que van desde la extracción, el acondicionamiento, hasta el transporte y la distribución a los consumidores finales. Sin embargo, cada una de estas etapas está condicionada a una serie de factores que definirán las tecnologías a emplear en cada etapa y las características de operación de cada una.

Entre estos factores tenemos:

- Condiciones del reservorio.- composición del fluido, temperatura y presión
- Estrategia para el desarrollo del yacimiento.- Volúmenes temperaturas y presiones
- Restricciones legales.- condiciones de venta, contratos, nominaciones de venta, etc...
- Factores medioambientales.- ubicación del yacimiento, costumbres locales, zonas sensibles, etc...
- Mercados.- para el gas natural, para los líquidos del gas natural (NGL), precios, etc..
- Especificaciones de los productos (Gas).- punto de rocío de H₂O e hidrocarburo, poder calorífico, contenido de CO₂, H₂S, etc..
- Especificaciones del NGL (Líquidos del Gas Natural).- Presión de vapor, contenido de C₂, contenido de H₂O y CO₂, etc...
- Economía del Proceso.- Rentabilidad del proceso de tratamiento.
- Política.- Interés nacional como la conservación de recursos, etc...
- Acuerdos de Procesamiento.- Para la extracción del NGL (Líquidos del gas natural)

De forma general, las razones para el procesamiento son:

- 1.- Es necesario en términos operacionales.
- 2.- Es necesario comercialmente alcanzar determinadas especificaciones de los productos
- 3.- Es económicamente atractivo.

Mientras que todos los términos mencionados anteriormente son críticos para un diseño efectivo, hay 4 factores en los que se requiere especial énfasis:

Composición del fluido, contratos y especificaciones del gas, contratos y especificaciones de los líquidos (NGL) y Acuerdos de Procesamiento.

1.2.1.2.- Composiciones de Gas Típicas.-

Como se menciona anteriormente, el gas natural sin tratamiento se encuentra constituido por una serie de componentes hidrocarburos, como el metano, etano, propano y superiores, así como algunos otros como son H₂O y H₂S, y a pesar de que las composiciones pueden variar significativamente, hay tendencias que son útiles para estimar el rendimiento de la planta. Por ejemplo, en los Estados Unidos el gas es generalmente más rico en las Montañas Rocosas y se vuelve más ligero o pobre a medida que avance hacia el Golfo de México, con la excepción de la zona Permian Basin que tiene el gas más rico en el país.

El término "GPM" se puede utilizar para definir el contenido líquido del gas natural. GPM es una abreviatura de galones (de líquido) por millar de pies cúbicos estándar (de gas). En la industria de petróleo y gas el valor de "mil" es generalmente abreviado por el número romano "M", por lo tanto Mscf es la designación por mil pies cúbicos estándar. Sólo para efectos de este ejemplo, para distinguir el contenido de líquidos de gas (GPM) de flujo de líquido (gpm-galones por minuto), se harán uso de letras mayúsculas o minúsculas según se ha citado respectivamente.

La descripción de gas como "rico" y "pobre" es subjetiva. La mayor parte de la industria designa gas rico a aquel que tiene un contenido líquido de más de 5 GPM (C₂+), con un contenido moderado de

líquido entre 5 y 2 GPM (C2+) y un gas pobre con menos de 2 GPM (C2 +). Cuando se define el contenido líquido se considera el mismo como un adjetivo que debe especificar cuáles hidrocarburos serán incluidos en el cálculo. Los números anteriores, en nuestro caso se trata del "etano plus (C2+)" que indicaría que para definir el contenido líquidos del gas se está considerando el etano y los hidrocarburos más pesados. En la Tabla 1.1 Para los casos citados anteriormente tendríamos:

Tabla 1.1.- Contenido de Líquido en Gas Natural – Valores Referenciales

Gas Plant Region	NGL Gal per Mscf (GPM-C2+)
Rocky Mountain States	4.8
Oklahoma-Kansas	4.1
Texas Panhandle	4.8
Permian Basin	6.2
East Texas/Texas Coast	2.7
Louisiana, Miss., Ala.	2.0
Gulf of Mexico-Offshore	0.9

Asimismo, un reporte más detallado, mostrando el contenido de cada componente en %molar se muestra en la Tabla 1.2:

Tabla 1.2.- Composición Típica del Gas Natural

Component	Rocky Mt	Okl-KS	Permian Basin	E. TX./ TX Gulf	Gulf of Mexico
Nitrogen	0.12	2.16	2.89	0.83	0.22
Hydrogen Sulfide	0.00	0.00	0.02	0.00	1.33
Carbon Dioxide	1.58	0.34	0.05	0.18	4.00
Methane	86.75	81.54	70.45	88.88	88.15
Ethane	7.75	8.48	12.77	5.74	4.51
Propane	2.38	4.63	7.93	2.49	1.18
i Butane	0.45	0.50	1.06	0.73	0.26
n-Butane	0.43	1.42	2.66	0.62	0.20
i-Pentane	0.18	0.27	0.66	0.14	0.05
n-Pentane	0.14	0.37	0.70	0.09	0.02
n-Hexane	0.12	0.32	0.51	0.12	0.01
n-Heptane	0.08	0.00	0.20	0.11	0.02
n-Octane	0.04	0.00	0.10	0.11	0.05
Total	100.00	100.00	100.00	100.00	100.00
C ₂ + gpm	3.23	4.51	7.60	2.89	1.74

1.2.1.3.- Especificaciones de Calidad de los Productos.-

Típicamente, para el caso del gas natural se consideran algunos factores contractuales, como el máximo, mínimo y presión nominal de entrega de gas, máxima temperatura de entrega, máximo contenido de agua, máxima cantidad de hidrocarburos condensables, concentración permitida de contaminantes como H₂S, CO₂, etc...

Como ejemplo, en la Tabla 1.3, resumimos algunas características típicas que se consideran en algunos lugares, como U.K, Estados Unidos y el Medio Oriente :

Tabla 1.3.- Especificaciones Típicas del Gas Natural para Venta

	U.K.	North America	Middle East
H ₂ S - max	4-5 ppm (vol)	4-16 ppm(vol) [0.25-1.0 gr/100 scf]	8 ppm (vol)
Total S - max	150 mg/std m ³	8-480 ppm (vol) [0.5-30 gr/100 scf]	---
CO ₂ - max vol	no limit	1-3%	< 5%
O ₂ - max vol	0.5%	0.001-1%	---
H ₂ O dewpoint	-10°C @ 70 Barg [15°F @ 1000 psig]	4-7 lb H ₂ O/MMscf Gas	-3°C [26°F]
Total Inlets (N ₂ , CO ₂ , O ₂)			
Gross heating value			
max		1050-1235 Btu/scf	
min	30 MJ/std m ³ [800 Btu/scf]	950-1000 Btu/scf	1020-1200 Btu/scf
Wobbe Index	41-45 MJ/std m ³ [1100-1200 Btu/scf]	Not typical, but 1200-1300 Btu/scf	---
Hydrocarbon dewpoint	-1°C [30°F] @ delivery pressure	-50°F to 40°F	10°C [50°F]

Notes: 1) std m³ is abbreviation of standard cubic meters (at 15°C and 101.325 kPa).
2) Wobbe Index is equal to:

$$\frac{\text{Gross Heating Value}}{\sqrt{\text{Specific Gravity}}}$$

and is a way of characterizing the heat release at the burner tip for gaseous fuels.

Asimismo, para el caso de los líquidos, generalmente se suele considerar en los contratos la calidad del producto como presión de vapor Reid (medida indirecta del contenido de etano-C2- y propano-C3), densidad absoluta o relativa, características típicas para propano comercial, especificaciones de color, contenido de contaminantes a ser determinados por test que siguen algún estándar o norma; contenido de H2O, etc...

Para el caso de los productos líquidos, debe considerarse si se trata de fluidos líquidos que vienen de alguna etapa de separación primaria o si son fluidos líquidos que vienen de alguna columna de fraccionamiento, o si provienen de otro conjunto de procesos. A continuación daremos un resumen de alguna de las terminologías empleadas:

1.2.1.4.- Terminología Utilizada para Identificar Líquidos del Gas Natural según su Composición.-

Los hidrocarburos del gas natural se pueden agrupar de diferentes formas para dar un producto aceptable energéticamente, así tenemos el **Gas Natural Licuado (LNG)** que es una porción de hidrocarburos livianos del gas natural predominantemente metano en estado líquido

El propano y el butano se encuentran en estado gaseoso a temperaturas y presiones normales. La mezcla del propano y del butano, sea en estado gaseoso o en estado líquido (si se enfría a menos de 42 °C) se denomina **Gas Licuado de Petróleo (LPG)**.

Los **Líquidos del Gas Natural (NGL)** se refieren a la combinación del gas etano, propano, butano, y otros condensados que puede tener el gas natural. Cuando el gas natural contiene cantidades elevadas de NGL puede ser conveniente remover algunos de sus componentes, asegurando así que no se condensen en la tubería y permitiendo que el gas cumpla con sus especificaciones.

El **Condensado**, típicamente es el líquido producido por efectos de la condensación. Puede tratarse de hidrocarburos en estado líquido, agua o ambos. Se forma por condensación de los vapores del gas. Específicamente se refiere a los hidrocarburos líquidos que se condensan del gas natural como consecuencia de los cambios de presión y temperatura cuando el gas del yacimiento se lleva a condiciones de superficie.

La **Gasolina Natural** es una mezcla de pentano e hidrocarburos más pesados que pasan con facilidad al estado líquido y el **Condensado Estabilizado** es una mezcla de butano, pentano, e

hidrocarburos más pesados en estado líquido que han sido estabilizados a una determinada presión en un sistema de fraccionamiento (Ver Tabla 1.4).

Tabla 1.4.- Principales Componentes de Productos del Gas Natural

	COMPONENTES											
	CO ₂	H ₂ S	N ₂	C ₁	C ₂	C ₃	i-C ₄	n-C ₄	i-C ₅	n-C ₅	C ₆	C ₇ ⁺
Gas Natural	*	*	*	*	*	*	*	*	*	*	*	*
LGN			*	*	*	*	*	*				
LPG					*	*	*	*				
NGL					*	*	*	*	*	*	*	*
Gasolina Natural						*	*	*	*	*	*	*
Condensado Estabilizado							*	*	*	*	*	*

Si bien los componentes presentes en la gasolina natural y el condensado estabilizado pueden variar dependiendo de las particularidades de cada yacimiento o Planta (Ver Tabla 1.5).

Tabla 1.5.- Especificaciones Típicas para el Condensado Estabilizado

Reid vapor pressure: 70-235 kPa [10-34 psia] Percentage evaporated at 60°C [140°F]: 25-85% Percentage evaporated at 135°C [275°F]: not less than 90% End point: not higher than 190°C [375°F] Corrosion: not corrosive by specified test Doctor test: negative Color: not less than plus 25 (Saybolt) Water content: no free water

Donde la presión de vapor (ó en un caso particular “presión de vapor Reid”) viene determinada por :

$$Pv_{mix} = \sum xi * Pvi$$

Donde :

- Pvmix = Presión de vapor de la mezcla de NGL, bar abs (Psia)
- xi = fracción molar de cada componente de la mezcla
- Pvi = Presión de vapor de cada componente en la mezcla, bar abs (Psia)

Y tiene por lo tanto una relación directa con la composición a mantener para el producto líquido.

1.2.2.- Esquema Básico de un Sistema de Procesamiento de Gas Natural

A continuación, en la Fig. 1.5, se muestra un esquema básico de un sistema de procesamiento de gas natural :

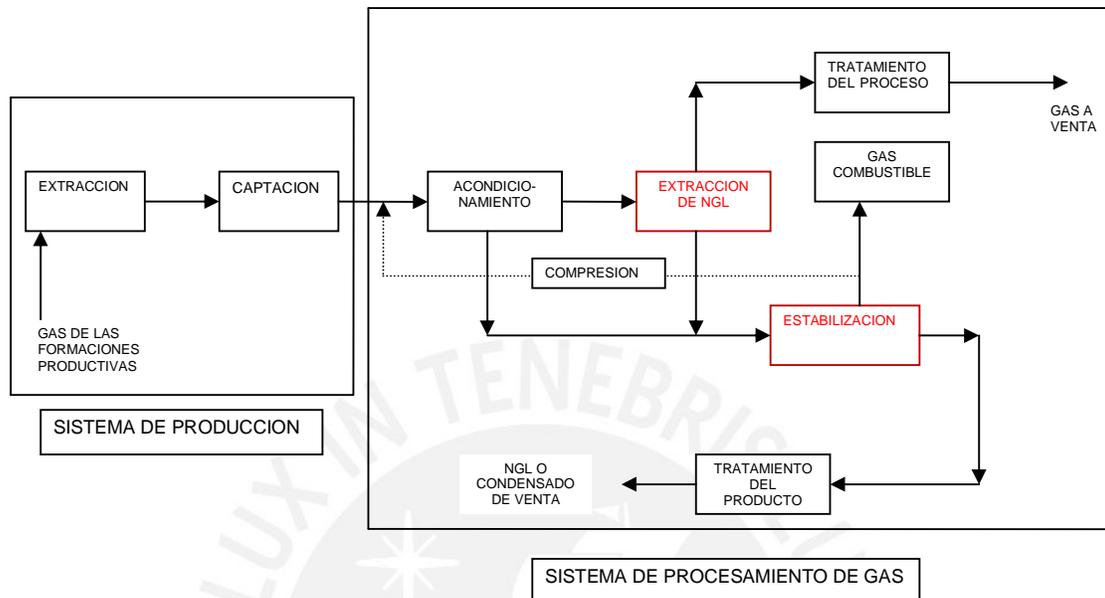


Fig. 1.5.- Esquema Típico de un Sistema de Procesamiento de Gas Natural

Cada uno de los subprocesos que conforman el sistema de procesamiento de gas, tienen determinadas particularidades en lo que respecta a las tecnologías de las operaciones unitarias que los conforman. De estos subsistemas, los que resultan de especial interés para el proyecto de tesis que queremos desarrollar son los de Extracción de NGL y Estabilización.

La extracción de NGL típicamente se justifica:

- Para alcanzar una especificación en el gas a venta como el punto de rocío del hidrocarburo.
- Para aumentar el valor comercial de las corrientes de gas y líquidos producidas.

La justificación económica para una instalación de extracción de los líquidos del gas natural (NGL) requiere que el valor comercial del producto NGL sea lo suficiente como para cubrir los costos asociados con la extracción: combustible, mantenimiento y operación, transporte y fraccionamiento, almacenamiento, impuestos, etc...

El grado de recuperación de NGL tiene un profundo efecto en la selección del proceso, en la complejidad del mismo, y en el costo de las instalaciones de procesamiento. En algunos casos, los hidrocarburos pesados son removidos para controlar el punto de rocío de los hidrocarburos en la corriente de gas y prevenir la condensación de líquidos en las líneas de transporte de gas.

La composición del gas tiene el mayor efecto en la economía de la recuperación de NGL y en la selección del proceso. En general, un gas con un alto contenido de líquidos licuables, produce una mayor cantidad de productos y por tanto mayores réditos para la instalación de procesamiento de gas.

Un gas más rico también exige una refrigeración mayor, superficies de intercambio de calor mayores y costos de capital más altos, para una eficiencia de recuperación determinada. Los gases más

pobres, generalmente requieren condiciones de proceso más severas (temperaturas más bajas) para alcanzar altas eficacias de recuperación.

Sin embargo, la otra mayor consideración en la evaluación de las tecnologías para la recuperación de NGL y el grado de recuperación a alcanzar es la especificación del gas residual de venta. Las especificaciones de venta están usualmente relacionadas con el contenido energético mínimo o máximo solicitado para el gas, expresado comúnmente en BTU/ MMSCF (BTU son las unidades de medición de energía, MMSCF es una abreviatura para representar millones de pies cúbicos de gas en condiciones estándar y que generalmente se refieren a 14.696 Psia y 60 °F). Es así que, para garantizar un contenido energético mínimo en el gas de venta, es necesario determinar el grado de recuperación de líquidos que se necesita para el mismo, lo cual irá de la mano con la tecnología que se seleccione para dicho proceso.

1.2.3.- Los Sistemas de Estabilización de Condensado

Una vez que el NGL ha sido extraído del gas natural, éste deberá ser estabilizado para poder alcanzar las especificaciones de venta. Dichas especificaciones pueden variar significativamente dependiendo del mercado externo y del método de transporte. En algunos casos, el producto NGL es un condensado estabilizado que consiste solo de C_5^+ (mezcla de hidrocarburos que comprende lo que se puede separar a partir del isopentano (iC_5) e incluye los componentes más pesados que este: C_6 , C_7 , etc...), en otros casos el producto NGL es una mezcla de C_4^+ , la cual puede ser inyectada en una corriente de crudo que será dispuesta para la venta. En otras plantas el producto líquido es generalmente un producto que consiste de C_2^+ ó C_3^+ , el cual será transportado hacia una planta de fraccionamiento para la separación de diferentes productos, la venta y la distribución.

Generalmente, el término “Estabilización” está relacionado al tratamiento que recibe el condensado que se obtiene del gas natural, muchas veces en la entrada de la planta de procesamiento de gas, en la sub-etapa de acondicionamiento. Posteriormente, este Condensado Estabilizado (generalmente formado por componentes más pesados que los del NGL) puede ser mezclado con el NGL que se obtiene en las plantas de procesamiento, logrando de ésta manera alcanzar la presión de vapor requerida para su comercialización.

En otros procesos, tanto el condensado como el NGL, extraído en las instalaciones de la planta de procesamiento; son enviados, ambos; hacia el sistema de estabilización, obteniéndose en esos casos, como producto líquido del Sistema de Procesamiento, un “producto estabilizado” que será enviado posteriormente a sistemas de fraccionamiento, donde se extraería etano, propano o butano; por ejemplo.

Sistemas de Estabilización: La estabilización de los productos líquidos extraídos es típicamente realizada en sistemas de fraccionamiento. Un fraccionador es un dispositivo para separar una mezcla en dos o más partes, al menos una de las cuales tendrá un control de composición o presión de vapor. En los sistemas de condensado o de crudo, éste fraccionador es llamado “estabilizador” y es a menudo una alternativa para efectuar la separación Sin embargo, en determinados casos, particularmente cuando el producto es una corriente de C_5^+ con una presión de vapor menor a 1 atm.; la estabilización se puede lograr en “separadores flash”, en los cuales se reduce la presión para separar los hidrocarburos livianos que estuvieran presentes. En las figuras siguientes se muestran diagramas comparativos de estas alternativas para los sistemas de estabilización de condensado que se utilizan (Ver Fig. 1.6 y Fig. 1.7).

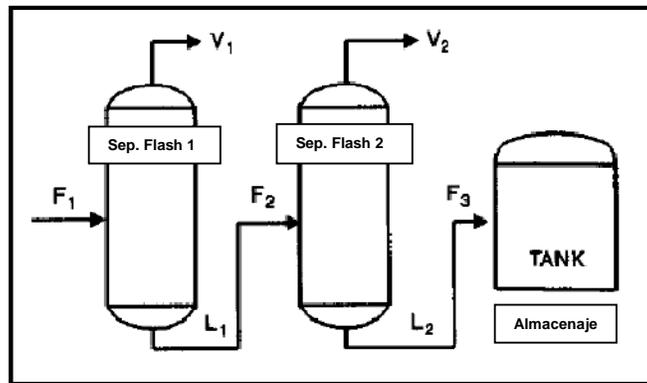


Fig. 1.6.- Sistema de Estabilización basado en Separaciones Flash

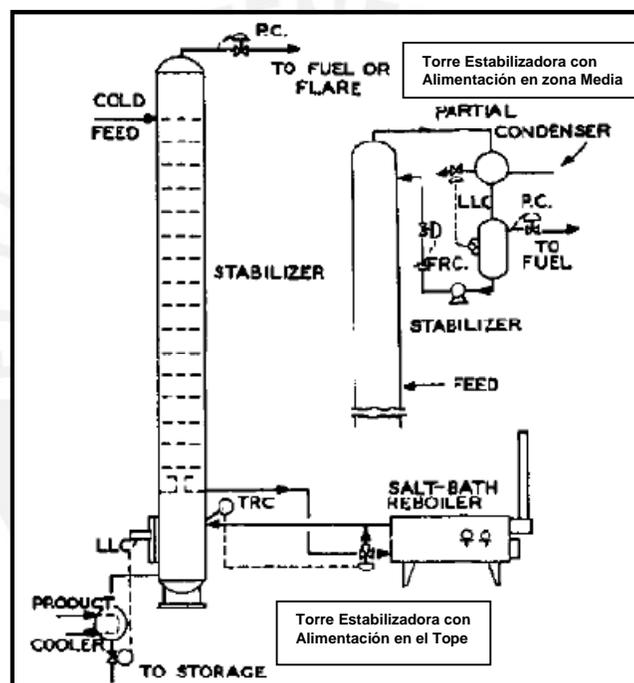


Fig. 1.7.- Sistema de Estabilización basado en Fraccionamiento

Como se ha mencionado líneas arriba, el esquema a adoptar para los sistemas de estabilización de condensado depende también de la naturaleza del líquido que se requiere “Estabilizar” para cumplir un objetivo específico que puede ser de almacenamiento y transporte o por alguna especificación comercial o contractual. Sin embargo, de forma general, es muy común encontrar sistemas de estabilización con una configuración que considera etapas de separación flash como algún sistema de fraccionamiento en serie.

Así por ejemplo, siendo dos tecnologías de uso común para la recuperación de líquidos del gas natural los procesos de Turboexpansión (por ejemplo el sistema SCORE - Single Column Overhead Recycle- desarrollado por Ortloff Engineers Ltd.) que consideran como medio de enfriamiento del gas, la expansión del mismo en una turbina, y los sistemas LTS (Low Temperature Separation) que consideran como medio de enfriamiento del gas un circuito cerrado de refrigeración con propano; es usual mantener la misma configuración para los sistemas de estabilización de condensado, y las variaciones que se

Separador trifásico para separar el agua de la corriente de alimentación, separador flash que ayuda en la eliminación de fracciones de componentes hidrocarburos ligeros, filtros de partículas, filtros coalescedores, columna de platos o empaques dependiendo del nivel de separación deseado, así como de las características del producto a estabilizar, aerofriadores, entre otros.

A continuación mostraremos un poco más de detalle de estas configuraciones.

1.3.- Estado del Arte del Sistema de Control Neural para el Monitoreo y Control de Calidad en una Columna de Destilación Multicomponentes

1.3.1.- Estado del Arte de los Sistemas de Estabilización de Condensado en la Industria del Gas Natural

Como hemos visto hasta ahora, los esquemas de estabilización de condensado tienen una disposición de equipos que principalmente están constituidos por separadores y columnas de fraccionamiento. Sin embargo, esto no implica que no haya avances tecnológicos asociados a los mismos.

Si bien las tecnologías para el acondicionamiento del gas, así como las que se usan para la recuperación de líquidos del gas natural, han ido evolucionando; del mismo modo, las tecnologías para las operaciones unitarias específicas como la separación y el fraccionamiento o destilación, también están experimentando innovaciones como son la tecnología de separación por gravedad tradicional frente a la separación en ciclones, donde se hace uso de fuerzas centrífugas; y se encuentran a prestigiosas compañías como Cameron, FMC ó Sulzer, que están haciendo innovaciones en los tipos de internos a utilizarse en estos separadores, con la finalidad de optimizar el nivel de separación a alcanzar.

Asimismo, en materia de los internos de las columnas de fraccionamiento, se tiene a compañías como Koch-Glitsch o Sulzer que llevan décadas haciendo innovaciones con la finalidad de alcanzar cada vez niveles de separación más exigentes.

Todo esto, implica que si bien se pueden encontrar dos procesos de estabilización de condensado con la misma disposición de equipos, será la tecnología que caracteriza a estos equipos lo que condicionará la eficiencia de un proceso respecto de otro, así como la disposición e interrelación entre estos equipos.

A continuación, en la Fig. 1.10, se muestra un esquema de estabilización de condensado, que considera como hemos mencionado el uso de separador (de tipo bifásico) y una columna de fraccionamiento:

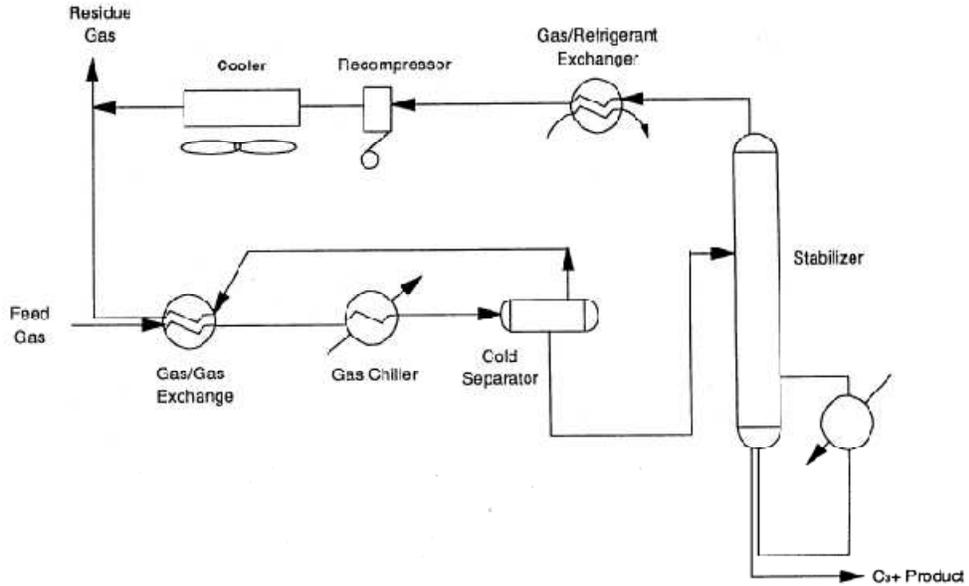


Fig. 1.10.- Esquema de Estabilización de Condensado en un Sistema LTS

Y también mostraremos, en la Fig. 1.11, otro sistema de estabilización que tiene también separadores y columna de fraccionamiento, pero considera dos etapas de separación, uno de ellos del tipo trifásico, además de filtros e intercambiadores adicionales:

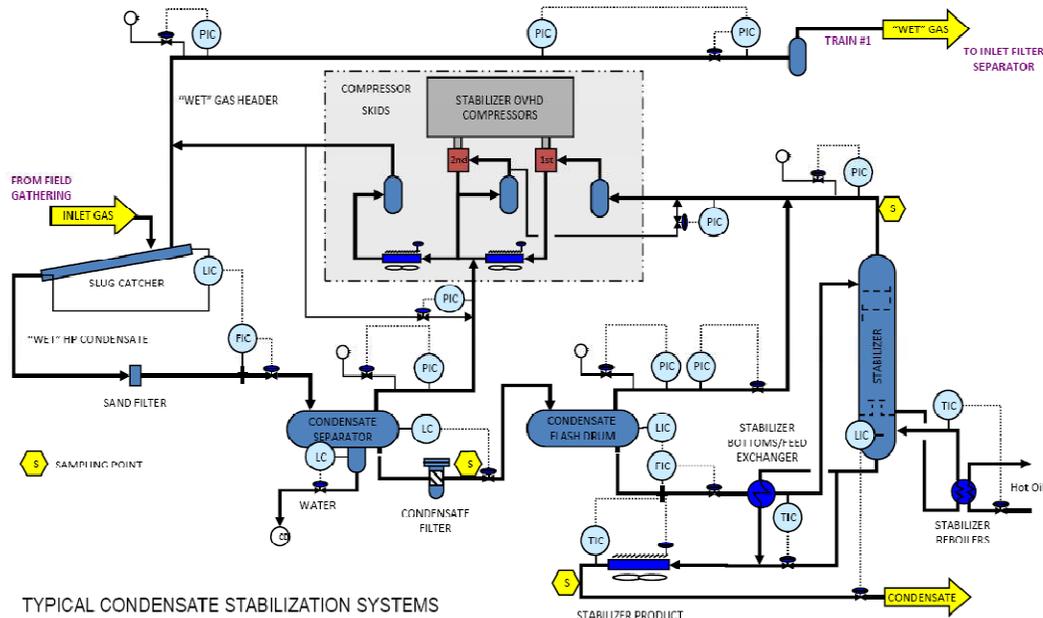


Fig. 1.11.- Esquema Alternativo de un Sistema de Estabilización de Condensado

En ambos sistemas se puede observar que se mantiene un arreglo similar para la columna de fraccionamiento, en lo que respecta a que la alimentación es por el tope, y que no hay un sistema de recuperación de vapores, que los condense y alimente un reflujo, pero las características de funcionamiento dependerán de las especificaciones requeridas para el producto de fondo.

Asimismo, las particularidades de la operación, condicionarian también las estrategias de control de procesos que se utilizarían y que de forma general se mencionarán más adelante.

Por otro lado, los objetivos típicos en estos sistemas de estabilización están asociados al cumplimiento de especificaciones sobre la calidad de los productos, y para lo cual usualmente se cuenta con analizadores online para monitoreo de estas especificaciones como es el caso de los equipos cromatográficos, así como análisis en laboratorio mediante técnicas específicas.

Un esquema típico de estos sistemas de medición se muestra a continuación, en la Fig.1.12:

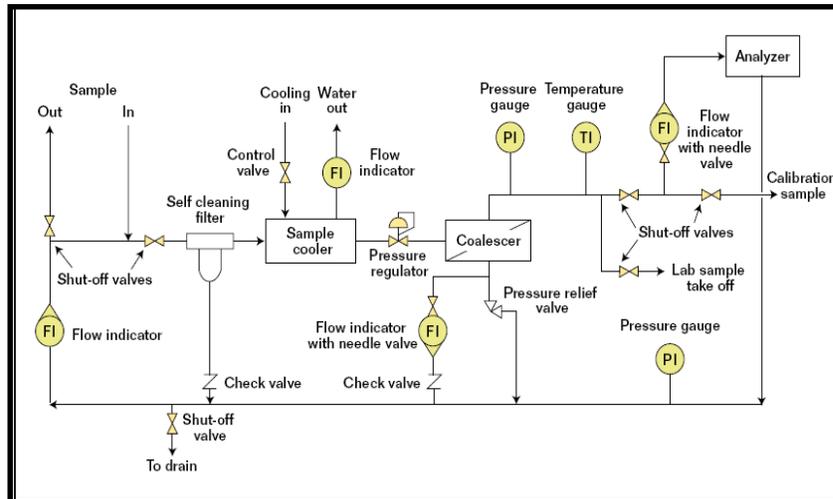


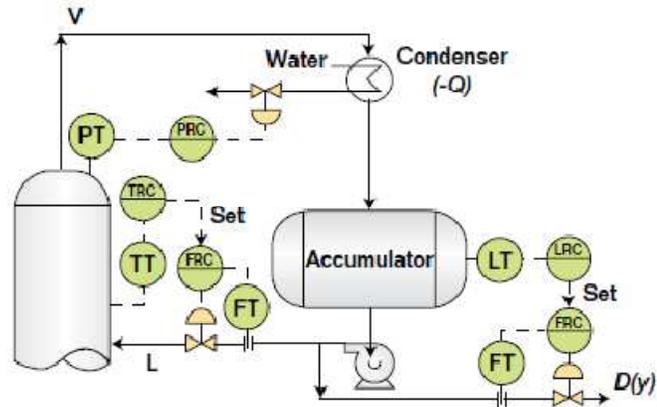
Fig. 1.12.- Esquema Típico de un Sistema de Medición de Cromatografía Líquida



1.3.2.- Estado del Arte de los Sistemas de Control en Columnas de Destilación

Hay distintas alternativas ampliamente estudiadas para el control en columnas de fraccionamiento y la complejidad de cada una de ellas guarda relación con el objetivo deseado para los productos que se obtiene de las mismas. Las variables a controlar también son variadas y es así que en algunos casos se tendrá control de temperatura de tope y fondo, en otros el control de presión cobraría mayor importancia, y en casos, como el nuestro, lo que interesa es conocer las alternativas para el control de composición de los productos. Por ejemplo, una alternativa podría ser la que se muestra a continuación en la Fig. 1.13.

En este caso, para el control de la calidad del producto de tope, se tiene un control en cascada, con el master controller asociado a la temperatura del tope de la columna, manipulando el reflujo líquido hacia la columna.



De forma análoga, para el control de la composición de fondo, se tiene un sistema de control en cascada, donde el master está en la temperatura de fondo regulando el ingreso de energía hacia el calentador de fondo o reboiler.

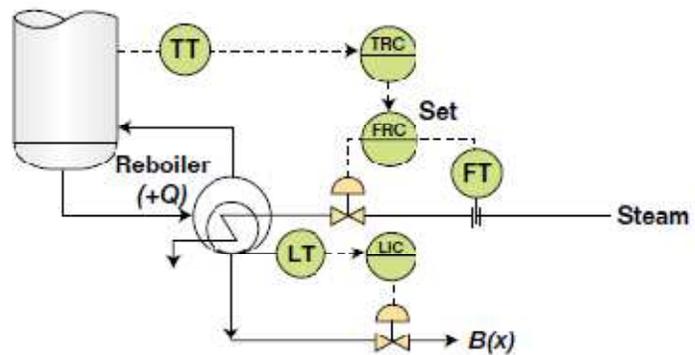
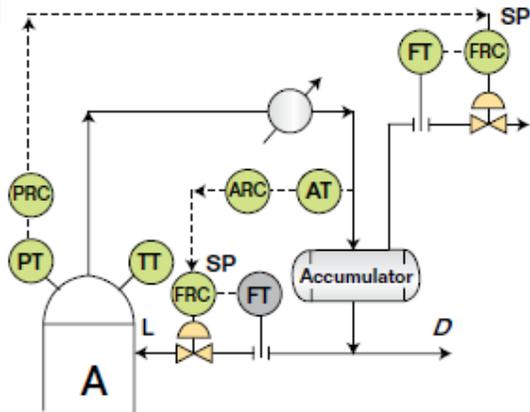
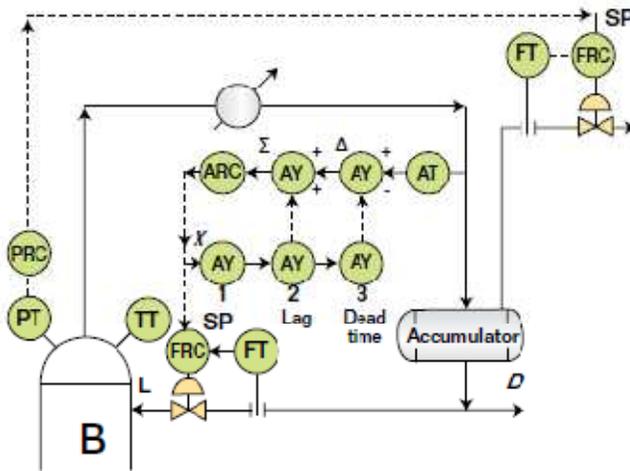


Fig. 1.13.- Esquemas de Control de Composición en Columnas de Fraccionamiento

Otros esquemas también consideran estructuras de control con los elementos de medición online como se muestra en la Fig. 1.14.

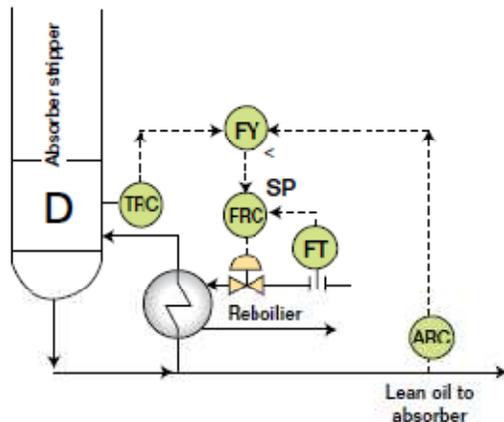
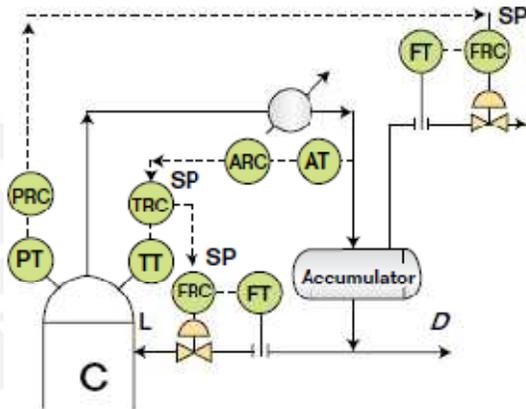


(A) En esta estructura de control, tenemos un lazo de control en cascada, donde el master controller es la medición online de composición y se regula el reflujo líquido hacia el tope de la columna. Este esquema es válido para el control de calidad o composición del producto de tope de la columna.



(B) En este esquema tenemos ahora la estructura de control del Predictor de Smith, que es básicamente el mismo esquema anterior, pero con compensación de tiempo muerto añadido.

(C) Ahora este tercer esquema considera un sistema de triple cascada para el control de composición de tope de la columna, en el siguiente orden: Desde el analizador (ARC), hacia el controlador de temperatura de tope (TRC) y hacia el control de flujo del reflujo líquido (FRC).



(D) Para este caso, tenemos el control de composición de fondo de una columna de fraccionamiento llamada "Absorbedor"; mediante un lazo de control en cascada que basado en la medición del analizador online (ARC), regula la carga térmica al reboiler (TRC), con un override de temperatura de fondo.

Fig. 1.14.- Esquemas de Control de Composición usando Analizadores Online

Y de forma general, podemos generalizar que hay tantas combinaciones, como particularidades de cada columna existen, por lo que no se citarán más ejemplos, debido a lo amplio de la bibliografía existente en el mercado.

Sin embargo, si bien existen distintos esquemas de control dependiendo de las características dinámicas del proceso, del objetivo del control y de la naturaleza de los productos que se procesan; se puede afirmar que todo el valor económico en la operación de las columnas de destilación reside en la calidad o composición de sus productos. No hay un valor económico inherente en el control de nivel de fondo o en el control de presión, y es por esto que la configuración de estos lazos se vuelve secundaria frente a la necesidad de controlar adecuadamente la calidad de los productos. Esto es por ejemplo, que la configuración de un lazo de control de nivel, de presión o de temperatura en la columna debe basarse en aquella configuración que asegure el mejor control de la composición o calidad de los productos y no necesariamente el mejor control de nivel, presión o temperatura.

1.3.3.- Estado del Arte de los Sistemas de Control Inferencial

Como se mencionó en la sección 1.3.1, a menudo es difícil proveer información confiable y rápida de una medición en línea para controlar la calidad del producto de una columna de fraccionamiento. Muchas veces la medición de la calidad más confiable sólo está disponible por análisis de laboratorio o con muy poca frecuencia de forma online. Esto puede conducir a un exceso de productos fuera de especificación, sobre todo al cambiar de región operativa.

Es así, que las técnicas de Medición Inferencial, son poderosas metodologías que permiten que la calidad de un proceso, o parámetros difíciles de medirse, sean inferidos a partir de otras mediciones de la planta que son fáciles de hacer, tales como presión, caudal o temperatura.

Entre los problemas más comunes que enfrentan los sistemas de medición que además son empleados para control, se tiene:

- Falta de un adecuado sistema de medición en línea
- Poca confiabilidad de los instrumentos online

Estas limitaciones se traducen en que el control automático y los sistemas de optimización no se puedan aplicar y, en consecuencia, el rendimiento del proceso se degrada en el tiempo. Debido a que los problemas de medición pueden limitar la aplicabilidad de los esquemas automáticos de control de retroalimentación, un enfoque común para efectuar el control sobre el proceso pasa por controlar de forma manual el sistema. Otra alternativa de solución que suele aplicarse consiste en el uso de un sistema de control en cascada que se ejecuta en paralelo (Ver Fig. 1.15).

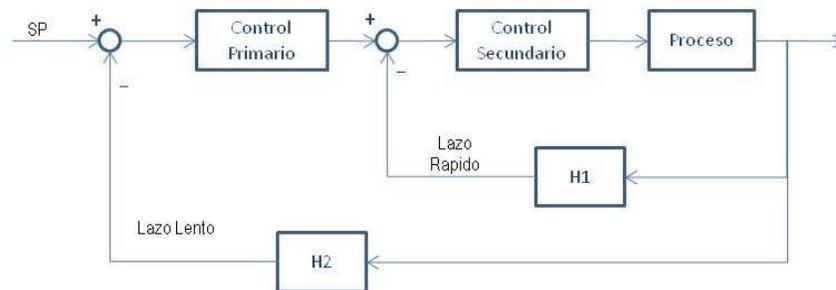


Fig. 1.15.- Estrategia de Control en Cascada

Este sistema aplicado en una columna de destilación usualmente tiene al “fast loop” secundario controlando la temperatura de un plato, la cual es una variable fácilmente medida y que además está relacionada con la composición del producto, que es la variable primaria de control. El “slow loop” opera

en una escala de tiempo que depende de las demoras típicas asociadas a la medición online, como en el caso de los cromatógrafos que se describieron anteriormente.

De esta forma, con la estrategia de control en cascada, en paralelo el loop de control interno podría manejarse con un controlador proporcional. El comportamiento de este esquema de control es simple: Si la variable secundaria es mantenida en un valor, entonces la variable primaria debería, como resultado, mantenerse también en un nivel fijo debido a que ambas están relacionadas. El “slow loop” es utilizado entonces para corregir el set point del “faster loop” secundario cuando se dispongan de las mediciones lentas (delay) de la variable primaria.

Una limitación radica en que se “asume” que las perturbaciones en la variable secundaria afectan de la misma forma a la variable primaria de control. Otra asunción es que la relación entre las variables primaria (calidad) y la secundaria es lineal, y en el mundo real, esto no siempre se cumple y la dependencia no lineal entre ambas, puede generar ciclos de perturbaciones entre sí que hacen inviable este tipo de control.

En los sistemas de control inferencial, sin embargo, el objetivo es modelar la relación existente entre una variable primaria y secundaria con las variables de entrada. El modelo puede ser usado entonces para generar estimaciones de la variable primaria que tiene dificultades para ser medida con la frecuencia con la que se obtienen las lecturas de la variable secundaria. Entonces, en lugar de esperar por ejemplo 30 minutos para que el cromatógrafo finalice su análisis (tiempo típico de refresco de un cromatógrafo online industrial), el sistema de medición inferencial podría estar brindando estimaciones de la composición cada 5 minutos, usando las mediciones de temperaturas y flujos, obteniéndose un comportamiento como el que se muestra a continuación, en la Fig. 1.16:

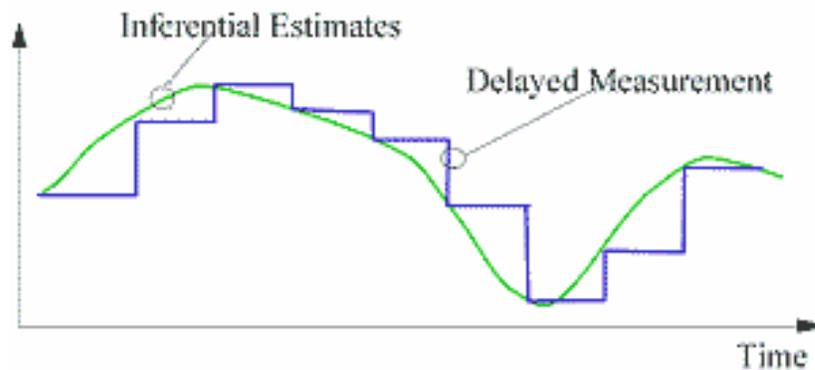


Fig. 1.16.- Comportamiento de un Estimador Inferencial frente a las Mediciones Reales

De esta forma, si los valores inferidos son lo suficientemente confiables, podrían ser usados dentro de una estructura de control para conseguir la optimización de la producción de un sistema determinado. Los datos empleados para el diseño de los sistemas de medición inferencial se basan en algunas de las siguientes técnicas:

- Series de Tiempo
- Redes Neuronales
- Algoritmos Genéticos

En cada enfoque, se desarrolla la relación entre las variables secundarias y la primaria, pero los modelos inferenciales desarrollados usando redes neuronales artificiales y algoritmos genéticos son capaces de capturar características no lineales del proceso, lo cual les da cierta ventaja para el sistema que estamos analizando.

Un esquema del Estimador Inferencial sería de la forma que se muestra en la Fig. 1.17.

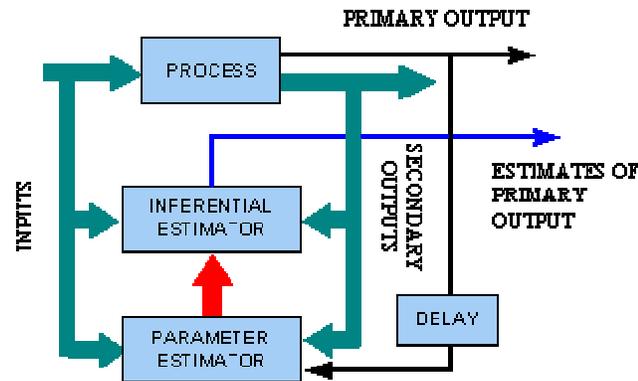


Fig. 1.17.- Esquema de un Estimator Inferencial

Si bien el concepto de estimación inferencial es simple y las técnicas de construcción del modelo inferencial deben ser sencillas debido a la abundancia de herramientas computacionales que están disponibles ahora, hay una serie de aspectos importantes a tener en cuenta:

- La principal es el acondicionamiento de los datos utilizados para la construcción de modelos y cuando el estimator inferencial se está ejecutando en línea.
- La siguiente es la selección de las variables secundarias y las entradas para usarse en la construcción de los modelos, y finalmente,
- El testing o prueba del modelo de estimación desarrollado.

En nuestro caso, los datos a generarse para la construcción del modelo de estimación, se basarán en redes neuronales, que, de forma referencial por ahora, pueden adoptar una estructura como la que se muestra a continuación:

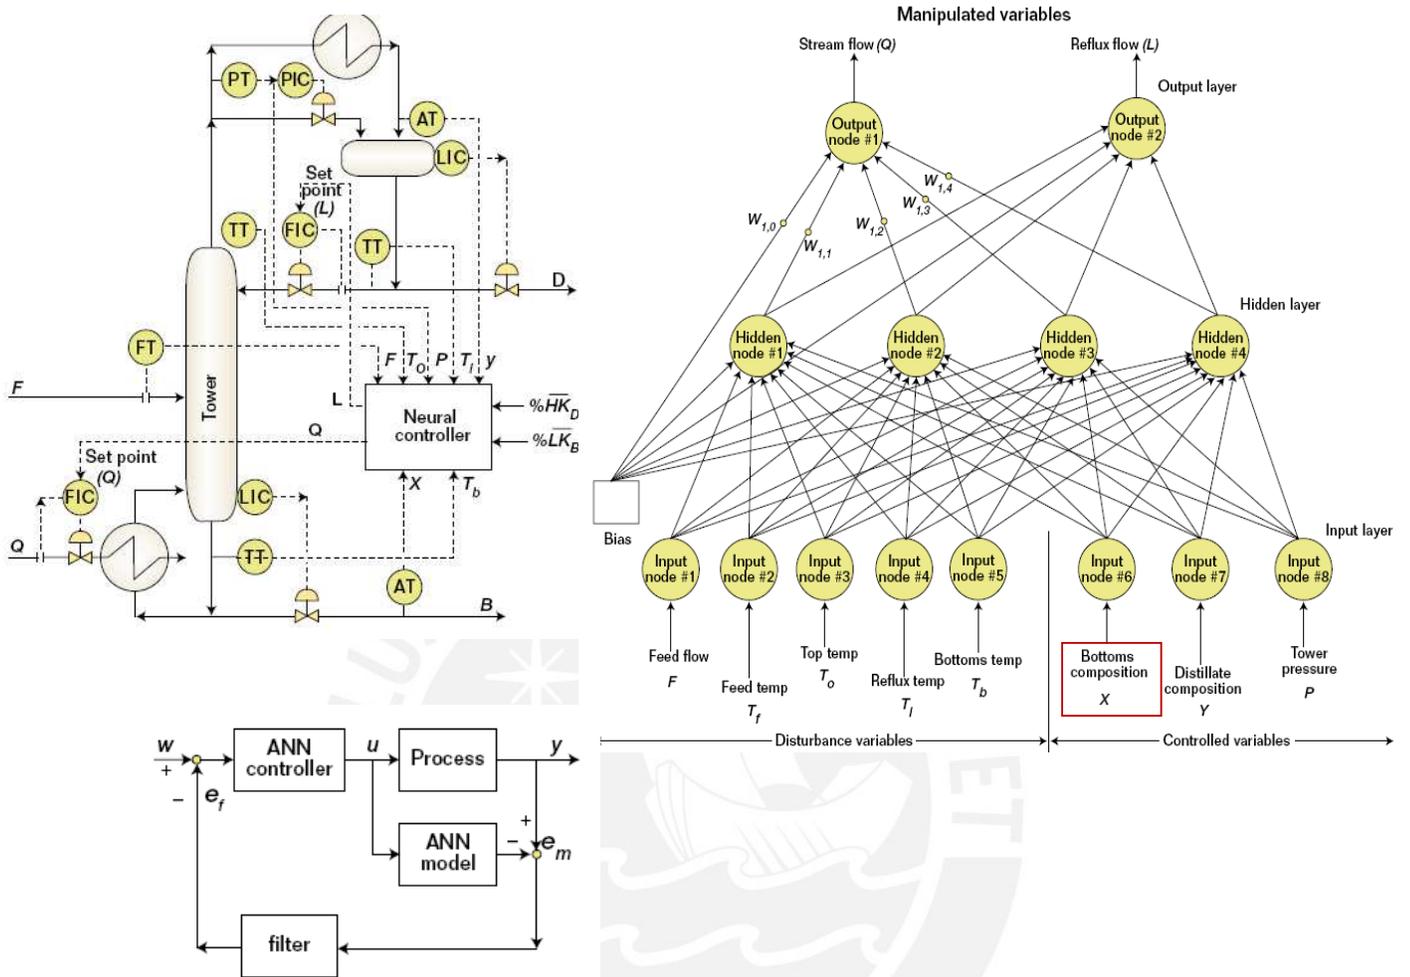


Fig. 1.18.- Sistema de Control Inferencial basado en Redes Neuronales

De esta forma, los esquemas de control que podrían probarse sobre el sistema de estabilización de condensado mostrado en la Fig. 1.11, podría quedar de alguna de las formas que se muestran en la Fig. 1.19.

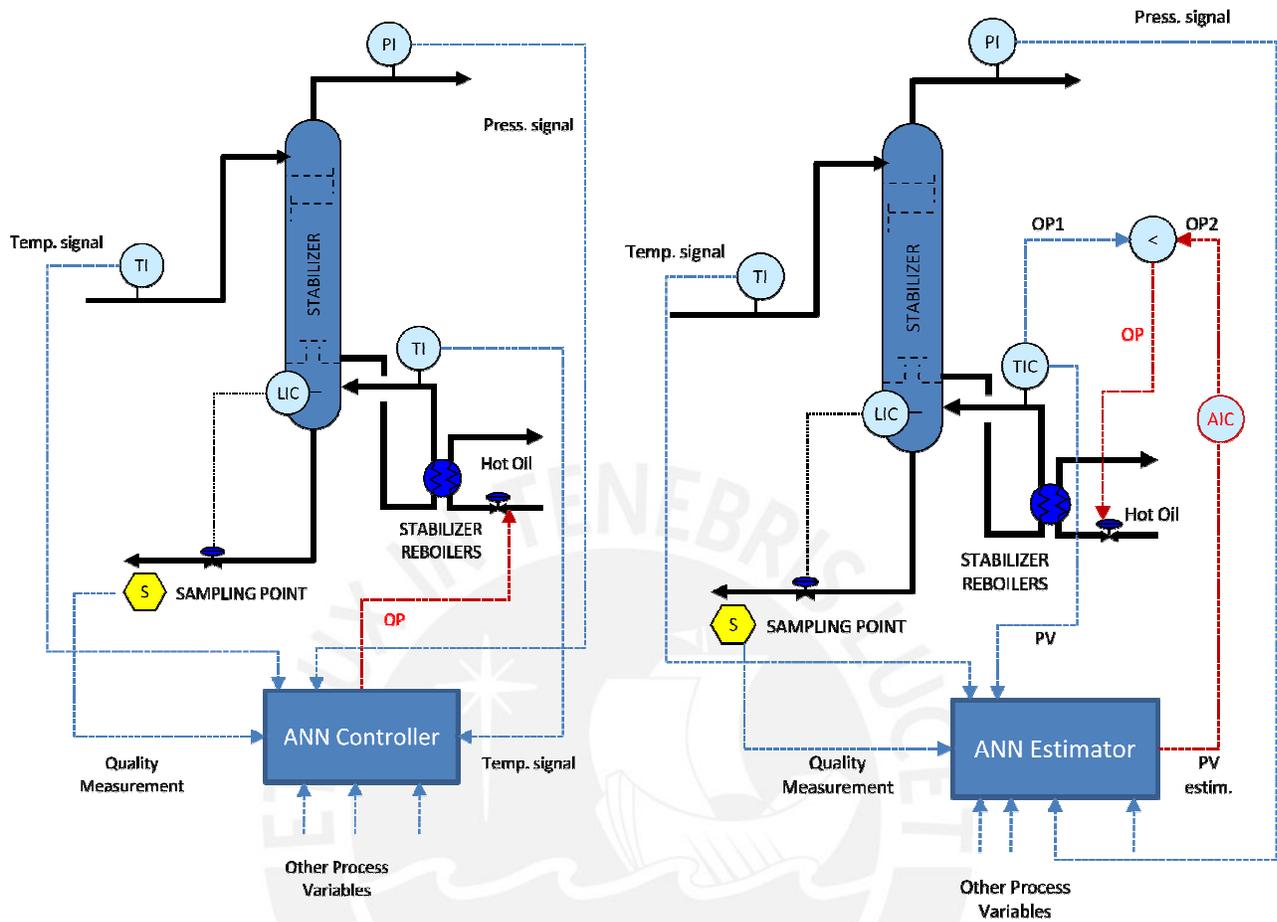


Fig. 1.19.- Alternativas para el Uso de Control Inferencial basado en ANN para una Columna Estabilizadora

En el esquema de la izquierda la red neuronal se usa directamente como controlador (Neurocontrolador) y la salida de la red es la señal de control sobre la válvula de ingreso de aceite termico.

En el esquema de la derecha, la red neuronal se usa como un modelo inferencial cuya señal de salida alimenta a un nuevo controlador de calidad, que puede ser del tipo PID. A partir de este punto, una variante puede ser el uso del esquema tradicional de control a través de un controlador de temperatura para establecer un controlador override.

El esquema general de red neuronal mostrado en la Fig. 1.18 anterior, considera como entrada una serie de señales que pueden ser tomadas de la información histórica de la planta de proceso y usando esta data, la red neuronal puede ser “entrenada” y se crearia un modelo interno no lineal del proceso. De hecho, el neurocontrolador puede terminar siendo un submodelo interno de la red total usada para estimar la calidad del sistema. Esto es, se usa data de proceso en un modelo neuronal para estimar la composición de fondo y luego este valor para a ser un dato mas a ser usado en el modelo del neurocontrolador.

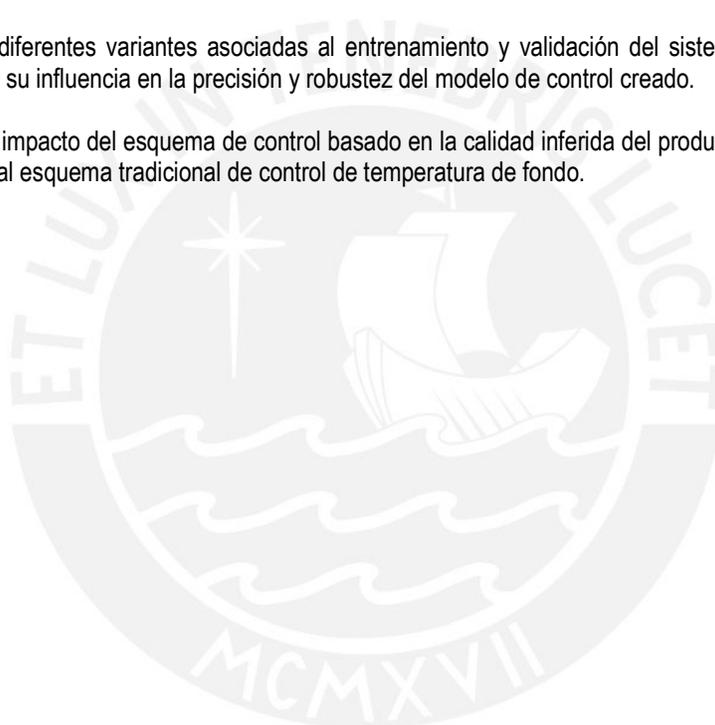
1.4.- Objetivos de la Tesis

1.4.1.- Objetivo General

Diseñar un sistema de estimación y control basado en redes neurales, para mejorar el control de calidad en una columna de destilación de multicomponentes, que cuenta con un sistema de control de temperatura para el ajuste de la calidad del producto de fondo.

1.4.2.- Objetivos Específicos

- Desarrollar un sistema de red neural para estimar la calidad del producto de fondo de la columna de destilación, basado en mediciones de otras variables de proceso.
- Evaluar la precisión de la data generada por los observadores (estimadores de calidad).
- Investigar las diferentes variantes asociadas al entrenamiento y validación del sistema de red neural implementado, y su influencia en la precisión y robustez del modelo de control creado.
- Evaluación del impacto del esquema de control basado en la calidad inferida del producto de fondo de la columna, frente al esquema tradicional de control de temperatura de fondo.



2.2.1.1.- Descripción de los Equipos Principales y sus Características de Operación.-

Los principales equipos y los objetivos de los mismos se describen a continuación, agrupados en etapas que comparten objetivos específicos, que a su vez justifican su existencia dentro del sistema:

I.- Separación Primaria.- El objetivo de esta etapa es producir una primera separación gruesa de componentes volátiles del condensado “crudo” que se alimenta al sistema, así como separar el agua libre que usualmente acompaña a este tipo de corrientes. La separación de las corrientes líquidas se produce por efectos gravitatorios.

Usualmente, en esta etapa se cuenta con un separador trifásico para separar las fases gas, condensado y agua, que se opera a una presión menor que la corriente de alimentación. En la corriente de entrada, así como en la corriente de salida se suele contar con filtros para separación de partículas (Ver Fig. 2.2).

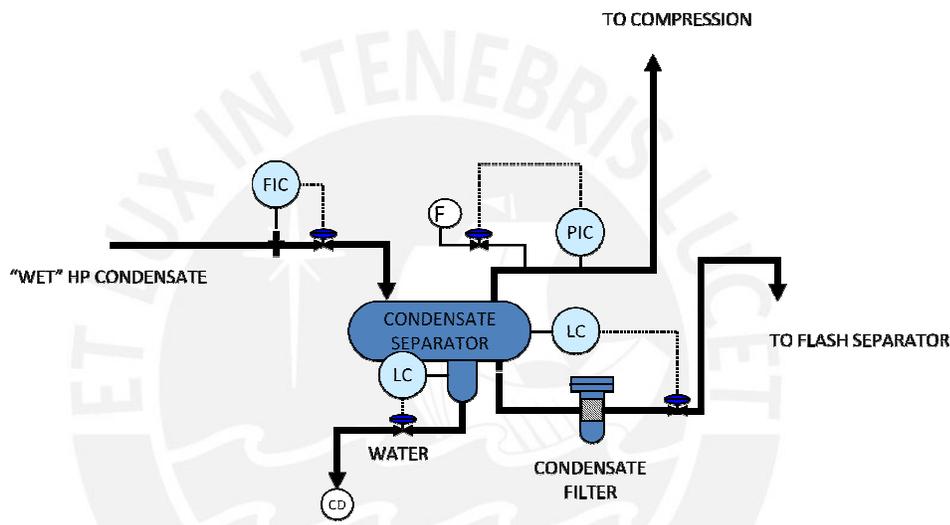


Fig. 2.2.- Esquema de la Etapa de Separación Primaria

Condiciones de Operación:

Presión = 485 – 500 Psig

Temperatura = 80 – 95 °F

% Nivel que se controla en la sección de hidrocarburo = 30 – 50 %

% Nivel que se controla en la bota inferior de separación de H2O = 30 – 50%

Caudal de alimentación = 23000 – 28000 BSPD (bbls / día medidos a condiciones estándar: 14.696 Psia y 60 °F.)

II.- Separación Flash.- El objetivo de esta etapa es producir una 2da etapa de eliminación de componentes hidrocarburos volátiles, del condensado que está ingresando al sistema. Usualmente se trata de un separador bifásico para separación de hidrocarburos líquidos y gas, operando a una presión menor que el primer separador trifásico. Debido al riesgo de presencia de agua libre dispersa en la fase líquida de hidrocarburo, se suele incorporar a la salida de hidrocarburo de esta etapa un filtro coalescedor que remueva por efecto de coalescencia de partículas dispersas, el agua libre (Ver Fig. 2.3).

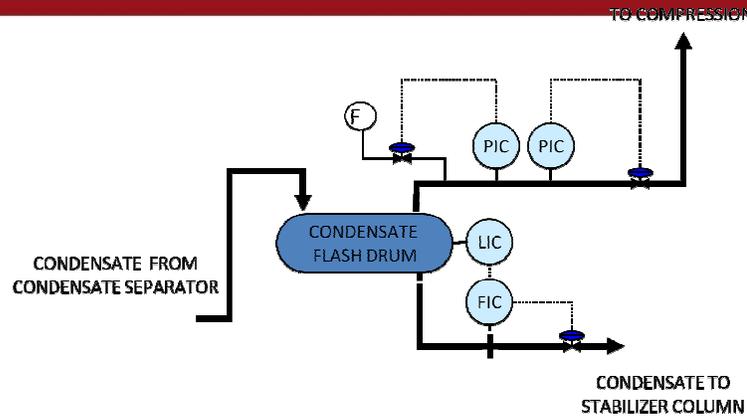


Fig. 2.3.- Esquema de la Etapa de Separación Flash

Condiciones de Operación:

Presión = 230 – 260 Psig

Temperatura = 80 – 90 °F

% Nivel que se controla = 30 – 50 %

III.- Fraccionamiento. - El objetivo de esta última etapa es la de remover en una columna de destilación los componentes volátiles que están todavía presentes en la corriente líquida de condensado. Esta etapa se opera usualmente a un nivel de presión más bajo, con la finalidad de producir un mayor nivel de remoción de estos componentes. Con la finalidad de optimizar la demanda energética del sistema, se suele colocar un intercambiador de calor entre el producto de alimentación a la columna y que está "frio" debido a las etapas de expansión a las que estuvo sometido en el separador trifásico y flash; con el producto de salida de fondo de la columna y que está caliente, antes que el mismo se dirija hacia el aerorefractor de salida de producto (Ver Fig. 2.4).

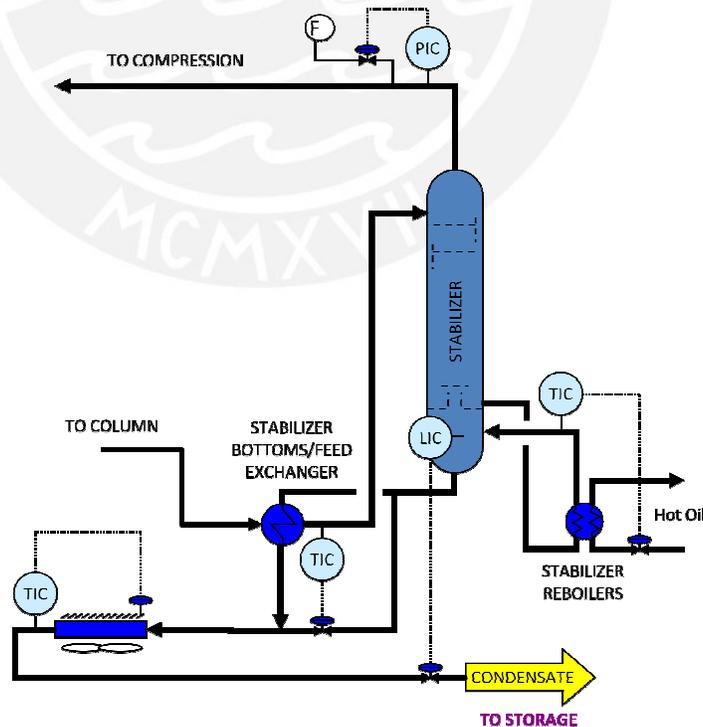


Fig. 2.4.- Esquema de la Etapa de Fraccionamiento

Condiciones de Operación:

Presión = 180 – 195 Psig

Temperatura de alimentación = 100 – 115 °F

Temperatura de fondo = 310 – 330 °F (usualmente el valor fluctúa dependiendo de la presión de operación de la columna y de la especificación de calidad del producto de fondo que se requiera mantener)

% Nivel que se controla = 30 – 50 %

Especificación de calidad máxima del Producto de Fondo = ratio molar C2/C3 = 2% (valor que equivale a una Presión de Vapor de Reid, PVR = 23.4 Psia).

2.2.1.2.- Descripción de las Estrategias de Control del Sistema.-

Los lazos de control que ayudan a los sistemas descritos, a cumplir sus objetivos de separación y fraccionamiento son los siguientes:

I.- Separación Primaria.-

- El caudal de ingreso al sistema tiene un lazo de control de caudal por retroalimentación, en el cual la variable de control es medida por una placa de orificio y la variable manipulada es la posición de la válvula de control ubicada aguas debajo de la medición (elemento final de control). En la válvula de control se produce el flasheo del producto líquido de ingreso, producto del cual se genera una corriente bifásica que ingresa al separador de condensado, para poder separarse en corrientes de hidrocarburos líquidos y agua, así como gases que serían derivados a un sistema de compresión.

- La presión de operación del separador de condensado es regulada por la succión de compresores, y tiene un lazo de control que ante algún escenario de sobrepresión, derivaría el exceso de gas hacia el flare de quema.

- El nivel de hidrocarburo en el interior del separador de condensado, es controlado por un lazo en cascada donde la variable primaria de control (master) es el nivel y la variable secundaria (esclavo) es el flujo de salida de condensado, el cual es medido por una placa de orificio.

- El nivel de agua en la bota del separador trifásico, es controlado por un lazo en cascada donde la variable primaria de control es el nivel, que se regula a través del control de flujo de salida de agua en esta etapa.

II.- Separación Flash.-

- El caudal de ingreso a esta etapa es garantizado únicamente por el lazo de control de nivel en cascada de la etapa anterior. Similar a lo que ocurría en el ingreso al separador de condensado, el flasheo del producto líquido que alimenta a esta etapa se produce en la válvula de control de flujo que es el elemento de control final del lazo de control de nivel de la etapa anterior.

- El control de presión de este separador consta de 2 lazos de control de retroalimentación e independientes. El primero de ellos regula la presión del separador y deriva los gases generados por la expansión del producto de alimentación, hacia una etapa posterior de compresión y cuyo análisis no forma parte del alcance del presente trabajo. El 2do lazo vigila que la presión en el separador no supere el valor de set point del mismo, derivando el exceso de gas hacia el flare de quema.

- El control de nivel de este separador bifásico, se realiza a través de un lazo de control en cascada, con un esquema similar al que se tenía en la etapa previa: la variable primaria de control es el nivel, que es controlado a través de la regulación del caudal de salida de hidrocarburo del separador y que alimentará a la columna de fraccionamiento.

- Una variante que se empleará en el modelamiento del sistema es considerar al separador flash como un separador trifásico, que permita remover eventuales trazas de agua libre que pudieran llegar hasta este equipo producto de alguna perturbación en el separador de condensado. De esta forma, un segundo lazo de control de nivel sería necesario, para controlar el nivel de agua en la bota de este nuevo separador flash, pero debido a la dinámica del sistema, en este caso sólo se requeriría un lazo de control tipo On-Off que active el drenaje del sistema en un rango de operación.

III.- Fraccionamiento.-

- El caudal de ingreso a esta etapa está garantizado por el control de nivel de la etapa anterior. Asimismo, de igual forma que en las etapas anteriores, el paso del producto líquido a través de las válvulas de control de flujo genera vaporización del mismo y al ingreso de la columna se tendrá un producto de naturaleza bifásica, que ingresa por el tope de la misma.

- Previo a su ingreso a la columna, el producto frío y con cierto grado de vaporización, es calentado en un intercambiador de tubos y coraza, donde gana temperatura a costa de pre-enfriar el producto caliente de fondos de la columna, que a su vez se dirigirá posteriormente a un enfriador con aire, para luego derivarse a almacenamiento. De esta forma, el precalentador de entrada a la columna sirve como un economizador que permite reducir el área de transferencia de calor del aerofriador del producto de fondos de la columna.

- Con la finalidad de evitar el sobrecalentamiento de la corriente de alimentación, existe un lazo de control de temperatura que vigila la temperatura de alimentación a la columna y la regula, bypaseando una fracción del condensado caliente proveniente de fondo de la columna hacia el intercambiador. De esta forma, una parte del producto caliente de fondo de la columna, suele derivarse sin pasar por el precalentador de alimentación hacia el aerofriador de producto de fondo.

- La calidad del producto de fondos de la columna es regulado de forma indirecta mediante un lazo de control de temperatura en una estrategia de control en cascada, donde la variable de control primaria es la temperatura de retorno de los vapores

2.2.1.3.- **Característica de las Corrientes de Alimentación y Productos del Sistema.-**

Las características de la corriente de alimentación al sistema son las siguientes:

Presión = 1315 Psig
Temperatura = 105 °F
Caudal = 25140 BSPD
Composición :

Componente	Fración Molar	%Molar
Nitrogen	0.0014	0.1446
CO2	0.0015	0.1526
Methane	0.3479	34.7913
Ethane	0.1069	10.6885
Propane	0.0843	8.4347
i-Butane	0.0176	1.7557
n-Butane	0.0383	3.8293
i-Pentane	0.0233	2.3281
n-Pentane	0.0257	2.5672
n-Hexane	0.0566	5.6633
Benzene	0.0000	0.0000
n-Heptane	0.0637	6.3743

n-Octane	0.0744	7.4396
n-Nonane	0.0445	4.4515
n-Decane	0.0306	3.0587
n-C11	0.0199	1.9944
n-C12	0.0111	1.1058
n-C13	0.0093	0.9309
n-C14	0.0067	0.6663
n-C15	0.0087	0.8742
n-C16	0.0014	0.1418
n-C17	0.0011	0.1087
n-C18	0.0007	0.0709
n-C19	0.0005	0.0473
n-C20	0.0010	0.0992
n-C21	0.0000	0.0000
n-C22	0.0000	0.0000
n-C23	0.0000	0.0000
H2O	0.0228	2.2813
Total	1.0000	100.0000

Para el caso de los productos de fondo y tope de la columna, las calidades suelen variar dependiendo del valor objetivo de control de calidad del producto de fondo (ratio %molar C2/C3), así como de las condiciones de Temperatura de alimentación a la columna, Presión de operación de la columna y Temperatura de fondo de la columna.

A continuación se mostrarán las características de los productos para una condición de operación específica.

Las características del producto de fondo de la columna son las siguientes:

Presión = 185 Psig
 Temperatura = 319.2 °F
 Caudal = 17250 BSPD
 Composición :

Componente	Fracción Molar	%Molar
Nitrogen	0.0000	0.0000
CO2	0.0000	0.0000
Methane	0.0000	0.0000
Ethane	0.0016	0.1554
Propane	0.1037	10.3672
i-Butane	0.0294	2.9404
n-Butane	0.0683	6.8252
i-Pentane	0.0458	4.5805
n-Pentane	0.0514	5.1409
n-Hexane	0.1181	11.8058
Benzene	0.0000	0.0000
n-Heptane	0.1348	13.4797
n-Octane	0.1582	15.8176

n-Nonane	0.0948	9.4835
n-Decane	0.0652	6.5214
n-C11	0.0425	4.2537
n-C12	0.0236	2.3588
n-C13	0.0199	1.9858
n-C14	0.0142	1.4213
n-C15	0.0186	1.8649
n-C16	0.0030	0.3024
n-C17	0.0023	0.2318
n-C18	0.0015	0.1512
n-C19	0.0010	0.1008
n-C20	0.0021	0.2117
n-C21	0.0000	0.0000
n-C22	0.0000	0.0000
n-C23	0.0000	0.0000
H2O	0.0000	0.0000
Total	1.0000	100.0000

Se debe notar, que la relación %molar C2/C3 = 1.5 % (equivale a un valor de PVR = 23.06 Psia)

Las características del producto de tope de la columna son las siguientes:

Presión = 185 Psig

Temperatura = 319.2 °F

Caudal = 3.34 MMSCFD (millones de pies cúbicos estándar por día, medidos a condiciones estándar de 14.696 Psia y 60 °F)

Composición :

Componente	Fracción Molar	%Molar
Nitrogen	0.0003	0.0304
CO2	0.0040	0.4004
Methane	0.3480	34.8001
Ethane	0.4602	46.0236
Propane	0.1295	12.9482
i-Butane	0.0134	1.3408
n-Butane	0.0224	2.2378
i-Pentane	0.0063	0.6346
n-Pentane	0.0055	0.5521
n-Hexane	0.0045	0.4470
Benzene	0.0000	0.0000
n-Heptane	0.0019	0.1891
n-Octane	0.0008	0.0832
n-Nonane	0.0002	0.0195
n-Decane	0.0001	0.0054
n-C11	0.0000	0.0014
n-C12	0.0000	0.0003
n-C13	0.0000	0.0001

n-C14	0.0000	0.0000
n-C15	0.0000	0.0000
n-C16	0.0000	0.0000
n-C17	0.0000	0.0000
n-C18	0.0000	0.0000
n-C19	0.0000	0.0000
n-C20	0.0000	0.0000
n-C21	0.0000	0.0000
n-C22	0.0000	0.0000
n-C23	0.0000	0.0000
H2O	0.0029	0.2859
Total	1.0000	100.0000

Estas composiciones tienen una dependencia del objetivo de control de calidad de la columna, que para los cuadros mostrados, está fijado en 1.5% como ratio molar de C2/C3, y que es controlado indirectamente a través del control de temperatura de la columna.

2.2.1.4.- Especificaciones de Calidad a Controlar en los Productos del Sistema.-

El producto principal del sistema es el condensado estabilizado que se obtiene en el fondo de la columna y el límite de especificación del mismo es el ratio %molar etano / propano $\leq 2\%$.

Si bien, se puede regular de forma indirecta esta relación de los productos etano/propano, a través del control de temperatura de fondos (como en el caso de los datos presentados en los cuadros anteriores, que son válidos para un esquema con ratio %molar C2/C3 = 1.5 %), cualquier oscilación muy por debajo del límite de especificación implica un regalo de calidad en el producto, por cuanto se deja de incluir etano en el producto líquido y sale con los gases en el tope de la columna, que tendría en cualquier esquema un menor precio.

2.2.2.- Comportamiento en Estado Estacionario del Sistema

A continuación se resumirán algunas de las principales características del comportamiento del sistema en estado estacionario, y que servirían de herramienta para definir las dependencias entre las variables de proceso.

2.2.2.1.- Simulación del Sistema en Estado Estacionario.-

En el esquema de la Fig. 2.5 que se muestra a continuación, se detalla la simulación en estado estacionario del sistema para una condición en particular. En este mismo esquema se encuentra el balance de masa y volumétrico del sistema.

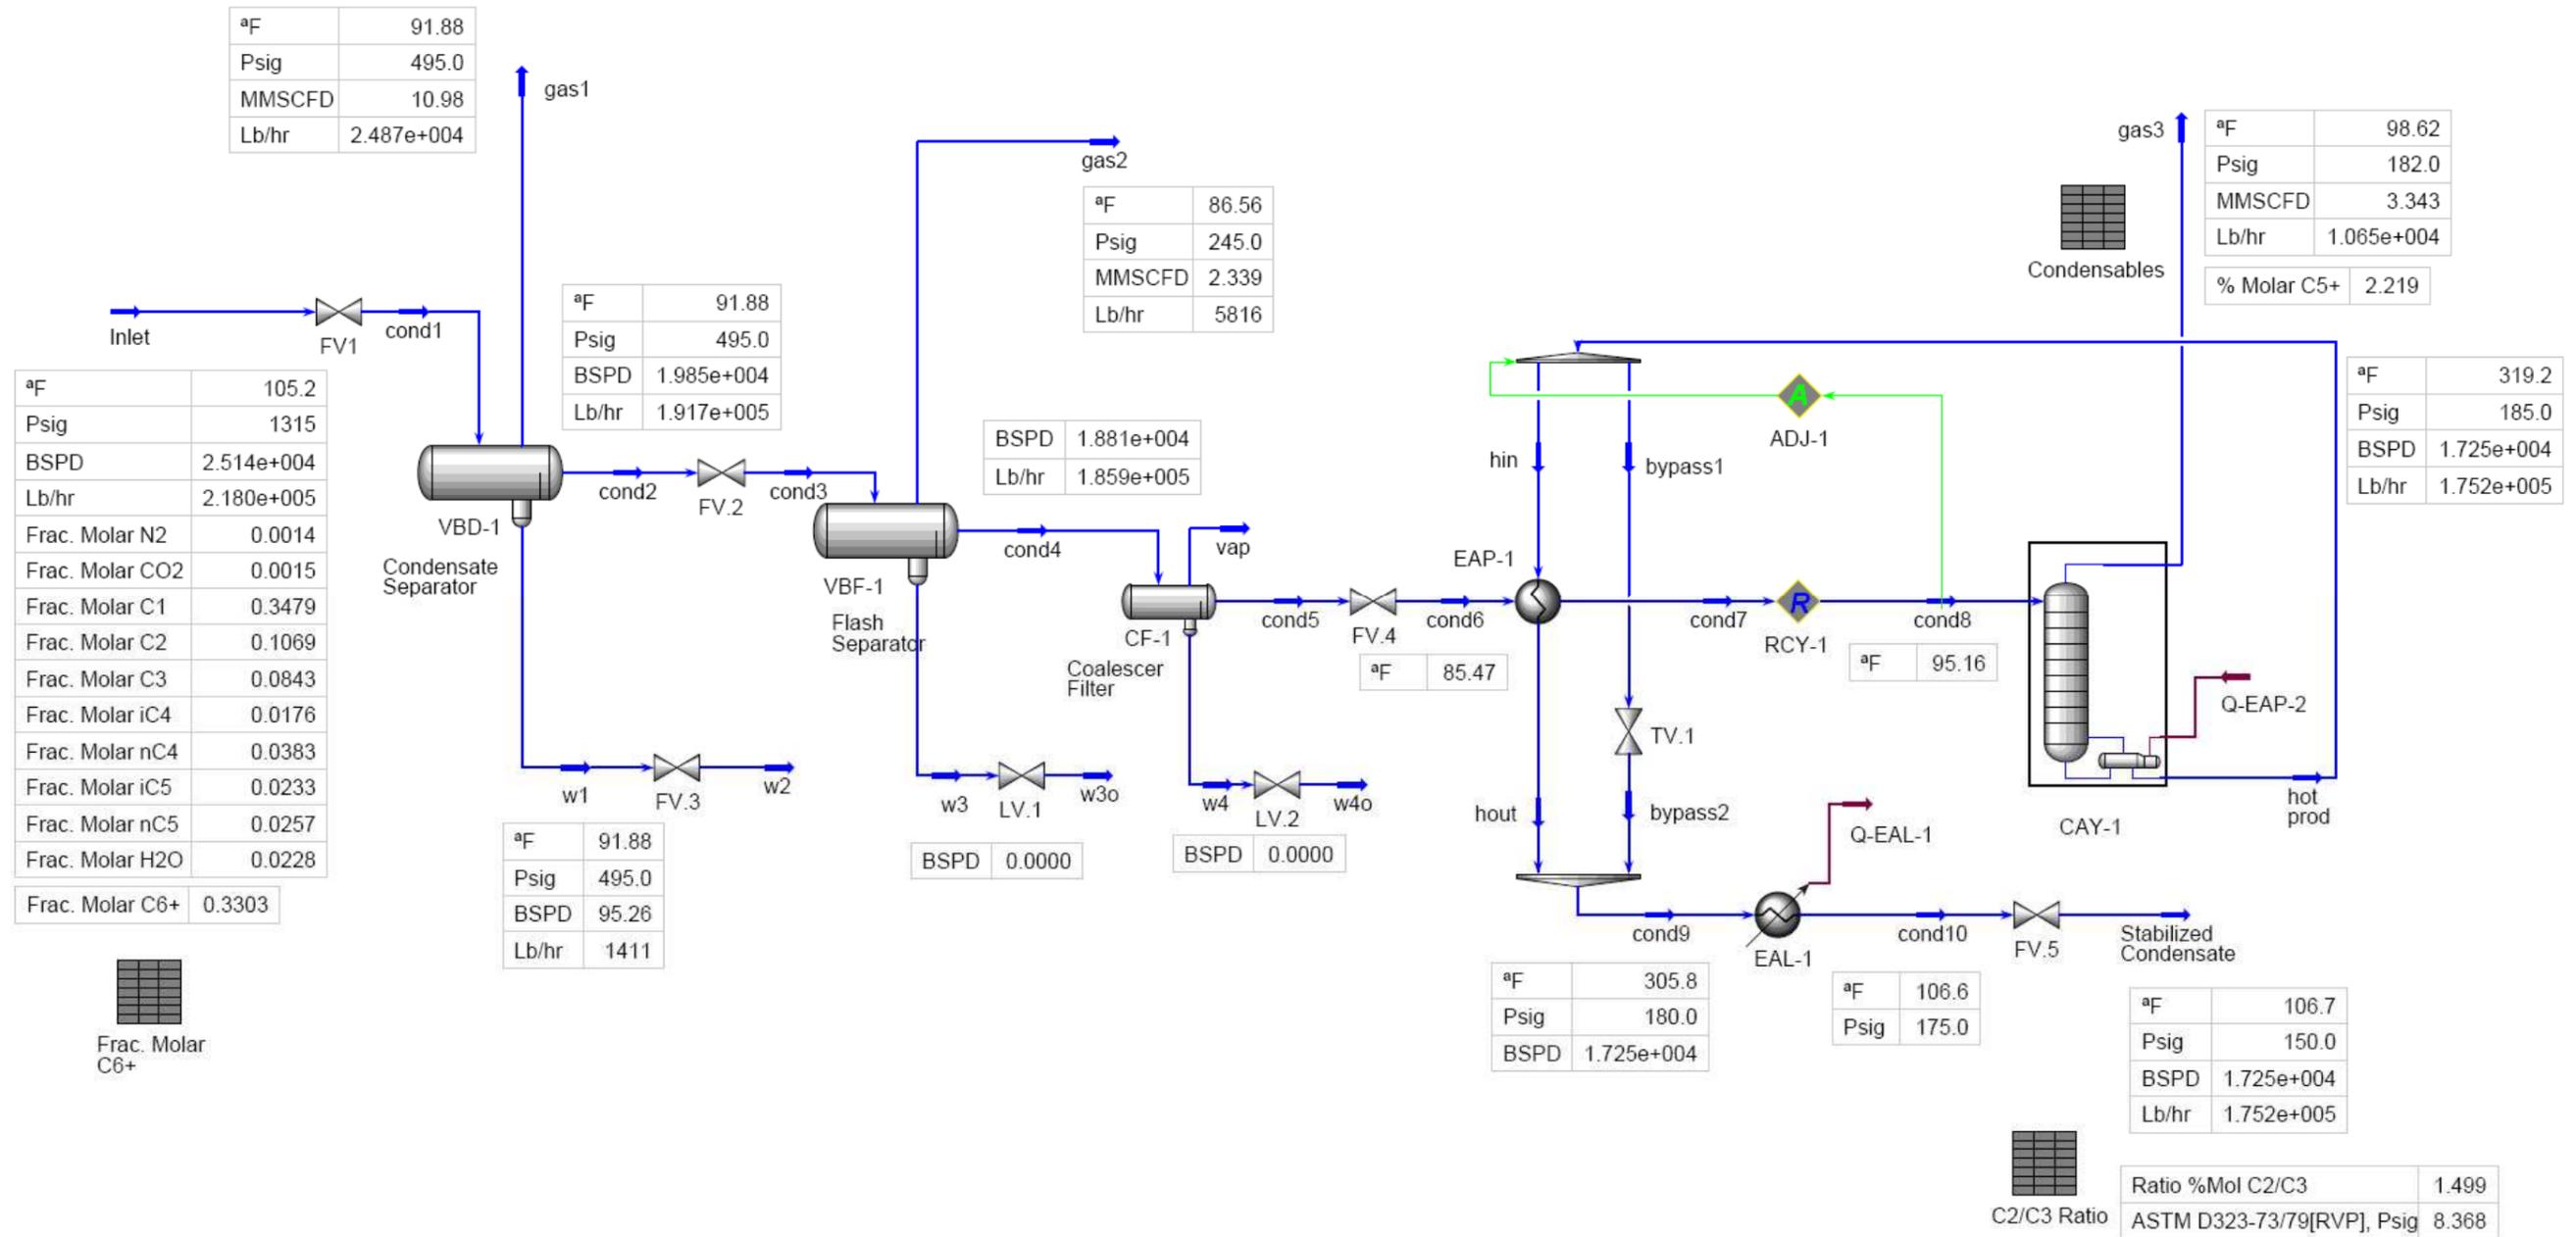


Fig. 2.5.- Simulación en Estado Estacionario del Sistema de Estabilización de Condensados de Gas Natural

A continuación se mostraran las relaciones que existen entre las principales variables de la columna de fraccionamiento multicomponentes.

2.2.2.2.- Comportamiento de la Calidad del Producto de Fondo de la Columna de Destilación.-

En la Fig. 2.6 se puede observar el comportamiento de calidad del producto de fondo de la columna, a diferentes valores de presión de la columna y con una carga de condensado al sistema de 25140 BPSD y una Temperatura de alimentación a la columna de 95 °F.

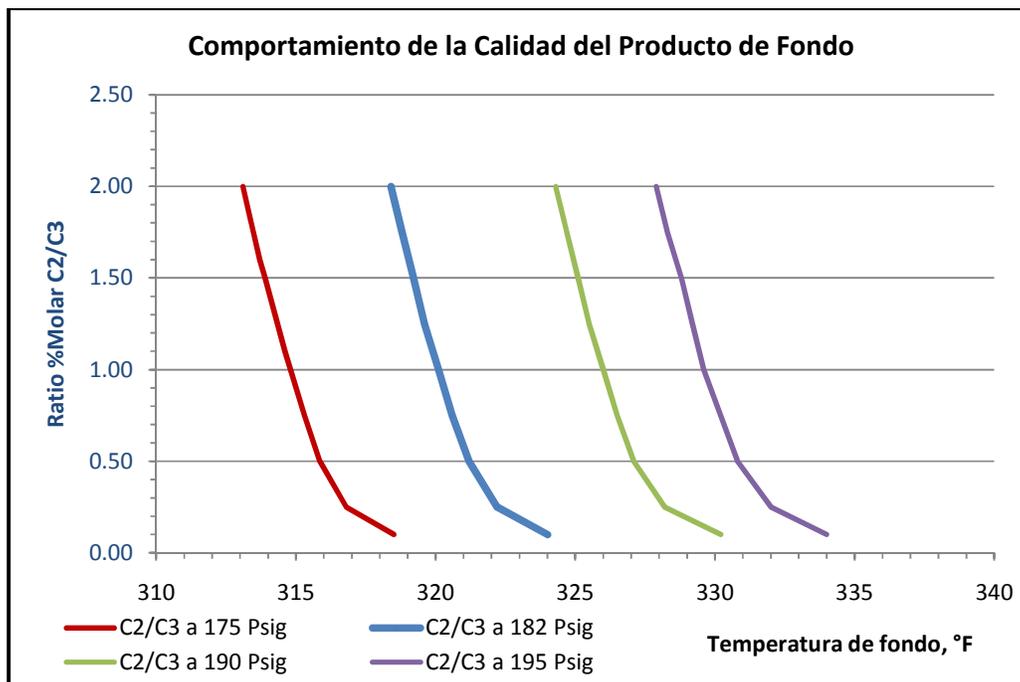


Fig. 2.6.- Comportamiento de la Calidad del Producto de Fondo

En la Fig. 2.6 se evidencia que en la medida que se aumenta la temperatura de fondo, para un valor de presión fijo, se reduce la relación de C2/C3 del producto de fondo. Asimismo, las diferentes curvas evidencian que en la medida que la presión de operación aumenta, se requerirá mayor temperatura en el fondo de la columna para mantener estable la calidad en un mismo valor de C2/C3.

En el caso que se produjeran variaciones en alguna de las variables del sistema como temperatura de alimentación o carga de condensado al sistema, estas curvas variarían, por ejemplo para diferentes valores de presión de tope de la columna, temperatura de operación de la misma, o inclusive para distintos niveles de carga al sistema, generándose por tanto distintas curvas de operación del sistema. A continuación se muestran algunas dependencias entre algunas variables.

2.2.2.3.- Curvas de Operación de la columna.-

A continuación se muestran algunas dependencias entre las variables de operación del sistema considerando que se mantiene fija la temperatura de entrada a la columna (Temp. entrada en 95 °F) y modificando únicamente la presión de operación de la columna (Ver Fig. 2.7, Fig. 2.8 y Fig. 2.9).

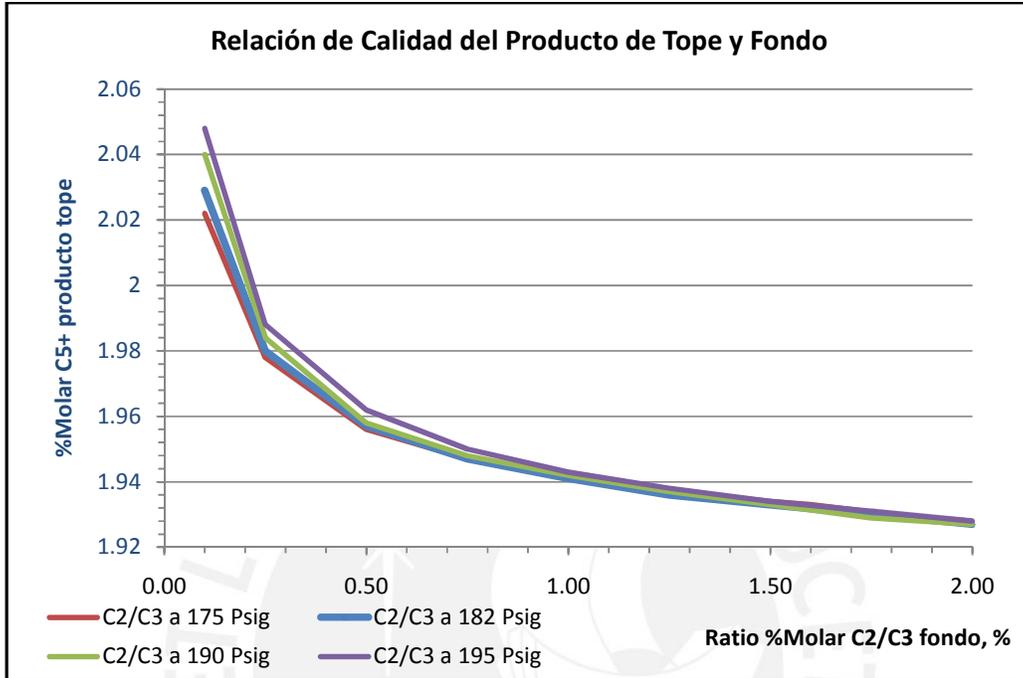


Fig. 2.7.- Relación de Calidad de Producto de Tope y Fondo

La Fig. 2.7 muestra que en la medida que se aumenta la relación C2/C3 en el producto de fondo de la columna, se disminuye el contenido de componentes pesados (C5+) en el producto de tope de la misma. Esta relación y tendencia se mantiene aun para diferentes valores de presión de operación de la columna; pero se requerirán mayores valores de temperatura de fondo para un mismo valor de calidad C2/C3 a diferentes presiones, como se mostró en la Fig. 2.6.

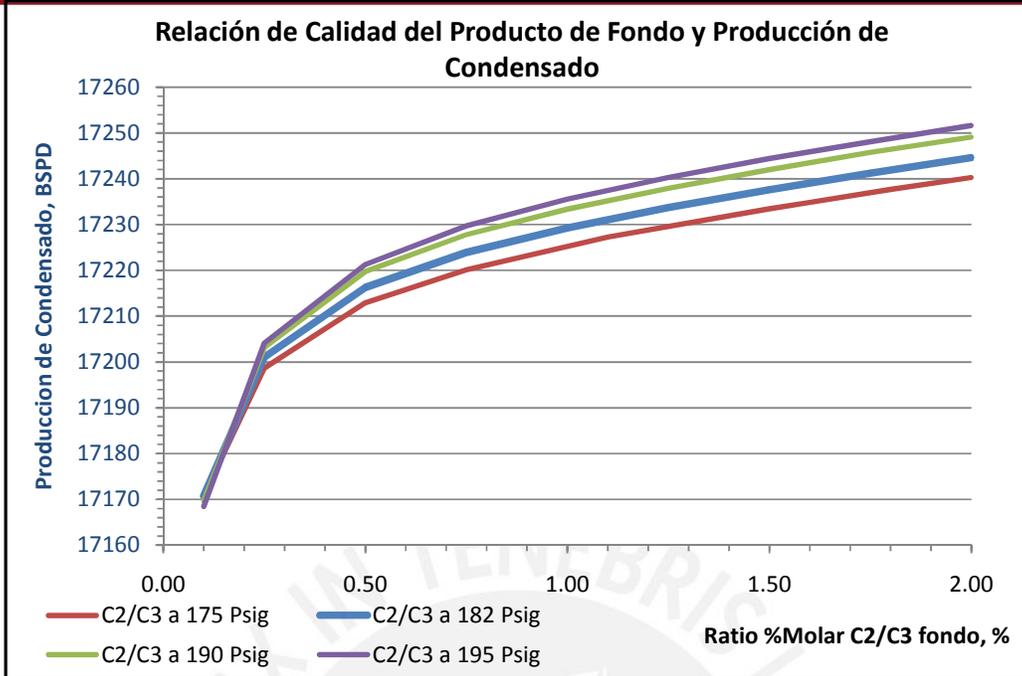


Fig. 2.8.- Relación entre Calidad de Producto de Fondo y la Producción de Condensado

En la Fig. 2.8 se muestra que en la medida que se aumenta la relación de calidad C2/C3 se aumenta la producción de condensado de fondo de la columna de destilación. Este aumento de producción tiene como límite la especificación de calidad del producto de fondo en $C2/C3 \leq 2\%$ y se ve favorecido por una presión de operación más alta de la columna.

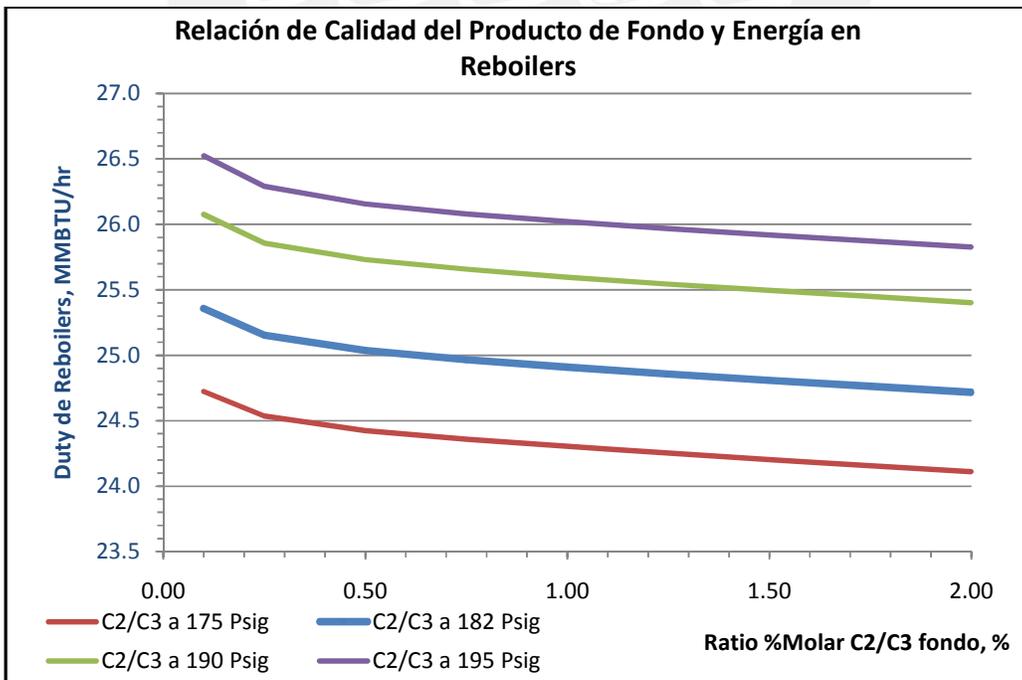


Fig. 2.9.- Relación entre Calidad del Producto de Fondo y la Energía Requerida

En la Fig. 2.9 se muestra que en a medida que se aumenta la relación C2/C3 del producto de fondo de la columna de destilación, la energía requerida en los reboiler de fondo es menor. Esto es equivalente a disminuir la temperatura de fondo para que aparezca etano en el producto de fondo (aumento de la relación C2/C3). Por el contrario, en la medida que se aumenta la energía en el fondo de la columna, la relación C2/C3 disminuye por la eliminación del componente etano (C2) principalmente. Asimismo, conforme aumenta la presión de operación de la columna, para una misma calidad C2/C3, se requerirá mayor energía.

Hasta ahora hemos visto las relaciones entre algunas de las variables de operación alrededor de la columna, dejando la temperatura de alimentación constante, pero ahora se mostrarán las dependencias entre las variables de operación cuando se varía la temperatura de alimentación a la columna, pero buscando una especificación de calidad del condensado estabilizado fija en un valor referencial de C2/C3 = 1.849 % (Ver Fig. 2.10, Fig. 2.11 y Fig. 2.12). Esto con la única finalidad de facilitar el análisis.

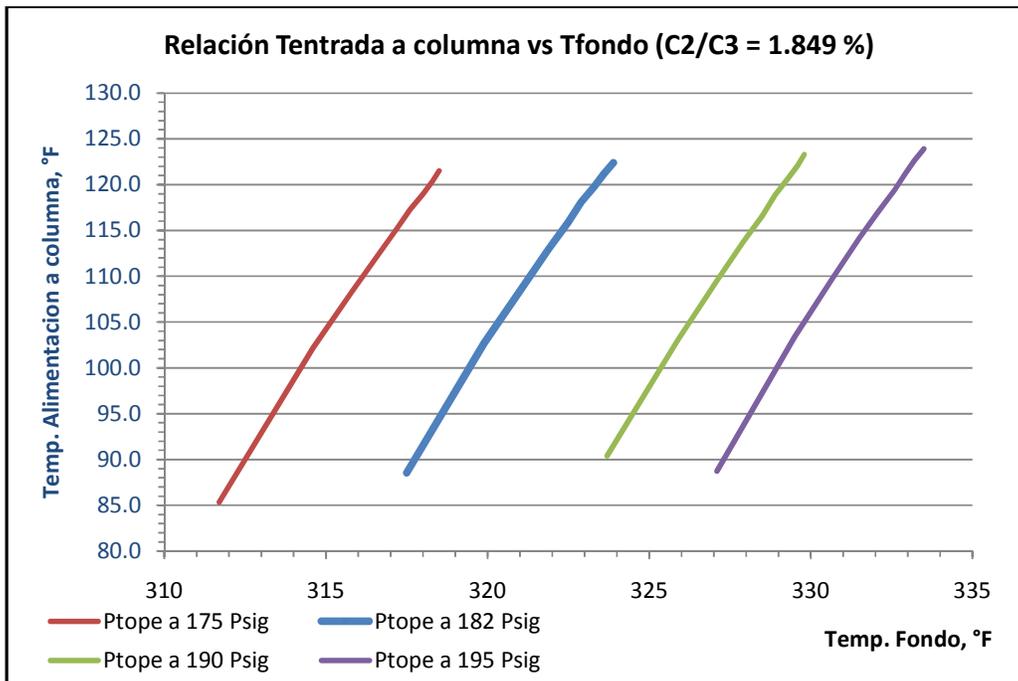


Fig. 2.10.- Relación entre Temperatura de Entrada y la Temperatura de Fondo

En la Fig. 2.10 se observa que en la medida que se aumenta la temperatura de entrada a la columna, para una misma presión de operación del sistema y un mismo objetivo de calidad en el fondo (C2/C3 = 1.849%), se requeriría mayor temperatura en el fondo de la columna. Esto debido a que la alimentación a la columna se produce por el tope de la misma, y el ingreso a mayor temperatura elimina componentes livianos, incrementando la densidad y peso molecular del producto liquido que desciende por el interior de la misma.

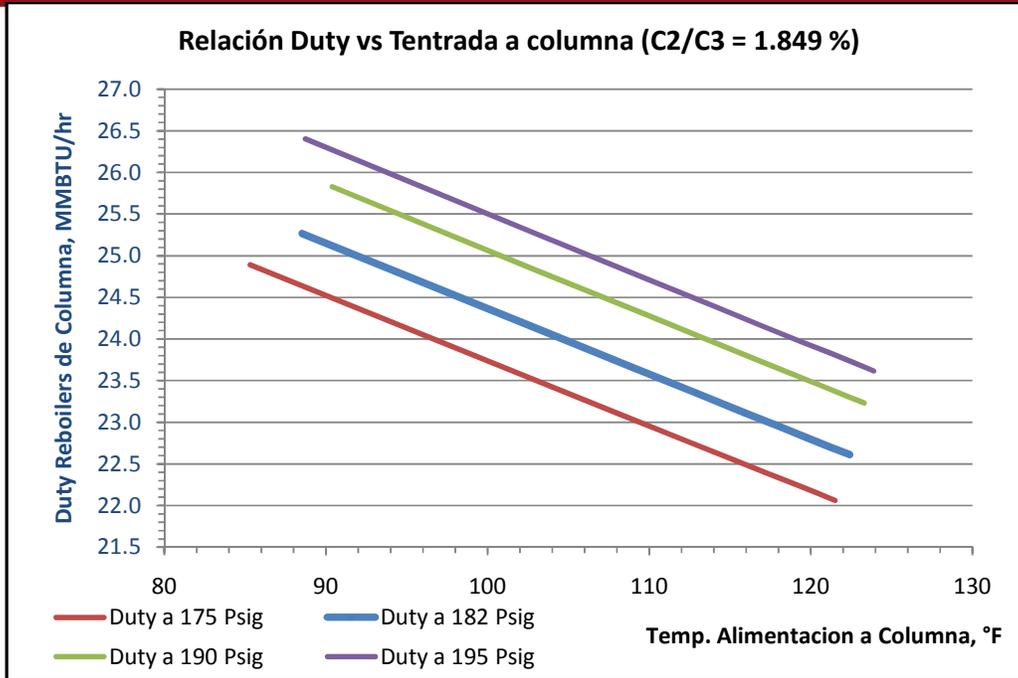


Fig. 2.11.- Influencia de la Temperatura de Entrada sobre la Energía requerida en el Sistema

En la Fig. 2.11 podemos observar que en la medida que la temperatura de alimentación se incrementa, la energía del fondo de la columna disminuye. Este comportamiento que parece contradecirse con lo que se observa en la Fig. 2.10 tiene su justificación en el hecho que a mayor temperatura de alimentación, hay disminución del producto líquido que desciende por el interior de la misma (por la eliminación de componentes livianos que se describió antes) y debido a esto, a pesar de manejarse mayor temperatura en el fondo de la columna, la energía total consumida es menor porque hay menor cantidad de producto líquido que calentar.

En la Fig. 2.12 se muestra cómo es que disminuye la producción de condensado de fondo de la columna cuando se manejan valores de temperatura de alimentación mayores para una misma calidad objetivo, y se evidencia lo mencionado en el párrafo anterior sobre la disminución de producto líquido que desciende por el interior de la columna, y por tanto, menor demanda de energía a pesar de los mayores requerimientos de temperatura de fondo.

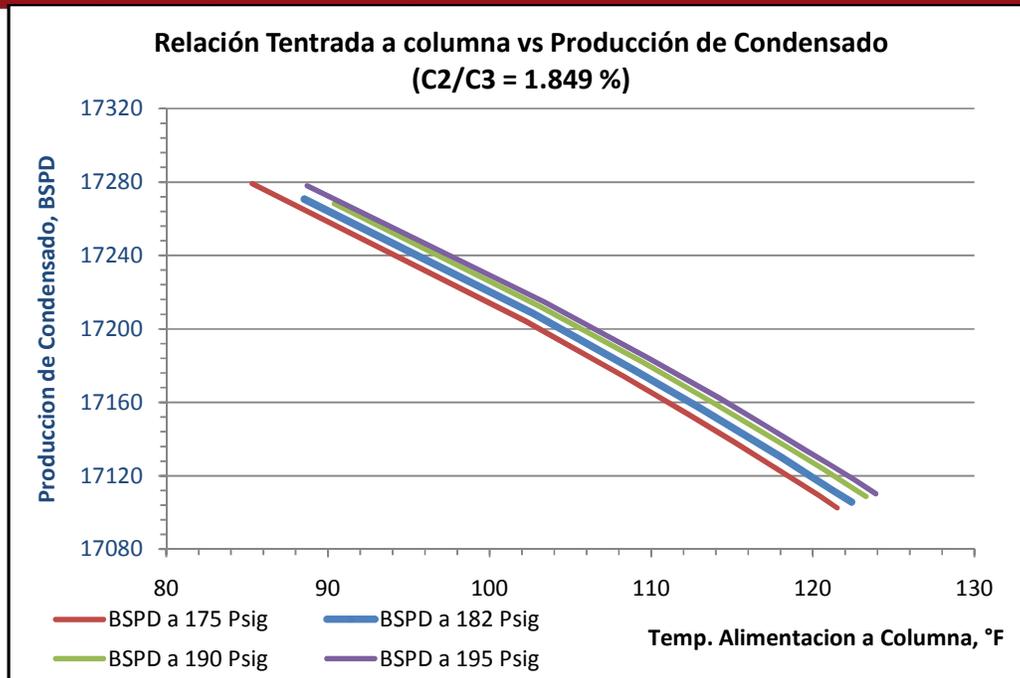


Fig. 2.12.- Relación entre Temperatura de Entrada y la Producción de Condensado

De las gráficas presentadas se evidencia que las relaciones entre las variables de operación de la columna son complejas y hay diferentes combinaciones de las mismas, que se pueden presentar en condiciones de operación dinámicas.

Es así que, para poder explorar todas las dependencias de las variables entre sí, se construirá la simulación dinámica del sistema, que además permitirá tomar en cuenta efectos de hold up en los equipos, coeficiente de flujo de las válvulas de control, y otros efectos dinámicos que suelen no tomarse en cuenta en un modelamiento en estado estacionario del sistema, pero que permiten una mejor aproximación al comportamiento del sistema real.

2.2.3.- Comportamiento Dinámico del Sistema

Como se ha revisado en la sección anterior, al estudiar las condiciones de operación de la columna y la relación entre estas variables; se evidencia que existen numerosas combinaciones para determinar el comportamiento de la columna cuando se producen variaciones en alguna de sus variables de operación como presión, temperaturas o nivel y es por esta relación que la calidad del producto de fondo cambiará, y no solo al alcanzar el estado estacionario; sino que además habrán múltiples combinaciones en los periodos transientes a los que puede estar sometido el sistema en su conjunto, y debido a esto, se pueden presentar oscilaciones simultáneas en las condiciones de operación del sistema que a través de los modelos en estado estacionario son difíciles de estudiar.

Por esto, se ha realizado el modelamiento del sistema en estado dinámico, considerando geometrías de equipos, estructuras de lazos de control y características de elementos finales de control, que nos permitirán explorar mejor la dinámica del sistema y definir el conjunto de variables que formarán parte de las entradas al modelo de red neuronal artificial, que se usará para el diseño de la estructura de control inferencial.

2.2.3.1.- Simulación Dinámica del Sistema de Estabilización de Condensado.-

A continuación, en la Fig. 2.13, se presenta el esquema de simulación dinámica del sistema de Estabilización de Condensados de Gas Natural, que se usará para explorar las dependencias de las variables primarias y secundarias del sistema, con la finalidad de escoger las variables para el modelo de red neuronal artificial dinámica.



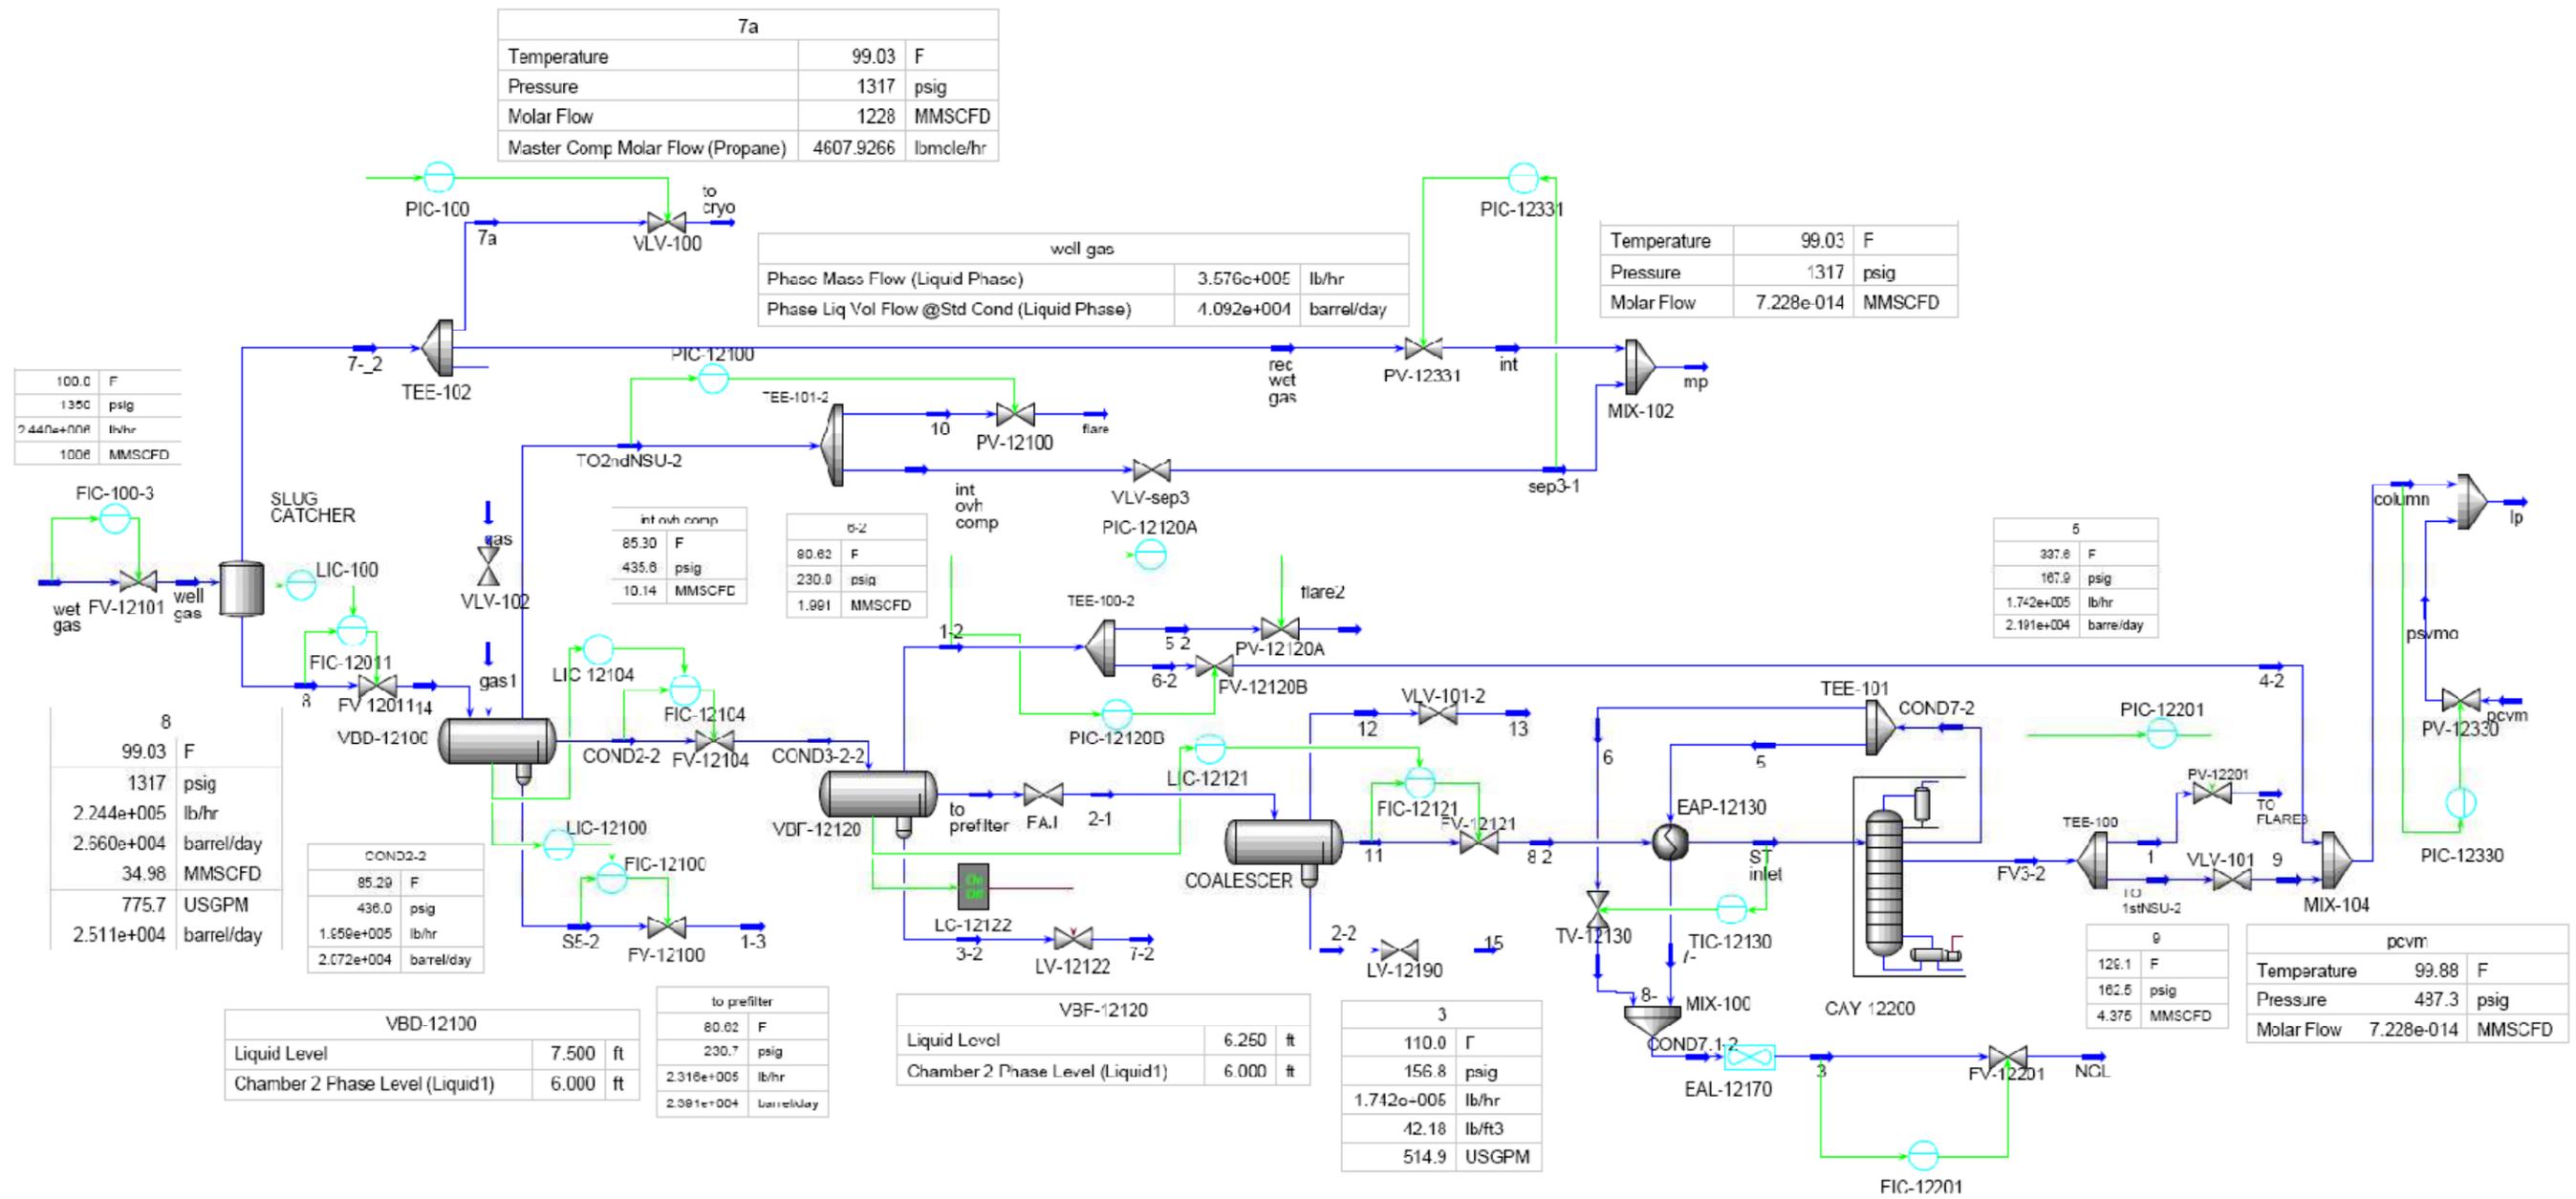


Fig. 2.13.- Simulación en Estado Dinámico del Sistema de Estabilización de Condensados de Gas Natural

CAPÍTULO 3: DISEÑO DEL SISTEMA DE CONTROL BASADO EN REDES NEURONALES ARTIFICIALES PARA EL MONITOREO Y CONTROL DE CALIDAD DE LA COLUMNA DE DESTILACION MULTICOMPONENTES

3.1.- Introducción

Hemos revisado a lo largo de las secciones anteriores los equipos y lazos de control asociados al sistema de estabilización de condensados de gas natural, dentro del cual se encuentra la columna de fraccionamiento sobre la que nos concentraremos para el diseño del sistema de control alternativo.

Debido a que el principio fundamental de la destilación es la separación de productos basada en la diferencia de presión de vapor de sus componentes y debido a que la presión de vapor es justamente una función controlada por la temperatura, es muy usual que se use el control de temperatura para ejercer un control indirecto de la composición del producto de interés. Esta situación asume que no hay cambios en la presión de la columna o que la medición de temperatura es compensada por los cambios en la presión y que la composición y caudal de alimentación permanece estable en un rango acotado. Sin embargo, como se observó en la sección anterior, las relaciones entre estas variables de presión y temperatura alrededor de nuestra columna de destilación, pueden ser cambiantes y tienen interacción entre sí, por lo que ningún cambio en la composición podría ser detectado con alta precisión a través de un cambio en la temperatura.

Debido a esto, el uso común de analizadores en línea que acompañan, como elementos de monitoreo de calidad, a los lazos de control de temperatura. Pero como ya hemos mencionado en secciones anteriores, existen problemas de retardos de tiempo en los mismos, que además son muy sensibles a la presencia de contaminantes y es por esto que cuando se quiere usar analizadores online dentro de una estructura de control de la calidad de alguno de los productos, se tienen que hacer ciertas consideraciones en la configuración del controlador a implementar y en algunos casos resulta imposible diseñar un sistema de control por retroalimentación efectivo.

Es entonces que surge la alternativa de los sistemas de control inferencial, cuyo objetivo fundamental es modelar la relación que existe entre variables de proceso secundarias y las principales; y entonces, este modelo podría ser usado para estimar la calidad del producto de la columna de destilación la cual resulta muchas veces difícil de medir con precisión y de forma sostenida. Esto es factible de hacer en las columnas de fraccionamiento debido a la naturaleza del proceso en que el estado de determinadas variables secundarias puede reflejar el comportamiento de variables principales y por la relación que existe entre las mismas, inferir la calidad de estas variables primarias, como se mostró en el capítulo anterior.

En el presente trabajo, se pretende usar un modelo basado en Redes Neuronales Artificiales para realizar la estimación de calidad del producto de fondo de la columna, y se seleccionó el uso de redes neuronales, porque estas estructuras pueden “aprender” las relaciones complejas y no lineales entre las distintas variables secundarias y primarias a partir de generalizaciones que establecen a partir de una limitada cantidad de datos. Por esto, pueden servir como modelos de caja oscura de sistemas no lineales, multivariados estáticos o dinámicos incluso. Entre las ventajas de utilizar redes neuronales se encuentra el hecho de no requerir solucionar ningún modelo matemático, así como no tener una fuerte dependencia de los parámetros que definen la dinámica del sistema (Ong, 1998), y que luego de ser entrenado la validación y operación en tiempo real es mucho más rápida que otros sistemas, entre otros beneficios.

La red neuronal artificial es capaz de aprender las relaciones entre las variables de entrada y salida de este sistema y su co-dependencia, y por tanto es muy útil para usarse dentro de un esquema de control de modelo interno (IMC) basado en la estructura de la red o también en un controlador neuronal donde la red neuronal artificial es usada para calcular directamente la señal de control.

3.2.- Construcción del Modelo de Red Neuronal Artificial para la Estimación de la Calidad del Producto de la Columna de Destilación Multicomponentes

3.2.1.- Esquema General de un Sistema de Red Neuronal Artificial (RNA)

Entre los pioneros en el modelado de neuronas se encuentra Warren McCulloch y Walter Pitts, quienes en 1943 propusieron un modelo matemático de neurona (Ver Fig. 3.1). En este modelo cada neurona estaba dotada de un conjunto de entradas y salidas, donde cada entrada tenía un peso w_i asociado, luego se totalizaban todas las entradas multiplicadas por sus respectivos pesos, para luego hacer pasar este resultado por una función no lineal, llamada función de activación y obtener la salida del sistema.

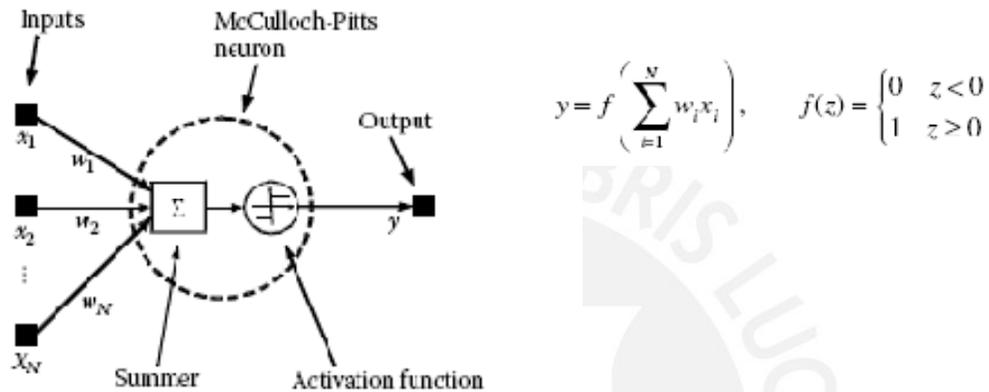


Fig. 3.1.- Modelo de Neurona de McCulloch - Pitts

Los distintos X_i son las variables de entrada, y es la salida de la neurona y $f(z)$ es la función de activación.

Sin embargo, es debido a las limitaciones que tenía el uso de una sola neurona, que continuaron las investigaciones y en 1986 una publicación de Rumelhart y McClelland mostraba los beneficios del uso de múltiples capas de neuronas acondicionadas, con un modelo de red que se muestra en la Fig. 3.2.

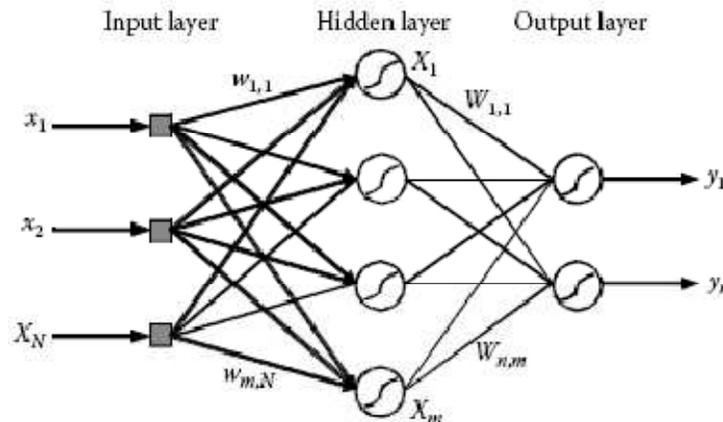


Fig. 3.2.- Esquema de Red Neuronal Multicapa

En estos esquemas existen 3 tipos de neuronas:

- *Neuronas de Capa de Entrada:* Son aquellas que reciben los estímulos o señales externas.

– *Neuronas de Capas Ocultas o Intermedias*: Tienen contacto directo con las neuronas de entrada y salida, mas no con las señales de entrada y salida.

– *Neuronas de Capa de Salida*: Transmiten las respuestas del sistema.

Las neuronas de entrada no realizan ningún cálculo, estas simplemente distribuyen las entradas x_k con los pesos w_{jk} hacia las neuronas de la capa oculta.

En cada neurona de la capa oculta, se realiza la sumatoria de todas las entradas que llegan hasta la misma:

$$h_j = \sum_k w_{jk} \cdot x_k$$

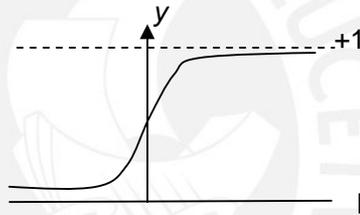
Una función de transferencia no lineal es aplicada sobre el resultado anterior (también conocida como función de activación), de tal forma de obtener la salida de cada neurona de capa oculta o de capa intermedia:

$$X_j = f(z) = f\left(\sum_k w_{jk} \cdot x_k\right)$$

Esta función de transferencia añade no linealidad y estabilidad a la red neuronal. Las más comunes funciones de activación son las siguientes :

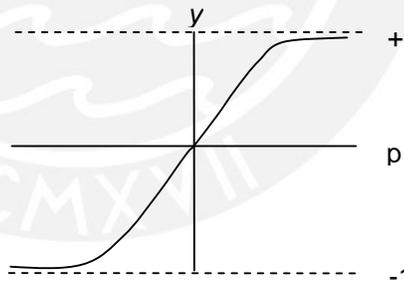
Sigmoidea Tipo 1 :

$$y = \frac{1}{1 + e^{-p}}$$



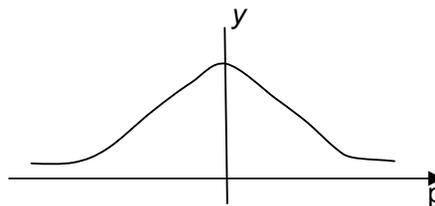
Sigmoidea Tipo 2 :

$$y = \frac{2}{1 + e^{-p}} - 1$$



Gausiana :

$$y = e^{-p^2}$$



El valor de salida de la función de transferencia generalmente es pasado directamente hacia la neurona de la capa de salida que puede ser de tipo lineal o no. Cada neurona de la capa de salida se encuentra conectada a diferentes entradas que a su vez, son las salidas de cada neurona de la capa intermedia, obteniéndose como valor total de entrada a cada neurona de la capa de salida:

$$H_i = \sum_j W_{ij} \cdot X_j = \sum_j W_{ij} \cdot f\left(\sum_k w_{jk} \cdot x_k\right)$$

Y entonces, cada variable de salida tendrá la forma siguiente :

$$Y_i = f(H_i) = f\left(\sum_j W_{ij} \cdot f\left(\sum_k w_{jk} \cdot x_k\right)\right)$$

Y para el caso de modelamiento de sistemas basados en técnicas de regresión, se suele emplear funciones lineales en esta última capa.

3.2.1.1.- Entrenamiento de la Red Neuronal Artificial (RNA).-

Consiste en el proceso sistemático que permite el ajuste de los pesos de las conexiones entre unidades de procesamiento (w_{jk} y W_{ij}).

El número de neuronas de la capa intermedia interviene directamente en la eficiencia del aprendizaje, y si bien se han escrito varias recomendaciones al respecto, muchas veces se termina definiendo por prueba y error. Se debe tomar en consideración el número de iteraciones, el error que se puede alcanzar, y el menor tiempo de procesamiento. Cuando la red ya está entrenada, y se desea verificar los pesos logrados, se puede correr una única iteración con un ratio de aprendizaje cero; a este proceso se le denomina "validación".

Según Chen (1996), en cada iteración del sistema, se incorporan señales de entrada que pasan a través de la red cruzando todas las capas de esta, la salida de la red es utilizada para compararla con una salida deseada, produciéndose un error.

Una función de costo que busca minimizar dicho error es la encargada de modificar los pesos actuales incrementándolos o decrementándolos a razón de un ratio de aprendizaje.

Típicamente la función de costo a minimizar es de la forma:

$$J = \min_{E_{w,w}} = \frac{1}{2} \left(\sum_n \sum_i [y_i(X_n) - Y_i(X_n)]^2 \right)$$

$$J = \frac{1}{2} \left(\sum_n \sum_i \left[y_i(X_n) - f\left(\sum_j W_{ij} \cdot f\left(\sum_k w_{jk} \cdot x_{k,n}\right)\right) \right]^2 \right)$$

Donde :

$Y_i(X_n)$, es la salida de la red neuronal y $y_i(X_n)$, es la salida deseada que usualmente es un dato conocido.

El aprendizaje de una red neuronal se realiza mediante el ajuste de los pesos que conectan sus neuronas y es sinónimo de entrenamiento.

Tipo de entrenamiento según la modalidad de dicho aprendizaje.-

Red con Aprendizaje Supervisado: Su entrenamiento se realiza mediante la dirección de un agente externo (supervisor) que determina la respuesta que debe producir la red a partir de una condición de entrada determinada. Puede ser:

– *Sistema con corrección de error*: Los pesos se ajustan en función al error entre la salida real y la salida deseada.

– *Sistema por refuerzo*: El agente supervisor indica mediante una señal de refuerzo, si la salida obtenida se ajusta a la deseada o no, los pesos son ajustados mediante un mecanismo basado en probabilidades

– *Estocástico*: Consiste en hacer cambios aleatorios de los valores de la red y determinar si la energía de la red es menor después de realizado dicho cambio, quedando así aceptado dicho cambio, la energía de la red se calcula usando los teoremas de Lyapunov.

Red con Aprendizaje No Supervisado: También llamado autosupervisado, no requiere de influencia externa para cambiar sus parámetros, sus pesos se ajustan automáticamente. Pueden ser:

– Hebbiano: Consiste en el ajuste de pesos de acuerdo con la correlación de los valores de activación de dos neuronas conectadas.

– Competitiva y Cooperativa: Las neuronas compiten y cooperan unas con otras de forma tal que solo una salida se activa, tratando de clasificar los datos que son introducidos.

Tipo de entrenamiento según la modalidad de actualización de pesos.-

Batch: Cuando se usa todos los datos para actualizar los pesos, y por tanto es necesario esperar un ciclo completo de iteraciones para recién ajustar los pesos.

Patrón: Cuando se usa el dato presente para actualizar los pesos, por cada nuevo dato calculado se va ajustando los pesos.

De acuerdo el método de optimización por gradiente descendiente, la actualización de los pesos se realiza mediante :

Actualización de los pesos de las neuronas de salida :

$$W_{ij} = W_{ij} - \eta \cdot \frac{\partial J}{\partial W_{ij}}$$

Visto de otra manera :

$$\Delta W_{ij} = -\eta \cdot \frac{\partial J}{\partial W_{ij}} = -\eta \cdot \frac{\partial E^2}{\partial W_{ij}}$$

$$\Delta W_{ij} = -\eta \cdot \frac{\partial E^2}{\partial W_{ij}} = \eta \cdot \sum_n [y_i(X_n) - Y_i(X_n)]^2 \cdot f'(H_i) X_j = \eta \cdot \sum_n \Delta_i \cdot X_j$$

Donde: η es el ratio de aprendizaje y

$$\Delta_i = \eta \cdot [y_i(X_n) - Y_i(X_n)]^2 f'(H_i)$$

Actualización de los pesos de las neuronas de entrada :

$$w_{jk} = w_{jk} - \eta \cdot \frac{\partial J}{\partial w_{jk}}$$

Visto de otra manera :

$$\Delta w_{jk} = -\eta \cdot \frac{\partial J}{\partial w_{jk}} = -\eta \cdot \frac{\partial E^2}{\partial w_{jk}}$$

$$\Delta w_{jk} = \eta \cdot \sum_n \cdot \sum_i [y_i(X_n) - Y_i(X_n)]^2 \cdot f'(H_i) W_{ij} f'(h_i) x_{n,k}$$

$$\Delta w_{jk} = \eta \cdot \sum_n \cdot \sum_i \Delta_i W_{ij} f'(h_i) x_n = \eta \cdot \sum_n \delta_j x_n$$

$$\delta_j = \eta f'(h_i) \sum_i \Delta_i W_{ij}$$

Estos deltas para la capa de entrada son calculados a partir de los deltas de la capa de salida y cuando los errores calculados a partir de la capa de salida son reusados para calcular los errores de la capa de entrada a través de las capas intermedias, se denomina método de “retropropagación de errores” (Backpropagation), que resulta ser una metodología práctica de cálculo de las derivadas : $\frac{\partial J}{\partial w_{ij}}$ y $\frac{\partial J}{\partial w_{jk}}$

De los métodos de entrenamiento por la modalidad de actualización de los pesos, el entrenamiento tipo Batch es considerado el mejor por cuanto las derivadas $\frac{\partial J}{\partial w_{ij}}$ y $\frac{\partial J}{\partial w_{jk}}$ se calculan para cada patrón o conjunto de datos y se van acumulando para que los pesos se actualicen recién al final del proceso de cálculo, luego de haber recorrido el total de conjunto de datos; y luego recién se inicia la siguiente iteración, repitiéndose todo el proceso nuevamente. Por ello, este tipo de entrenamiento es más riguroso y exigente.

3.2.1.2.- Acondicionamiento de los Datos.-

Debido a que las funciones de activación que conforman las unidades de procesamiento o neuronas de capa intermedia, tienen un límite de saturación, se debe tener cuidado de que los valores de entrada y salida sean llevados proporcionalmente al rango de trabajo de la red y de esta forma aprovechar las capacidades de la red al máximo.

Cuando los datos son empleados en sus unidades de ingeniería, si los rangos de los valores numéricos son muy distintos, se corre riesgo de saturar a las funciones de activación, para evitar esta situación se hace un escalamiento de los datos para llevarlos a valores entre 0 y 1 de tal forma de homogenizar la magnitud de los datos. Luego de obtener las salidas de la red neuronal, se realiza el proceso inverso y allí se obtendría los valores de salida con las unidades de ingeniería deseada.

3.2.2.- Modelamiento de Sistemas Mediante Red Neuronal Artificial (RNA) Dinámica

Para el modelamiento de sistemas usando redes neuronales, o para la creación de controladores basados en redes neuronales se suelen usar redes neuronales estáticas y dinámicas.

La principal diferencia entre estos esquemas radica en la fuente de datos para el entrenamiento. En el caso de las redes neuronales estáticas, las entradas se toman directamente del proceso real, mientras que en las redes dinámicas se toman de la salida de la misma red, adoptándose un modelo recursivo.

Red Neuronal Estática: $X_{k+1} = f(X_k ; \mu_k)$
 Red Neuronal Dinámica : $X_{k+1} = f(X_k ; \mu_k)$

donde \bar{X}_k son datos reales, y X_{k+1} es la salida de la red

Entre los métodos de entrenamiento de la red neuronal dinámica se tienen:

- BPTT (Back Propagation Through Time)
- DBP (Dynamic Back Propagation)

De estos métodos el segundo es más rápido y consume menos recursos de memoria.

Debido a la forma recursiva del método y la estructura de la red neuronal dinámica, el sistema se transforma en un sistema con un número de subredes neuronales de tal forma que la salida de cada una de estas redes se convierte en la entrada de la siguiente. El número de subredes es igual al número de conjunto de datos que se requiere usar para el entrenamiento. El proceso de pasar a través del total de subredes neuronales para determinar las derivadas y luego recién actualizar los pesos, implica que el método de entrenamiento es del tipo Batch.

Como el entrenamiento de una red implica la determinación de los pesos a través de la determinación de las derivadas $\frac{\partial J}{\partial w_{ij}}$ y $\frac{\partial J}{\partial w_{jk}}$, se había mencionado el algoritmo de retropropagación de errores (Back Propagation), pero para el caso de redes neuronales dinámicas en las que se trata de subredes neuronales que convierten al sistema total, en uno recursivo, se hace una adaptación al método y el algoritmo es el de retropropagación dinámica de errores (DBP), que es rápido y de menor consumo de recursos del sistema ya que se apoya en técnicas recursivas para el cálculo de los pesos.

De esta forma tendremos que el sistema neuronal se expresa de la forma:

$$X_{k+1} = f(X_k ; X_{k-1} ; X_{k-2} ; \dots ; \mu_k)$$

Donde X_{k+1} es la salida de la red

Y la función de costo a minimizar es la siguiente :

$$J = \frac{1}{2}(X_1 - \bar{X}_1)^2 + \frac{1}{2}(X_2 - \bar{X}_2)^2 + \dots + \frac{1}{2}(X_{k+1} - \bar{X}_{k+1})^2$$

La estimación de los pesos se mantiene de forma similar a lo ya citado antes :

$$W_{ij} = W_{ij} - \eta \cdot \frac{d\bar{J}}{dW_{ij}}$$

$$w_{jk} = w_{jk} - \eta \cdot \frac{d\bar{J}}{dw_{jk}}$$

Pero la estimación de las derivadas ahora implica trabajar con derivadas parciales totales; y tomando en cuenta que :

$$\frac{d\bar{X}_{k+1}}{d\bar{w}} = \frac{dX_{k+1}}{dw} + \frac{dX_{k+1}}{dX_k} \cdot \frac{d\bar{X}_k}{d\bar{w}}$$

$$\frac{d\bar{X}_{k+1}}{d\bar{W}} = \frac{dX_{k+1}}{dW} + \frac{dX_{k+1}}{dX_k} \cdot \frac{d\bar{X}_k}{d\bar{W}}$$

Tendremos entonces, que las derivadas se calcularían de la forma :

$$\frac{\overline{dJ}}{d\overline{w}} = (X_1 - \overline{X}_1) \frac{d\overline{X}_1}{d\overline{w}} + (X_2 - \overline{X}_2) \frac{d\overline{X}_2}{d\overline{w}} + \dots + (X_{k+1} - \overline{X}_{k+1}) \frac{d\overline{X}_{k+1}}{d\overline{w}}$$

$$\frac{\overline{dJ}}{d\overline{W}} = (X_1 - \overline{X}_1) \frac{d\overline{X}_1}{d\overline{W}} + (X_2 - \overline{X}_2) \frac{d\overline{X}_2}{d\overline{W}} + \dots + (X_{k+1} - \overline{X}_{k+1}) \frac{d\overline{X}_{k+1}}{d\overline{W}}$$

Hay que notar que para el cálculo de estas derivadas se ha recorrido el total de subredes neuronales y luego recién se actualizan los pesos (entrenamiento tipo Batch), para pasar a la siguiente iteración, repitiéndose todo el proceso nuevamente hasta terminar el total de iteraciones pedidas o alcanzar el error objetivo.

3.2.3.- Selección de Variables del Sistema de Estabilización de Condensado para el Modelamiento

Una etapa importante para iniciar el modelamiento del sistema es definir cuáles serán las variables secundarias que alimentaran a la red. Esta selección puede hacerse probando diferentes combinaciones de variables y evaluando el comportamiento de la red. En nuestro caso, nos apoyaremos en las relaciones que tienen entre si algunas variables que se mostraron en el capítulo 2 y añadiremos otras, que pueden actuar como perturbaciones en el sistema.

De esta forma, el sistema tendría las siguientes variables:

Variable de Salida de la Red Neuronal:

$Y(k)$ = Calidad del producto de fondo de la columna de destilación : Ratio %molar C2*100 / %molar C3, que se suele denominar simplemente %C2/C3.

Variables de Entrada a la Red Neuronal:

$X_1(k)$ = Flujo de entrada de condensado al sistema, en GPM.

$X_2(k)$ = Presión del separador de entrada al sistema, en Psig.

$X_3(k)$ = Presión del separador intermedio del sistema, en Psig.

$X_4(k)$ = Presión del tope de la columna, en Psig.

$X_5(k)$ = Temperatura de alimentación a la columna, en °F.

$X_6(k)$ = Flujo de entrada a la columna en GPM.

$X_7(k)$ = Temperatura de fondo de la columna, en °F.

$X_8(k) = X_7(k-1)$ = Temperatura de fondo de la columna en el instante $t = t-1*\Delta t$

$X_9(k) = X_7(k-2)$ = Temperatura de fondo de la columna en el instante $t = t-2*\Delta t$

$X_{10}(k)$ = Nivel de fondo de la columna, en %.

$X_{11}(k) = Y(k-1)$ = Calidad del producto de fondo de la columna en el instante $t = t-1*\Delta t$

$X_{12}(k) = Y(k-2)$ = Calidad del producto de fondo de la columna en el instante $t = t-2*\Delta t$

$X_{13}(k) = Y(k-3)$ = Calidad del producto de fondo de la columna en el instante $t = t-3*\Delta t$

$X_{14}(k) = Y(k-4)$ = Calidad del producto de fondo de la columna en el instante $t = t-4*\Delta t$

En el caso de variables como la temperatura de fondo (que tiene un efecto directo en la calidad del producto de fondo de la columna) y la propia calidad del producto de fondo, estamos tomando valores pasados de las mismas, para alimentar a la red; básicamente porque son datos que tienen alto retardo frente a las otras variables del sistema que son en su mayoría mas rápidas.

De esta forma, el modelo del sistema sería de la forma:

$$Y_k = f(X_{1,k}; X_{2,k}; X_{3,k}; X_{4,k}; X_{5,k}; X_{6,k}; X_{7,k}; X_{7,k-1}; X_{7,k-2}; X_{10,k}; Y_{k-1}; Y_{k-2}; Y_{k-3}; Y_{k-4})$$

En el gráfico adjunto de la Fig. 3.3 se resaltan en cuadros rojos las variables de proceso que se tomaran para el entrenamiento de la red neuronal dinámica, usando entrenamiento tipo batch y con actualización de los pesos vía el método retropropagación dinámica de errores (DBP).

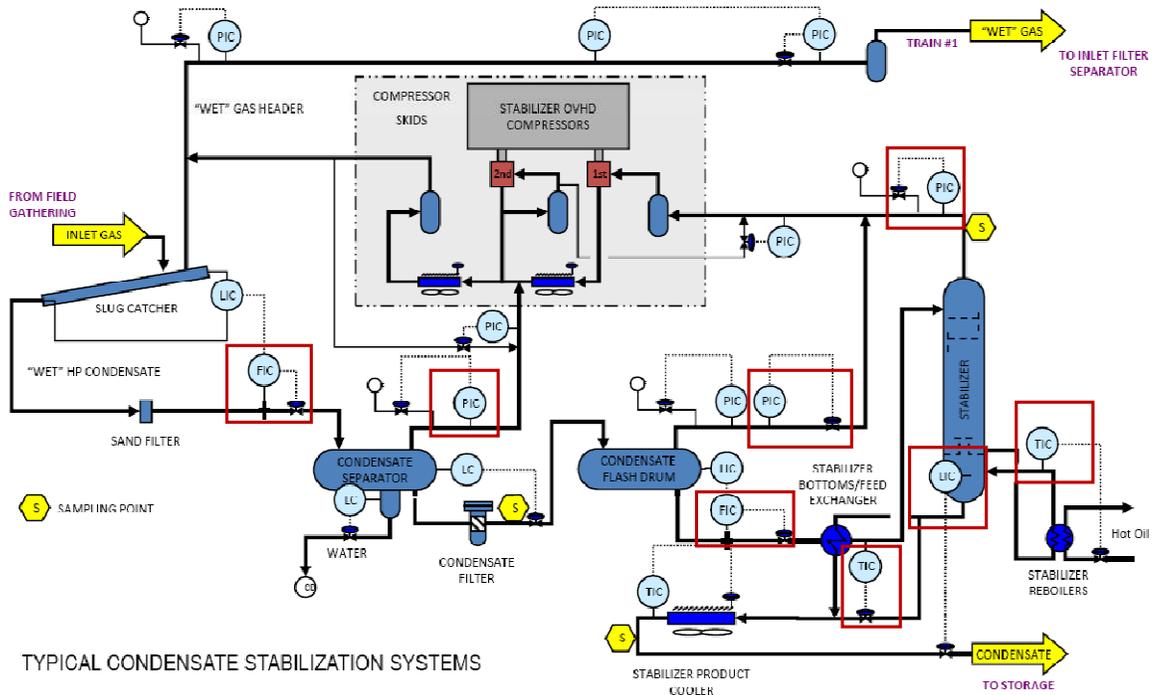


Fig. 3.3.- Variables a usarse para el entrenamiento de la red neuronal

3.2.3.1.- Esquema a Implementar en Matlab.-

En resumen haremos los siguientes pasos:

- **Acondicionamiento de los datos a usar para el entrenamiento :**

Para expresar los datos en números entre 0 y 1, para cada dato de entrada x_k ; una alternativa es el escalamiento lineal antes de entrenar:

$$X_{escalado} = 2 * \{ (X_{original} - X_{m\acute{a}x}) / (X_{m\acute{a}x} - X_{m\acute{i}n}) \} + 1$$

Y esta ecuación se origina al considera que el $X_{m\acute{a}x}$ en unidades escaladas equivale a +1 y el $X_{m\acute{i}n}$ en unidades escaladas equivale a -1. Con este escalamiento lineal se evita el riesgo de saturación de las funciones de activación y se acelera la convergencia de la red.

- **Asignación de pesos iniciales w_{jk} y W_{ij} :**

Los valores iniciales serán considerados aleatorios dentro de la estructura de programación que se empleará para el entrenamiento y validación de la red.

$$w_{jk} = K * randm(ne, nm)$$

$$W_{ij} = K * randm(nm, ns)$$

Donde:

K es un factor pequeño como 0.25; 0.50 ó 0.75.

$randm()$ es una función que genera un número aleatorio.

ne es el número de neuronas de la capa de entrada

nm es el número de neuronas de la capa intermedia
 ns es el número de neuronas de la capa de salida

- **Variación de la inclinación de la función de activación :**

Como trabajaremos con una estructura sigmoidea tipo 2 para la función de activación, a fin de evitar el fenómeno de saturación en la red, se pueden modificar las inclinaciones de estas funciones considerando que las mismas son de la forma genérica siguiente:

Sigmoidea Tipo 1:

$$y = \frac{1}{1 + e^{-\left(\frac{p}{a}\right)}}$$

Sigmoidea Tipo 2:

$$y = \frac{2}{1 + e^{-\left(\frac{p}{a}\right)}} - 1$$

Gausiana:

$$y = e^{-\left(\frac{p}{a}\right)^2}$$

Y ahora, en el algoritmo de cálculo se debe considerar que esta inclinación de las funciones Sigmoidea (para la función gausiana, se regula la abertura de la curva) se actualizará cada vez que se actualicen los pesos, siguiendo la ecuación:

$$a = a - \eta a \cdot \frac{\partial J}{\partial a}$$

Donde, ηa es el ratio de aprendizaje que uno fija en el desarrollo del proceso de cálculo y se recomienda que sea menor que el ratio de aprendizaje que se usa para la actualización de los pesos.

De forma similar a lo que sucede con los pesos de las capas de entrada y salida, esta inclinación también requiere un valor inicial que se especifica en 1. De esta forma, si no se desea variar dicha inclinación bastará con especificar $\eta a = 0$.

- **Uso del algoritmo DBP para el entrenamiento tipo Batch del sistema de red neuronal dinámico:**

Cuando se hayan cargado los datos al programa, en unidades de ingeniería y se haya realizado el escalamiento de los mismos, se realizará el ingreso de los ratios de aprendizaje. El sistema inicia entonces el proceso iterativo con los pesos iniciales del sistema. Especificaremos el número de neuronas de la capa intermedia, que será sólo 1 capa intermedia; así como el número de iteraciones y el error máximo que se tolerará.

La función a minimizar para una red neuronal dinámica será:

$$J = \frac{1}{2}(X_1 - \bar{X}_1)^2 + \frac{1}{2}(X_2 - \bar{X}_2)^2 + \dots + \frac{1}{2}(X_{k+1} - \bar{X}_{k+1})^2$$

Donde los X_{k+1} son los valores estimados por las subredes neuronales que se establecen en el método y los \bar{X}_{k+1} son los datos reales.

Recordar que la estructura neuronal dinámica es de la forma: $X_{k+1} = f(X_k, X_{k-1}, X_{k-2} \dots)$

Debido al uso del método DBP con entrenamiento tipo Batch para un sistema de red neuronal, el cálculo de las derivadas se hace considerando:

$$\frac{\partial J}{\partial w} = (X_1 - \bar{X}_1) \frac{d\bar{X}_1}{dw} + (X_2 - \bar{X}_2) \frac{d\bar{X}_2}{dw} + \dots + (X_{k+1} - \bar{X}_{k+1}) \frac{d\bar{X}_{k+1}}{dw}$$

$$\frac{\overline{dJ}}{d\overline{w}} = \sum_{K=0}^n (X_{k+1} - \overline{X}_{k+1}) \frac{d\overline{X}_{k+1}}{d\overline{w}}$$

$$\frac{\overline{dJ}}{d\overline{w}} = (X_1 - \overline{X}_1) \frac{d\overline{X}_1}{d\overline{w}} + (X_2 - \overline{X}_2) \frac{d\overline{X}_2}{d\overline{w}} + \dots + (X_{k+1} - \overline{X}_{k+1}) \frac{d\overline{X}_{k+1}}{d\overline{w}}$$

$$\frac{\overline{dJ}}{d\overline{w}} = \sum_{K=0}^n (X_{k+1} - \overline{X}_{k+1}) \frac{d\overline{X}_{k+1}}{d\overline{w}}$$

Donde n es el número de subredes neuronales o número de conjunto de datos reales que se usan en el entrenamiento y las derivadas se calculan según .

$$\frac{d\overline{X}_{k+1}}{d\overline{w}} = \frac{dX_{k+1}}{dw} + \frac{dX_{k+1}}{dX_k} \cdot \frac{d\overline{X}_k}{d\overline{w}}$$

$$\frac{d\overline{X}_{k+1}}{d\overline{w}} = \frac{dX_{k+1}}{dW} + \frac{dX_{k+1}}{dX_k} \cdot \frac{d\overline{X}_k}{d\overline{w}}$$

Y luego de obtener las derivadas parciales totales, se actualizan los pesos según:

$$W_{ij} = W_{ij} - \eta \cdot \frac{d\overline{J}}{dW_{ij}}$$

$$w_{jk} = w_{jk} - \eta \cdot \frac{d\overline{J}}{dw_{jk}}$$

Debe notarse que al hacer una primera iteración, se hace un recorrido por todas las subredes neuronales que se habrán establecido, en un número igual al número de conjunto de datos que se tiene. Esto para obtener las derivadas de la función de costo respecto de los pesos.

Luego, al término de todo el recorrido por las subredes, se hace una actualización de los pesos y se inicia la siguiente iteración. Es así que el número de subredes neuronales lo determina el número de datos, y el proceso iterativo se hace según el número de iteraciones que especificamos, deteniéndose únicamente al completar el total de iteraciones pedidas o si se ha alcanzado el objetivo de error especificado (valor de la función de costo a minimizar).

El entrenamiento es del tipo batch ya que los pesos se actualizan luego de haber realizado un barrido completo a través de todas las subredes y haber calculado las derivadas.

3.2.4.- Generación de Datos para el Entrenamiento y Validación del Sistema de Red Neuronal Artificial (RNA) Dinámica

Para la generación de datos para el entrenamiento, someteremos a cada una de las variables que forman parte del modelo, a perturbaciones a través de manipulación en los set point de los controladores de proceso y en algunos casos a través de manipulación directa de las aperturas de las válvulas de control.

El objetivo es generar suficientes cambios en las variables de la red neuronal para que esta "aprenda" y guarde ese conocimiento adquirido en el entrenamiento para futuras validaciones del proceso y estimaciones de la calidad del producto de fondo.

Algunas de las variables que alimentan a la red neuronal no requieren alguna manipulación específica porque estas cambian con la perturbación de alguna otra. Por ejemplo, ante perturbaciones en la presión del separador de entrada y en el separador intermedio, se presenta alteración en el flujo de entrada a la columna así como en la temperatura. Esta combinación de valores y la interacción entre sí, alimentan a la red neuronal dinámica y le permite “descubrir y aprender” la relación matemática que existe entre estas variables. Muchos de los cambios se efectúan de forma simultánea, pero para efectos de facilitar su entendimiento se presentan agrupadas en los siguientes gráficos (Ver Fig. 3.4 y Fig. 3.5):

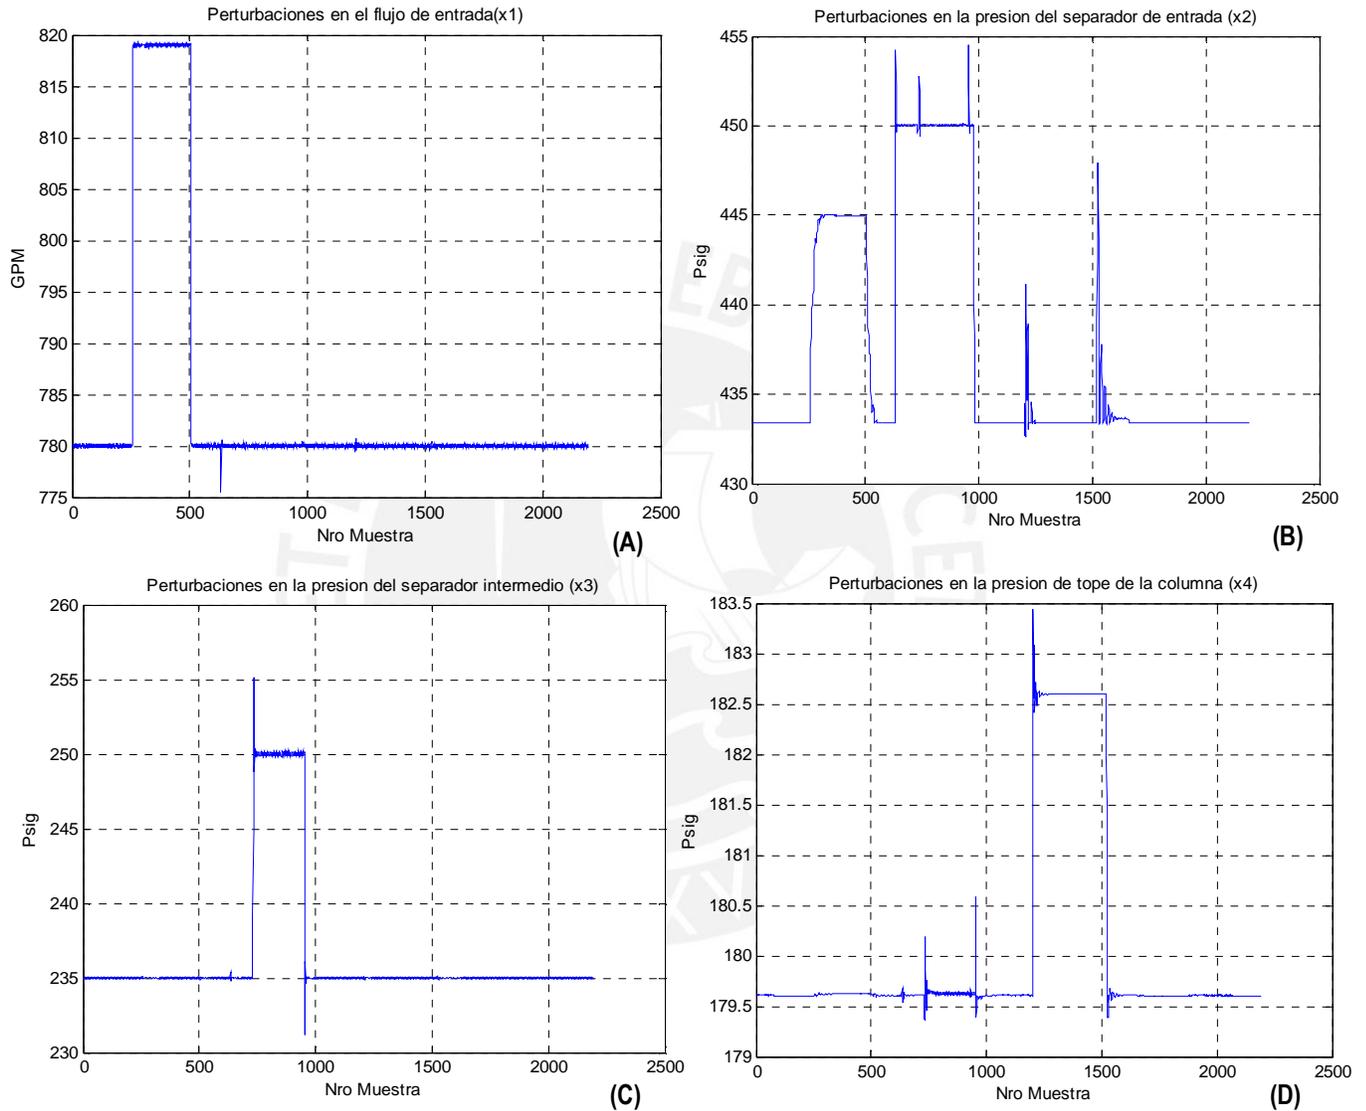


Fig. 3.4.- Perturbaciones en las Variables X1, X2, X3 y X4

En las Fig. 3.4 (A), (B), (C) y (D) se muestran las perturbaciones que se realizaron sobre las variables de proceso del sistema: flujo de entrada al sistema, cambios en presión del separador de entrada, presión en el separador intermedio, así como cambios en la presión de la columna.

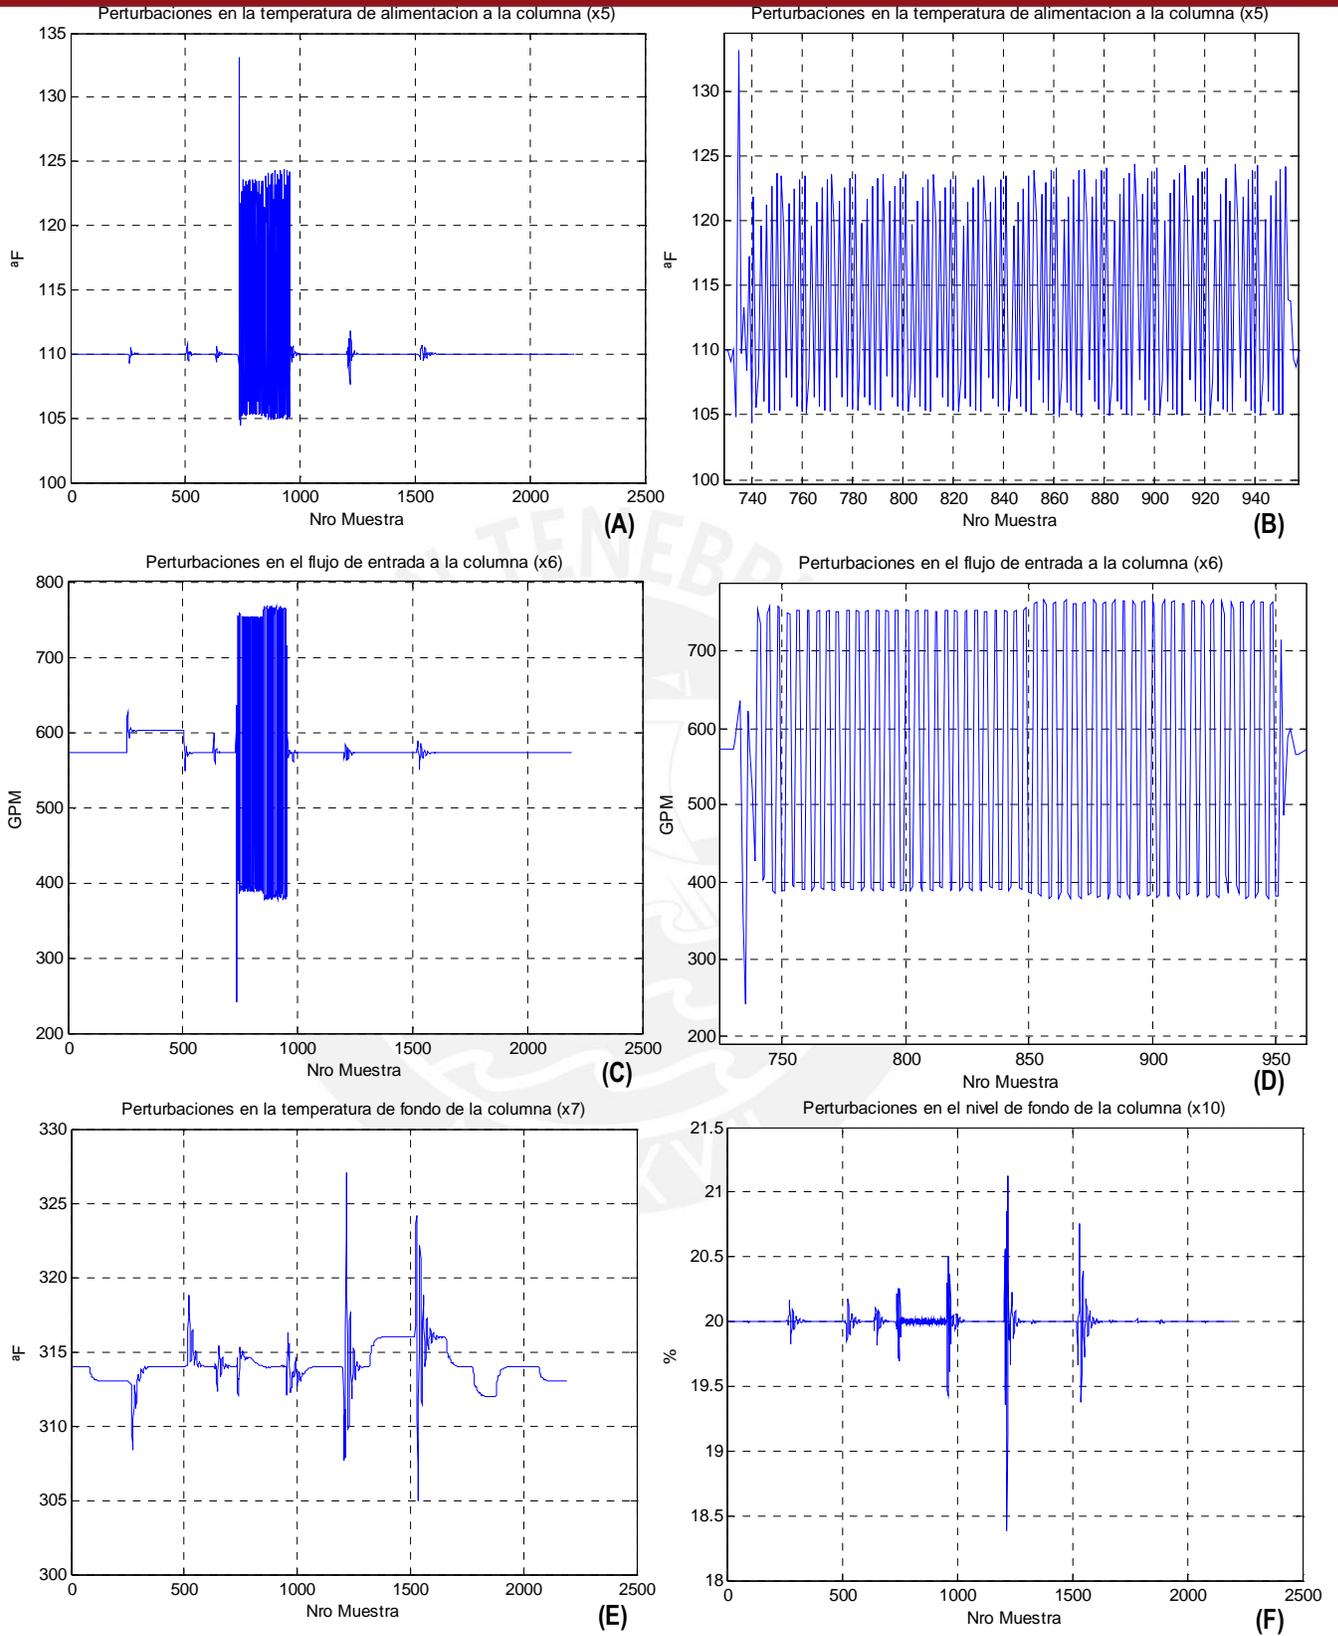


Fig. 3.5.- Cambios en las Variables X5, X6, X7 y X10

En los gráficos de la Fig. 3.5 (A), (C), (E) y (F) se muestran el comportamiento de otras variables de proceso, ante las perturbaciones que se establecieron sobre el sistema, como se mostró en la Fig. 3.4. Las subgráficas (B) y (D) son ampliaciones del comportamiento de la variable mostrada en las subgráficas (A) y (C) que son la temperatura de entrada a la columna y el flujo de alimentación a la misma y que tienen una dependencia fuerte de los cambios en la presión del separador de entrada y separador intermedio, como se evidenció en los gráficos de la Fig. 3.4 (B) y (C).

Asimismo, en la Fig. 3.6 mostraremos la evolución de la calidad del producto de fondo de la columna, durante las perturbaciones que se establecieron en el sistema.

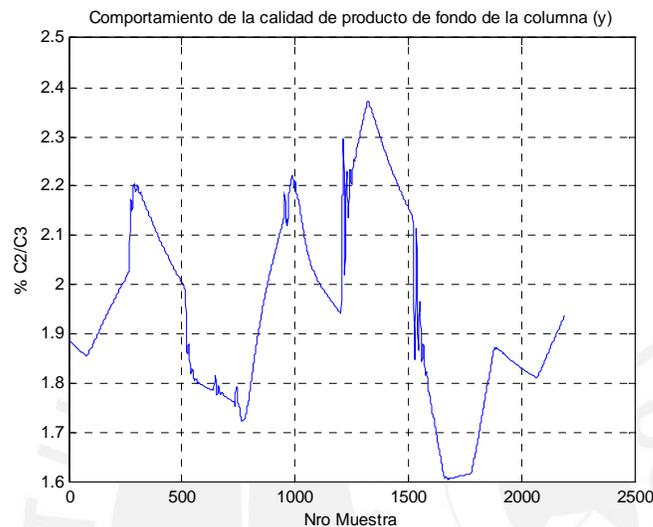


Fig. 3.6.- Evolución de la Calidad del Producto de Fondo de la Columna durante las Perturbaciones

Como se mencionó antes, durante las perturbaciones que se presentaron en las variables de la Fig. 3.4, se fue registrando el comportamiento de las variables de las Fig. 3.5 y 3.6. Los lazos de control de nivel, presión y temperatura de fondo de la columna estuvieron en servicio, con cambios en los set point de tal forma de tratar de mantener la especificación límite de calidad del producto de fondo de 2% expresado como % C2/C3.

Se observa por ello el comportamiento de la variable X7 (Temperatura de fondo de la columna) que a lo largo del procedimiento de generación de perturbaciones y registro de variables, que se ha mantenido oscilando, siguiendo diversos valores de set point.

Uno de los objetivos que se persiguió a lo largo del proceso de generación de perturbaciones fue de tratar de mantener el producto de fondo en especificación: $0 < \% C2/C3 < 2$ usando el lazo de control de temperatura de fondo de la columna de destilación (variable X7) y se evidenció que no siempre fue posible cumplir tal objetivo.

3.3.- Entrenamiento y Validación de la Red Neuronal Artificial Dinámica del Sistema

3.3.1.- Resultados de la Estimación de la Calidad del Producto de Fondo de la Columna de Destilación Multicomponentes Durante el Entrenamiento de la Red Neuronal Dinámica

Usando el programa del Anexo 1 se probaron distintas alternativas para el entrenamiento. El diagrama de la Fig. 3.7 adjunta, resume la secuencia de pasos seguidos por el programa usado para el entrenamiento.

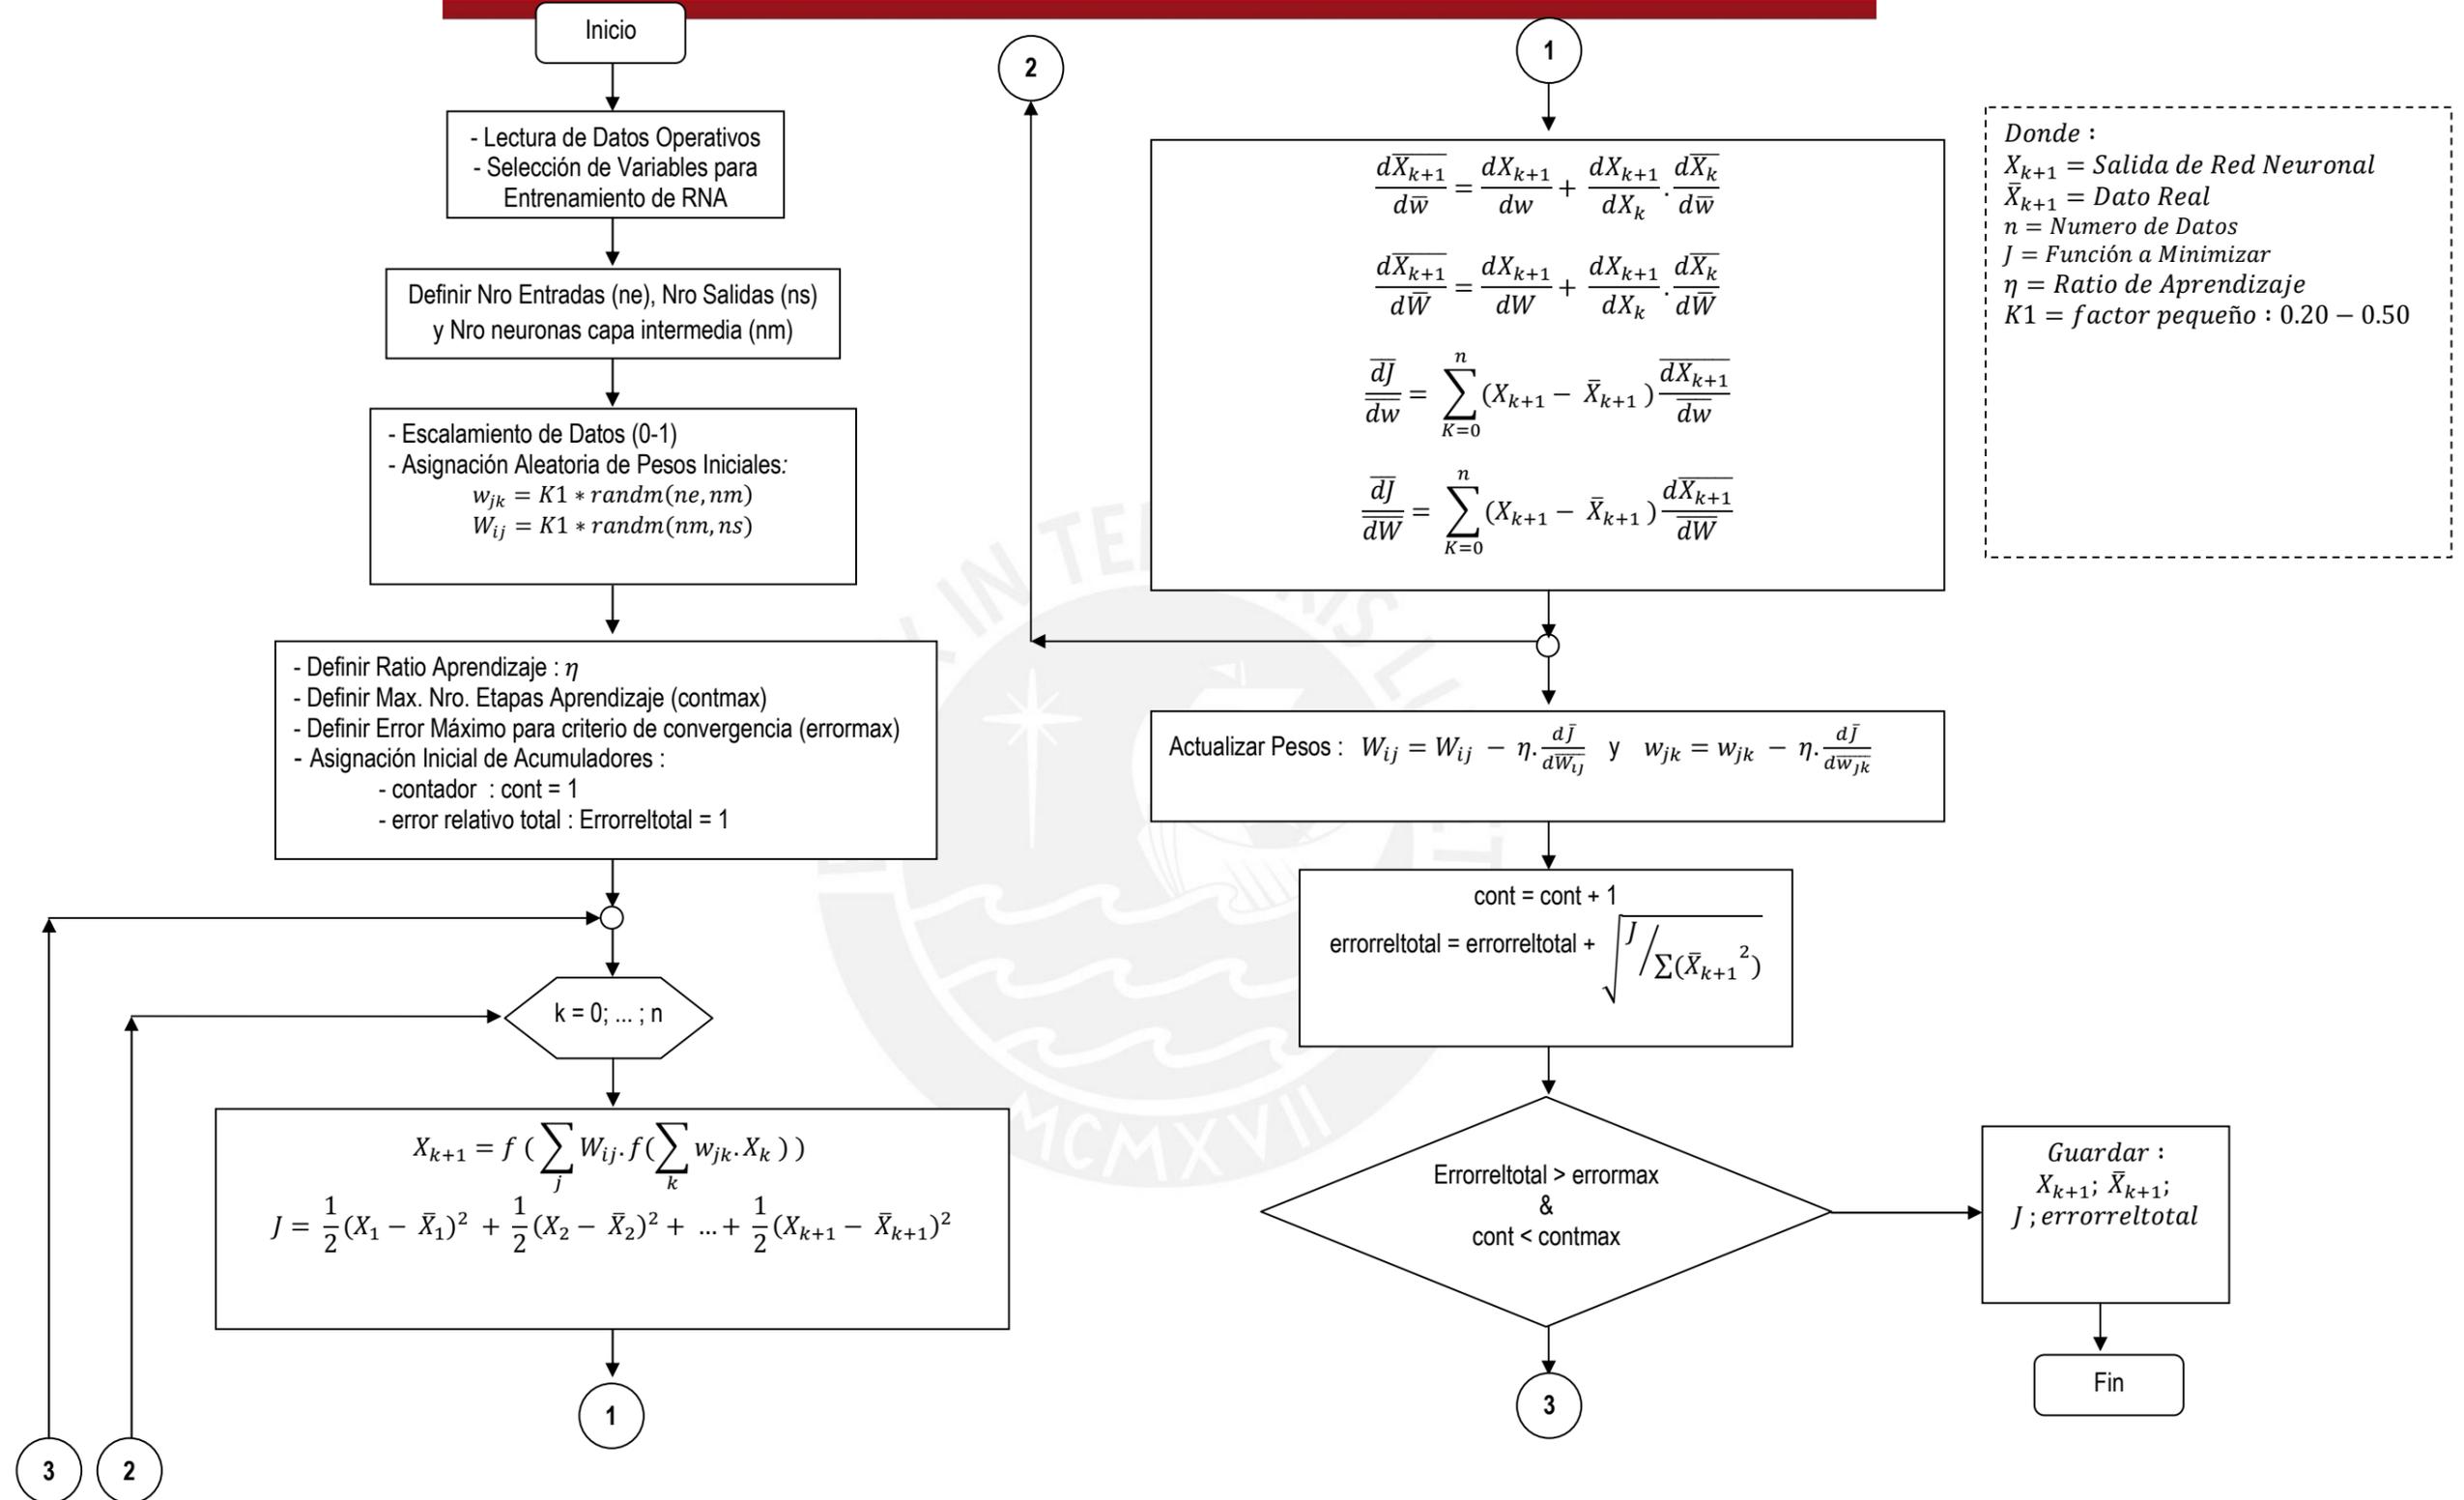


Fig. 3.7.- Diagrama de Flujo del Programa de Entrenamiento de la Red Neuronal Artificial Dinámica Implementada en Matlab

Las características que forman parte de la arquitectura de la red neuronal creada, son las siguientes:

- Red Neuronal Dinámica con Entrenamiento tipo Batch y método DBP para el cálculo de los pesos.
- Tratamiento de datos : Normalizados los datos de entrada y salida (valores entre 0 y 1)
- Ratio de aprendizaje: 0.1
- Número de capas intermedias de neuronas: 1
- Número de neuronas en la capa de entrada: 15 (consideramos realimentar la variable de salida incluso)
- Número de neuronas de capa intermedia: 15.
- Número de neuronas de capa salida: 1 (la calidad del producto de fondo)
- Función de activación: sigmoidea tipo 2.
- Número de patrones (conjunto de datos) para el entrenamiento : 2191
- Error máximo a considerar : 1%
- Número máximo de iteraciones o etapas de aprendizaje: 10,000.
- Neurona bias : 0 (No se considera el uso de neurona bias)

La función de costo a minimizar es la suma de errores al cuadrado (entre los valores de salida de red y el valor deseado) y el término error en el programa desarrollado es la raíz cuadrada de estos errores al cuadrado, a fin de darle un mejor sentido al error porcentual; y con una adaptación particular que nos hace expresarlo como error relativo, ya que es el error total al cuadrado respecto del total de salidas deseadas al cuadrado. Esto es :

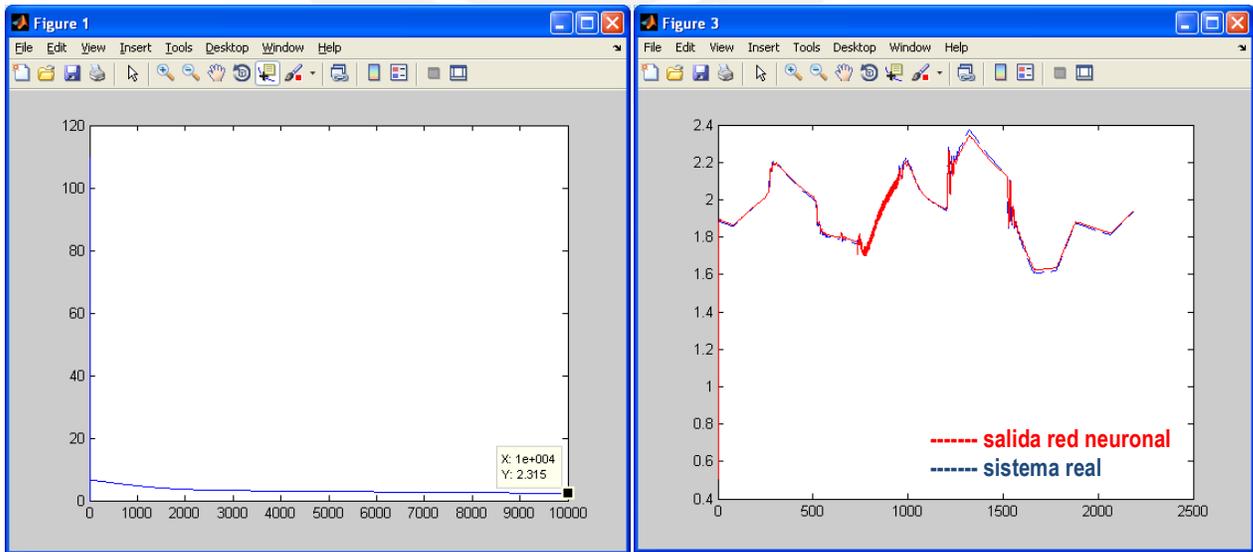
$$errorreltotal = \text{sqrt} \left(\frac{\sum (y_{i,RNA} - y_{i,real})^2}{\sum y_{i,real}^2} \right)$$

Y de las alternativas que se probaron, se obtuvieron los siguientes resultados:

Caso 1.- Entrenamiento sin efecto de inclinación de la sigmoidea y error relativo total máximo de 2%

La Fig. 3.8 (A) muestra el decaimiento del error relativo total, que alcanzó un error de 2.315 % al completar las 10,000 iteraciones. La Fig. 3.8 (B) muestra la comparación entre la salida de la red neuronal ya “de-escalada” y llevada a sus unidades de ingeniería (rojo) vs la salida real del sistema (azul).

```
Introducir ratio de aprendizaje : 0.1
Introducir ratio de aprendizaje de inclinacion a : 0
Introducir el valor maximo del error (%) : 2
Introducir el maximo numero de etapas de aprendizaje : 10000
```



(A) (B)
Fig. 3.8.- Entrenamiento Sin Efecto de Inclinación de Sigmoidea y Error Relativo Total Máximo 2%

Probaremos algunas variaciones en el entrenamiento a fin de disminuir el error relativo total que alcanza el sistema.

Caso 2.- Entrenamiento con efecto de inclinación de la sigmoidea y error relativo total máximo de 1%

La Fig. 3.9 (A) muestra el decaimiento del error relativo total, que alcanzó un error de 2.025 % al completar las 10,000 iteraciones. La Fig. 3.9 (B) muestra la comparación entre la salida de la red neuronal (rojo) vs la salida real del sistema (azul).

```
Introducir ratio de aprendizaje : 0.1
Introducir ratio de aprendizaje de inclinacion a : 0.01
Introducir el valor maximo del error (%) : 1
Introducir el maximo numero de etapas de aprendizaje : 10000
```

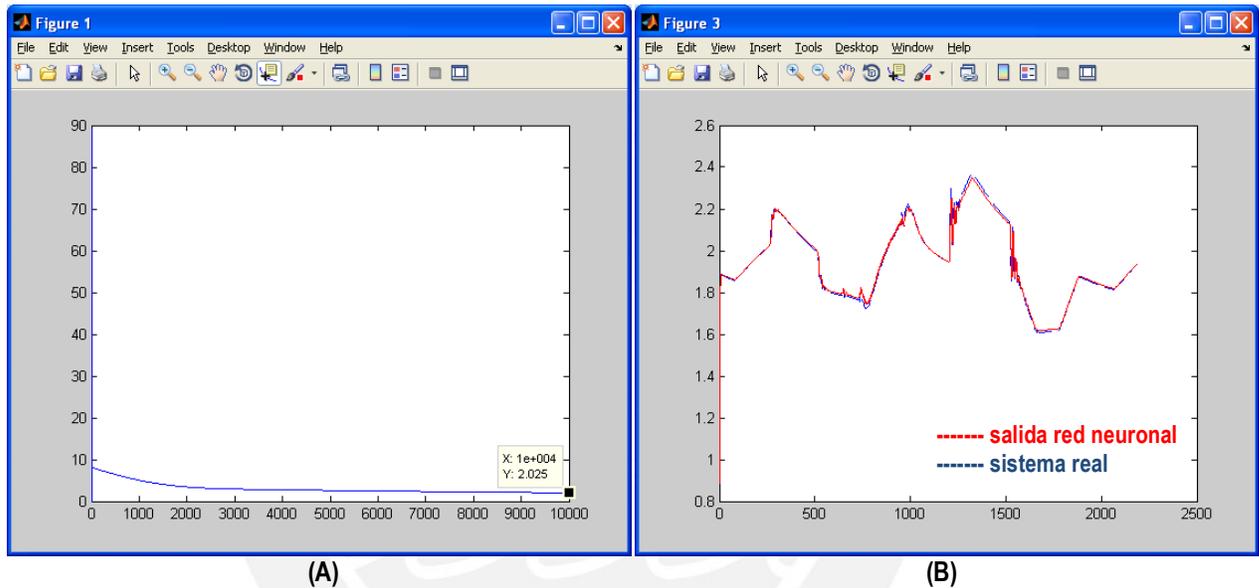


Fig. 3.9.- Entrenamiento Con Efecto de Inclinación de Sigmoidea y Error Relativo Total Máximo 1%

Caso 3.- Entrenamiento con efecto de inclinación de la sigmoidea y error relativo total máximo de 1%

El error relativo total alcanzó un error de 1.978 % al completar las 10,000 iteraciones. La Fig. 3.10 (B) muestra la comparación entre la salida de la red neuronal (rojo) vs la salida real del sistema (azul).

```
Introducir ratio de aprendizaje : 0.1
Introducir ratio de aprendizaje de inclinacion a : 0.05
Introducir el valor maximo del error (%): 1
Introducir el maximo numero de etapas de aprendizaje : 10000
```

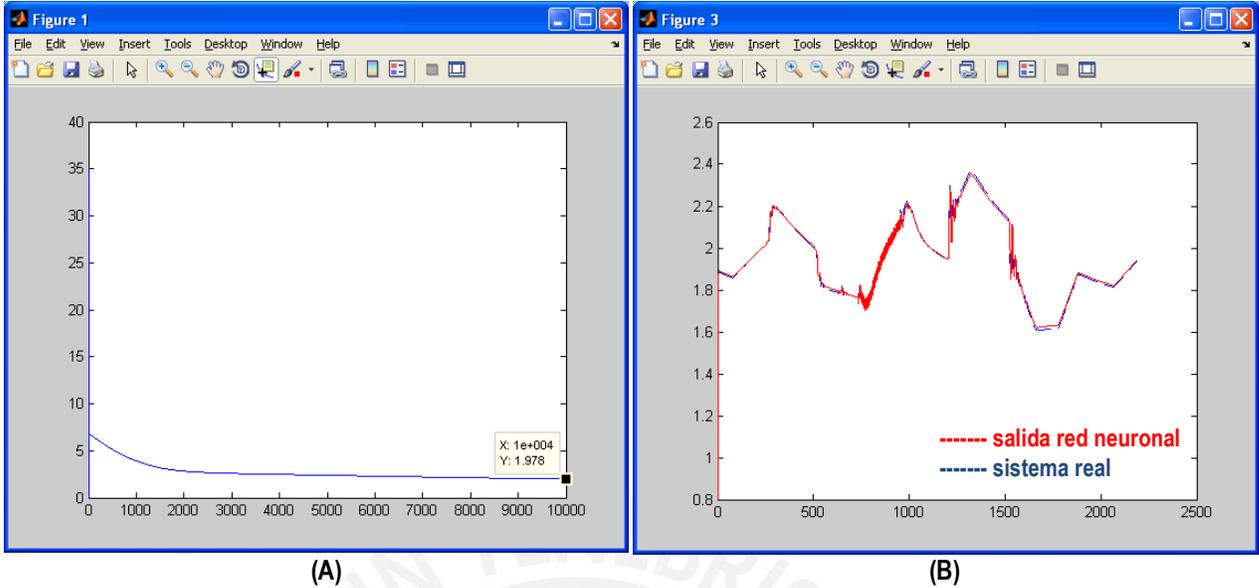


Fig. 3.10.- Entrenamiento Con Efecto de Inclínación de Sigmoidea y Error Relativo Total Máximo 1%

Sin embargo, como vemos que el error relativo no ha sufrido una disminución muy importante, repetimos el entrenamiento desde este punto, considerando como punto de partida los pesos que se han alcanzado hasta este momento (Ver Fig. 3.11). Esto es añadir una etapa de entrenamiento adicional, con las mismas consideraciones. Obtenemos entonces:

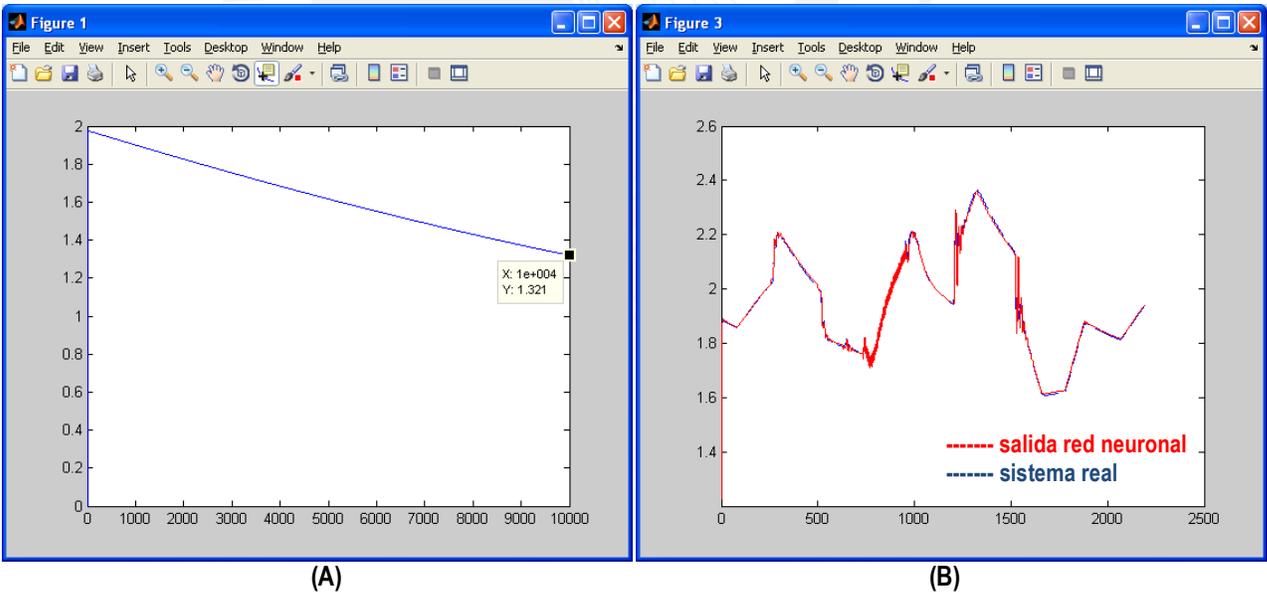


Fig. 3.11.- Entrenamiento Con Efecto de Inclínación de Sigmoidea y Error Relativo Total Máximo 1% (2 Etapas de Entrenamiento Total)

Entonces, se evidencia que esta etapa adicional de entrenamiento permitió reducir el Error Relativo Total hasta un 1.321 % como lo muestra la Fig. 3.11 (A).

Y finalmente realizamos una tercera etapa de entrenamiento, con las mismas consideraciones y el error relativo máximo disminuye hasta valores de 0.9584 %, como se evidencia en la Fig. 3.12 (A). La superposición entre los valores reales y los estimados por el sistema de red neuronal dinámica se mantienen, como lo evidencia la Fig. 3.12 (B), en la cual tenemos la comparación entre la salida de la red neuronal en color rojo, frente a la salida real del sistema en color azul.

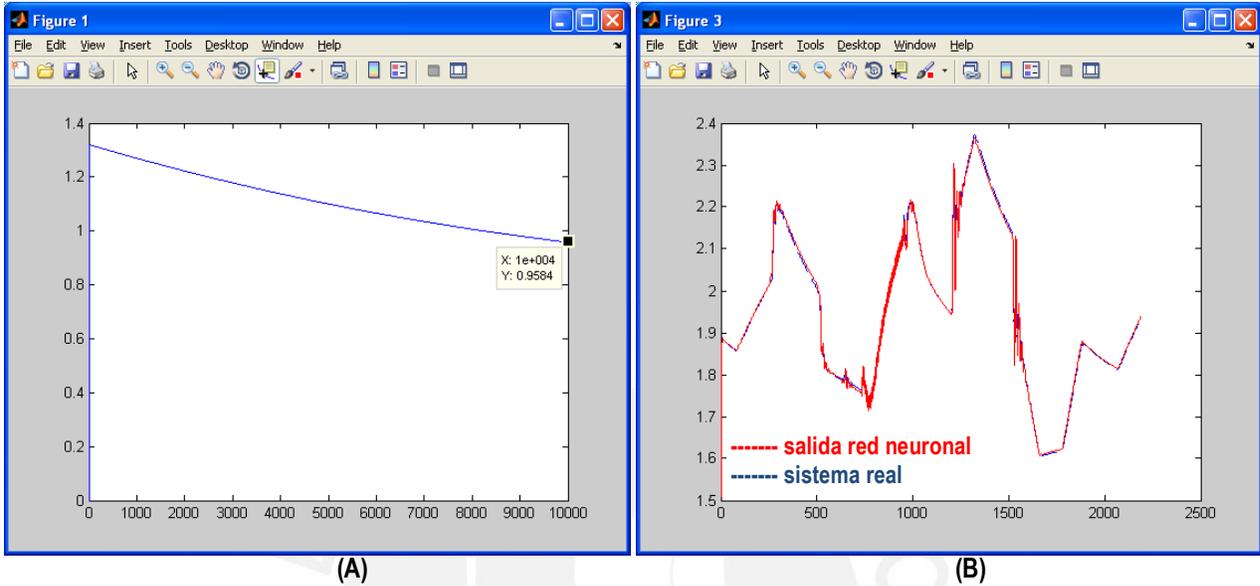


Fig. 3.12.- Entrenamiento Con Efecto de Inclinaación de Sigmoidea y Error Relativo Total Máximo 1% (3 Etapas de Entrenamiento Total)

En resumen, para el entrenamiento de los 2191 conjuntos de datos, tenemos los resultados en la Tabla 3.1 adjunta:

Tabla 3.1.- Resumen del Entrenamiento de la Red Neuronal Artificial Dinámica

Caso	Ratio aprendizaje para sigmoidea 2	Error relativo total, %	Tiempo del entrenamiento, min	Nro veces que se entrena el sistema
1	0	2.315	25	1
2	0.01	1.978	35	1
3	0.05	0.958	45	3

En todos los casos se consideró:

Número de neuronas en capa intermedia = 15

Número máximo de iteraciones (etapas de aprendizaje) = 10,000

Ratio de aprendizaje para actualización de los pesos = 0.1

Ahora veremos la robustez del modelo de red neuronal dinamiza que ya se encuentra entrenado cuando lo sometemos a un comportamiento de planta distinto al usado para el entrenamiento. Este proceso conocido como Validación lo mostraremos a continuación.

3.3.2.- Validación de la Red Neuronal Artificial (RNA) Dinámica

Para realizar la validación de la red neuronal dinámica se generó datos con las mismas variables seleccionadas para el entrenamiento, pero se sometió al proceso a condiciones de operación diferentes a fin de exigir a la red neuronal ya entrenada y determinar el nivel de precisión que podrá entregar.

Los datos usados para la validación fueron los que se muestran a continuación en las Fig. 3.13 y Fig.3.14.

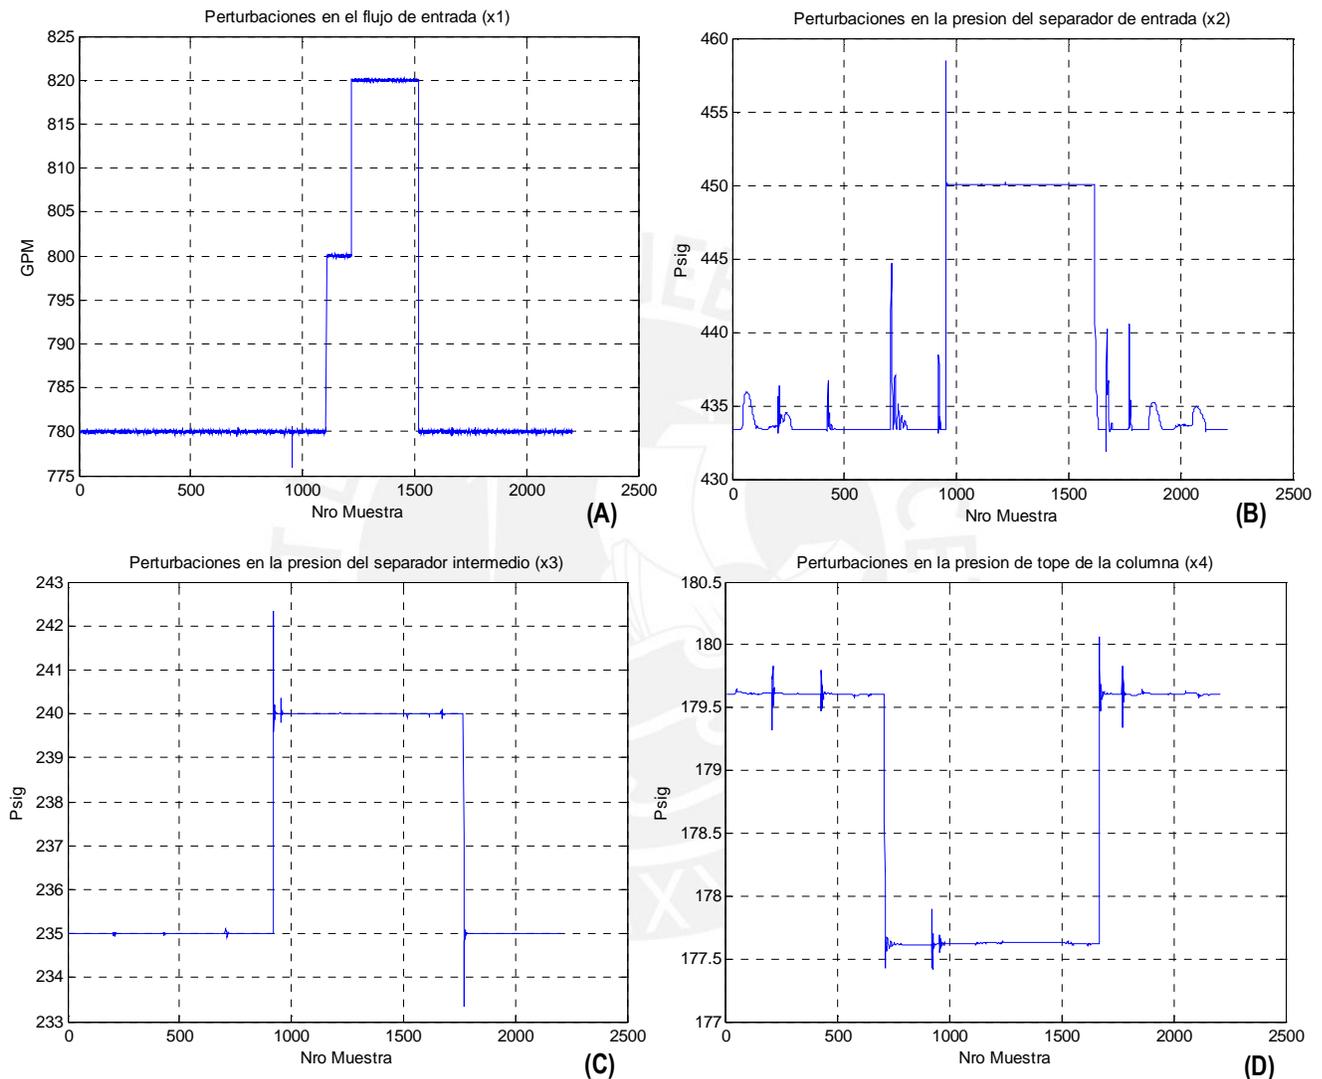


Fig. 3.13.- Perturbaciones en las Variables X1, X2, X3 y X4

Conforme a lo mencionado líneas arriba, las graficas de la Fig. 3.13 (A), (B), (C) y (D) muestran perturbaciones sobre las mismas variables de proceso que las usadas para el Entrenamiento de la red neuronal artificial, pero en magnitud diferente y ejecutadas en intervalos de tiempo distinto también. Para evidenciar esta situación, se pueden comparar con las gráficas de la Fig. 3.4 (A), (B), (C) y (D).

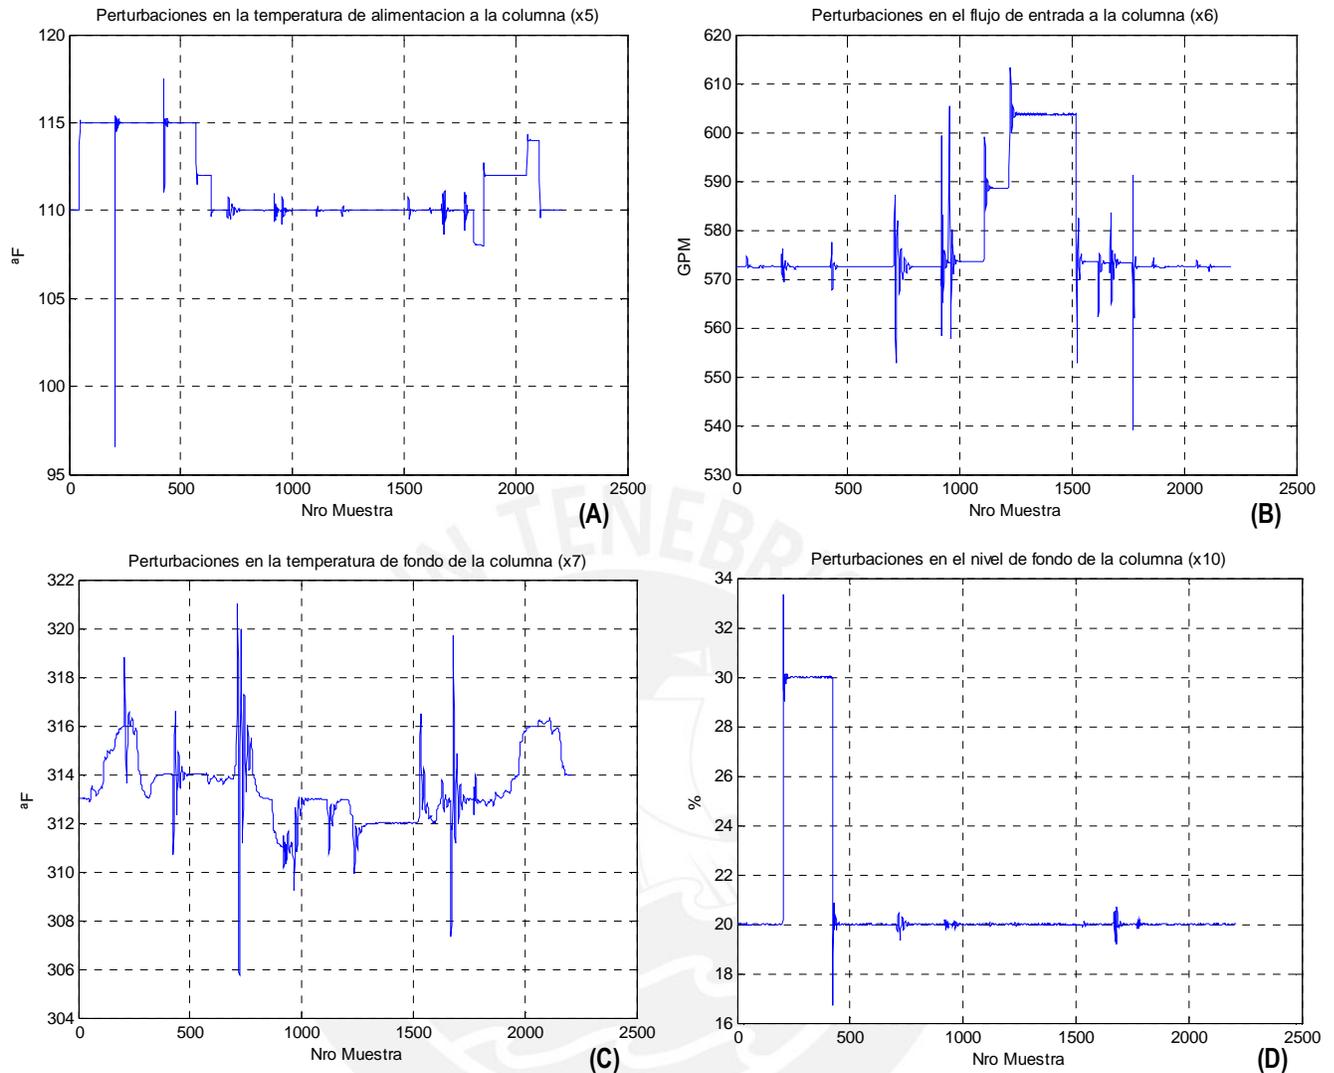


Fig. 3.14.- Cambios en las Variables X5, X6, X7 y X10

De forma diferente a lo sucedido durante el entrenamiento de la red neuronal artificial, ahora para las variables X5 y X6, que representan la temperatura y caudal de entrada a la columna respectivamente; se crearon perturbaciones específicas (Ver Fig. 3.14 (A) y (B)) a fin de obtener comportamiento diferente del sistema durante el Entrenamiento y evaluar si el Estimador Neuronal puede predecirlo. Situación similar se desarrolló para el nivel de fondo de la columna (Ver Fig. 3.14 (D)).

Sin embargo, de forma similar a lo realizado antes, la temperatura de fondo representada por la variable X7 se fue ajustando tratando de mantener la relación de calidad C2/C3 por debajo del límite de 2% (Ver Fig. 3.14 (C)).

A continuación, en la Fig. 3.15, se muestra el comportamiento de la calidad del producto de fondo de la columna de destilación durante las perturbaciones a las condiciones de operación del sistema.

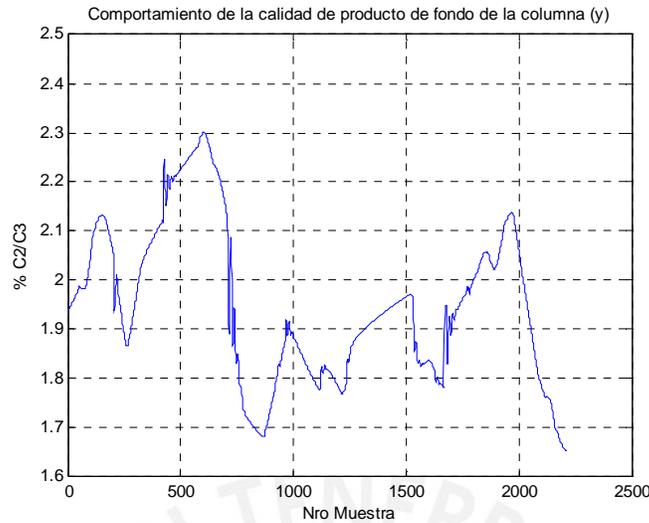


Fig. 3.15.- Evolución de la Calidad del Producto de Fondo de la Columna durante las Perturbaciones

Y si realizamos una comparación entre la calidad de producto de fondo de la columna con la que se hizo el entrenamiento, frente a la calidad que se usara para la validación tenemos el gráfico de la Fig. 3.16.

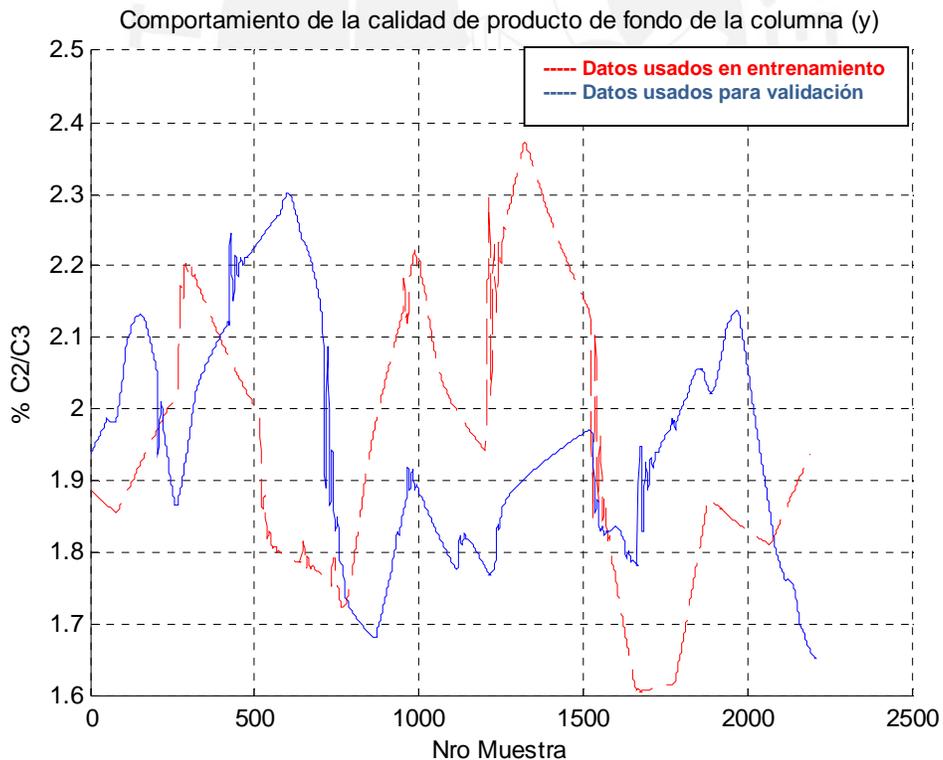


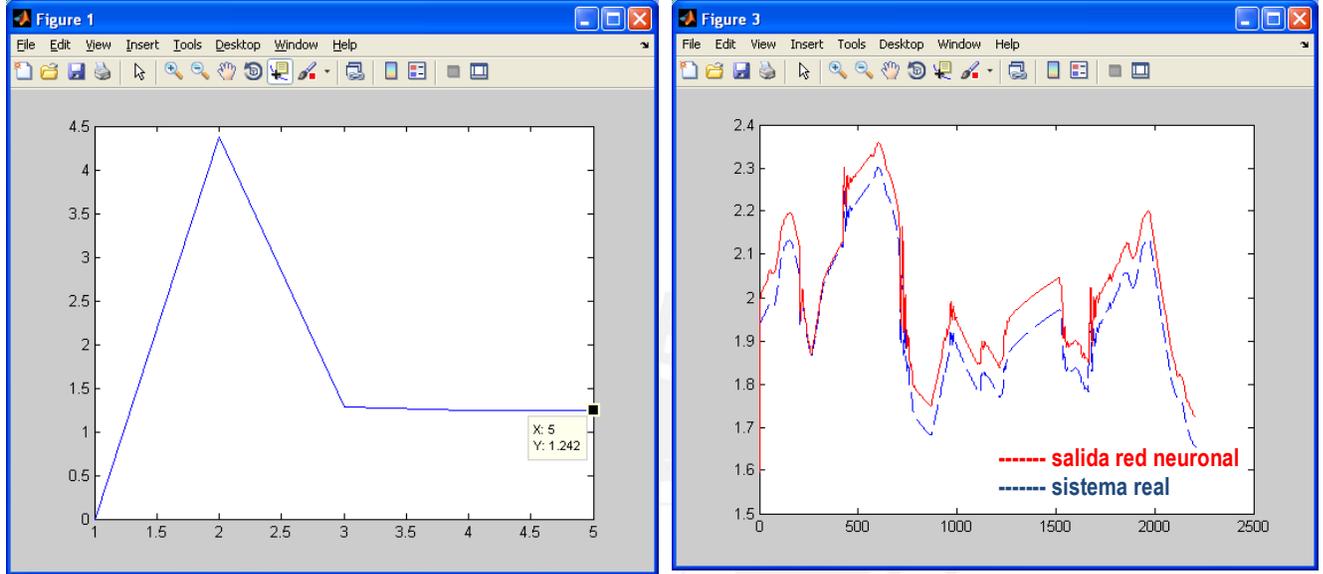
Fig. 3.16.- Calidad del Producto de Fondo de la Columna durante el Entrenamiento y Validación

Los datos en color rojo son los datos de calidad usados para el entrenamiento de la red y que vimos que el sistema neuronal dinámico pudo aproximar con un error relativo acumulado del orden de 0.9584%. Los datos en color azul son los datos de calidad que se le pedirá a la red que valide.

Al usar el programa del Anexo 2 para la validación de los datos obtenemos el siguiente resultado para la Validación (Ver Fig. 3.17 y Fig. 3.18):

```

Introducir ratio de aprendizaje : 0.1
Introducir ratio de inclinación a : 0
Introducir el valor maximo del error (%) : 0
Introducir el maximo numero de etapas de aprendizaje : 5
    
```



(A) (B)
Fig. 3.17.- Resultados de la Validación del Estimador Neuronal

La Fig. 3.17 (A) nos muestra el error relativo del sistema de red neuronal de 1.2 % y en la Fig. 3.17 (B) obtenemos en color rojo la calidad estimada por la red neuronal y en color azul la calidad real del sistema. En la Fig. 3.17 mostramos algunos de los puntos de mayor divergencia.

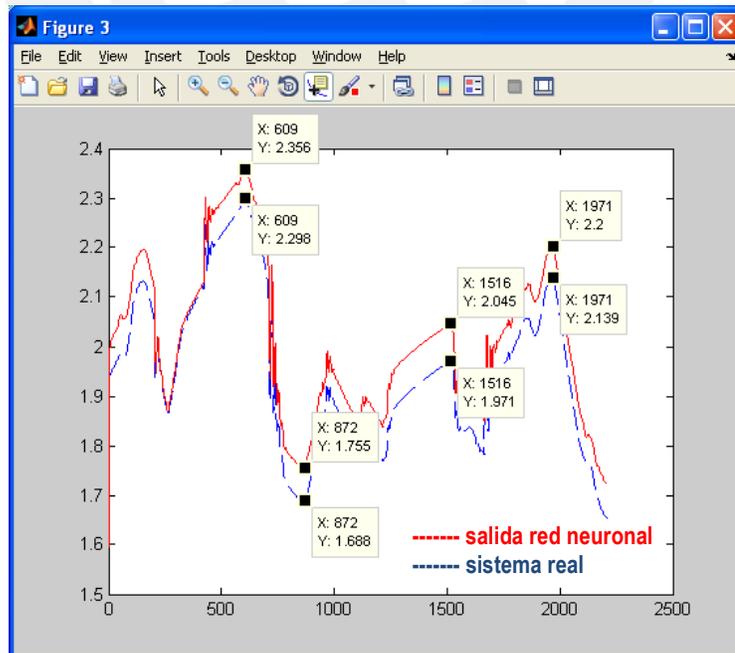


Fig. 3.18.- Divergencias Alcanzadas durante la Validación del Estimador Neuronal

Y vemos entonces, en la Fig. 3.18, que los valores estimados siguen la misma tendencia que los valores reales y si bien la diferencia de valores en los picos de mayor diferencia, alcanzan valores de hasta un 4% (estimado respecto del real), en realidad son valores muy similares que redondeados al primer decimal podrían considerarse prácticamente lo mismo.

Un aspecto importante a mencionar es que respecto del tiempo que le tomó al sistema entrenarse, para la validación de los 2207 conjuntos de datos que se disponía, al sistema le tomó cerca de 10 seg el entregar el total de los datos estimados.

Con este resultado, vemos que a pesar de haber sometido a la red neuronal dinámica a un entrenamiento con datos bastante diferentes a los usados para su validación, reproduce con una precisión bastante aceptable las relaciones matemáticas que existen entre las variables del modelo, por lo que veremos de usar los valores estimados dentro de una estructura de control que propondremos a continuación.



de calidad. Debido a las posibles perturbaciones que se pueden presentar en el flujo de aceite térmico y por la dinámica del proceso, se propone establecer un esquema de control en cascada, entre el controlador de calidad (lazo primario) y el controlador de flujo de aceite térmico (lazo secundario).

Controlador de Calidad AIC :

El controlador AIC que se propone implementar será un controlador tipo P+I con estructura de algoritmo de velocidad (PID Velocity Form) :

$$u(t) = u(t - 1) + Kc \left[e(t) - e(t - 1) + \frac{h}{Ti} e(t) - \frac{Td}{h} (pv(t) - 2pv(t - 1) + pv(t - 2)) \right]$$

Donde :

- 1.- $u(t)$ = Señal de control en el instante t
- 2.- $u(t - k)$ = Señal de control k periodos de tiempo antes
- 3.- $e(t)$ = Señal del error en el instante t
- 4.- $e(t - k)$ = Señal del error k periodos de tiempo antes
- 5.- $pv(t - k)$ = Señal de la variable de proceso k periodos de tiempo antes
- 6.- Kc, Ti y Td = Son los parámetros del controlador
- 7.- h = periodo de muestreo

Para evaluar el comportamiento del controlador, fijaremos los siguientes parámetros:

Modo de Acción del Controlador AIC sobre la válvula de control : Acción Directa

PVmin = 0.01 %C2/C3

PV max = 2.5 %C2/C3

h = 20 seg (periodo de muestreo)

Kc = 0.1

Ti = 0.2

Set Point = 1.9 %C2/C3 (Debido a que la salida del estimador inferencial basado en red neuronal entrega la señal de proceso al controlador, y dado que queremos maximizar la producción, fijamos un valor de 1.9 que como vimos en secciones anteriores, se corresponde a un valor del orden de 2% de C2/C3)

Estamos seleccionando un algoritmo de velocidad básicamente porque su implementación en un sistema DCS real permitiría aprovechar una estructura que en lugar de ejercer la acción de control basada en el error, lo haría en función a los cambios en el error (desde su valor anterior hasta el valor actual), y en lugar de establecer directamente los nuevos valores para la salida del controlador, estos algoritmos de velocidad aplican incrementos o decrementos a los valores previos de salida del controlador para alcanzar los nuevos valores.

Otra ventaja de estos algoritmos de velocidad, es que de forma inherente permiten transferencias sin sobresaltos para el cambio de manual a automático (Bumpless manual-auto transfer), así como para el cambio de parámetros del controlador (Bumpless tuning).

Controlador de flujo de aceite térmico FIC :

Considerando que pudieran producirse perturbaciones en el flujo de aceite térmico se considera la adición de un elemento de medición de flujo tipo placa de orificio y un transmisor de flujo que permita establecer una estructura de control de flujo por retroalimentación.

La estructura del controlador FIC sería como la del controlador AIC descrito líneas arriba (PID velocity form). Los parámetros a fijar son los siguientes:

Modo de Acción del Controlador FIC sobre la válvula de control : Acción Inversa

$h = 20$ seg (periodo de muestreo)

$K_c = 0.3$ (ganancia del controlador)

Ahora se puede establecer una estructura de control tipo cascada en la que el lazo primario sea el controlador de calidad y el secundario el lazo de control de flujo de aceite térmico. Y la estructura de control override sería como se mostró en la Fig. 3.10. Esto es, las señales de salida de los controladores AIC y de temperatura de fondo TIC se comparan y el menor valor pedido en el sistema será el set point remoto que se establece en el lazo secundario de control de flujo de aceite térmico.

Para esta estructura, y dado que queremos evitar que la temperatura de fondo se incremente demasiado por algún problema con el controlador de calidad, se establecerá como set point del TIC un valor sobre el cual no queremos excedernos. Este set point se establece considerando la relación que se estudio en el capítulo 2 para la calidad del producto de fondo vs temperaturas de fondo para distintos niveles de presión. Es así que el set point del TIC quedaría fijado en 335 °F.

Se mostrará en breve el comportamiento del sistema con la estructura de control del AIC en cascada con el FIC de control de flujo de hot oil y luego veremos el comportamiento del sistema de control completo. Esto es control override + control en cascada entre los AIC y TIC como lazos de control primario y el FIC como lazo de control interno o secundario.

3.5.- Evaluación de la Performance del Sistema de Control a Implementar

Para evaluar el comportamiento de la estructura de control propuesta, se ha realizado la implementación en 2 etapas a partir de la estructura de control original, con la finalidad de poder comparar la performance del Sistema de Control propuesto ante perturbaciones en las variables de operación del sistema.

- *Esquema Original* : En la Fig. 3.20 se muestra el diagrama de bloques del esquema de control original y contra el que compararemos el sistema propuesto. El comportamiento de este esquema original fue mostrado durante el Entrenamiento y Validación del Estimador Neuronal, ya que se usaron los datos del sistema con el lazo de control original.
- *1ra etapa* : Implementación de un estimador inferencia basado en red neuronal dinámica + control de calidad tipo P+I, en cascada con el lazo de flujo de aceite térmico. El diagrama de bloques se muestra en la Fig. 3.21.
- *2da etapa* : Implementación de un control override de temperatura de fondo de la columna, limitando la señal de set point que el controlador de calidad (control inferencial basado en RNA Dinámica) pueda establecer al lazo secundario de flujo de aceite térmico. El diagrama de bloques se muestra en la Fig. 3.22; y representa el Esquema Completo de Control Propuesto, que se corresponde además con la Fig. 3.19 mostrado anteriormente.

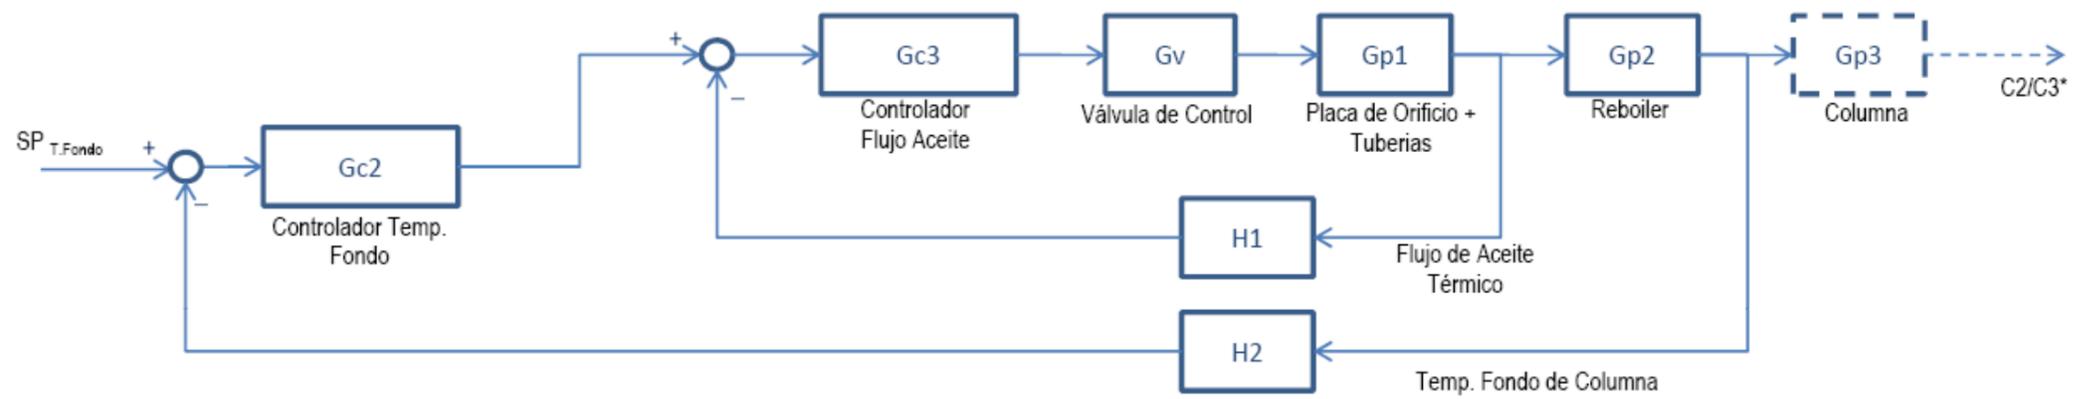


Fig. 3.20.- Esquema de Control Original (Control de Temperatura)

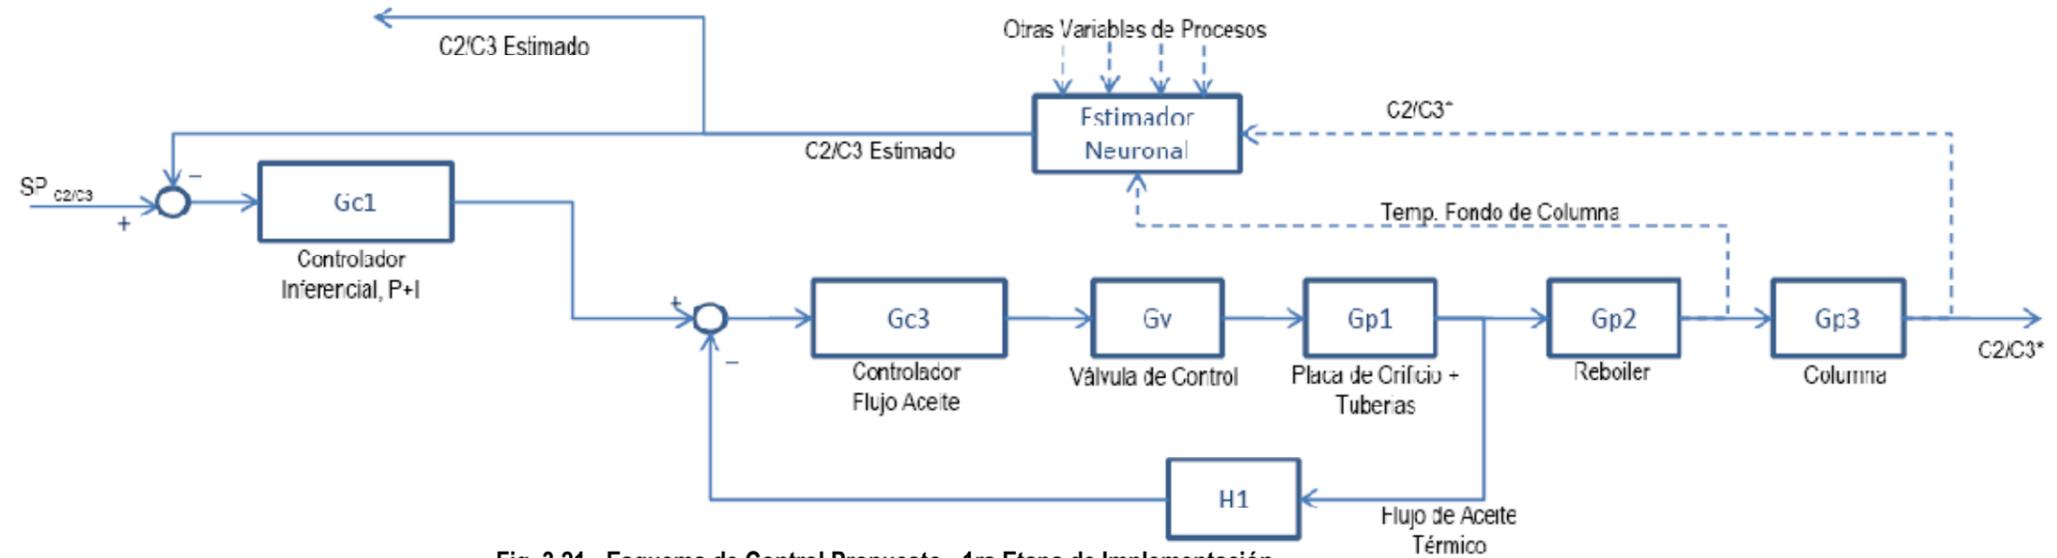


Fig. 3.21.- Esquema de Control Propuesto - 1ra Etapa de Implementación

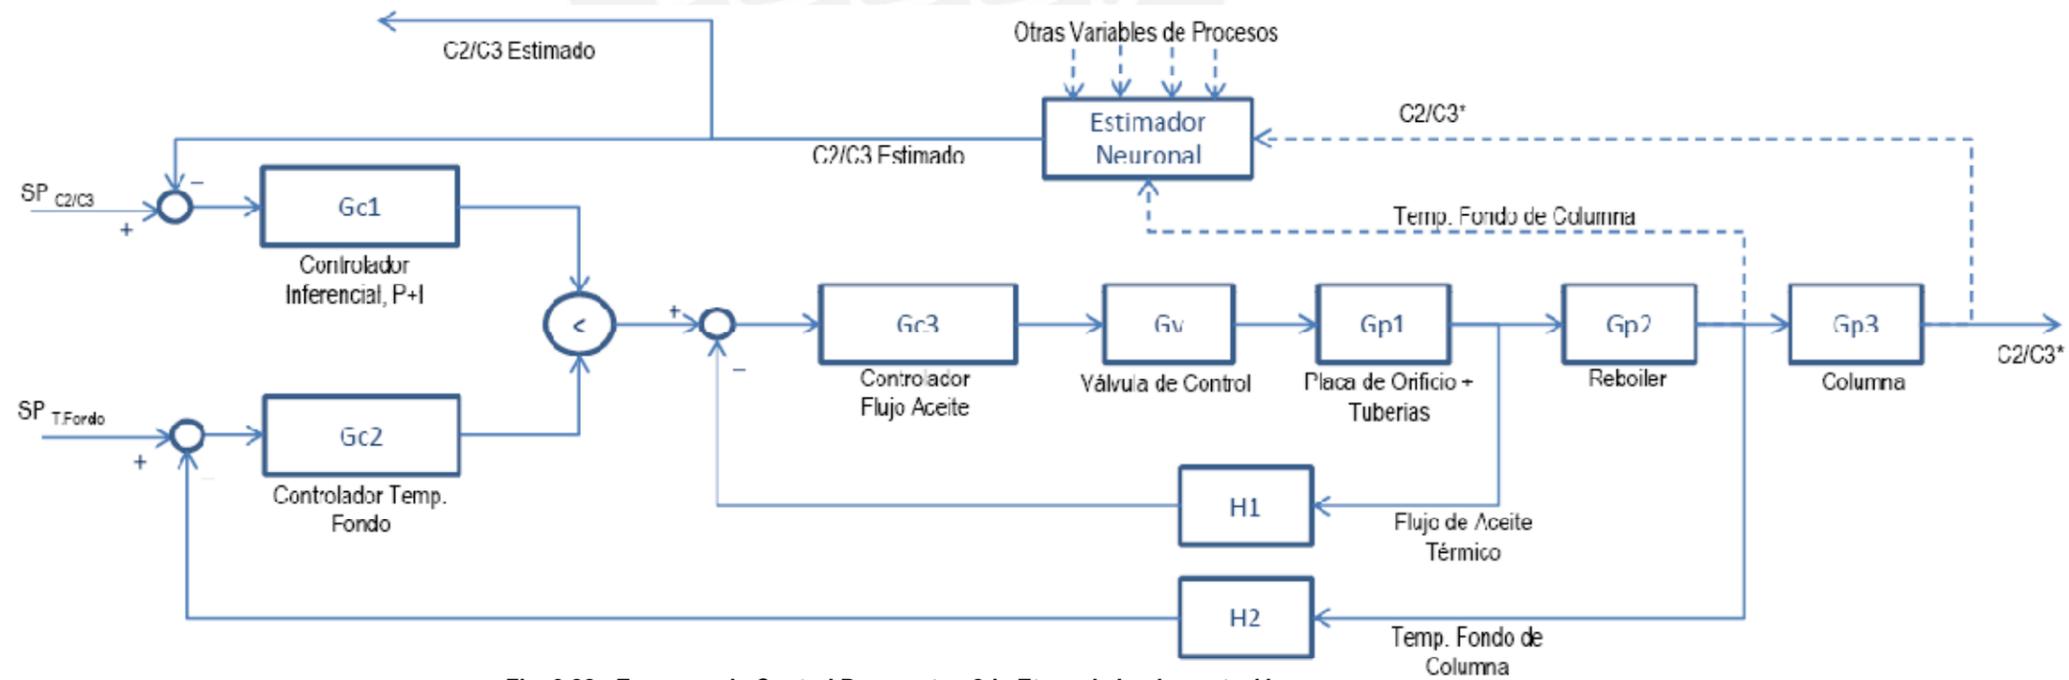


Fig. 3.22.- Esquema de Control Propuesto - 2da Etapa de Implementación

Veremos a continuación el comportamiento de cada una de estas estructuras de control propuestas en las Etapas 1 y 2 de Implementación.

3.5.1.- Resultados del Comportamiento del Controlador Inferencial Basado en RNA Dinámica con Estructura en Cascada sobre el Flujo de Aceite Térmico a la Columna

A fin de poder evaluar el comportamiento de esta primera etapa de la estructura de control (Ver Fig. 3.21) se sometió al sistema de estabilización de condensado, incluyendo a la columna de destilación, a una serie de perturbaciones en las variables que se usaron para el modelamiento del sistema (entrenamiento y validación) y esto se muestra en las Fig. 3.23 y Fig. 3.24 adjuntas:

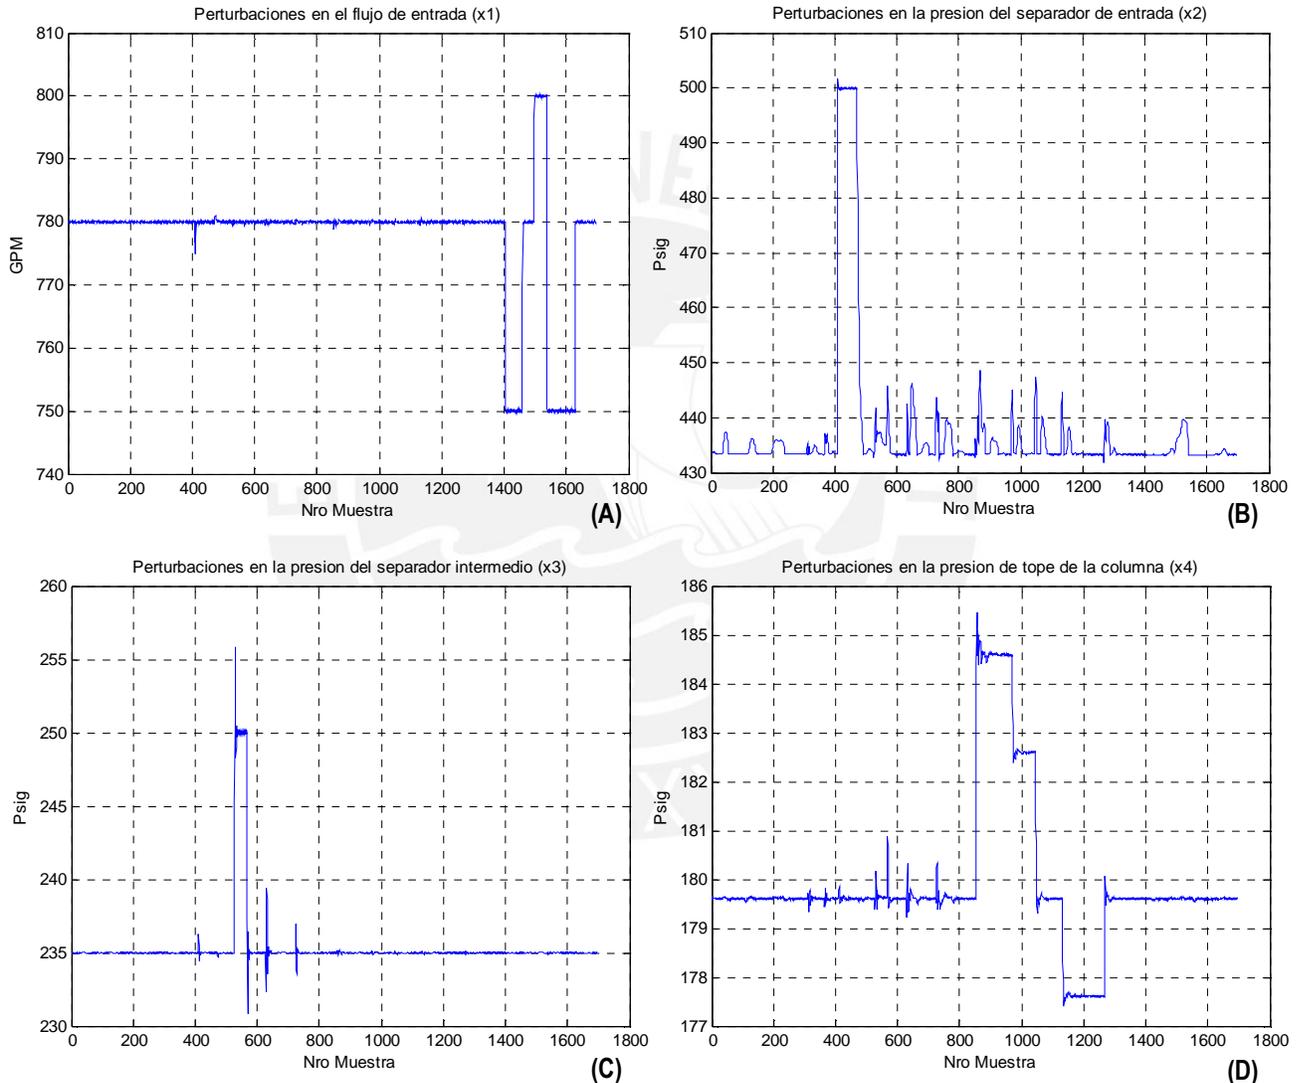


Fig. 3.23.- Perturbaciones Generadas en las Variables X1, X2, X3 y X4 para Probar la Efectividad del Lazo de Control Inferencial

Conforme a lo mencionado líneas arriba, las graficas de la Fig. 3.23 (A), (B), (C) y (D) muestran perturbaciones sobre las mismas variables de proceso que las usadas para el entrenamiento o validación de la red neuronal artificial, pero en magnitud diferente y ejecutadas en intervalos de tiempo distinto también. Esto con la finalidad de exigir al Estimador Neuronal y verificar la efectividad del lazo de control propuesto.

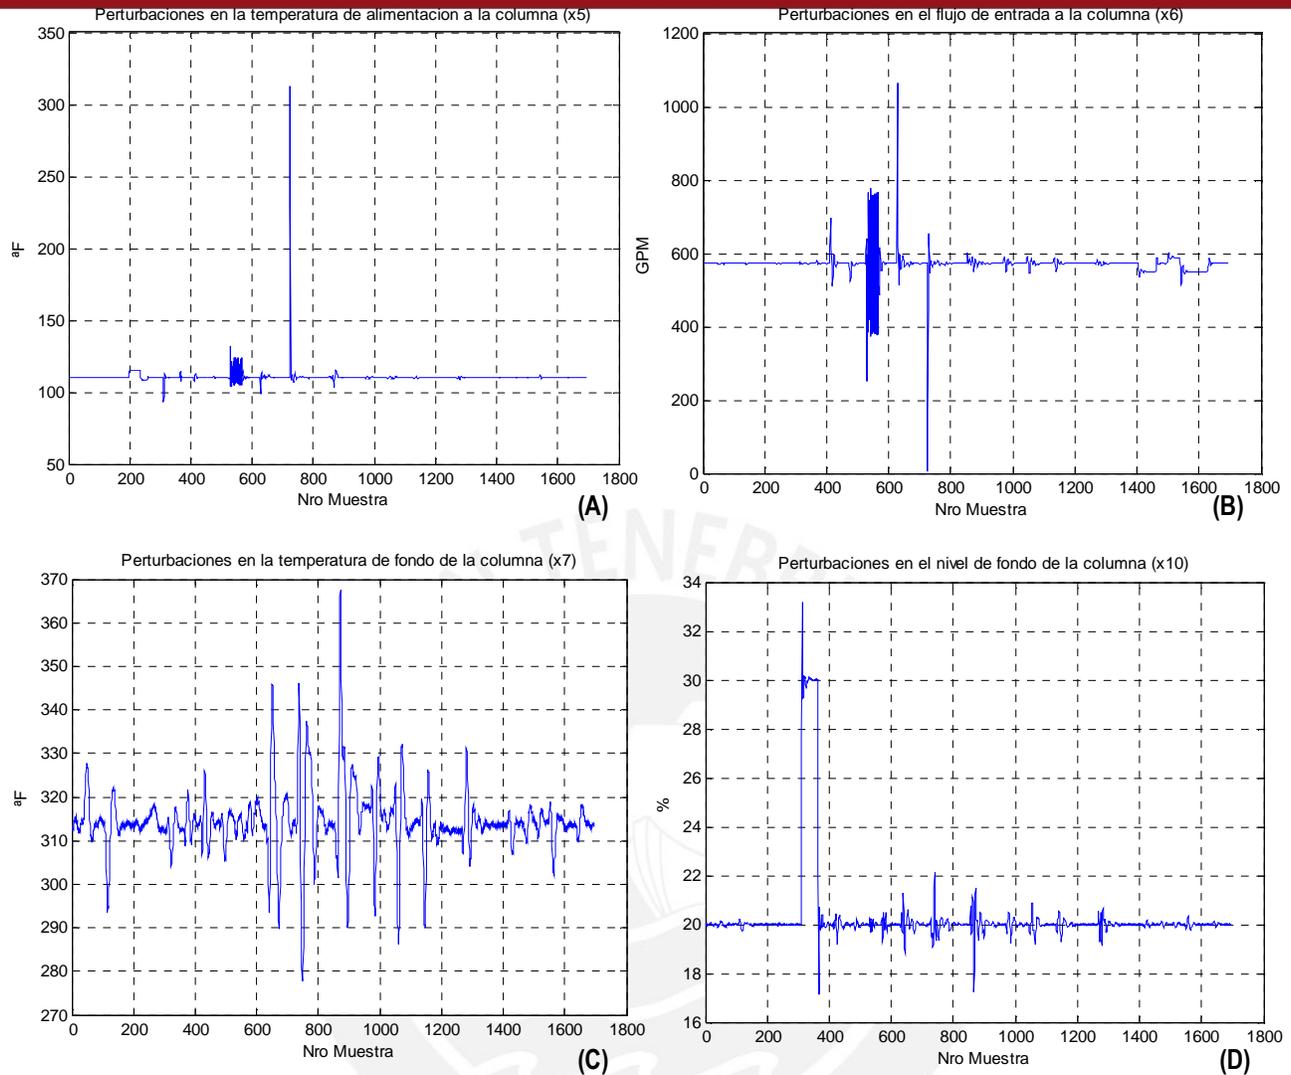


Fig. 3.24.- Perturbaciones Generadas en las Variables X5, X6, X7 y X10 para Probar la Efectividad del Lazo de Control Inferencial

En el comportamiento de las variables de la Fig. 3.24 (A), (B), (C) y (D) se evidencia el comportamiento de las otras variables de proceso durante las perturbaciones que se realizaron sobre las variables X1, X2, X3 y X4 del modelo de red neuronal.

Y el comportamiento de la calidad del producto de fondo de la columna, para un Set Point de 1.9% (expresado como %C2/C3) a lo largo de todas las perturbaciones fue el que se muestra en la Fig. 3.25 :

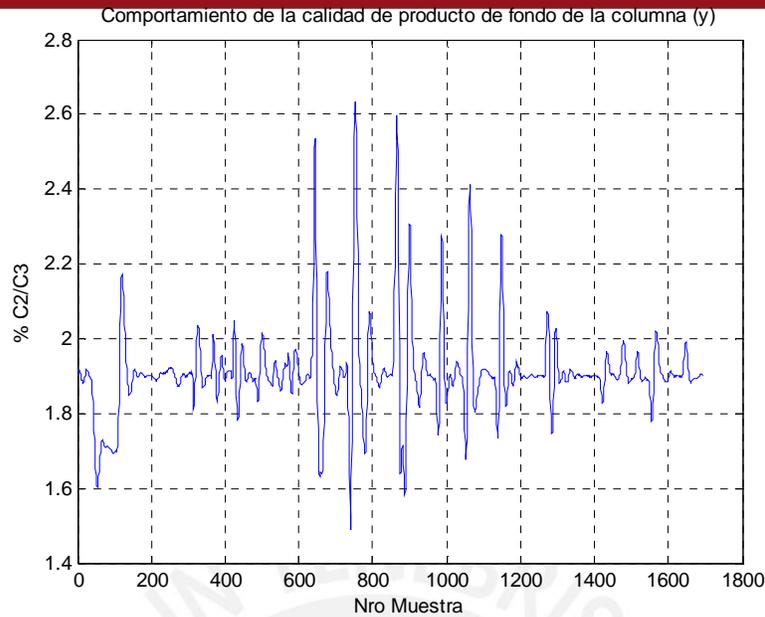


Fig. 3.25.- Evolución de la Calidad del Producto de Fondo de la Columna durante las Perturbaciones

Y a fin de comparar la performance de este nuevo lazo de control con el comportamiento del sistema en su estrategia original, colocaremos en un mismo gráfico estos resultados, con los valores reales obtenidos durante el entrenamiento y validación del sistema (Ver Fig. 3.26).

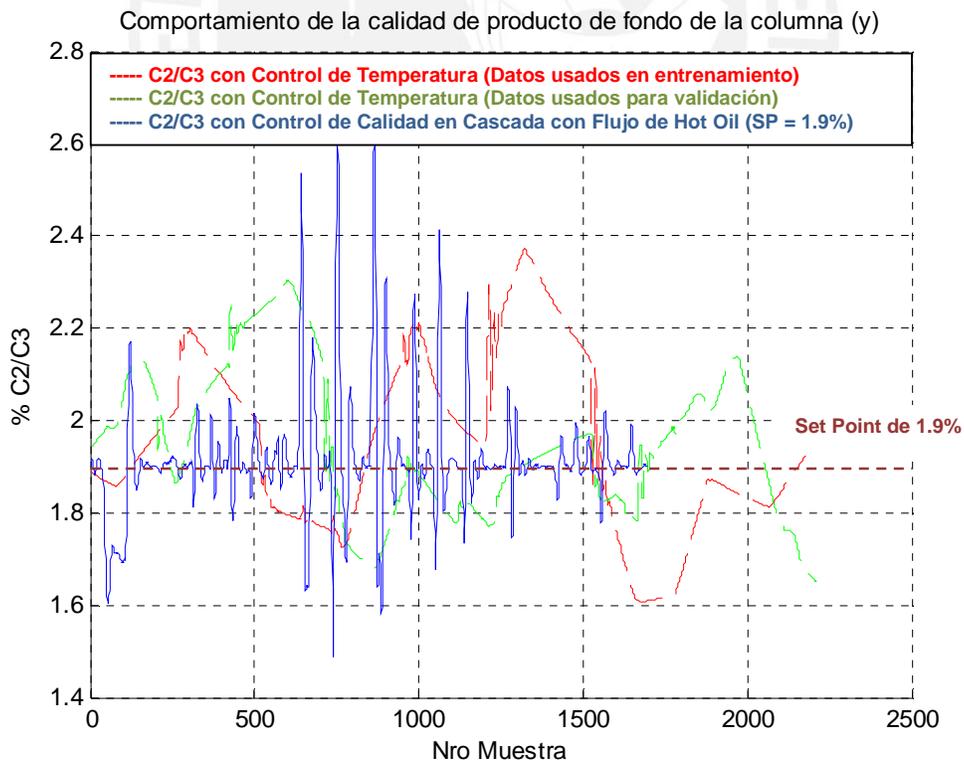


Fig. 3.26.- Comparación de Evolución de Calidad de Fondo de la Columna para las Estructuras de Control Original vs Control Inferencial 1ra Etapa

Y observamos, en la línea azul de la Fig. 3.26, que la oscilación de la calidad del sistema ha tenido una mejora importante ya que las desviaciones respecto del set point son de menor amplitud, obteniéndose que la calidad permanece oscilando muy cercana del valor $\%C2/C3 = 1.9 \%$.

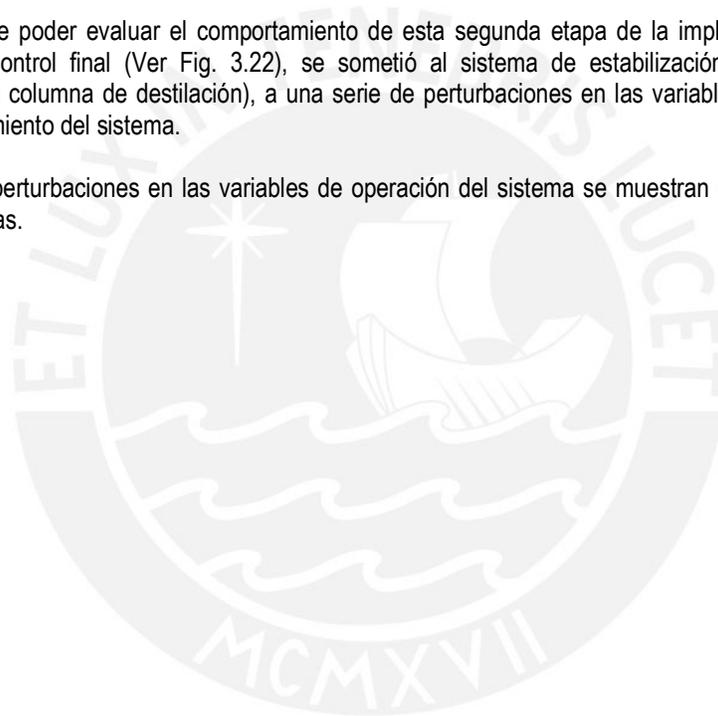
Esto se evidencia en la comparación visual de las líneas azul, roja y verde de la Fig. 3.26; en donde se compara el comportamiento de calidad del sistema con el Controlador Inferencial en la 1ra etapa de implementación (línea azul) y el comportamiento de la calidad con el esquema de control original (línea roja o verde que son datos usados durante el entrenamiento y validación del estimador neuronal).

Veremos ahora cómo se comporta el lazo de control cuando es completado, frente a las perturbaciones que se originan en el sistema.

3.5.2.- Resultados del Comportamiento del Controlador Inferencial Basado en RNA Dinámica con Estructura en Cascada sobre el Flujo de Aceite Térmico a la Columna y Override de Temperatura de Fondo de la Columna

A fin de poder evaluar el comportamiento de esta segunda etapa de la implementación de la estructura de control final (Ver Fig. 3.22), se sometió al sistema de estabilización de condensado (incluyendo a la columna de destilación), a una serie de perturbaciones en las variables que se usaron para el modelamiento del sistema.

Estas perturbaciones en las variables de operación del sistema se muestran en las Fig. 3.27 y Fig. 3.28 adjuntas.



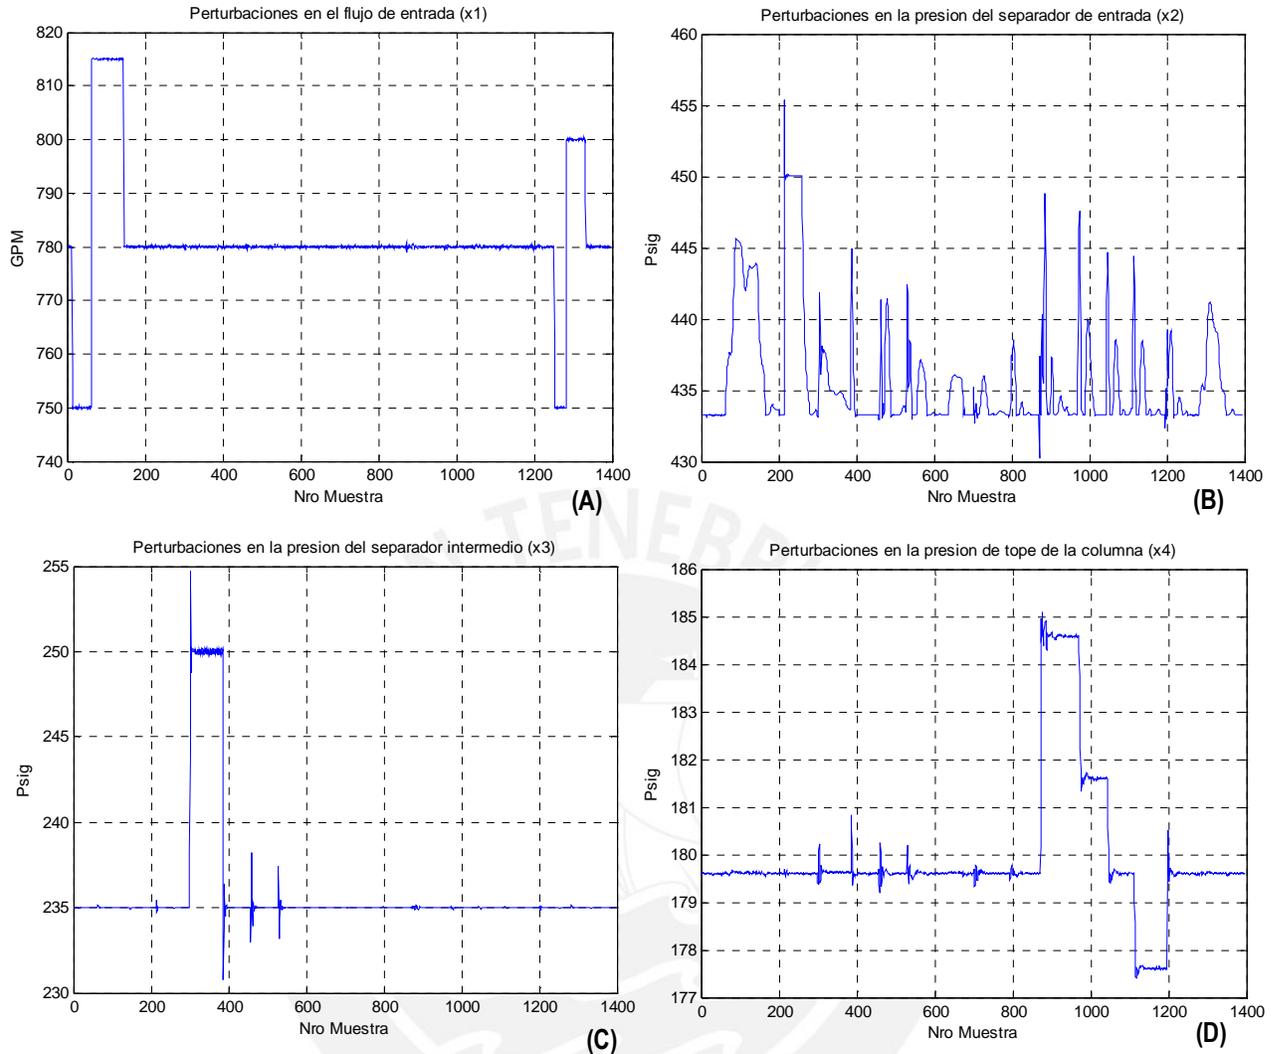


Fig. 3.27.- Perturbaciones Generadas en las Variables X1, X2, X3 y X4 para Probar la Efectividad del Lazo de Control Inferencial (Esquema Final)

De forma similar a lo realizado en la 1ra etapa de implementación, las graficas de la Fig. 3.27 (A), (B), (C) y (D) muestran perturbaciones sobre las mismas variables de proceso que las usadas para el entrenamiento o validación de la red neuronal artificial, pero en magnitud diferente y ejecutadas en intervalos de tiempo distinto también; con la finalidad de exigir al Estimador Neuronal y verificar la efectividad del lazo de control propuesto. En la Fig. 3.28 siguiente se muestran otras perturbaciones.

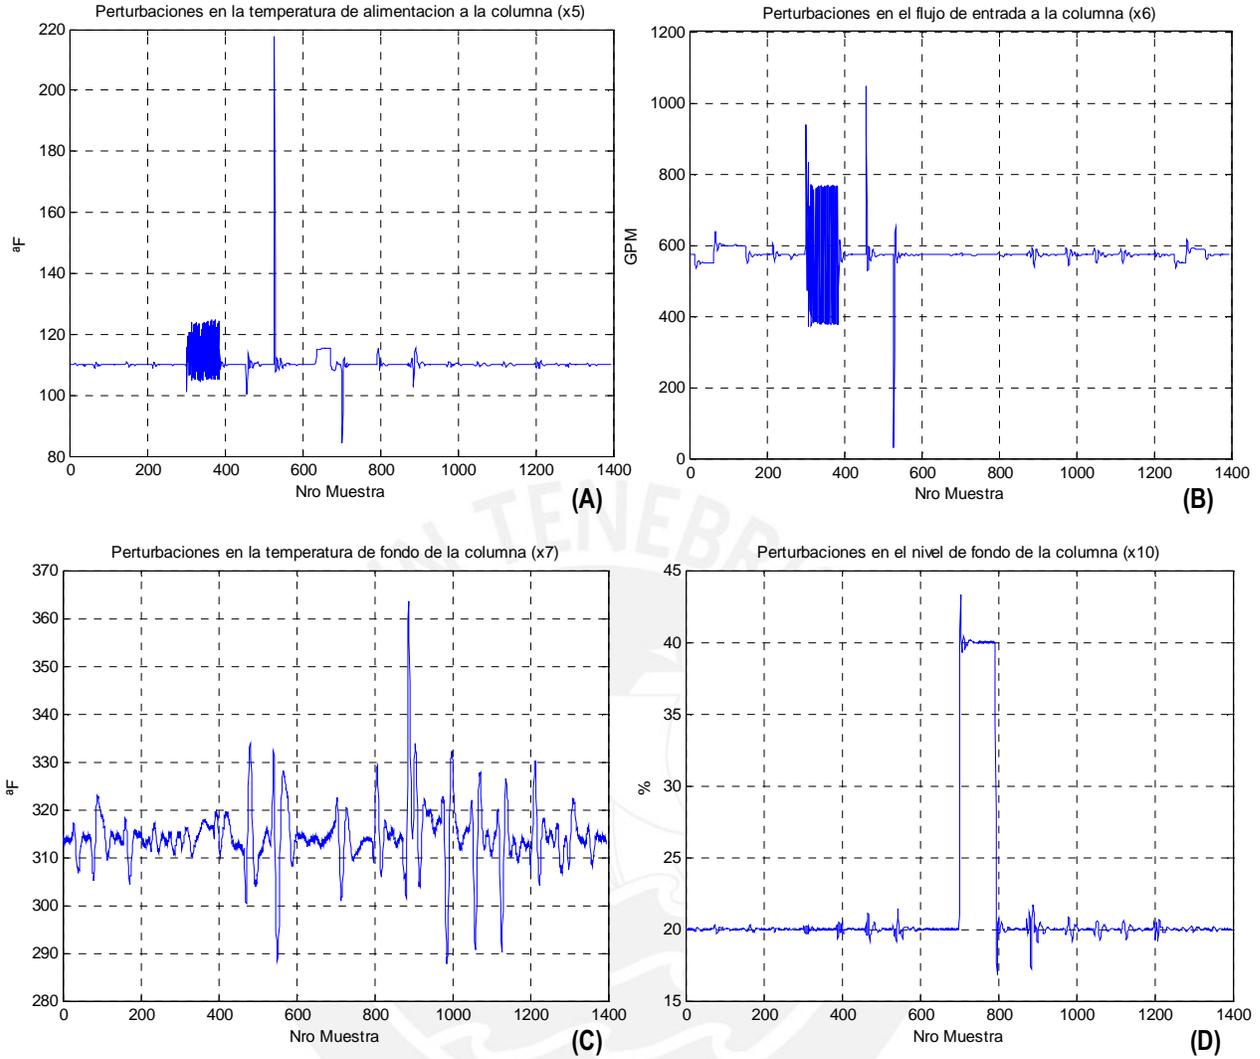


Fig.3.28.- Perturbaciones Generadas en las Variables X5, X6, X7 y X10 para Probar la Efectividad del Lazo de Control Inferencial (Esquema Final)

En el comportamiento de las variables de la Fig. 3.28 (A), (B), (C) y (D) se evidencia el comportamiento de las otras variables de proceso durante las perturbaciones que se realizaron sobre las variables X1,X2, X3 y X4 del modelo de red neuronal.

Y el comportamiento de la calidad del producto de fondo de la columna, para un Set Point de 1.9% (expresado como %C2/C3) a lo largo de todas las perturbaciones fue el que se muestra en la Fig. 3.29.

Comportamiento de la calidad de producto de fondo de la columna (y)

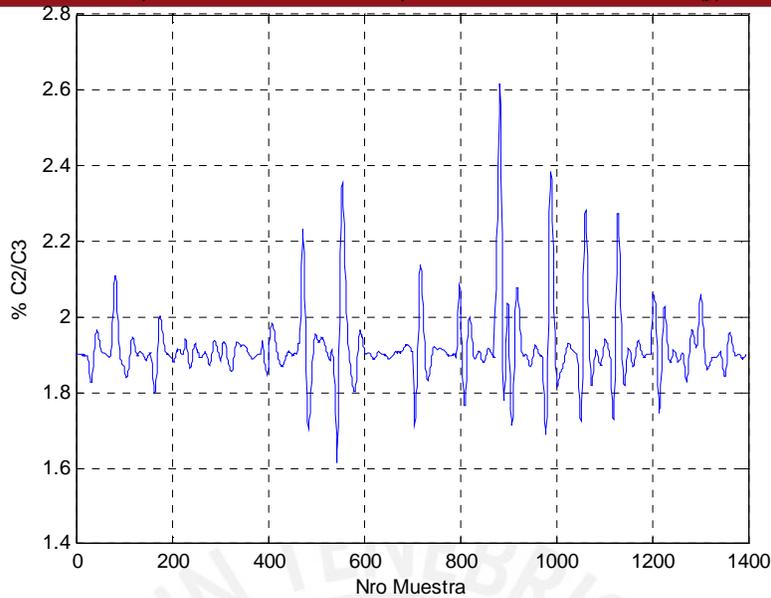


Fig. 3.29.- Evolución de la Calidad del Producto de Fondo de la Columna durante las Perturbaciones

Para comparar la performance de esta nueva estructura de control completa (Ver fig. 3.22) con la estructura en su primera etapa (Ver Fig. 3.21) y con la estrategia de control original (Ver fig. 3.20), colocaremos en un mismo gráfico estos resultados, con los valores reales obtenidos durante el entrenamiento del sistema. Esto se evidencia en la Fig. 3.30.

Comportamiento de la calidad de producto de fondo de la columna (y)

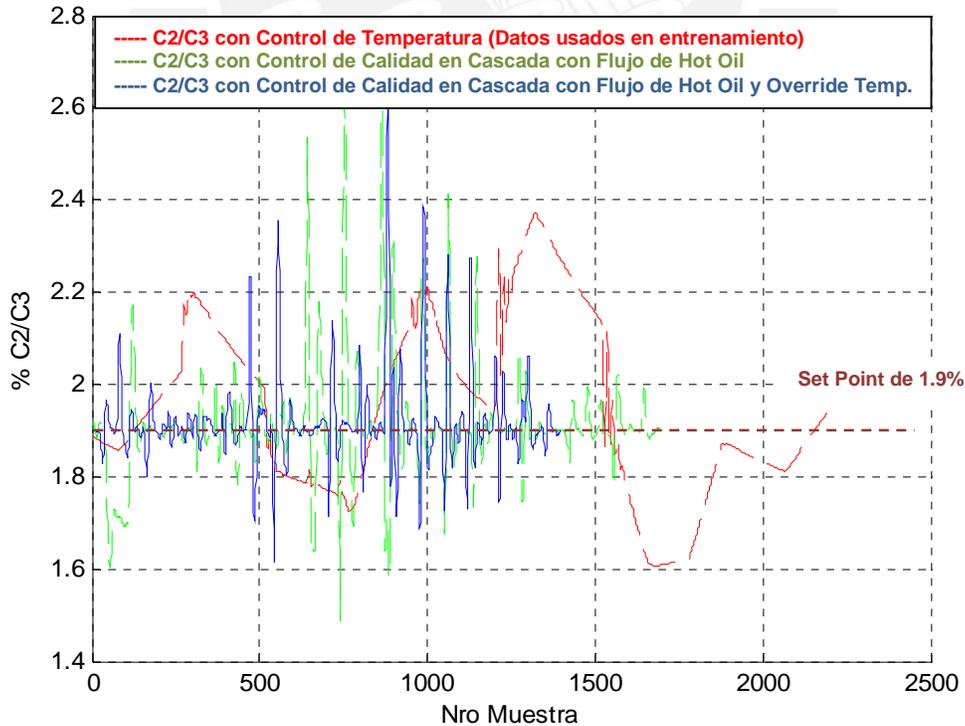


Fig. 3.30.- Comparación de Evolución de Calidad de Fondo de la Columna para las Estructuras de Control Original vs Control Inferencial 1ra Etapa vs Esquema de Control Final

Como se puede observar en la Fig. 3.30, el esquema de control completo, que considera estimador inferencial de calidad + controlador de calidad en esquema de control en cascada con el flujo de hot oil + control override de temperatura de fondo (Ver Fig. 3.22); se muestra más estable a las perturbaciones que el sistema original y con menos picos que el controlador inferencial sin el override de temperatura (Esquema de control implementado como 1ra etapa, Ver Fig. 3.21).

Finalmente, en la Fig. 3.31 realizamos una comparación únicamente entre el esquema final de control a utilizar y el esquema original de control de la columna a fin de cuantificar el impacto de esta nueva estructura de control.

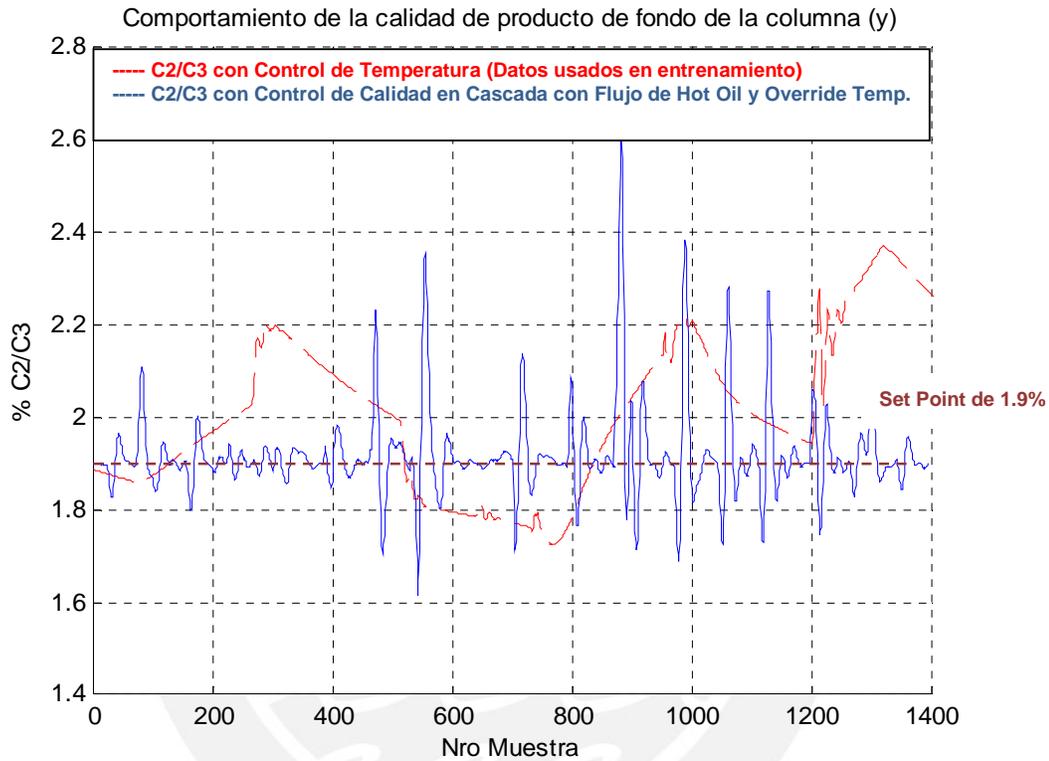


Fig. 3.31.- Comparación de Evolución de Calidad de Fondo de la Columna para las Estructuras de Control Original vs Esquema de Control Final Propuesto

El comportamiento de la Fig. 3.31 lo resumiremos en la Tabla 3.2 siguiente, a fin de cuantificar la estabilidad del nuevo de lazo de control mediante la medición de la dispersión y varianza de los datos:

Tabla 3.2.- Comportamiento de la Calidad para los Esquema de Control Propuesto vs Original

Caso	Set Point Objetivo, C2/C3	Especificación Límite de Calidad, C2/C3	Promedio	Valor Máximo	Valor Mínimo	Desviación Estándar	Varianza
Esquema de Control Original	1.9 %	2 %	2.0076 %	2.373 %	1.7239 %	0.1684 %	0.0284 % ²
Esquema de Control Propuesto	1.9 %	2 %	1.9189 %	2.6170 %	1.6164 %	0.0976 %	0.0095 % ²

Los parámetros mostrados en la Tabla 3.2 se calcularon según:

$$\text{Promedio} = \bar{X} = \frac{1}{N} \sum_{i=1}^N X_i ; \text{ donde } N : \text{Numero de Datos Evaluados}$$

$$\text{Desviación Estándar} = S = \sqrt{\frac{1}{N} \sum_{i=1}^N (X_i - \bar{X})^2}$$

$$\text{Varianza} = \text{Var} = S^2$$

De los resultados mostrados en la Fig. 3.31 y la Tabla 3.2; se obtiene que el Esquema de Control propuesto reduce la variación y la dispersión de los datos, respecto del valor objetivo de control de 1.9 %. En el caso de la Desviación Estándar se alcanzó una reducción respecto del Esquema de Control Original de un 42%, y en el caso de la Varianza, la reducción alcanzada ha sido del orden del 66%.

3.6.- Conclusiones Preliminares

1.- Se implementó una red neuronal dinámica para el estimador inferencial, y con entrenamiento tipo Batch, para asegurar la precisión del estimador. Como se describió en la sección 3.2.1 y 3.2.2; el hecho que la red neuronal sea dinámica implica que se establece un número de subredes igual al número de conjunto de datos, y la salida de cada subred alimenta a la siguiente, adoptándose un modelo recursivo; que por tener que recorrer toda la estructura de subredes para luego recién actualizar los pesos (w_{jk} y W_{ij}), implica que adoptamos un entrenamiento tipo Batch que es más riguroso y exigente.

2.- Dentro de la arquitectura de la red neuronal se consideraron un total de 15 variables de proceso de entrada (6 de las cuales eran realimentaciones de valores pasados de las variables que tienen alto retardo), siendo el parámetro de calidad % C2/C3 la única salida de la red que también se realimenta al sistema. Se usó una función de activación sigmoidea tipo 2, una sola capa de neuronas intermedias y se hicieron pruebas durante el entrenamiento de la red variando el error máximo entre la variable estimada y real, la inclinación de la función de activación y el número de veces que se entrena el sistema.

3.- El uso de la función de activación Sigmoidea tipo 2 brinda buenos resultados para el entrenamiento de la red neuronal dinámica del sistema modelado, ya que permite un buen nivel de estimación de la calidad del producto de fondo de la columna, como se evidenció en la etapa de validación de la estructura de red neuronal adoptada (sección 3.3.2).

Por experiencias previas en el uso de redes neuronales en otros sistemas, se evidenció que el entrenamiento con la función sigmoidea era más rápido que al usar una función gaussiana, para condiciones similares de entrenamiento; ya que requiere menor número de iteraciones para alcanzar un nivel determinado de error relativo total.

4.- El ajuste de la inclinación de la sigmoidea tipo 2 ayudó a disminuir el error relativo total que el sistema neuronal alcanza durante el entrenamiento. Esto se evidencia en el cuadro resumen que se presentó en la sección 3.3.1 con los resultados del entrenamiento (Ver Tabla 3.1).

5.- Se determinó por pruebas experimentales que un ratio de aprendizaje óptimo para el sistema propuesto es de 0.1, para el ratio de aprendizaje de actualización de los pesos; y de 0.05 para el ratio de aprendizaje de actualización de la inclinación de la Sigmoidea. A valores menores de ratios de aprendizaje el error relativo total se mantiene alto; y para ratios mayores se produce sobre-aprendizaje en el sistema neuronal dinámico y los valores estimados oscilan mucho, volviéndose ineficientes para ser considerados dentro de una estructura de control como la que se propone en el presente proyecto

6.- Con la finalidad de disminuir aun más el error relativo total especificado para el entrenamiento, se procedió a incrementar el Nro de entrenamientos del sistema hasta un valor de 3. Esto equivale a realizar 3 veces más iteraciones que las especificadas en el programa (10,000 iteraciones).

7.- Se evidenció que a pesar de exigir al sistema neural dinámico que valide el comportamiento de un sistema bastante diferente al usado para el entrenamiento; el modelo estimó con mucha precisión la calidad del producto de fondo de la columna, de tal forma que aproximando los valores al primer decimal se produciría una diferencia nula respecto de los valores reales.

8.- Si bien la bibliografía establece algunos criterios para la definición del número de neuronas de la capa intermedia, o incluso para el número de capas intermedias u ocultas; por experiencia con otros sistemas de red neuronal, se ha evidenciado que es suficiente el trabajar con una capa intermedia de neuronas, y con un número que sea mayor o igual al número de neuronas de la capa de entrada.

9.- La importancia de usar como valores de entrada al sistema neuronal, los valores pasados de temperaturas o de calidad del producto de fondo de la columna, radica en que estos valores tienen retardo de tiempo frente a perturbaciones en el sistema y la inclusión de valores pasados del sistema, permite agilizar la convergencia del sistema y le brinda mayor precisión al modelo.

10.- La arquitectura de red neuronal artificial (RNA) dinámica adoptada para el estimador inferencial de calidad considera entonces función de activación sigmoidea tipo 2, con inclinación y usando 3 etapas de entrenamiento de la red.

11.- Se ha evidenciado que el sistema de control inferencial basado en RNA dinámica en estructura de control en cascada con el flujo de aceite térmico (1ra Etapa de Implementación), permite al sistema un mejor nivel de control de calidad del producto de fondo respecto del esquema original de control por temperatura de fondo, por cuanto acelera la respuesta del sistema para responder ante las perturbaciones en las condiciones operativas del proceso y minimiza las desviaciones del set point.

12.- Se ha evidenciado que el sistema de control inferencial basado en RNA dinámica en estructura de control en cascada con el flujo de aceite térmico y con el override de temperatura de fondo (Esquema de Control Propuesto), mejora aún más la respuesta del sistema, que se aleja menos del set point establecido y asegura que el producto de fondo se mantenga en especificación por mucho más tiempo. Disminuyendo por tanto, la dispersión de los datos y la varianza de los mismos.

13.- Si bien los tiempos de entrenamiento del sistema de red neuronal dinámica son relativamente altos (hasta 45 min para 3 etapas de entrenamiento de 10,000 iteraciones cada una), los tiempos de estimación de la calidad son bastante rápidos como se observó en la validación del sistema, en que para 2207 conjuntos de datos, le tomó sólo 10 seg y esto permite considerar al estimador inferencial como parte del lazo de control propuesto.

14.- Para el esquema de control original basado en control de temperatura de fondo de columna, se ha evidenciado que las perturbaciones que tiene más impacto sobre el control de calidad del producto de fondo de la columna, son el caudal de alimentación a la columna y la presión de operación de la misma.

Sin embargo, con el esquema de control propuesto, las perturbaciones en el flujo de entrada a la columna no producen cambios significativos en la calidad, mientras que los cambios en la presión de operación de la columna, si bien producen cambios negativos en la calidad del producto, el sistema tiene una respuesta de corrección bastante rápida.

15.- El algoritmo de los controladores tipo PID que se propone (PID velocity form) tiene ciertas ventajas respecto de estructuras tradicionales de los controladores PID ya que en lugar de ejercer la acción de control basada en el error, lo haría en función a los cambios en el error (desde su valor anterior hasta el valor actual), aplicando incrementos o decrementos a los valores previos de salida del controlador para alcanzar los nuevos valores.

CAPÍTULO 4: IMPACTO EN LA PRODUCCIÓN Y BENEFICIO DE LA ESTRATEGIA DE CONTROL IMPLEMENTADA

En la sección anterior se hicieron pruebas generando diferentes perturbaciones en el sistema de estabilización de condensado, con la finalidad de estudiar el comportamiento de las diferentes estructuras de control que se disponían para el control de la calidad del producto de fondo de la columna de destilación.

Entonces, se evidenció el beneficio del sistema de control inferencial basado en redes neuronales que se implementó, por cuanto permite mantener la variable de interés (ratio %C2/C3) lo más cerca del set point de 1.9 %.

Sin embargo, resulta importante poder cuantificar el impacto sobre el proceso productivo, por mantener estable esta variable de calidad. Para eso, enfocaremos el análisis desde el punto de vista de:

- 1.- Impacto en la producción de condensado de fondo de columna para mantenerlo en especificación.
- 2.- Impacto económico asociado a la demanda de aceite térmico.

4.1.- Impacto de la Estrategia de Control en la Producción de Condensado de Fondo de Columna

Debemos recordar la relación entre la calidad del producto de fondo y el caudal del mismo, puesto que tiene una relación directa. Esto es, cuanto mayor sea el contenido de etano en el producto de fondo, o el ratio C2/C3, mayor será la producción de condensado.

Sin embargo, si el contenido de C2/C3 es muy alto (arriba de 2%), el producto estará fuera especificación y deberá por tanto enviarse a almacenamiento para luego reprocesarse.

Por esto, antes de realizar una evaluación del impacto en la producción, vamos a depurar la información para comparar únicamente los periodos de tiempo en que el producto está en especificación.

Al realizar este análisis obtenemos el comportamiento que se muestra en la Fig. 4.1 :

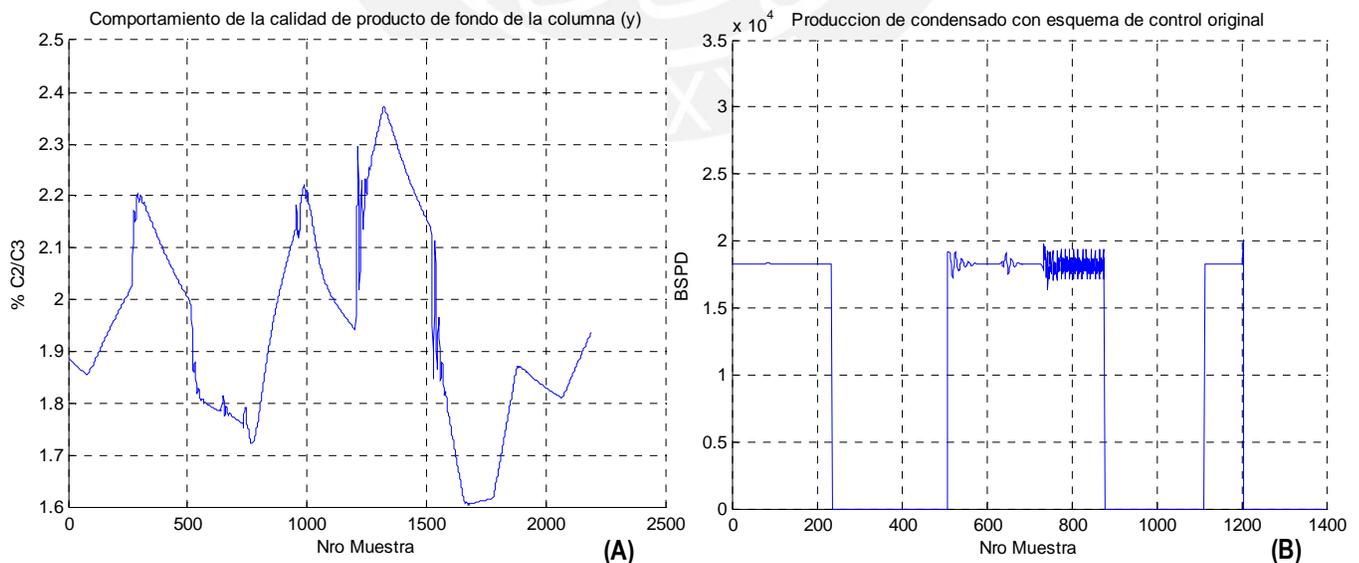


Fig. 4.1.- Producción de Condensado de Fondo de Columna para el Esquema de Control de Calidad Original

Y del comportamiento de la calidad que se muestra en la Fig. 4.1 (A) se puede observar que hay varios períodos en los cuales el condensado de producción estuvo fuera de especificación ($\%C2/C3 > 2\%$) y por eso se considera como caudal de producción de condensado cero (Ver Fig. 4.1 (B)), ya que no se le contabilizará como producto en especificación para despacho.

Ahora veremos el comportamiento del caudal de producción con la nueva estructura de control propuesta (Ver Fig. 4.2).

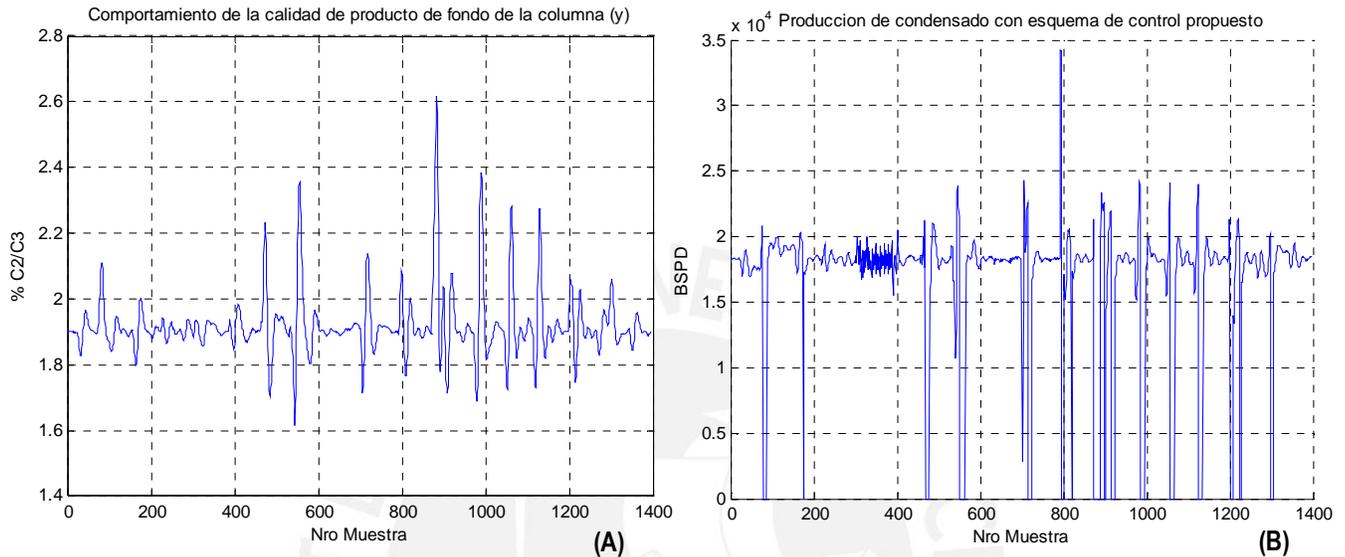


Fig. 4.2.- Producción de Condensado de Fondo de Columna para el Esquema de Control de Calidad Propuesto

Al observar el comportamiento de la calidad del producto de fondo de la columna en la Fig. 4.2 (A), vemos que la dispersión alrededor del valor objetivo de $\%C2/C3 = 1.9\%$ es menor que el que se tenía con el esquema de control original que se muestra en la Fig. 4.1 (A). Debido a esto, el tiempo de producción de condensado en especificación es mayor al que se obtuvo con el esquema de control de calidad original que tenía control de temperatura de producto de fondo para el ajuste de la calidad (Ver Fig. 4.1 (B) y Fig. 4.2(B)).

Ahora veremos de cuantificar el diferencial de producción de condensado entre ambos esquemas de control:

[Producción con Esquema de Control Propuesto – Producción con Esquema de Control Original]

Y obtenemos el siguiente comportamiento (Ver Fig. 4.3):

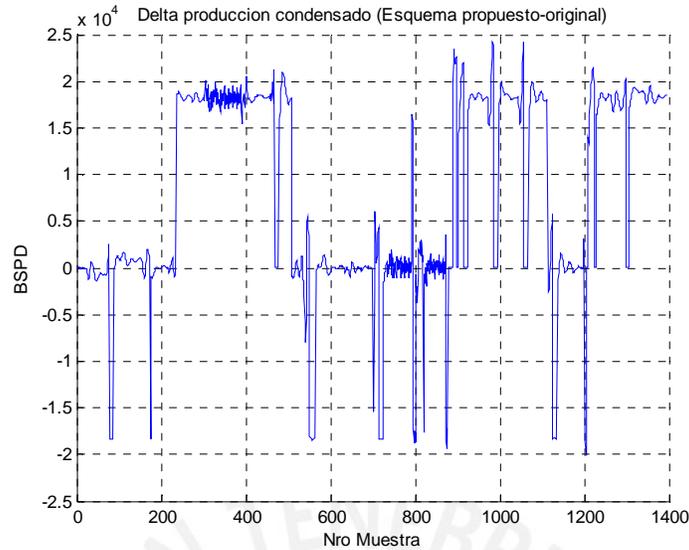


Fig. 4.3.- Diferencial de Produccion de Condensado: Esquema de Control Propuesto - Original

Debido a que necesitamos valorizar este incremento acumulado de producción de condensado por la nueva estrategia de control, buscaremos el valor acumulado para el periodo de análisis y luego lo normalizaremos, para expresarlo en unidades adecuadas que nos permitan una evaluación económica de este impacto en producción.

Para la normalización haremos lo siguiente:

$$\Delta Produccion\ total\ acumulada = \sum_{i=1}^k (\Delta Prod_i \cdot \Delta t)$$

Donde :

k = Nro muestras (1396)

Δt = Periodo de muestreo (20 seg)

$\Delta Prod$ = Diferencia de producción de condensado entre esquema de control propuesto – esquema original para cada período de muestreo

Al resolver obtenemos:

$\Delta Produccion\ total\ acumulada = 2405.47\ bbls$

Asimismo, debido a que el tiempo total de análisis fue :

$$Tiempo\ total\ analisis = \Delta t * Nro\ muestras$$

Tenemos : $\Delta t * Nro\ muestras = 27920\ seg = 0.32315\ dias$

Finalmente, el flujo de producción de condensado normalizado, para expresarlo, como caudal de condensado en especificación por día, estaría definido por la siguiente expresión:

$$\Delta Prod.\ de\ condensado = \left(\frac{\Delta Prod\ total\ acumulada}{Tiempo\ total\ analisis} \right) \dots en\ bbls/d$$

Y entonces tenemos que el incremento de producción de condensado en especificación por el uso de la nueva estrategia de control sería de :

$$\Delta \text{Prod. de condensado} = 7443.86 \text{ bbl/día}$$

Luego, considerando un costo del condensado de : 40 US\$/bbl obtenemos el beneficio por el incremento de producción como :

$$\text{Ingreso por producción incremental} = (\Delta \text{Prod. de condensado}) * \text{Precio producto}$$

Y evaluando obtenemos:

$$\text{Ingreso por producción incremental} = 7443.86 \text{ bbl/día} * 40 \text{ US\$/día} = 297754.4 \text{ US\$/día}$$

$$\text{Ingreso por producción incremental} = 297.75 \text{ MUS\$/día}$$

A anualizando este ingreso por producción incremental tendríamos :

$$\text{Ingreso por producción incremental} = 297.75 \text{ MUS\$/día} * 365 \text{ días/año}$$

$$\text{Ingreso por producción incremental} = 108680.36 \text{ MUS\$/año} = 108.68 \text{ MMUS\$/año}$$

En resumen, la implementación del esquema de control propuesto impacta sobre la producción de condensado en especificación, de forma positiva; y genera beneficios económicos importantes por cuanto evita que el producto tenga demasiados componentes ligeros así como evita que haya mucha eliminación de los mismos, perdiéndose en los vapores de tope de la columna.

Sin embargo, a costa de esta ganancia en producción, hay una mayor demanda de energía en el sistema que se manifiesta como un mayor consumo de hot oil en los reboilers. A continuación estudiaremos el comportamiento de esta variable.

4.2.- Impacto de la Estrategia de Control en la Demanda de Aceite Térmico de los Reboiler de la Columna

Para esta evaluación también debemos recordar las relaciones que se mostraron en el Capítulo 2, en los gráficos de las curvas de operación de la columna, de donde podemos concluir que la relación entre la calidad del producto de fondo de la columna y la demanda de aceite térmico en el sistema, es una relación inversa.

Esto implica que en la medida que se busca disminuir el ratio C2/C3, se requiere una mayor temperatura de fondo de la columna y con esto, el consumo de aceite térmico en los reboiler de la misma aumenta.

Entonces, tenemos el siguiente comportamiento para el sistema en que se controla la calidad con el esquema de control original de temperatura de fondo (Ver Fig. 4.4).

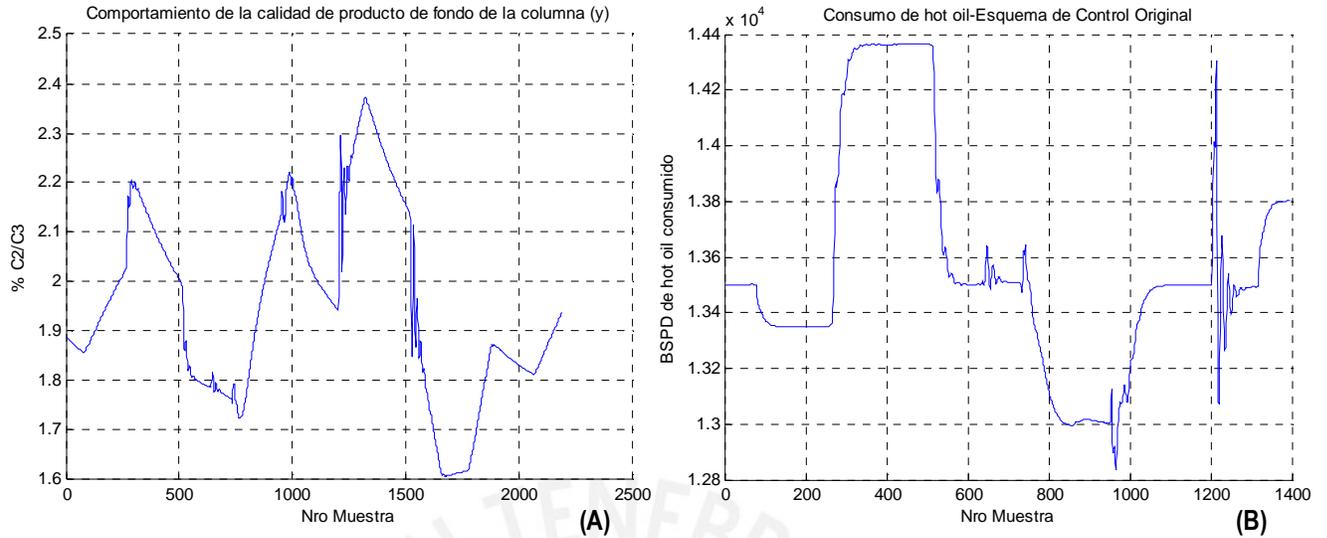


Fig. 4.4.- Consumo de Hot Oil para el Esquema de Control de Calidad Original

Se evidencia, en la Fig. 4.4 (A), que hay varios períodos de tiempo en los cuales el producto está fuera de especificación (ratio C2/C3 > 2%) y para estos períodos, como el lazo de control de temperatura busca ajustar la calidad, origina que la demanda de hot oil se incremente de forma puntual, como se evidencia en la Fig. 4.4 (B).

Ahora veremos el comportamiento del consumo de hot oil cuando el sistema se encuentra operando con el nuevo sistema de control inferencial basado en red neuronal dinámica (Ver Fig. 4.5).

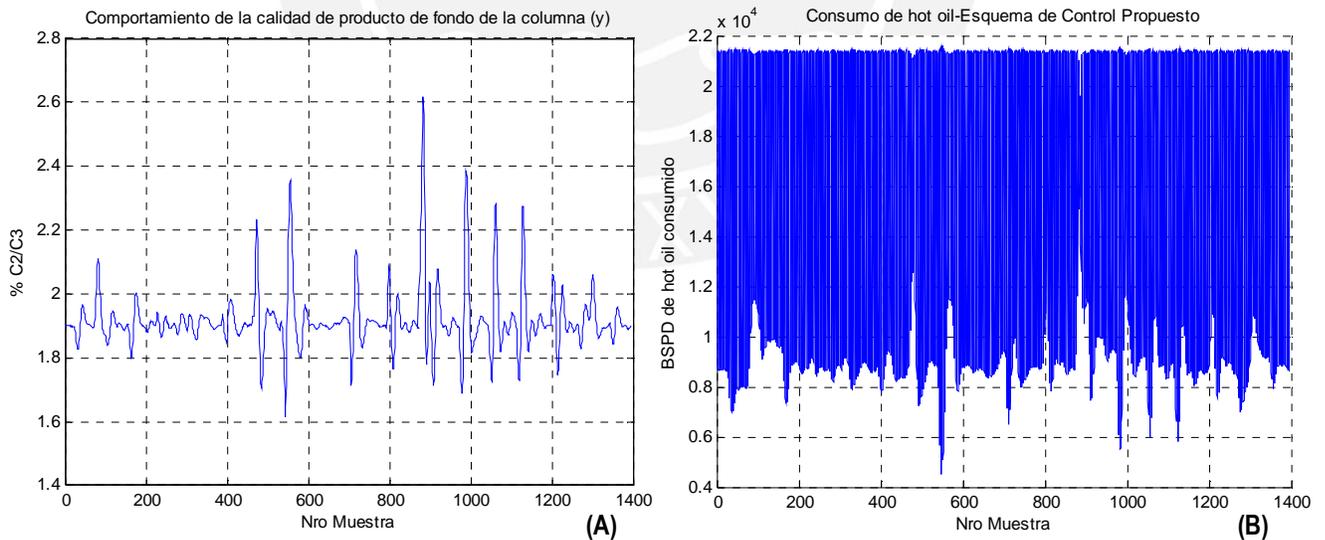


Fig. 4.5.- Consumo de Hot Oil para el Esquema de Control Propuesto

Se observa entonces que, a costa de mantener el producto de fondo de columna en especificación, como lo muestra la Fig. 4.5(A); con valores muy poco dispersos respecto del valor objetivo de $\%c2/C3 = 1.9\%$, a pesar de todas las perturbaciones a las que fue sometido el sistema, el caudal de hot oil que ingresa al sistema oscila permanentemente, como se evidencia en la Fig. 4.5 (B).

Ahora veremos cuál es el diferencial de consumo de hot oil en el tiempo, calculado como:

[Consumo de hot oil en esquema de control propuesto – Consumo hot oil en esquema de control original]

Y tenemos entonces el siguiente comportamiento que se muestra en la Fig. 4.6:

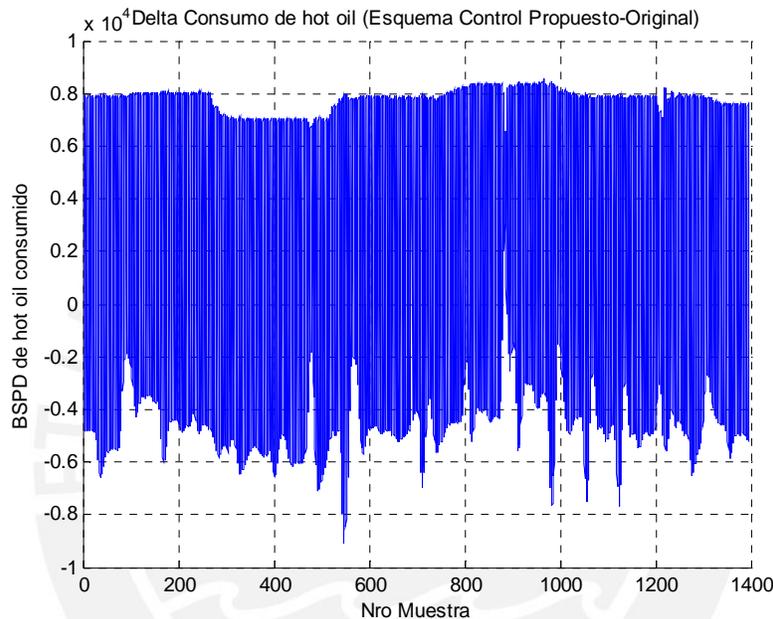


Fig. 4.6.- Diferencial de Consumo de Hot Oil : Esquema de Control Propuesto - Original

Se observa entonces que por la estrategia de control propuesta para mantener la calidad del producto de fondo de la columna en un valor estable, hay una mayor demanda de aceite térmico para los reboiler de la columna.

Y a fin de cuantificar el impacto económico de este consumo de hot oil, tomaremos el valor de caudal de consumo normalizado, de la siguiente forma:

Total acumulado de hot oil durante el periodo de muestreo:

$$\Delta Q_{total \text{ acumulado hot oil}} = \sum_{i=1}^k (\Delta Q_{hot \text{ oil } i} \cdot \Delta t)$$

Donde :

k = Nro muestras (1396)

Δt = Periodo de muestreo (20 seg)

$\Delta Q_{hot \text{ oil}}$ = Diferencia de consumo de hot oil entre esquema de control propuesto – esquema original para cada período de muestreo

Y al hacer los cálculos obtenemos:

ΔQ_{total} acumulado hot oil = 494.43 bbls

Asimismo, debido a que el tiempo total de análisis fue:

$$Tiempo\ total\ analisis = \Delta t * Nro\ muestras$$

Tenemos : $\Delta t * Nro\ muestras = 27920\ seg = 0.32315\ dias$

Finalmente, el flujo de hot oil normalizado para expresarlo como caudal de hot oil consumido por día estaría definido por la siguiente expresión:

$$\Delta Q_{normalizado\ de\ hot\ oil} = \left(\frac{\Delta Q_{total\ acumulado\ hot\ oil}}{Tiempo\ total\ analisis} \right) \dots en\ bbls/d$$

Y entonces tenemos que el incremento de consumo de hot oil por el uso de la nueva estrategia de control sería de :

$\Delta Q_{normalizado\ de\ hot\ oil} = 1530.052\ bbl/dia$

Ahora, para asociar un costo a este incremento de consumo de hot oil, tomaremos como referencia el hecho que este hot oil es calentado en hornos de tiro inducido, que aprovechan la combustión del gas natural para calentar por radiación al aceite térmico; bajo las siguientes consideraciones:

Duty Teórico del horno : 54 MMBTU/hr

Eficiencia térmica : 85 %

Poder calorífico del fuel gas : 1078 BTU/scf

Precio del gas natural para consumo industrial en Lima: 3 US\$/MMBTU

Y la asignación de precio se realizará considerando el costo de energía necesario para calentar el $\Delta Q_{normalizado}$ de hot oil. Para esto calcularemos la demanda de energía asociada a este incremental de hot oil de la siguiente forma:

$$\Delta Duty\ acumulado\ reboiler = m_{hot\ oil} * Cp * \Delta T$$

Donde :

C_p = capacidad calorífica del aceite térmico

m = flujo másico del hot oil obtenido a partir del ΔQ normalizado de hot oil

ΔT = Diferencial de temperatura del hot oil en los reboilers (ingreso en 525 °F y salida en 340 °F como valores de diseño)

Debido a que el fluido de referencia es el aceite sintético Terminol 55, las propiedades a considerar serían:

C_p a temperatura de entrada : 0.649 BTU/lb.°F

C_p a temperatura de salida : 0.575 BTU/lb.°F

C_p promedio : 0.612 BTU/lb.°F

Densidad @ Std. Cond = 53.7 lb/ft³

Y para la conversión del flujo incremental de acetite a unidades másicas consideraremos:

Flujo másico en Lb/hr = factor de conversión * Densidad * ($\Delta Q_{normalizado}$ de hot oil)

Y factor de conversión = 0.233941

Evaluando tenemos :

$$\Delta \text{Duty Reboiler} = (0.233941 * 53.7 * 1530.052 * 0.612 * (525 - 340)) \text{ BTU/hr}$$

$$\Delta \text{Duty Reboiler} = 2176255,9 \text{ BTU /hr}$$

$$\Delta \text{Duty Reboiler} = 2.176 \text{ MMBTU/hr}$$

Esta energía sería la energía incremental a consumir en los reboiler debido al incremento de consumo de hot oil en el sistema.

Luego el costo asociado a esta energía sería :

$$\text{Costo energía incremental} = \left(\frac{\Delta \text{Duty Reboiler} * \text{Precio energía}}{\text{Eficiencia termica del horno}} \right)$$

Y evaluando tenemos :

$$\text{Costo energía incremental} = (2.176 \text{ MMBTU/hr} * 3 \text{ US\$/MMBTU}) / 0.85$$

$$\text{Costo energía incremental} = 7.68 \text{ US\$/hr}$$

Anualizando el costo incremental sería :

$$\text{Costo incremental anualizado} = 7.68 \text{ US\$/hr} * 365 \text{ días} * 24 \text{ hr/día}$$

$$\text{Costo incremental anualizado} = 67.28 \text{ MUS\$ / año}$$

Como resumen, en la Tabla 4.1 se muestra el impacto del sistema de control inferencial basado en red neuronal dinámica sobre el sistema productivo:

Tabla 4.1.- Estimación del Impacto del Esquema de Control Propuesto

Estimación de impacto	Valor	Unidades
Δ Producción	7443.86	Bbls/d
Ingreso incremental	108.68	MMUS\$/año
Costo incremental	67.28	MUS\$/año

4.3.- Conclusiones Preliminares

1.- Se ha evidenciado que el esquema propuesto de control inferencial basado en RNA dinámica, permite una mayor producción de condensado de fondo de columna en especificación, por lo que minimiza los costos de reprocesamiento del producto y genera un beneficio incremental respecto del modo de operación con control de temperatura de fondo de columna.

2.- Se ha evidenciado que el esquema de control propuesto, para mantener estable la calidad del producto de fondo, origina mucha oscilación en el caudal de aceite térmico requerido en los reboiler de la columna, con lo cual se incrementa la demanda de gas combustible asociada al calentamiento del aceite térmico, en hornos de tiro inducido.

3.- Se ha determinado que el beneficio económico asociado a la mejora en la calidad del producto de fondo de la columna de destilación supera por mucho al costo de gas combustible asociado a la mayor demanda de aceite térmico caliente hacia los reboiler.

4.- Los costos de los productos son referenciales y se tomaron como base en los precios establecidos para el gas combustible de uso industrial que se maneja en Lima; y para el caso del condensado estabilizado de fondo de la columna, se ha considerado un precio por debajo del precio de crudo WTI (alrededor de 85 US\$/bbl en Dic'12) ya que no está considerado como un producto terminado y comercializable dentro de algún esquema local.

El objetivo de la asignación de precios es establecer una magnitud de costo para los volúmenes de producción y consumo de hot oil, que permitan comparar los mismos y mostrar el posible impacto en el esquema productivo de una planta de procesamiento.



CONCLUSIONES GENERALES

Conclusión Principal.-

1.- Se ha diseñado un Sistema de Estimación y Control de Calidad del Producto de Fondo de una Columna de Destilación de Multicomponentes, basado en red neuronal artificial dinámica; verificándose precisión y rapidez del estimador neuronal para determinar la calidad del producto, y con ello se garantizó la factibilidad de introducir dicha estimación en un esquema de control, que disminuyó la variabilidad del parámetro de calidad, a pesar de las perturbaciones en las condiciones operativas del proceso.

Conclusiones Secundarias.-

1.- Se ha desarrollado un sistema de red neuronal artificial dinámica que estima la calidad del producto de fondo de una columna de destilación, y que considera entrenamiento de la red tipo Batch con metodología de retro propagación dinámica de errores (DBP, por sus siglas en inglés) teniendo como entradas al estimador neuronal las mediciones de diferentes variables del proceso del sistema, como son: temperaturas, flujos, presiones y la calidad del analizador online del proceso.

2.- Se ha evidenciado que el sistema de red neuronal dinámica, estima de forma muy precisa la calidad del producto de fondo de la columna de destilación; aun cuando se encuentra con condiciones operativas en el proceso, diferentes a las que uso el estimador neuronal para su entrenamiento. Desviaciones máximas del orden del 4% que se encontraron, entre el dato real y el estimado en la etapa de validación de la red neuronal, implican cambios insignificantes en el parámetro estimado (cambios en el 2do o 3er decimal) y no son limitantes para su uso en la estructura de control propuesta, como se demostró en la sección 3.5 del presente trabajo.

3.- A lo largo del presente trabajo se investigaron algunas variantes durante el entrenamiento del sistema de red neuronal artificial dinámica, como son:

- Uso de función de activación Sigmoidea tipo 2, sin modificación en su inclinación.
- Uso de función de activación Sigmoidea tipo 2, con modificación en su inclinación.
- Uso de función de activación Sigmoidea tipo 2, con modificación en su inclinación y variación del máximo error admitido en la estimación.
- Uso de función de activación Sigmoidea tipo 2, con modificación en su inclinación y variación del máximo error admitido en la estimación; con aumento del número de etapas de entrenamiento.

Y se seleccionó un modelo de estimador neuronal que considera: función de activación Sigmoidea tipo 2, con inclinación y 3 etapas de entrenamiento de la red, con lo cual se mejoró la precisión del estimador antes de someterlo a la validación del modelo, en la cual se obtuvo una precisión aceptable, como se menciona en el ítem anterior.

4.- Se investigó la robustez y rapidez del modelo de la red neuronal ya entrenado, mediante la validación del mismo, usando condiciones de operación diferentes a las empleadas durante el entrenamiento. Se obtuvo un comportamiento aceptable del estimador, que hizo la validación de 2207 conjuntos de datos en cerca de 10 seg.; y confirmó la factibilidad de uso dentro de una estructura de control, por la rapidez en la generación de datos respecto a los tiempos de los analizadores online (20-30 min).

5.- Se verificó que el sistema de control inferencial propuesto reduce la variación y dispersión de los datos, alrededor del valor objetivo de control ($\%C2/C3 = 1.9\%$) respecto a la performance que se alcanza con el esquema original de control, por regulación de la temperatura de fondo de columna únicamente. En el uso del esquema de control propuesto, se evidenció una reducción en la varianza en un 66% y la desviación estándar se redujo en un 42%; consiguiéndose una estabilidad importante en el esquema de control de calidad de producto de fondo de la columna de destilación.

6.- Se ha evidenciado que el beneficio económico asociado a la implementación del esquema de control propuesto, producto del aumento de producción de condensado en especificación; es bastante mayor respecto del costo de energía asociado a la demanda de aceite térmico en la columna, producto de la acción de control del esquema nuevo propuesto.



RECOMENDACIONES

Con miras a considerar el desarrollo de futuros trabajos e investigación, asociados al comportamiento del sistema de control basado en redes neuronales artificiales, se plantean las siguientes recomendaciones, que estuvieron fuera del alcance de este proyecto:

1.- Evaluar el comportamiento de la red neuronal frente a cambios en la composición de entrada al sistema de estabilización de condensado, para determinar la tolerancia que tiene el sistema para la estimación de calidad del producto de fondo. Esta perturbación no se probó dentro del presente proyecto de tesis y sería interesante evaluar hasta qué punto el sistema entrenado puede manejar dicho cambio sin requerir entrenarse nuevamente.

2.- Estudiar el beneficio asociado a implementar un neurocontrolador en adición al estimador de calidad basado en red neuronal dinámica, con la finalidad de estudiar si se produciría un impacto mayor en el incremento de producción de condensado.

Inclusive, si se profundiza en determinar la relación existente entre las variables de proceso, se podría analizar la conveniencia o no de implementar un controlador neuro-fuzzy a fin de especificar algunos criterios operativos que hagan la estructura de control más robusta.

3.- En el presente trabajo se trató de someter al sistema a distintas perturbaciones, algunas de ellas de forma simultánea y en algunos casos, a condiciones extremas que en una operación normal no se presentarían, con la finalidad de generar puntos de operación que cubran un rango de operación razonable. En una implementación real se pueden tomar datos del sistema de historización de variables para tal fin, pero asegurando que los instrumentos estén debidamente calibrados.

4.- Debido a que el modelo de red neuronal dinámica es un modelo experimental, es susceptible a errores cuando las condiciones de operación se alejan mucho de las condiciones bajo las que se hizo el entrenamiento del sistema, condicionando a que el sistema vuelva a ser entrenado para aprender la nueva dinámica del sistema.

5.- El proceso de aprendizaje de la red neuronal dinámica requiere que los cambios en los pesos sean proporcionales a los ratios de cambio del error respecto a los ratios de cambio de los pesos. Esa constante de proporcionalidad llamada ratio de aprendizaje ayuda a agilizar el proceso de convergencia de la red mediante la minimización de la función de costo y error relativo total. En el caso del modelo neuronal del presente trabajo, el óptimo de dicho valor fue de 0.1 considerando el uso de una función de activación sigmoidea tipo 2.

Por experiencias previas con redes neuronales usando funciones de activación sigmoideas y gaussianas, se ha evidenciado que el uso de sigmoideas permite el uso de ratios de aprendizajes más altos que aquellos que pueden usarse con funciones gaussianas (valores de hasta 0.1 frente a valores de 0.0001 para las funciones gaussianas).

REFERENCIAS BIBLIOGRÁFICAS

- 1.- Ming T. Tham (2000). *"Inferential Measurement and Control"*. Newcastle University, School of Chemical Engineering and Advanced Materials.
- 2.- Thompson, M. L., and Kramer, M. A (1994)., *"Modeling Chemical Processes Using Prior Knowledge and Neural Networks"*, AIChE Journal, Vol. 40, 1994, pp. 1328 - 1340.
- 3.- L. Fortuna, S. Grazinai, M.G.Xibilia (2004). *"Soft Sensors for Product Quality in Debutanizer distillation columns"*. Elsevier – Control Engineering Practice. May 25th, 2004.
- 4.- Vijander Singh, Indra Gupta, H.O.Gupta (2006). *"ANN-based estimator for distillation using Levenberg-Marquardt Approach"*. Elsevier – Engineering Applications of Artificial Intelligence. September 11th, 2006.
- 5.- Béla G. Lipták (2006). *"Instrument Engineers' Handbook"*, 4th Ed, Ch. 2 Control Theory, 2.18 Neural Network for Process Modeling. Taylor and Francis, New York, 2006, pp. 253-264.
- 6.- M.W. Foley (2005). *"Composition Estimation in an industrial distillation column"*. Department of Chemical Engineering, University of the West Indies.
- 7.- J. Fernandez de Canete, S.Gonzales-Perez and P. Del Saz-Orozco (2008). *"Software tools for system identification and control using neural networks in Process Engineering"*. World Academy of Science, Engineering and Technology 47. 2008
- 8.- Wen Yu, Alexander S. Poznyak, Jaime Alvarez (1999). *"Neuro Control for Multicomponent Distillation Column"*. 14th World Congress of IFAC, 1999
- 9.- M.A.Torres, M.E.Pardo, J.M.Pupo, L.Boquete, R.Barea, L.M.Bergasa (2000). *"Neurocontrol of a Binary Distillation Column"*. European Symposium of Artificial Neural Network, April 2000.
- 10.- Moonyong Lee and Sunwon Park (2000). *"Process Control Using a Neural Network combined with the conventional PID controllers"*. ICASE (The Institute of Control, automation and System Engineers), Korea. Vol 2 N°3. September 2000.
- 11.- Vijander Singh, Indra Gupta, H.O.Gupta, Puneet Gulati (2002). *"Online Estimator for Distillation Column usnig ANN"*.Department of Electrical Engineering, Indian Institute of Technology Roorkee, Roorkee, Uttaranchal - India.2002.
- 12.- Hesam Komari Alaei, Karim Salahshoor, Hamed Komari Alaei (2010). *"Model Predictive Control of Distillation Column based recursive parameter estimation method using Hysys Simulation"*. 2010 International Conference on Intelligent Computing and Cognitive Informatics.
- 13.- Yahya Chetouani (2007). *"Using Artificial Neural networks for the Modelling of a Distillation Column"*. International Journal of Computer Science & Applications. 2007 Technomathematics Research Foundation. Vol. 4 Issue 3, pp 119-133.
- 14.- L.O.Werle, J.G.Teleken, C.Marangoni, C.Sayer, R.A.F.Machado (2009). *"Estimation of Distillation product compositions using neural networks : Application of Levenberg – Marquardt algorithm"*. Department of Chemical Engineering – Federal University of Santa Catarina, Technological Center – University Campus – Trindade. Florianopolis – Brazil.
- 15.- Khairiyah Mohd. Yusof, Fakhri Karray, Peter L. Douglas (2003). *"Development of Neural Models for a Crude Oil Distillation Column"*. Journal Teknologi – Universiti Teknologi Malaysia. Jun 2003.

- 16.- Totok R. Biyanto, Totok Suhartanto and Bambang L. Widjiantoro (2007). "*Predicting Liquid – Vapor (LV) composition at Distillation Column*". Songklanakarin J.Sci. Technol, 2007. Indonesia.
- 17.- Sandhya Samarasinghe (2006). "*Neural Network for Applied Sciences and Engineering*". Auerbach Publications. Taylor & Francis Group. 2006
- 18.- A. Morán (2011). "*Curso de Redes Neuronales*". Maestría en Ingeniería de Control y Automatización. Pontificia Universidad Católica del Perú. 2011.
- 19.- John M. Campbell (1998). "*Gas Conditioning and Processing*". Vol. 1 : The Basic Principles. 8th Ed, Ch. 9, Process Control and Instrumentation, 1998, pp. 249-282.
- 20.- John M. Campbell (1998). "*Gas Conditioning and Processing*". Vol. 2 : The Equipment Modules. 8th Ed, Ch. 17, Fractionation and Absorption Fundamentals, 1998, pp. 267-301.
- 21.- Miller, T. W. III, Sutton, R. S., and Werbos, P. J. (1990), "*Neural Networks for Control, Cambridge*", MA: MIT Press, 1990.
- 22.- William L. Luyben (1990). "*Process Modeling Simulation and Control For Chemical Engineers*". Singapore, McGraw-Hill, 2nd Ed., 1990.
- 23.- William L. Luyben, Bjorn D. Tyreus, Michael L. Luyben (1999). "*Plant Wide Process Control*" . McGraw-Hill, 1999.
- 24.- Kroschwitz, Jacqueline I., and Mary Howe-Grant (1993). "*Encyclopedia of Chemical Technology*". 4th Ed., vol. 12 (Natural Gas), John Wiley and Sons, Inc., New York, 1993.
- 25.- Tussing, Arlon R., and Bob Tippee (1995). "*The Natural Gas Industry: Evolution, Structure, and Economics*". 2nd Ed, PennWell Publishing, Tulsa, OK, 1995.
- 26.- William L. Luyben. (2006). "*Distillation Design and Control Using Aspen Simulation*". McGraw-Hill.
- 27.- Michael L. Luyben; William L. Luyben (1997). "*Essentials of Process Control*". Singapore, McGraw-Hill, 1997.
- 28.- Ljung L. (1999). "*System Identification –Theory for the Use*". 2nd Ed., Englewoods Cliffs , NJ: PrenticeHall. 1999.
- 29.- Terrence L. Fine. (1999) "*Feedforward Neural Network Methodology*". Springer, 1999.
- 30.- Omid Omidvar, David L. Elliott (1997). "*Neural Systems for Control*". Academic Press, 1997.
- 31.- L. Fortuna, S. Grazinai, A. Rizzo, M.G.Xibilia (2007). "*Soft Sensors for Monitoring and Control of Industrial Processes*". Springer, 2007.
- 32.- Oliver Nelles (2000). "*Non Linear System Identification – From Clasical Approaches to Neural Networks and Fuzzy Models*". Springer, 2000.