

**DMC ADAPTATIVO PARA PROCESOS NO LINEALES UTILIZANDO
INTELIGENCIA ARTIFICIAL**

JOSÉ DAVID POSADA AGUILAR

TESIS DE PREGRADO
Requisito para optar por el título de INGENIERO ELECTRÓNICO

DIRECTOR:
Ph.D MARCO ENRIQUE SANJUAN MEJÍA

UNIVERSIDAD DEL NORTE
DIVISIÓN DE INGENIERÍAS
DEPARTAMENTO DE INGENIERÍA ELECTRÓNICA Y ELÉCTRICA
BARRANQUILLA
2006

**DMC ADAPTATIVO PARA PROCESOS NO LINEALES UTILIZANDO
INTELIGENCIA ARTIFICIAL**

APROBADO POR:

**Ph.D MARCO ENRIQUE SANJUÁN MEJÍA
DIRECTOR DE LA TESIS**

**Msc. ALFREDO ANDRÉS GUTIERREZ VIVIUS
CORRECTOR**

**ING. MIGUEL ANGEL SOTAQUIRÁ
COORDINADOR DE PROGRAMA**

**Ph.D JUAN CARLOS VELEZ
JEFE DE DEPARTAMENTO DE
INGENIERÍA ELECTRÓNICA Y ELÉCTRICA**

AGRADECIMIENTOS

Quiero agradecer primero a Dios por darme la claridad, tranquilidad y paciencia para llevar a cabo este proceso investigativo. Igualmente agradecer a mi familia por brindarme el apoyo necesario en momentos cruciales.

A mi director Marco por soportarme, acompañarme y ayudarme a desarrollar y culminar con éxito esta labor, así como de valorar esta labor investigativa no siempre bien apreciada.

Por último agradecer a compañeros de trabajo que acompañaron este proceso y aportaron ideas al mismo como Ramiro Chamorro.

Quiero agradecer especialmente a Graciela Angulo por apoyarme y no dejarme desfallecer cuando las ganas parecían acabar.

CONTENIDO

	pág
INTRODUCCIÓN	13
1. PLANTEAMIENTO DEL PROBLEMA	15
2. ANTECEDENTES.....	16
3. OBJETIVOS.....	18
3.1. Objetivo General.....	18
3.2. Objetivos Específicos.....	18
4. ALCANCES.....	19
5. LIMITACIONES	20
6. JUSTIFICACIÓN E IMPACTO ESPERADO	21
7. MARCO TEÓRICO	22
7.1. CONCEPTOS BÁSICOS ACERCA DEL CONTROL AUTOMÁTICO DE PROCESOS	22
7.2. ESTRATEGIAS DE CONTROL CLÁSICO.....	23
7.2.1. CONTROLADORES PID.	23
7.2.2. CONTROL ADAPTATIVO.....	25
7.2.3. CONTROL PREDICTIVO BASADO EN MODELOS (<i>MPC</i>).....	26
7.2.4. CONTROL POR MATRIZ DINÁMICA (<i>DMC</i>).....	27
7.3. REDES NEURONALES ARTIFICIALES (RNA).....	30
7.3.1. COMPONENTES BÁSICOS DE UNA RNA.	30
7.3.2. REGULATED ACTIVATION WEIGHTS NEURAL NETWORK (<i>RAWNN</i>).	32
7.3.3. MODELO NO LINEAL EN REDES NEURONALES.....	34
7.4. SISTEMA DE INFERENCIA DIFUSO TAKAGI-SUGENO-KANG (TSK).....	34
7.5. ALGORITMOS EVOLUTIVOS.....	36
7.5.1. CODIFICACIÓN DE LAS SOLUCIONES.	37
7.5.2. OPERADORES EVOLUTIVOS.	37
8. DESCRIPCIÓN GENERAL DEL SISTEMA.....	40
8.1. IDENTIFICACIÓN.....	40

	pág
8.2. SINTONIZACIÓN DE LOS CONTROLADORES.....	40
8.3. ESTRATEGIA ADAPTATIVA	41
9. DESCRIPCIÓN DETALLADA DEL SISTEMA	45
9.1. INSTRUMENTACIÓN DE LOS PROCESOS.....	45
9.1.1. TANQUE REACTOR CON TANQUE DE HOMOGENIZACIÓN.	45
9.1.2. REACTOR NEUTRALIZADOR DE pH.	46
9.2. IDENTIFICACIÓN DE LOS PROCESOS Y SINTONIZACIÓN DE LOS CONTROLADORES PID Y DMC	48
9.2.1. IDENTIFICACIÓN DE LOS PROCESOS.	48
9.2.2. SINTONIZACIÓN DE LOS CONTROLADORES PID	51
9.2.3. SINTONIZACIÓN DE LOS CONTROLADORES DMC.	52
9.3. DMC ADAPTATIVO.....	54
9.3.1. MODELO NO LINEAL EN REDES NEURONALES.	54
9.3.2. DMC CON MODELO DE REFERENCIA.	59
9.3.3. ALGORITMO EVOLUTIVO: SPEA II.....	61
9.3.4. TOMA DE DECISIONES SOBRE EL FRENTE PARETO.	64
10. PRUEBAS Y RESULTADOS.....	68
10.1. PRUEBAS ANTE CAMBIOS EN EL PUNTO DE OPERACIÓN	68
10.1.1. TANQUE REACTOR CON TANQUE DE HOMOGENIZACIÓN.	68
10.1.2. REACTOR NEUTRALIZADOR DE pH SISO.	72
10.2. PRUEBAS ANTE CAMBIOS EN EL PUNTO DE OPERACIÓN, SUMANDO RUIDO EN LA SEÑAL DE LOS SENSORES	77
10.2.1. TANQUE REACTOR CON TANQUE DE HOMOGENIZACIÓN.	77
10.2.2. REACTOR NEUTRALIZADOR DE pH SISO.....	79
10.2.3. REACTOR NEUTRALIZADOR DE pH MIMO.	80
10.3. COMPARACIÓN ENTRE LOS SISTEMAS DE TOMA DE DECISIONES SOBRE EL FRENTE PARETO, APLICADO EN EL REACTOR NEUTRALIZADOR DE pH MIMO.....	85

	pág
11. ADMINISTRACIÓN DEL PROYECTO.....	87
12. CONCLUSIONES.....	88
13. RECOMENDACIONES.....	89
BIBLIOGRAFÍA.....	90

LISTA DE TABLAS

	pág
Tabla 1. Ecuaciones de sintonía para el DMC.....	30
Tabla 2. Sintonización del PID para el tanque reactor.	52
Tabla 3. Sintonización del PID para reactor neutralizador de pH.	52
Tabla 4. Sintonización del DMC para el tanque reactor.	53
Tabla 5. Sintonización del DMC para reactor neutralizador de pH SISO.....	53
Tabla 6. Sintonización del DMC para reactor neutralizador de pH MIMO.....	54
Tabla 7. Regresores seleccionados para los modelos no lineales.	57
Tabla 8. Base de reglas del sistema de inferencia difuso TSK.	66
Tabla 9. Parámetros para la estrategia adaptativa en el tanque reactor con tanque de homogenización.	69
Tabla 10. Comparación del IAE para las distintas estrategias ante cambios en el punto de operación para el tanque reactor con tanque de homogenización.	72
Tabla 11. Parámetros para la estrategia adaptativa en el reactor neutralizador de pH SISO.....	73
Tabla 12. Comparación del IAE para las distintas estrategias ante cambios en el punto de operación para el reactor neutralizador de pH SISO.....	76
Tabla 13. Comparación del IAE para las distintas estrategias ante cambios en el punto de operación para el tanque reactor con tanque de homogenización, sumando ruido a la señal de los sensores.....	78
Tabla 14. Comparación del IAE para las distintas estrategias ante cambios en el punto de operación para el reactor neutralizador de pH SISO, sumando ruido a la señal de los sensores.....	80
Tabla 15. Parámetros de la estrategia adaptativa para el reactor neutralizador de pH MIMO.....	81
Tabla 16. Comparación del IAE para las distintas estrategias ante cambios en el punto de operación para el reactor neutralizador de pH MIMO, sumando ruido a la señal de los sensores.	84
Tabla 17. Comparación del IAE para los distintos sistemas de decisión, para el reactor neutralizador de pH MIMO.....	86

LISTA DE FIGURAS

	pág
Figura 1. Esquema básico de un lazo de control por realimentación.....	22
Figura 2. Control adaptativo directo.....	25
Figura 3. Control adaptativo indirecto.	26
Figura 4. Diagrama de bloques del MPC.....	28
Figura 5. Componentes básicos de una neurona artificial.	31
Figura 6. Ejemplo de la estructura de una RAWNN (4 entradas, 3 neuronas en la capa oculta, una neurona en la capa de salida.	33
Figura 7. Función de pertenencia para alta.....	35
Figura 8. Configuración básica de un sistema de inferencia difuso TSK.	36
Figura 9. Diagrama de flujo de la estrategia adaptativa propuesta.	42
Figura 10. Diagrama de Flujo del algoritmo de control DMC.	43
Figura 11. Diagrama de flujo del SPEA II implementado.	44
Figura 12. Respuesta del tanque reactor ante una entrada escalón.	49
Figura 13. Comparación entre la salida del proceso real y de la aproximación FOPDT.	49
Figura 14. Diagrama de bloques de un sistema MIMO 2 x 2.....	50
Figura 15. Comparación entre la salida uno (izquierda) y dos (derecha) del reactor neutralizador de pH y la aproximación FOPDT para un cambio en la entrada uno.	51
Figura 16. Comparación entre la salida uno (izquierda) y dos (derecha) del reactor neutralizador de pH respectivamente y la aproximación FOPDT para un cambio en la entrada dos.	51
Figura 17. Diagrama general de la estrategia adaptativa.	54
Figura 18. Datos para el conjunto de entrenamiento (izquierda) y validación (derecha), respectivamente del tanque reactor con tanque de homogenización. .	55
Figura 19. Datos para el conjunto de entrenamiento (izquierda) y validación (derecha), del reactor neutralizador de pH SISO.	56
Figura 20. Datos para el conjunto de entrenamiento (izquierda) y validación (derecha), del reactor neutralizador de pH MIMO para cambios en la entrada uno.	56
Figura 21. Datos para el conjunto de entrenamiento (izquierda) y validación (derecha), del reactor neutralizador de pH MIMO para cambios en la entrada dos.	57
Figura 22. Diagrama de flujo para el cálculo de las funciones objetivo.	63
Figura 23. Diagrama general del sistema de inferencia difuso TSK usado.	64
Figura 24. Funciones de pertenencia de las entradas del sistema de inferencia difuso TSK.....	65
Figura 25. Respuesta en lazo cerrado del tanque reactor con tanque de homogenización ante cambios en el punto de operación.....	70
Figura 26. Señal de salida de los controladores ante cambios en la referencia para el tanque reactor con tanque de homogenización.	70

	pág
Figura 27. Error de modelo del DMC y del DMC adaptativo para cambios en el punto de operación en el tanque reactor con tanque de homogenización.	71
Figura 28. Comparación entre la salida del modelo de referencia (izquierda) y de la RNA (derecha) contra la del proceso.	71
Figura 29. λ (Izquierda) y γ (derecha) en cada período de muestreo.	72
Figura 30. Respuesta en lazo cerrado de reactor neutralizador de pH SISO ante cambios en el punto de operación.	74
Figura 31. Señal de salida de los controladores ante cambios en el punto de operación para el reactor neutralizador de pH SISO.	74
Figura 32. Error de modelo del DMC y del DMC adaptativo para cambios en el punto de operación en el reactor neutralizador de pH SISO.	75
Figura 33. Comparación entre la salida del modelo de referencia (izquierda) y de la RNA (derecha) contra la del reactor neutralizador de pH.	75
Figura 34. λ (Izquierda) y γ (derecha) en cada período de muestreo.	76
Figura 35. Respuesta en lazo cerrado del tanque reactor con tanque de homogenización (izquierda) y señal de salida del controlador (derecha), ante cambios en el punto de operación.	77
Figura 36. Comparación entre la salida del modelo de referencia (izquierda) y de la RNA (derecha) contra la del tanque reactor con tanque de homogenización.	78
Figura 37. Respuesta en lazo cerrado del reactor neutralizador de pH SISO (izquierda) y señal de salida de los controladores (derecha) ante cambios en el punto de operación.	79
Figura 38. Comparación entre la salida del modelo de referencia (izquierda) y de la RNA (derecha) contra la del reactor neutralizador pH.	79
Figura 39. Respuesta en lazo cerrado de las salidas uno (izquierda) y dos (derecha) del reactor neutralizador de pH MIMO ante cambios en el punto de operación.	80
Figura 40. Señal de salida de los controladores ante cambios en el punto de operación para el reactor neutralizador de pH MIMO.	82
Figura 41. Error de modelo para la salida uno del reactor neutralizador de pH MIMO, para el DMC y el DMC adaptativo para cambios en el punto de operación.	82
Figura 42. Comparación entre la salida del modelo de referencia uno (izquierda) y dos(derecha) contra la salida uno y dos del reactor neutralizador de pH MIMO.	83
Figura 43. Comparación entre la salida uno (izquierda) y dos (derecha) de la RNA contra la salida uno y dos del reactor neutralizador de pH MIMO.	83
Figura 44. λ_1 (Izquierda) y λ_2 (derecha) en cada período de muestreo.	84
Figura 45. γ_1 (Izquierda) y γ_2 (derecha) en cada período de muestreo.	84
Figura 46. Respuesta de las salidas uno (derecha) y dos (izquierda) en lazo cerrado modificando los sistemas de toma de decisiones sobre el frente pareto.	85
Figura 47. Señal de control modificando los sistemas de decisión sobre el frente pareto.	85

LISTA DE ANEXOS

	pàg
ANEXO A	92
ANEXO B	95
ANEXO C	97
ANEXO D	99
ANEXO E	105
ANEXO F	108
ANEXO G	123

SIGLAS Y SÍMBOLOS

DMC	controlador dinámico matricial.
RNA	redes neuronales artificiales.
GA	algoritmos genéticos.
MPC	control predictivo basado en modelos.
FL	lógica difusa.
TSK	takagi-sugeno-kang.
FIS	sistema de inferencia difuso.
FDM	sistema de toma de decisiones con lógica difusa.
FRB	conjunto base de reglas difusas.
GPC	control predictivo generalizado.
PID	controlador Proporcional integral derivativo.
FOPDT	función de transferencia de primer orden más tiempo muerto.
MRAC	control adaptativo por modelo de referencia.
RAWNN	random activation weights neural network.
RLS	mínimos cuadrados recursivos.
OLS	mínimos cuadrados estándar.
pH	potencial de hidrógeno.
SISO	una entrada, una salida.
MIMO	múltiples entradas, múltiples salidas.
FC	falla cerrada.
FO	falla abierta.
CO	señal de salida del controlador.
TO	señal de salida del sensor-transmisor.
DCS	sistemas de control descentralizado.

RESUMEN

En esta investigación, se desarrolló una estrategia adaptativa que consta de tres bloques funcionales: un controlador dinámico matricial (DMC) con modelo de referencia, un modelo no lineal en redes neuronales y un algoritmo de optimización multiobjetivo llamado Strength Pareto Evolutionary Algorithm (SPEA) II.

La estrategia se basa en la integración y adecuación de cada uno de los algoritmos a la solución del problema de control adaptativo. Aquí el algoritmo evolutivo se encarga de encontrar los mejores parámetros para el controlador DMC en cada período de muestreo, basándose en la respuesta que la red neuronal le entrega al mismo, simulando un conjunto de controladores sobre esta, minimizando el error cuadrático de seguimiento y las acciones de control.

La estrategia se evaluó en dos procesos. El primero fue un tanque reactor con tanque de homogenización y el segundo un reactor neutralizador de pH. La estrategia SISO se probó para ambos procesos obteniendo mejores resultados que el PID en cuanto al índice de rendimiento IAE para cambios en el punto de operación, mientras que para perturbaciones se observó una respuesta más lenta que la de este. La estrategia MIMO solo fue probada en el reactor neutralizador de pH, contrastando únicamente la estrategia adaptativa con el DMC estándar observando mejores resultados que para este en cuanto al índice de rendimiento IAE. Finalmente un mecanismo de decisión inteligente sobre el frente de Pareto usando un FDM TSK fue probado sobre la estrategia MIMO observando buenos resultados respecto al sistema de decisión basado en una suma ponderada fija.

INTRODUCCIÓN

En el contexto investigativo actual, se encuentran muchas estrategias de control desarrolladas para resolver problemas que involucran la dinámica no lineal inherente de todo sistema real.

El uso de las redes neuronales y la lógica difusa, ha sido una solución al momento de modelar la dinámica no lineal de los sistemas e integrarla con estrategias de control. El control adaptativo, el control predictivo y el control robusto se han servido de estas técnicas de inteligencia artificial, a fin de resolver el problema de control no lineal.

El problema de control no lineal consiste en la integración de la dinámica no lineal inherente de todo sistema real en la estrategia de control, a fin de lograr la respuesta deseada de un sistema en lazo cerrado para distintos puntos y modos de operación en los cuales, los modelos lineales pierden su validez y por ende las estrategias de control basadas en los mismos degeneran su respuesta o fallan al momento de controlar al sistema.

En esta investigación se usan tres técnicas de inteligencia artificial a saber: redes neuronales, algoritmos evolutivos multiobjetivo y lógica difusa, en conjunto con una estrategia de control predictivo llamada control dinámico matricial o *DMC*. Todas estas estrategias son integradas en un algoritmo de control adaptativo de modo que se pueda resolver el problema de control no lineal en dos procesos distintos: el tanque reactor con tanque de homogenización y el reactor neutralizador de pH.

Al algoritmo de control lineal *DMC* se le añadió una capa de adaptación basada en inteligencia artificial usando los algoritmos anteriormente mencionados. Las redes neuronales se usan para modelar la dinámica no lineal del sistema, mientras que el algoritmo evolutivo multiobjetivo se usó para hallar los mejores parámetros del controlador en cada período de muestreo basándose en la respuesta de la red y buscando minimizar el error cuadrático de seguimiento y el cuadrado de los movimientos del controlador. Por último, la lógica difusa fue usada para tomar una decisión sobre el frente de Pareto arrojado por el algoritmo evolutivo, teniendo en cuenta el estado actual del sistema, de modo que se escogiera lo más conveniente en cada instante de tiempo.

Para realizar una adecuada exposición del proceso investigativo se muestran los antecedentes del problema en donde se exponen algunos de los trabajos anteriores en esta línea de investigación. Igualmente se justifica el porqué de la realización del proyecto exponiendo el problema la justificación y los objetivos del mismo para ubicar al lector en los que se buscó con este trabajo.

Seguidamente tenemos al marco teórico, en donde se hace referencia a los conceptos básicos usados en el desarrollo sin profundizar mucho, teniendo en cuenta que podríamos

escribir un libro entero de cada algoritmo usado en el trabajo. Por tanto se limita brevemente a describir desde el punto de vista matemático y funcional a las estrategias dando solo un breve vistazo a las aplicaciones en las cuales se puede ver a cada una.

Después de esto se exponen las deducciones requeridas para la obtención de los modelos matemáticos en ecuaciones diferenciales de los procesos usados, así como su instrumentación. También se muestra el método usado para la sintonización de los controladores empleados en la estrategia y los que se usan para contrastar a la misma. Así mismo se aborda la obtención del modelo no lineal en redes neuronales escogiendo las entradas y salidas de la misma así como el número de nodos en su capa oculta. Los parámetros usados en el algoritmo evolutivo así como la manera como se integró el mecanismo de toma de decisiones sobre el frente de pareto se muestran en la parte final de esta sección.

A continuación de lo anterior, se muestra el rendimiento de la estrategia respecto a sus contrincantes: El PID digital y el DMC estándar. Se corrobora que su comportamiento ante cambios en el punto de operación es superior al de estos dos, mientras que ante cambios en las perturbaciones no lo es, debido a que su repuesta se hace lenta.

Por último se concluye resumiendo los resultados y mostrando aportes realizados, para recomendar posibles mejoras y nuevos aportes a la estrategia.

1. PLANTEAMIENTO DEL PROBLEMA

Desde hace muchos años el control de procesos no lineales ha sido una fuente de investigación y desarrollo de estrategias de compensación orientadas a obtener el mejor rendimiento de un sistema que se ha diseñado o construido para una tarea específica.

El control de estos procesos se ha abordado con estrategias de todo tipo, la más conocida es la acción PID, la cual es usada ampliamente en el ámbito industrial por su sencillez y sus resultados aceptables. Sin embargo, para determinados procesos, los resultados que se obtienen por medio de la estrategia antes mencionada no son los mejores, en cuanto a la productividad y estándares de calidad; por tanto, surgen otros tipos de controladores capaces de cumplir con las restricciones específicas del problema a tratar.

Dichos modelos, son nuevas estrategias de control en las que podemos incluir al adaptativo y al predictivo, siendo este último, en su forma DMC (*Dynamic Matrix Control*) más usado en el ámbito industrial que su contraparte GPC (*Generalized Predictive Control*).

No obstante el DMC se basa en la obtención de un modelo lineal del proceso y, por tanto, en muchas ocasiones no puede compensar satisfactoriamente ante perturbaciones no modeladas; o por el contrario, controlar al sistema fuera del punto de operación para el cual se identificó. Por lo anterior, su adaptación se necesita en procesos no lineales que modifican su dinámica debido a perturbaciones o a respuestas inherentes a sus no linealidades.

La adaptación se puede realizar de muchas maneras, sin embargo, técnicas de inteligencia artificial como los algoritmos genéticos y las redes neuronales han mostrado ser de gran utilidad para tal fin, debido a que evitan un desarrollo matemático, en muchas ocasiones extenuante para obtener los resultados deseados, logrando resultados comparables con estrategias tales como el control adaptivo por modelo de referencia basado en el gradiente descendiente (MRAC).

Por todo lo anterior el planteamiento de una estrategia de adaptación bajo estos algoritmos, se hace atractiva e interesante para su implementación.

2. ANTECEDENTES

El control predictivo por modelos o *MPC* por sus siglas en inglés se refiere a una clase de algoritmos de control que calculan una secuencia de ajustes en la variable manipulada de modo que se optimice el comportamiento futuro de la planta, con base en predicciones del comportamiento de esta. Originalmente fue desarrollado para cumplir con las necesidades en plantas de energía y en refinerías de petróleo. Además, esta tecnología puede ser encontrada en una gran variedad de aplicaciones industriales, incluyendo plantas químicas, de procesamiento de alimentos, automóviles, plantas de papel, etc.

Por todo lo anterior el MPC se ha convertido en una estrategia muy atractiva para el desarrollo de sistemas de control, por lo tanto, no es extraño que en el inicio de los 70 ingenieros de la *Shell Oil* desarrollaran una aplicación de este esquema. Cutler y Ramaker presentaron los detalles de un esquema de control multivariable sin restricciones al que le llamaron *Dynamic Matrix Control* (DMC) o en español control dinámico matricial en el marco del *Joint Automatic Control Conference* en 1980 casi 7 años después de la primera aplicación del mismo en 1973. Este algoritmo se basa en una respuesta escalón lineal como modelo de la planta, así como una función objetivo cuadrática, evaluada sobre un horizonte de predicción finito. No obstante las anteriores no son las únicas características del DMC pero si, las más importantes para hacer una diferenciación de otros esquemas de control predictivo.

Sin embargo, debido a las características más importantes resaltadas anteriormente se puede ver que este algoritmo, debido a que el modelo con el que trabaja es lineal, puede presentar inconvenientes al momento de ser implementado en procesos no lineales que requieran ser trabajados en un rango amplio de operación y, por tanto, debido a su dinámica no lineal, esta no pueda ser descrita adecuadamente por el modelo de respuesta escalón y, por consiguiente, falle al momento de controlar.

Por la anterior razón, distintos esquemas se han probado con el fin de solucionar este inconveniente, uno de ellos es diseñar un esquema de adaptación para dicho controlador.

Lo primero que se debe tener en cuenta es que cuando se habla de adaptación se tienen muchas posibilidades, sin embargo, los dos grandes grupos son el control adaptativo indirecto y directo. El control adaptativo indirecto se basa en la estimación de los parámetros de la planta, de modo que con una ley de control predefinida, se obtengan los parámetros del controlador requeridos para obtener la respuesta deseada. Mientras que el control adaptativo directo, basándose en las entradas y salidas del proceso así como en la referencia del mismo, por medio de un algoritmo que puede ser obtenido de distintas formas, se obtienen los parámetros del controlador adecuados para seguir la referencia, de la mejor forma posible.

Uno de los trabajos usando control adaptativo directo del DMC es el de [2], el cual desarrolla una estrategia de modelos múltiples y después una selección de los mismos observando el estado actual del proceso, y escogiendo el modelo que mejor represente dicho estado.

Otros enfoques han sido trabajados al interior de la universidad del norte, en donde en su mayoría, han usado el diseño de experimentos como una herramienta para obtener ecuaciones que relacionen la dinámica del proceso, con cambios en los parámetros del controlador, de manera que se pueda realizar una adaptación en línea de los mismos.

El trabajo de [1] muestra una estrategia de adaptación para procesos de ganancia variable ante perturbaciones, empleando la metodología de diseño factorial, en conjunto con el método de regresión lineal, y una medida del error de modelaje, como parámetro de referencia en la obtención del modelo matemático requerido para la adaptación del DMC ante condiciones variantes de ganancia.

En [3] se observa una estrategia similar a la anterior, pero en este caso, aplicada a procesos con ganancia no lineal. Para tal efecto se realizaron una serie de experimentos con un modelo de proceso ideal, de las cuales se infirieron unas relaciones matemáticas empíricas, que se implementaron en el control DMC para obtener los resultados deseados sin perder las ventajas que la estrategia misma nos proporciona como lo es, el manejo de restricciones y el ajuste de funcionamiento por medio del error de modelaje.

3. OBJETIVOS

3.1. Objetivo General.

- Diseñar una estrategia de adaptación para los parámetros móviles de supresión de un DMC, usando inteligencia artificial aplicada a procesos no lineales invariantes en el tiempo.

3.2. Objetivos Específicos.

- Medir el rendimiento de la estrategia adaptativa para el DMC sobre el modelo de simulación de un reactor con tanque de homogenización, respecto al obtenido por un controlador de la familia PID (P, PI, PD, PID), mediante el índice de rendimiento IAE.
- Obtener un modelo en redes neuronales del proceso.
- Realizar un algoritmo genético para la estrategia de adaptación.
- Realizar una simulación de la estrategia propuesta en una plataforma de software especializado como MATLAB, de modo que se puedan verificar los resultados.

4. ALCANCES

- Como elemento de contraste se utilizará el índice de rendimiento dinámico IAE.
- Se realizará una simulación del esquema de adaptación completo, es decir, de la estrategia de adaptación para el controlador, al igual que la de este último regulando el proceso.
- Se realizará la interconexión de todos los módulos software requeridos para la simulación.
- Se diseñará una estrategia de control adaptativo directo.
- Los algoritmos de inteligencia artificial se usarán para adaptar uno de los parámetros del controlador y para modelar el comportamiento dinámico del proceso

5. LIMITACIONES

- La estrategia de control se aplicará sólo al proceso escogido.
- No se adaptará ningún parámetro del controlador distinto a los factores de supresión.
- No se realizará ningún tipo de plataforma hardware para el controlador y el esquema de adaptación, solo será probado en software.
- El uso de otros algoritmos para la adaptación es de libre escogencia, es decir, se contempla el uso de otros algoritmos sin ser obligatorio su uso.

6. JUSTIFICACIÓN E IMPACTO ESPERADO

El desarrollo de nuevas estrategias de control se justifica en la medida en que estas aportan nuevas soluciones a los retos en el área, resolviendo problemas que han sido analizados desde muchas perspectivas distintas (control robusto, control óptimo, etc...) y que en muchas ocasiones no han sido resueltos de manera satisfactoria.

Debido a esto, propuestas como la que se desarrolla en esta investigación pueden servir para profundizar en conceptos de control avanzado como el adaptativo y el predictivo, así mismo como para crear una línea de investigación en estos temas y, por tanto, fomentarle inquietudes en el tema a los estudiantes de la universidad.

No obstante, dentro de los alcances dentro del mundo académico se espera la publicación en un *journal* en el ámbito nacional o internacional, así mismo como su exposición en conferencias, y así compartir los resultados de la investigación con el resto de la comunidad académica nacional e internacional.

7. MARCO TEÓRICO

7.1. CONCEPTOS BÁSICOS ACERCA DEL CONTROL AUTOMÁTICO DE PROCESOS

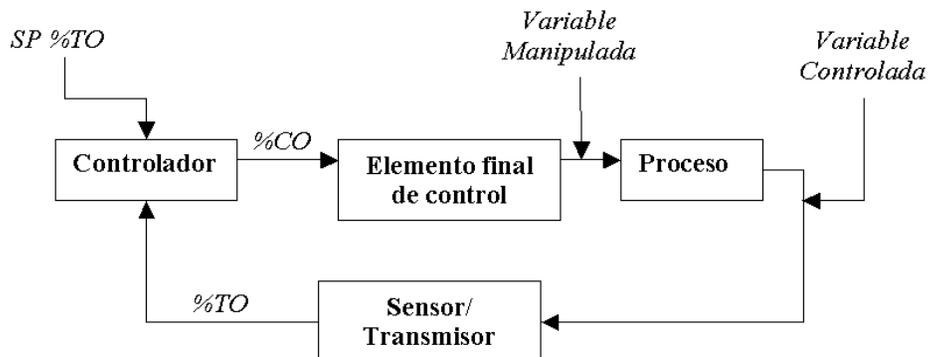
Los procesos son dinámicos por naturaleza, por tanto, las variables de los mismos deben ser reguladas de manera que las condiciones de diseño sean alcanzadas. Debido a esto acciones apropiadas deben ser tomadas de modo que se cumplan dichas condiciones.

El objetivo del control de procesos es mantener las variables de proceso (temperatura, flujo, concentración, etc....) dentro de un punto de operación específico. El control de esas variables esta altamente relacionado con mantener estándares de calidad, tasas de producción y seguridad.

La primera tarea de un sistema de control automático es la medición de la variable a controlar. Dicha medición es efectuada a través de un sensor. Usualmente, el sensor es conectado a un transmisor el cual se encarga de acondicionar la señal de forma que el pueda ser transmita y entendida por el controlador. Una vez el controlador recibe la señal del transmisor la compara con el valor requerido o *set point* y dependiendo del resultado de dicha comparación, decide que hacer con la variable manipulada para llevar o mantener a la variable controlada en su punto de operación. Esta decisión se traduce en una señal de salida, la cual va al elemento de control final, el cual modifica a la variable manipulada que afecta a la variable de proceso. Esta estrategia de control es conocida como control por realimentación y es mostrada en la Figura 1.[13]

Cualquiera de los componentes anteriormente nombrados debe estar en un lazo de control. Una vez la acción correctiva es ejecutada la variable medida debe ser modificada de modo que se pueda tomar la siguiente decisión correctiva. En caso de que sea así se diría que el proceso se encuentra en lazo abierto.

Figura 1. Esquema básico de un lazo de control por realimentación



Tomado de [13]

7.2. ESTRATEGIAS DE CONTROL CLÁSICO

En esta sección se presentan cuatro estrategias de control, llamadas clásicas para diferenciarlas de aquellas basadas en algoritmos de inteligencia artificial llamadas estrategias de control inteligente.

La primera de ellas será la más tradicional de todas y la más usada en la actualidad. La estrategia de control *PID*. Seguidamente se hablará del control adaptativo y del control predictivo basado en modelos o *MPC*. Por último se tocará el algoritmo de control *DMC*, quien pertenece a la familia de los controladores predictivos.

7.2.1. Controladores PID.

La estrategia de control PID es la más usada a nivel mundial en el control de procesos industriales, debido a que incluye las tres acciones de control básicas que cumplen con la mayor parte de los requerimientos de diseño y respuesta para muchas aplicaciones. Entre estos requerimientos podemos mencionar entre otros, al tiempo de levantamiento t_r al tiempo de asentamiento t_s y al sobreimpulso como parámetros de la respuesta temporal. Así mismo condiciones de estabilidad y robustez son cumplidas por este algoritmo, para muchos casos.

- **PID analógico.**

El algoritmo de control se muestra a continuación:

$$m(t) = \bar{m} + K_c e(t) + \frac{K_c}{\tau_I} \int e(t) dt + K_c \tau_D \frac{de(t)}{dt} \quad 1)$$

Aquí \bar{m} es la señal de control en estado estable, K_c es la ganancia proporcional, τ_I es el tiempo integral, τ_D el tiempo derivativo y e es la diferencia entre la referencia r y la salida c .

La acción de control proporcional como su nombre lo indica, es proporcional al error y tiene la característica de que entre mas alto sea el valor de la ganancia K_c , más agresivo será el controlador, y actuando sola, tenderá a minimizar el error en estado estacionario. Sin embargo, una ganancia muy alta comprometerá la estabilidad del sistema en la medida de que para cambios pequeños en el error se tendrán acciones de control muy grandes y, por tanto, un sobreimpulso importante en la variable controlada.

Para corregir el error en estado estacionario se tiene la acción de control integral. En esta acción de control, se integra el error y por tanto, se tendrá una señal de control distinta del valor inicial cuando el error sea cero y por ende, se logrará eliminar el error en estado estacionario del sistema. Por último la acción de control derivativa se encarga de llevar a error a cero más rápidamente anticipándose a la respuesta del proceso[13].

Sin embargo, la parte derivativa puede tener problemas con el ruido, por tanto la acción de control se modifica derivando no el error sino la señal de salida del sensor como se muestra en la siguiente ecuación.

$$m(t) = \bar{m} + k_c e(t) + \frac{K_c}{\tau_I} \int e(t) dt - K_c \tau_D \frac{dc(t)}{dt} \quad 2)$$

- **PID digital: algoritmo serie incremental.**

Para el PID digital al igual que para el analógico se tienen varias opciones al momento de implementar el algoritmo de control. Para el analógico solo se mostró una de las muchas modificaciones posibles que se le puede hacer, sin embargo debido a que en el presente trabajo se usó el algoritmo discreto, se mostrarán algunas otras modificaciones no consideradas para el otro caso.

El algoritmo serie incremental es tal vez el más usado en los sistemas de control descentralizados o *DCS* [13]. De hecho, este el algoritmo fue implementado en el presente trabajo para su contraste con la estrategia adaptativa desarrollada.

$$\Delta M \llbracket \Rightarrow K_c \left[\llbracket -z^{-1} \rrbracket \frac{T}{\tau_I} E(z) \right] \quad 3)$$

$$E(z) = R(z) - Y(z) \quad 4)$$

$$Y(z) = \frac{\tau_D' \llbracket -z^{-1} \rrbracket T}{\alpha \tau_D' \llbracket -z^{-1} \rrbracket T} C(z) \quad 5)$$

Reemplazando a las variables por sus correspondientes datos muestreados y a la variable z como el operador de corrimiento tenemos que:

$$y(t) = \frac{\alpha \tau_D'}{\alpha \tau_D' + T} y \llbracket -1 \rrbracket \left(1 - \frac{\alpha \tau_D'}{\alpha \tau_D' + T} \right) c(t) + \frac{\alpha \tau_D'}{\alpha \tau_D' + T} \mathbf{1}(t) - c \llbracket -1 \rrbracket \quad 6)$$

$$e(t) = r(t) - y(t) \quad 7)$$

$$\Delta m(t) = K_c \left[e(t) - e \llbracket -1 \rrbracket \frac{T}{\tau_I} e(t) \right] \quad 8)$$

$$m(t) = m \llbracket -1 \rrbracket + \Delta m(t) \quad 9)$$

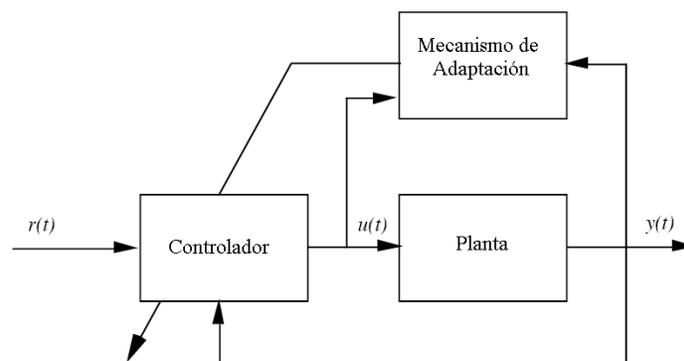
- **Sintonización de controladores PID.**

Para sintonizar un controlador PID hay muchos métodos posibles que van desde el lugar geométrico de las raíces pasando por el diseño mediante respuesta en frecuencia hasta sintonizaciones basadas en optimizaciones analíticas y numéricas. Sin embargo uno de los métodos más usados en la industria identifica a los procesos, como sistemas de primer orden más tiempo muerto (*FOPDT*), para después usar un conjunto de fórmulas deducidas a partir de diseños experimentales sobre este tipo de plantas, en donde se busca minimizar índices de rendimiento como el *IAE* (integral del valor absoluto del error) o el *ISE* (integral del error cuadrático). Este conjunto de fórmulas se muestra en [13].

7.2.2. Control adaptativo.

En el control adaptativo se encuentran dos esquemas básicos, el control adaptativo directo y el indirecto. El primero de ellos se muestra en la Figura 2. En este esquema el mecanismo de adaptación observa las señales del sistema de control y adapta los parámetros del controlador, de modo que se mantenga el rendimiento, incluso si se presentan cambios en la planta. Algunas veces el rendimiento es caracterizado a través de un modelo de referencia de modo que el controlador en conjunto con el mecanismo de adaptación, busca obtener las características en lazo cerrado de dicho modelo de referencia. Este esquema es llamado control adaptativo por modelo de referencia o *MRAC* (*model reference adaptive control*) por sus siglas en inglés [14].

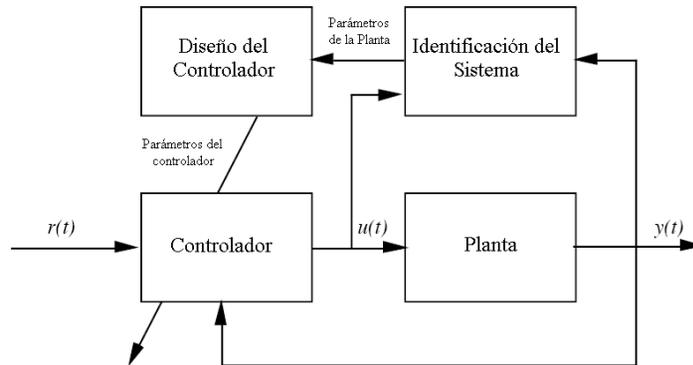
Figura 2. Control adaptativo directo.



Tomado de [14]

El segundo esquema de control adaptativo es mostrado en la Figura 3. Aquí se usa un sistema de identificación en línea para estimar los parámetros de la planta y un módulo llamado diseño del controlador, el cual tiene unas fórmulas predefinidas de los parámetros del mismo, basadas en los parámetros del proceso previamente seleccionados. Si los parámetros del proceso cambian el módulo de identificación del sistema se encargará de arrojar esos nuevos parámetros y por lo tanto el diseñador del controlador se encargará de arrojar los nuevos parámetros del controlador para realizar su sintonización [14].

Figura 3. Control adaptativo indirecto.



Tomado de [14]

7.2.3. Control predictivo basado en modelos (MPC).

El control predictivo es una estrategia conformada por un subconjunto de estrategias que proponen un amplio campo de métodos de control basados en filosofías comunes, la predicción. Estas estrategias ligadas al MPC constituyen un diseño de controladores lineales que poseen una estructura similar con suficientes grados de libertad [23].

Las características comunes de esta familia de controladores son:

1. Uso explícito de un modelo para predecir la salida del proceso en futuros instantes de tiempo.
2. Cálculo de las señales de control minimizando una cierta función objetivo.
3. Actualización del horizonte de predicción para cada instante de muestreo.

La diferencia radica en la estructura del algoritmo utilizada para trabajar los problemas como el ruido y la representación del modelo del proceso dentro de este [23].

- **Estrategia del MPC.**

1. En cada instante t y haciendo uso del modelo del proceso, se predicen las señales futuras de salidas para un determinado horizonte de predicción Np . Estas señales, $c(t+k/j)$ para $k=1$ hasta Np depende de los valores conocidos hasta el instante t (entradas y salidas) y de las señales de control futuras $m(t+k/j)$ para $k=0$ hasta Nu que se pretenden aplicar al sistema y que son las que se quieren calcular [23].
2. El conjunto de señales de control futuras se calcula optimizando un determinado criterio en el que se quiere mantener al proceso lo más cerca posible a la trayectoria referencia $R(t+k)$. Este criterio suele tomar la forma de una función cuadrática de los errores entre la salida predicha y la trayectoria de referencia también predicha, incluyendo en muchos casos el esfuerzo el esfuerzo de control. Si el criterio es cuadrático, el modelo es lineal y no existen restricciones se puede obtener una

solución explícita, en otro caso se usa un método iterativo de optimización o soluciones matemáticas mucho más complejas [23].

3. La señal de control $m(t/t)$ es la única que es aplicada al proceso, siendo el resto de las señales de control futuras, desechadas, debido a que en el siguiente instante de muestreo ya se conoce $c(t+1)$ repitiéndose el paso uno con este nuevo valor actualizando así todas las secuencias. Se calcula por tanto $m(t+1/t+1)$ (que en principio será diferente a $m(t+1/t)$ al disponer de una nueva información), haciendo uso del concepto de horizonte deslizante el cual es el que se usa en la estrategia DMC expuesta más adelante [23].

Para llevar a cabo esta estrategia, se usa una estructura como la mostrada en la Figura 4. En esta estrategia se hace uso de un modelo para predecir las salidas futuras del proceso, basándose en las futuras señales de control propuestas. Estas señales son calculadas por el optimizador teniendo en cuenta la función de coste (donde aparece el futuro error de seguimiento) así como las restricciones. Por tanto, el modelo juega un papel decisivo en el controlador. El modelo elegido debe ser capaz de capturar la dinámica del proceso, de modo que pueda realizar una buena predicción de las salidas futuras y, por tanto, poder realizar un control adecuado sobre el proceso [23].

El optimizador es otra parte fundamental de la estrategia, pues proporciona las acciones de control. Si la función de coste es cuadrática, el mínimo se puede obtener como una función explícita de las entradas y salidas pasadas y de la trayectoria de referencia. Sin embargo, cuando existen restricciones en los valores que pueden tomar las distintas variables que interviene en la función como lo son la señal de control y la salida del proceso la solución en muchos casos es calculada por métodos numéricos o por métodos analíticos que resultan ser bastante complejos no sólo matemáticamente sino computacionalmente [23].

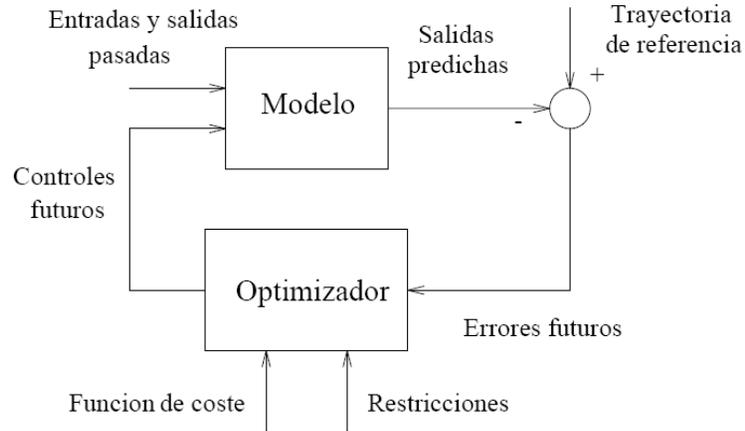
7.2.4. Control por matriz dinámica (DMC).

- **Filosofía del DMC.**

Los controladores de matriz dinámica se caracterizan por instaurar en su algoritmo el comportamiento del proceso en una matriz base llamada G cuyas dimensiones dependen de la cantidad de movimientos requeridos para llevar a cabo la acción de control y del tamaño de la muestra determinada.

Este arreglo matricial, se va a ver afectado por el número de variables a controlar en el caso del tipo de sistema que se está trabajando (MIMO o SISO), y por el número de perturbaciones presentes en el sistema, ya que para cada variable controlada y para cada perturbación existirá un cambio diferente en la señal o señales de salida. Sin embargo en la mayoría de las implementaciones el modelo de las perturbaciones no es incluido en la misma.

Figura 4. Diagrama de bloques del MPC.



Tomado de [23]

- **Matriz dinámica.**

Debido a que esta es una estrategia *MPC* requiere un modelo del proceso. El DMC cuenta con un modelo de respuesta escalón del sistema que tiene la siguiente forma.

$$\hat{c}(t) = \sum_{i=1}^{Np} g_i \Delta m(t-i) \quad (10)$$

En donde los g_i son los coeficientes de la respuesta ante un paso escalón unitario. Este modelo se organiza en una matriz dinámica de dimensiones $Np \times Nu$ de manera que se pueda predecir el comportamiento más de un tiempo de muestreo después considerando Nu acciones de control futuras [23]. La matriz se organiza de la siguiente manera

$$G = \begin{bmatrix} g_1 & 0 & \cdots & 0 \\ g_2 & g_1 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ g_{Nu} & g_{Nu-1} & \cdots & g_1 \\ \vdots & \vdots & \ddots & \vdots \\ g_{Np} & g_{Np-1} & \cdots & g_{Np-Nu+1} \end{bmatrix} \quad (11)$$

Por tanto se puede describir la predicción de manera matricial como sigue

$$\hat{C} = G\Delta M + C_{ant} + d \quad (12)$$

Donde \hat{C} es el vector de predicciones futuras, ΔM es el vector de acciones futuras de control, C_{ant} es el vector de predicción anterior y d es el vector de perturbaciones debidas al error de modelo y a errores en la medición. Para el vector ΔM solo se considera la acción de control siguiente y el resto se descartan [23].

Para procesos multivariables se debe obtener la matriz para cada par de entrada s y salida r que consideremos. Por tanto la matriz se modifica de la siguiente manera

$$G = \begin{bmatrix} G_{11} & G_{12} & \dots & G_{1s} & \dots & G_{1S} \\ G_{21} & G_{22} & \dots & G_{2s} & \dots & G_{2S} \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ G_{r1} & G_{r2} & \dots & G_{rs} & \dots & G_{rS} \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ G_{R1} & G_{R2} & \dots & G_{Rs} & \dots & G_{RS} \end{bmatrix} \quad (13)$$

Donde R es el número total de salidas y S el número total de entradas [23].

- **Ley de control.**

Para hallar la ley de control se propone la siguiente función de optimización cuadrática que busca minimizar el error cuadrático y el cuadrado del cambio en la acción de control como se muestra

$$J = \sum_{i=1}^{Np} \gamma(i) \left[(t+i) - \hat{C}(t+i) \right]^2 + \sum_{i=1}^{Nu} \lambda(i) \Delta m(t+i)^2 \quad (14)$$

Donde γ es el factor de ponderación de los errores, λ es el factor de supresión a las acciones del controlador y r la trayectoria de referencia deseada [23].

Derivando J e igualando a cero obtenemos la siguiente ley de control

$$\Delta m = \left(\Gamma^T \Gamma^T \Gamma G + \Lambda^T \Lambda \right)^{-1} \Gamma^T \Gamma^T \Gamma \left(-C_{ant} - d \right) \quad (15)$$

$$\Delta m = Kc \times E \quad (16)$$

$$Kc = \left(\Gamma^T \Gamma^T \Gamma G + \Lambda^T \Lambda \right)^{-1} \Gamma^T \Gamma^T \Gamma \quad (17)$$

$$E = \left(-C_{ant} - d \right) \quad (18)$$

En la cual Γ y Λ son matrices que contienen a los factores γ y λ en sus diagonales respectivas [22].

- **Sintonización de controladores DMC.**

La sintonización del controlador implica la escogencia de los siguientes parámetros: el horizonte de predicción, el horizonte de control, el tiempo de muestreo y los factores de ponderación y supresión.

Dado un proceso identificado como un sistema *FOPDT*, en [6] se obtuvieron las ecuaciones mostradas en la Tabla 1 para la sintonización del DMC.

Tabla 1. Ecuaciones de sintonía para el DMC

Parámetro	Ecuación
T_{rs}	$\max(0.1\tau_{rs}, 0.5t_{o_{rs}})$
T	$\min(T_{rs})$
k_{rs}	$\frac{t_{o_{rs}}}{T} + 1$
Np	$\max\left(\frac{5\tau_{rs}}{T} + k_{rs}\right)$
Nu	$\max\left(\frac{\tau_{rs}}{T} + k_{rs}\right)$
λ_s	$\frac{Nu}{500} \sum_{r=1}^R \gamma_r^2 K_{rs}^2 \left(Np - k_{rs} - \frac{3\tau_{rs}}{2T} + 2 - \frac{Nu - 1}{2} \right)$

Tomado de [6]

7.3. REDES NEURONALES ARTIFICIALES (RNA).

No hay una definición universalmente aceptada sobre redes neuronales, sin embargo una definición ampliamente aceptada es la siguiente: Una RNA es un sistema con muchas unidades altamente conectadas trabajando en paralelo, cuya función es determinada por la estructura de la red, peso de las conexiones y el procesamiento que ejecuta cada una de las unidades de computo o nodos.

Se han llamado redes neuronales por el hecho de que simulan la habilidad de aprendizaje de las neuronas biológicas en el hecho de entender un proceso no conocido o su comportamiento.

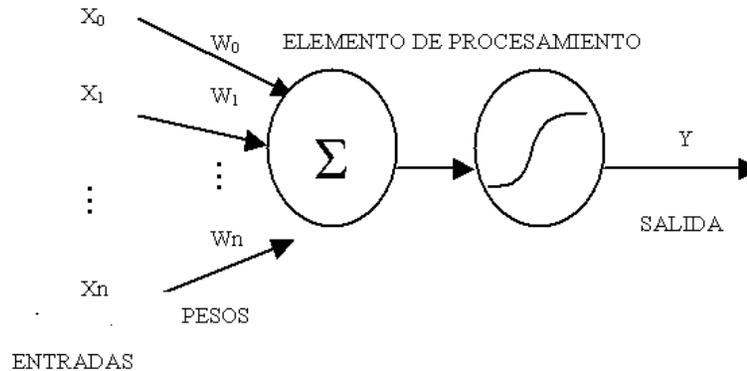
7.3.1. Componentes básicos de una RNA.

Las redes neuronales tratan de emular las funciones básicas de una neurona biológica. Reciben señales de entrada, las procesan y producen finalmente una salida Figura 5. A continuación describiremos los componentes básicos que componen una neurona artificial.

a) Pesos

Cada una de las entradas es multiplicada por un peso relativo. Los pesos, son coeficientes que determinan la intensidad de una señal de entrada dentro del elemento de procesamiento. Estos pesos pueden ser modificados en respuesta a varios conjuntos de entrenamiento y de acuerdo a la topología específica de la red o a su regla de aprendizaje.

Figura 5. Componentes básicos de una neurona artificial.



Tomado de [9]

b) Función de suma

Este es el primer paso en el elemento de procesamiento. Las entradas previamente escaladas por los correspondientes pesos son combinadas en una suma de productos. Considerando la entrada y los pesos como vectores (X y W), el resultado de la función de suma es el producto punto entre los dos vectores.

c) Función de Transferencia o activación

La función de transferencia es un algoritmo aplicado a la salida de la función de suma. La función de transferencia generalmente es no lineal, sin embargo las funciones lineales han mostrado ser de gran utilidad.

Una opción interesante en cuanto a las funciones de transferencia son las funciones sigmoideas. Dichas curvas tienen un máximo y un mínimo valor de salida posible, el cual es dado por sus asíntotas. Es muy común que este tipo de funciones sean llamadas sigmoideas cuando sus rangos varíen entre cero y uno, y también pueden denominarse tangente hiperbólica cuando su rango varía entre -1 y 1. La razón por la cual estas funciones se hacen interesantes es que la función y su derivada son continuas.

d) Función de salida

Normalmente la salida es directamente equivalente al resultado de la salida de la función de transferencia. Sin embargo, hay algunas topologías que incorporan competencia entre elementos de procesamiento vecinos. A las neuronas se les permite competir con cada una de las otras, inhibiendo elementos de procesamiento a menos que tengan suficiente fuerza.

e) Función de aprendizaje o entrenamiento

El objetivo de la función de aprendizaje es modificar los pesos variables en las entradas de cada elemento de procesamiento de acuerdo con algún algoritmo diseñado para este

objetivo en las redes. El proceso de cambiar los valores de los pesos de entrada para alcanzar algún resultado deseado puede ser llamado incluso, función de adaptación, así como modo de aprendizaje o ley de aprendizaje.

7.3.2. Regulated Activation Weights Neural Network (RAWNN).

La estructura de este tipo de red consiste en una capa oculta con una función de activación no lineal y una capa de salida con una función de activación lineal. Una capa esta conformada por un conjunto de neuronas y se nombra cada una de acuerdo a su posición dentro de la red. Por ejemplo, la capa oculta se le llama así porque se encuentra dentro de la red y no tiene contacto directo con la entrada o con la salida; en general puede ser más de una capa la que se encuentre oculta. En la Figura 6 se muestra un ejemplo de ellas.

La entradas $x(k)$ de la red pueden ser agrupadas en una matriz en donde cada fila corresponde a un evento y cada columna corresponde a una entrada como vemos a continuación.

$$X(k) = (x_1(k) \dots x_i(k) \dots x_{Ni}(k)) \quad (1) \quad (19)$$

$$X = \begin{bmatrix} X(1) \dots X(k) \dots X(Ne) \end{bmatrix}^T \quad (20)$$

Con Ni igual al número de entradas y Ne igual al número de eventos. Se ha incluido una columna de unos para los valores iniciales. Así mismo, podemos agrupar las salidas en una matriz de la misma manera:

$$Y(k) = (y_1(k) \dots y_i(k) \dots y_{No}(k)) \quad (21)$$

$$Y = \begin{bmatrix} Y(1) \dots Y(k) \dots Y(Ne) \end{bmatrix}^T \quad (22)$$

Con No igual al número de salidas de la red. Por tanto, teniendo a Nh como el número de neuronas en la capa oculta, ya podemos expresar a la red neuronal concretamente como:

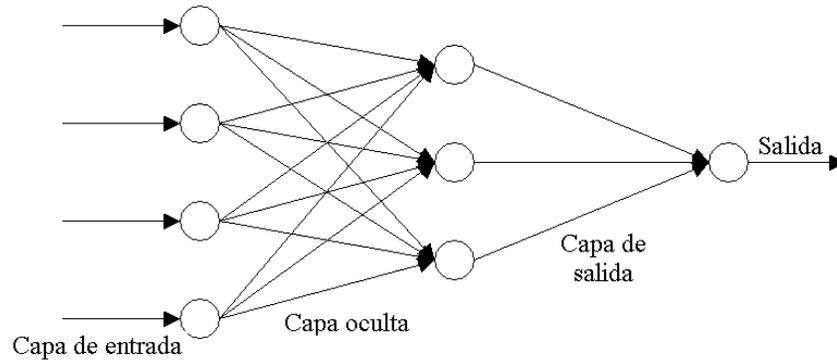
$$Z = X \times W^h \quad (23)$$

$$V = f \left(\begin{bmatrix} Z \\ 1 \end{bmatrix} \right) \quad (24)$$

$$Y = V_b \times W^o \quad (25)$$

Donde W^h con dimensiones $Ni+1 \times Nh$ es la matriz que agrupa a los pesos de activación de la red, f es la función de activación de la RNA, que para este caso es la función *tansig*, V_b con dimensiones $Ne \times Nh+1$ es igual a la matriz V con dimensiones $Ne \times Nh$ excepto por que se le añadió una columna de unos para expresar el bias b^o de la salida y W^o con dimensiones $Nh+1 \times No$ es la matriz que agrupa a los pesos de la capa de salida. Las matrices V y Z son matrices usadas para almacenar los resultados intermedios [19].

Figura 6. Ejemplo de la estructura de una RAWNN (4 entradas, 3 neuronas en la capa oculta, una neurona en la capa de salida).



- **Función de aprendizaje de las RAWNN.**

Lo bueno de la función de aprendizaje de las RAWNN es que se pueden realizar muy buenos mapeos tomando de manera aleatoria los pesos de la capa escondida. En este caso la estimación de los pesos de la capa de salida se convierte en una estimación lineal en sus parámetros y por tanto, pueden ser fácilmente resueltos por el método de mínimos cuadrados.

Ahora bien, suponiendo que la salida puede ser representada por:

$$Y = V_b W^o + e \quad (26)$$

Donde e es un termino que representa el error de modelo [19]. Minimizando la suma de los cuadrados del error mediante mínimos cuadrados tenemos que la estimación de los pesos de la capa de salida W^o puede ser obtenida como:

$$\hat{W}^o = (V_b^T V_b)^{-1} V_b^T Y \quad (27)$$

Los pesos de entrada pueden ser hallados como sigue

$$\max_k \text{var}_j \left\{ \sum_{l=1}^{N_j+1} x_j(k) W_{jl}^h \right\} \leq a \quad (28)$$

Lo que es equivalente a generar W^h como

$$W^h = \sqrt{\frac{a}{\max_k \sum_{i=1}^{N_j+1} x_i^2(k)}} N(0,1) \quad (29)$$

Donde $N(0,1)$ denota un generador de números aleatorios con media cero y varianza uno [19].

7.3.3. Modelo no lineal en redes neuronales.

En general un sistema no lineal de múltiples entradas y múltiples salidas MIMO, con un vector de entrada $\mathbf{u}(t)=[u_1(t)\dots u_n(t)]^T$ y un vector de salida $\mathbf{y}(t)=[y_1(t)\dots y_m(t)]^T$, puede ser descrito a través de la siguiente función:

$$\mathbf{y}(t) = \mathbf{f}(\boldsymbol{\varphi}(t)) + \mathbf{v}(t) \quad (30)$$

Donde $\mathbf{f}=[f_1\dots f_m]^T$, es una función no lineal. $\boldsymbol{\varphi}(t)$ es llamado el vector de regresores, y esta compuesto por los valores pasados de $\mathbf{y}(t)$ y $\mathbf{u}(t)$, quienes son definidos normalmente como los regresores[21]. El último término añadido a la función $\mathbf{v}(t)$, representa el error de modelo.

Generalmente la función \mathbf{f} no es conocida, y por tanto, se quiere aproximar a través de datos de entrada y salida del sistema, de manera que el error $\mathbf{v}(t)$, sea lo menor posible. Para tal fin hay muchos métodos posibles, tales como polinomios de orden superior, modelos difusos y redes neuronales, usando bien sea datos de entrada o salida de sistema, así mismo como conocimiento experto del mismo[21].

Para modelar al sistema con redes neuronales artificiales se deben distinguir entre dos tipos básicos de configuraciones, las cuales se diferencian por los elementos usados en el vector de regresores $\boldsymbol{\varphi}(t)$ [21]. El modelo no lineal auto-regresivo con entradas exógenas ó *NARX (Nonlinear Auto Regression with Exogenous inputs)* por sus siglas en inglés, usa los valores pasados de la entrada y la salida en un vector de regresores que tiene la siguiente forma:

$$\boldsymbol{\varphi}(t) = \begin{bmatrix} u_1(t-d_u) \dots u_1(t-d_u) \dots u_n(t-d_u) \dots u_n(t-d_u) \\ y_1(t-d_y) \dots y_1(t-d_y) \dots y_m(t-d_y) \dots y_m(t-d_y) \end{bmatrix}^T \quad (31)$$

Donde d_u y d_y son los retardos máximos considerados para cada una de las entradas y salidas respectivamente[21]. Por otro lado el modelo no lineal con error en la salida ó *NOE (Nonlinear Output Vector)* por sus siglas en inglés, usa el mismo vector de regresión que el *NARX*, sin embargo, las salidas pasadas corresponden a las simuladas $\hat{y}(t-k)$ en vez de las reales $y(t-k)$ en $\boldsymbol{\varphi}(t)$. El modelo *NARX* es usado sólo en la etapa de entrenamiento de la red, debido a que solamente puede predecir hasta un período después, mientras que el modelo *NOE* es usado para realizar las simulaciones continuas [21].

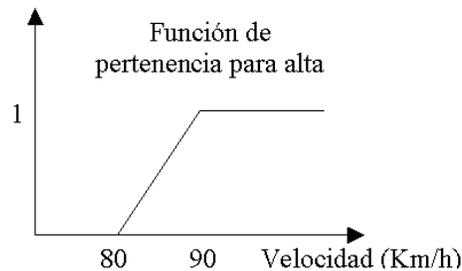
7.4. SISTEMA DE INFERENCIA DIFUSO TAKAGI-SUGENO-KANG (TSK).

Los sistemas difusos son sistemas basados en conocimientos o reglas. El corazón de un sistema difuso es la base de conocimiento que consiste en una serie de reglas si-entonces.

Una regla si-entonces es una oración en la cual algunas palabras están caracterizadas por funciones de pertenencia continuas. Por ejemplo la siguiente regla: *Si la velocidad x de un carro es alta, entonces la fuerza al acelerador es $y=cx$.*

Donde c es una constante y la palabra *alta* es un conjunto difuso caracterizado por la función de pertenencia mostrada en la Figura 7, en la que el eje vertical se encuentra el grado de pertenencia, que para el caso de un conjunto difuso normalizado el máximo es uno. Un sistema de inferencia difuso TSK es construido por un conjunto de reglas si-entonces como la anterior o *FRB* [15].

Figura 7. Función de pertenencia para alta.



Tomado de [15]

Generalizando, una regla en un sistema difuso TSK se puede expresar como: *Si x_1 es C_i^l y ... y x_n es C_n^l , entonces $y^l = c_0^l + c_1^l x_1 + \dots + c_n^l x_n$.*

Donde C_i^l son conjuntos difusos, c_i^l son constantes, x_i son las entradas al sistema y $l=1,2,\dots,M$, con M igual número de reglas. Aquí se ve claramente que los consecuentes de las reglas son combinaciones lineales de las entradas. Dada una entrada $x = \langle x_1, \dots, x_n \rangle \in U \subset R^n$, la salida $f(x) \in V \subset R$ para un sistema difuso TSK es calculada como el promedio ponderado de las y^l , esto es,

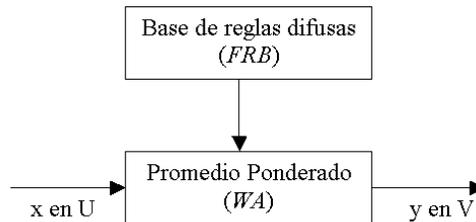
$$f(x) = \frac{\sum_{l=1}^M y^l w^l}{\sum_{l=1}^M w^l} \quad (32)$$

con los pesos w^l calculados como

$$w^l = \prod_{i=1}^n \mu_{C_i^l}(x_i) \quad (33)$$

Donde $\mu_{C_i^l}(x_i)$ es el grado de pertenencia de la entrada x_i en el conjunto difuso C_i^l con función de pertenencia μ_{C_i} .

Figura 8. Configuración básica de un sistema de inferencia difuso TSK.



Tomado de [15]

7.5. ALGORITMOS EVOLUTIVOS.

Los algoritmos evolutivos son herramientas estocásticas que permiten realizar un análisis combinatorio sobre el espacio de búsqueda de un problema en específico de modo que se pueda hallar una solución óptima al problema deseado. Debido a que son una metaheurística, estos nos permite resolver una gran variedad de problemas haciendo uso de su filosofía, particularizando la implementación para cada problema.

Los algoritmos evolutivos empiezan con una población de individuos generada generalmente de manera aleatoria. Cada individuo en la población representa na posible solución al problema en consideración. Los individuos evolucionan a través de iteraciones sucesivas llamadas generaciones. Durante cada generación, cada individuo es evaluado usando alguna medida llamada *fitness*. Después de esto, la siguiente generación es creada usando operadores evolutivos. El procedimiento continúa hasta que alguna condición de terminación es satisfecha [16].El siguiente es el código básico de un algoritmo evolutivo donde $P(t)$ denota la población en la generación t :

Inicio

$t=0$

Inicializar $P(t)$

Evaluar $P(t)$

Mientras que la condición de terminación no se cumpla **haga**

$t=t+1$;

Seleccionar $P(t)$ de $P(t-1)$

Alterar $P(t)$

Evaluar $P(t)$

Fin

Fin

Los procesos de selección y alteración de los individuos de la población se encuentran dentro de los operadores evolutivos, los cuales se describen a continuación junto con la codificación de las soluciones.

7.5.1. Codificación de las soluciones.

Para nuestro caso realizamos una codificación del cromosoma en punto flotante, es decir, la solución es el mismo cromosoma. Por tanto los operadores evolutivos que se muestran son para este tipo de codificación, exceptuando el de selección los cuales no dependen del tipo de representación escogida.

7.5.2. Operadores evolutivos.

En la siguiente sección se expondrán brevemente la manera como trabajan los distintos operadores evolutivos para la codificación en punto flotante.

- **Selección.**

En los procesos de selección, se escogen de acuerdo a cierta probabilidad a los individuos a los cuales se les aplicaran los otros operadores genéticos. Aquí se mostrarán dos maneras de hacerlo.

a) *Ruleta*

La idea básica es determinar la probabilidad de selección de cada individuo proporcional a su fitness. Dado el valor de fitness $f_i (>=0), i=1..,N$, para un individuo i tenemos que la probabilidad de selección es

$$p_i = \frac{f_i}{\sum_{j=1}^N f_j} \quad 34)$$

Para aclarar el uso de esta formula se puede usar la analogía de girar una circunferencia unitaria como una ruleta donde la ruleta es cortada como un pastel en N regiones donde la región i , es asociada con el elemento i de la población. Cada porción de la circunferencia es determinada por p_i . Para realizar la selección se gira la rueda N veces de modo que se escogen N individuos para aparearse. Debido a que los mejores individuos tienen una mayor porción en el círculo tendrán una mayor probabilidad de ser escogidos [16].

b) *Torneo binario*

En el torneo binario se escogen de manera aleatoria a dos miembros i y j de la población y se comparan sus fitness; si $f_i \geq f_j$ entonces el individuo i es escogido, en caso contrario se escoge al individuo j . Los individuos se reponen a la población es decir, pueden llegar a ser escogidos nuevamente. Por esta razón se llama torneo binario con reemplazo. El proceso termina cuando se han seleccionado N individuos.

- **Cruzamiento.**

Este operador busca intercambiar la información de dos o más individuos de una población para generar otros con características similares a los iniciales. Para codificación real tenemos entre otros a los siguientes operadores.

a) *Cruzamiento aritmético completo.*

De dos individuos padres v y w de la población se generan a dos hijos v' y w' , fruto de la combinación de sus padres de la siguiente manera:

$$v' = aw + (1 - a)v \quad (35)$$

$$w' = av + (1 - a)w \quad (36)$$

Donde a es un número aleatorio entre 0 y uno. Sin embargo, es de libre escogencia generar uno o dos de los hijos posibles [16].

b) *Cruzamiento heurístico.*

Este operador solo genera un hijo z a partir de dos padres a partir de siguiente la siguiente regla:

$$z = a(w - v) + w \quad (37)$$

Donde a es un número aleatorio entre 0 y uno y $f(w) \leq f(v)$ para problemas de minimización [16].

- **Mutación.**

El objetivo de la mutación es convertir una solución en otra. Para la codificación en punto flotante tenemos entre otras opciones a los siguientes operadores.

a) *Mutación uniforme.*

Este operador genera un solo hijo v' a partir de un padre v . Aquí se selecciona aleatoriamente un individuo i del vector $v = (v_1, \dots, v_i, \dots, v_n)$ y genera $v' = (v_1, \dots, v'_i, \dots, v_n)$. v'_i es un valor generado con probabilidad uniforme dentro del rango $[u(v_i), l(v_i)]$, con $u(v_i)$ y $l(v_i)$ como los límites superior e inferior de v_i respectivamente [16].

b) *Mutación no uniforme.*

A partir de un individuo padre v este operador genera un hijo v' a partir de

$$v' = \begin{cases} v + \left[\frac{(v) - v}{u(v) - v} \right] \Gamma(t) & \text{Si } r_1 < 0.5 \\ v - \left[\frac{v - l(v)}{v - l(v)} \right] \Gamma(t) & \text{Si } r_1 \geq 0.5 \end{cases} \quad (38)$$

con,

$$\Gamma(t) = \exp(-t/T) \quad (39)$$

Donde v' es el individuo a ser modificado, r_1 y r_2 son dos números aleatorios entre 0 y 1, b es un parámetro constante, t es número de la generación actual y $u(v)$ y $l(v)$ son los límites superior e inferior que puede tomar el cromosoma y h el individuo resultante [16].

8. DESCRIPCIÓN GENERAL DEL SISTEMA

Para que una estrategia de control como la propuesta tenga sentido, esta debe aplicarse a procesos que ameriten su uso. Tal es el caso de muchos procesos químicos industriales como los usados en el presente trabajo, los cuales permiten contrastar de manera eficiente el rendimiento de una estrategia no lineal contra una lineal como el PID.

A continuación se describirá brevemente cada módulo usado en la estrategia y aquellos usados para contrastarlas.

8.1. IDENTIFICACIÓN

La identificación de los procesos para el análisis de su respuesta y la sintonización de los controladores se hace con base en la asunción de que estos pueden ser aproximados cerca del punto operación a un proceso FOPDT.

¿Porque se asume de esta manera y no de otra? Esta es una pregunta trascendental al momento de identificar a un sistema debido que hay muchas opciones para hacerlo entre las que se encuentran funciones de transferencia de orden superior y modelos no lineales. Sin embargo, al identificar al sistema de esta manera si tiene muchas ventajas.

La primera de ellas es que en el ámbito industrial es muy usado este tipo de identificación y por ende hay mucha investigación y desarrollo realizada para ellos. Estas investigaciones incluyen análisis exhaustivo de la respuesta temporal y en frecuencia así como fórmulas de sintonización de controladores analógicos y digitales para los mismos a través de diseños experimentales. Esto último es bastante conveniente debido a que simplifica y agiliza la tarea de implementar un lazo de control, lo cual se traduce en una reducción de costos en la misma, logrando resultados bastante buenos para muchos de los procesos.

No obstante esta no es la única razón por la cual se usan estos sistemas. Como se vera en la descripción detallada del sistema, esta aproximación es bastante apropiada para este tipo de sistemas, arrojando errores muy pequeños al momento de comparar las respuestas del sistema real y el sistema lineal aproximado para el punto de operación específico. Esto se traduce en una complejidad computacional menor a la que tuviésemos en un sistema de orden superior o no lineal al momento de calcular su respuesta para el caso en donde alguna estrategia de control lo requiriese.

8.2. SINTONIZACIÓN DE LOS CONTROLADORES

En el presente trabajo se usarán dos controladores para contrastar a la estrategia propuesta: el controlador PID digital y el DMC estándar.

El PID fue escogido debido a que es uno de los controladores más usados a escala industrial y que, además, es muy simple al momento de ser implementado. A diferencia de otros

trabajos, se usará su forma discreta, debido a que tanto el DMC estándar como la estrategia propuesta que hace uso del DMC también lo son.

Para sintonizar a este controlador hay muchas maneras de hacerlo debido a su estructura lineal. Una manera de hacerlo es través del lugar geométrico de las raíces realizando una aproximación de padé de primer o segundo orden, al tiempo muerto del sistema FOPDT. Sin embargo, no deja de ser aproximación.

Otra manera es usar la respuesta en frecuencia del sistema en la cual no necesitamos realizar una aproximación para hacerlo. Sin embargo, para este caso no siempre es factible y tampoco sencillo realizar la sintonización del controlador para los requerimientos de diseño propuestos en el dominio del tiempo. Esto es debido a que las relaciones entre los parámetros de la respuesta en frecuencia y repuesta temporal, son aproximaciones hechas para determinados sistemas y no son válidas en general.

Debido a esto hacemos uso de las fórmulas de sintonización mostradas en [13]. Estas han sido obtenidas a través de un diseño de experimentos buscando minimizar índices de respuesta temporal del sistema como el IAE, parametrizando al sistema como FOPDT, pero no realizando ninguna aproximación sobre el mismo.

La sintonización del DMC en general es mucho más compleja que la del PID debido a que expresar a este controlador como una función de transferencia lineal, es mucho más complejo que para el PID y los parámetros involucrados son muchos más que para este. Por esta razón, métodos como el lugar de las raíces o la respuesta en frecuencia no son aplicados regularmente para sintonizar a este controlador. Debido a todo esto, se han usado fórmulas de sintonización mostradas en la sección 7.2.4 a partir de una identificación del sistema como una función de transferencia FOPDT, las cuales han mostrado buenos resultados en trabajos anteriores [6].

Esta sintonización inicial del DMC es usada en la estrategia adaptativa al momento de inicializar la población, haciéndose muy importante debido que es el punto inicial de búsqueda en el algoritmo de optimización.

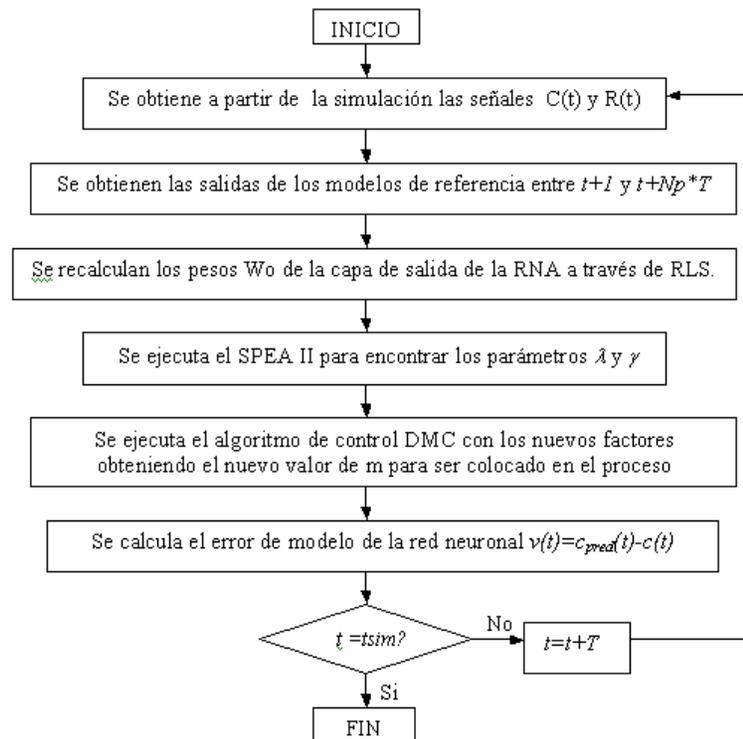
8.3. ESTRATEGIA ADAPTATIVA

La estrategia de control propuesta consta de tres bloques funcionales a saber: el controlador por modelo de referencia, el modelo no lineal y el optimizador evolutivo. El diagrama de flujo de la misma se muestra en la Figura 9.

El modelo no lineal del sistema fue obtenido a través de una red neuronal *feed-forward* de entrenamiento rápido llamada *RAWNN*. El entrenamiento fuera de línea de la red, se hace a través de una solución de mínimos cuadrados y el entrenamiento en línea se hace a través de mínimos cuadrados recursivos (*RLS*).

El controlador usado es el *DMC*, el cual se sintoniza usando fórmulas obtenidas en [6] y calculando la matriz dinámica del sistema a través de una prueba escalón del mismo. La referencia de este controlador no es un escalón sino por el contrario, una referencia suavizada de primer o segundo orden, en la cual se especifican los requerimientos en lazo cerrado del sistema. De esta referencia se obtiene un modelo lineal de respuesta escalón igual al que se obtiene para el modelo de la planta, lo cual permite una rápida evaluación de su salida para los posibles puntos de operación deseados por el sistema. El diagrama de flujo del controlador usado se muestra en la Figura 10. Aquí \bar{m} y \bar{c} son los valores iniciales de la entrada y la salida para cada proceso. Este diagrama es válido tanto para la ejecución del *DMC* estándar como para la ejecución del *DMC* usado en la estrategia.

Figura 9. Diagrama de flujo de la estrategia adaptativa propuesta.



El optimizador es un algoritmo evolutivo multiobjetivo llamado *SPEA II*, quien se encarga de la adaptación de dos de los parámetros más importantes del *DMC*; el factor de supresión y el factor de peso de las variables controladas. La adaptación de dichos parámetros la hace a través de un proceso de optimización en donde se buscan los parámetros óptimos basándose en la respuesta generada por cada uno en el modelo no lineal en redes neuronales. El diagrama de flujo del *SPEA II* implementado se muestra en la Figura 11.

Figura 10. Diagrama de Flujo del algoritmo de control DMC.

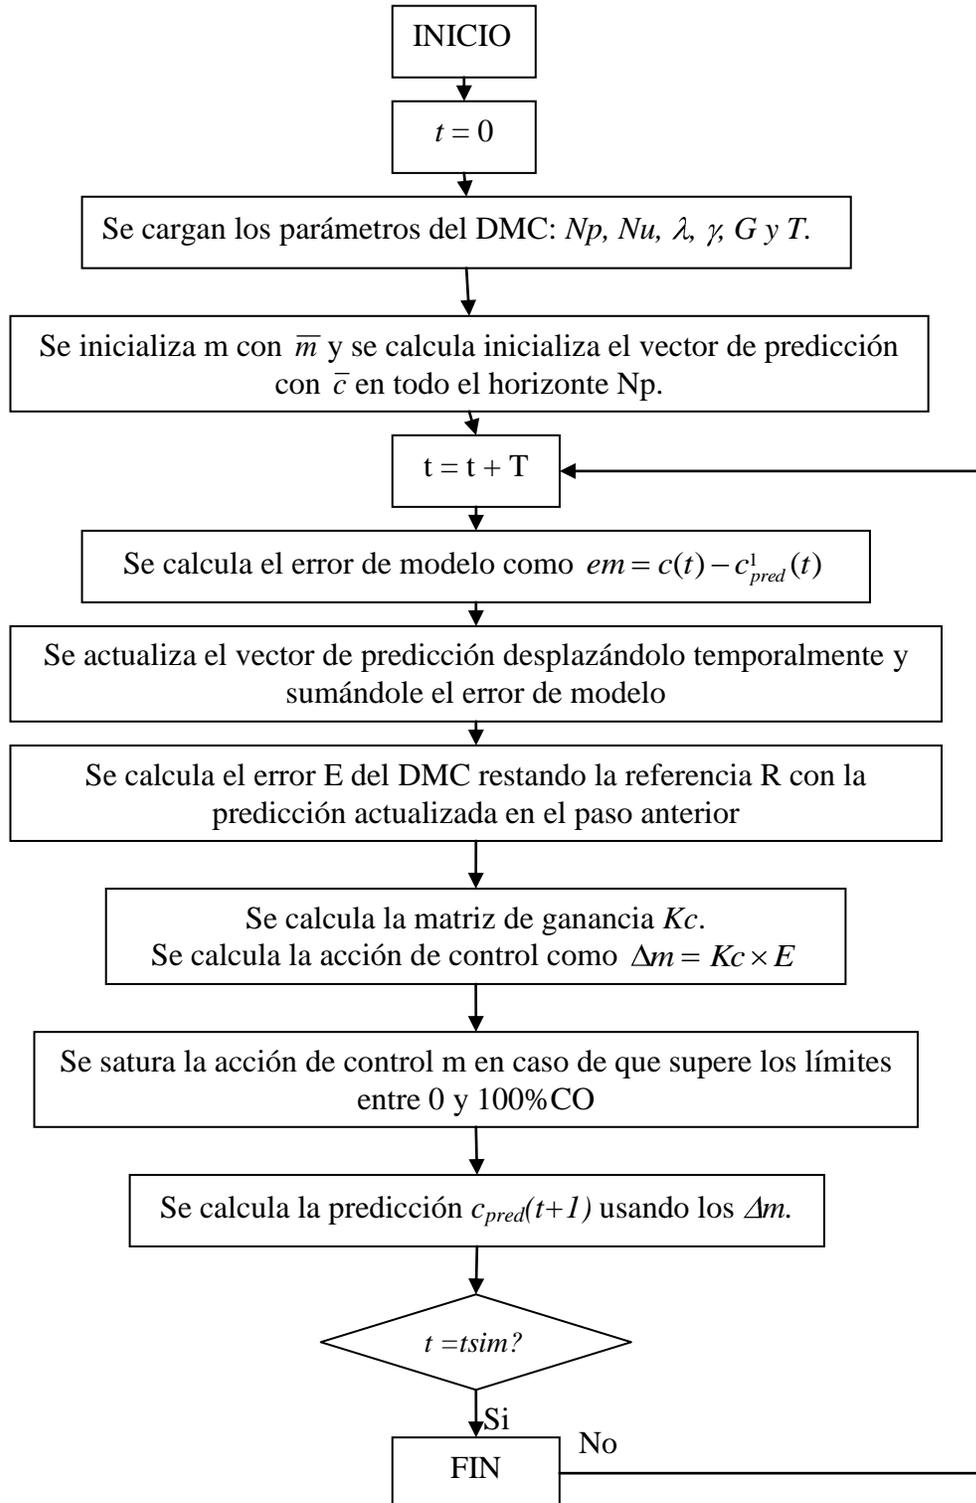
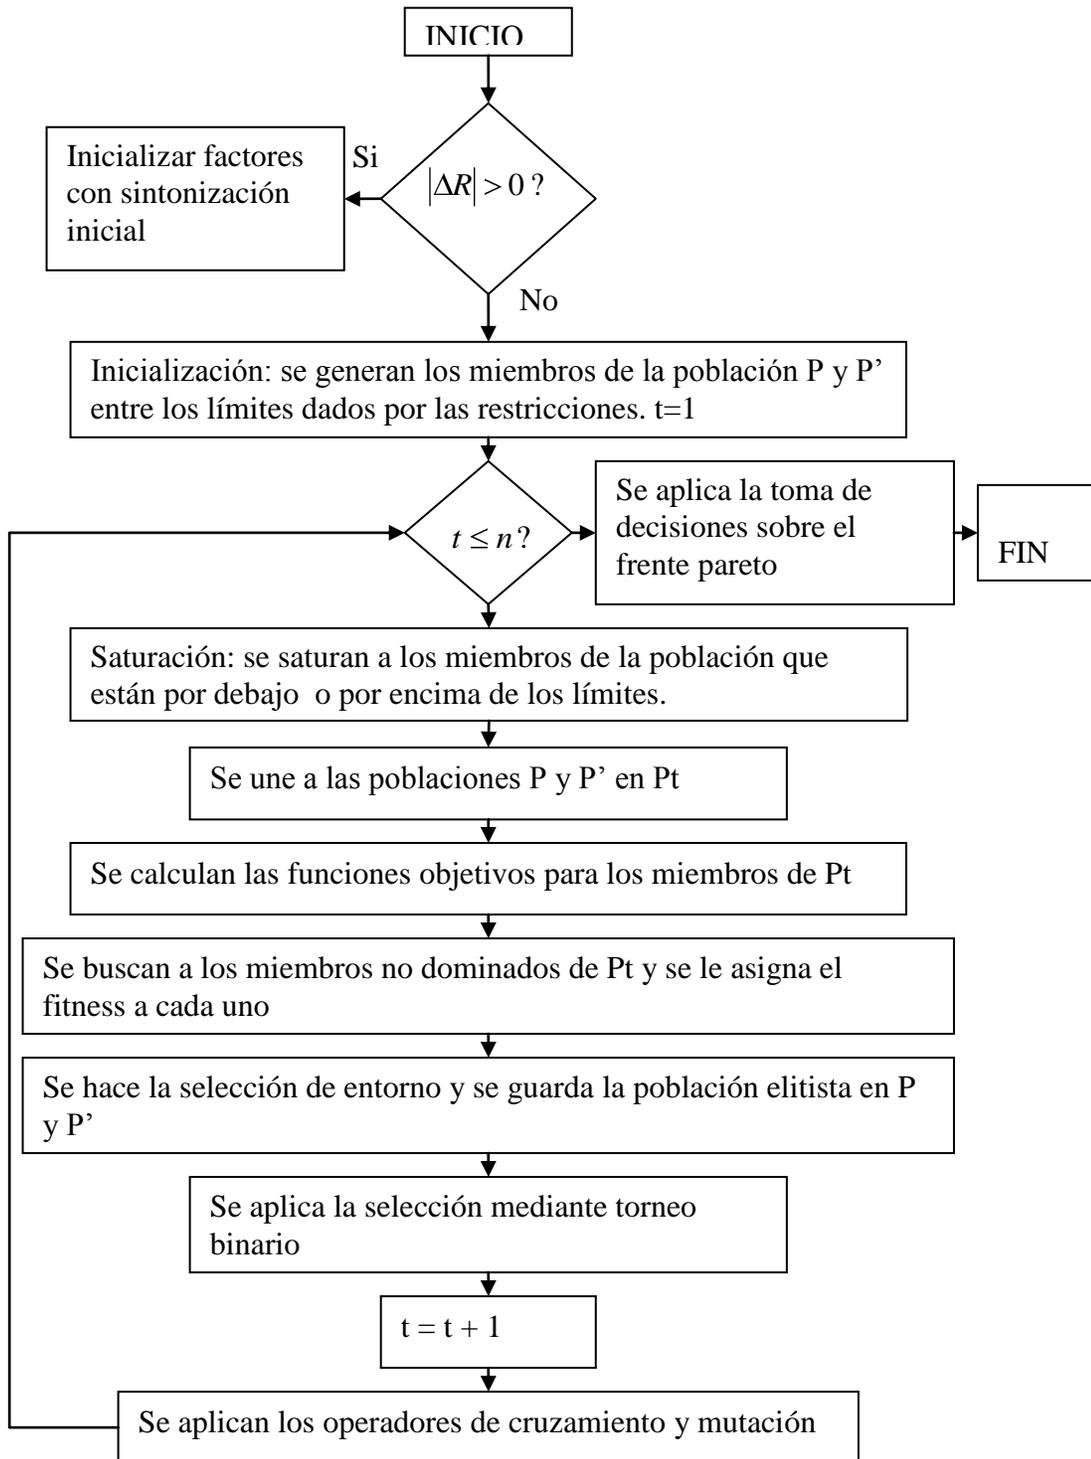


Figura 11. Diagrama de flujo del SPEA II implementado.



9. DESCRIPCIÓN DETALLADA DEL SISTEMA

A pesar de que la estrategia se compone de los tres bloques básicos mencionados anteriormente no se puede olvidar a los procesos industriales usados para probarla. Por tanto, la primera parte de este capítulo se dedicará a la manera como se obtuvieron los modelos de los procesos a través de las relaciones explicadas en el marco teórico, así mismo como la instrumentación empleada en los mismos. En las siguientes secciones se explicará de manera detallada cada uno de los módulos usados en la estrategia, así mismo como la sintonización de los controladores usados para realizar el contraste de la misma.

9.1. INSTRUMENTACIÓN DE LOS PROCESOS

9.1.1. Tanque reactor con tanque de homogenización.

- *Válvula*

Para obtener el tipo de válvula y los parámetros de la misma debemos analizar primero cual es la concentración para flujo nulo, que a través de simulación nos arrojó 315 Kg/m. Considerando que es conveniente tener una simetría respecto al punto de operación, tenemos que para un flujo de $2\text{m}^3/\text{s}$ la concentración de salida es 38.038 Kg/m^2 , lo cual nos arroja un punto de operación en casi la mitad el rango total.

Antes de seguir con el cálculo de los parámetros de la válvula debemos definir uno de ellos que esta relacionado con aspectos de seguridad de manera directa. En caso de un fallo en el suministro de energía ¿Qué se quiere que pase con el proceso? En este caso lo más recomendable sería detener la reacción, con lo cual suspender el flujo f_I sería la acción predeterminada. Para que esto suceda, se requiere una válvula falla cerrada.

Teniendo lo anterior presente queda por escoger entre una válvula proporcional o isoporcentual.

Para la válvula proporcional tenemos que:

$$Kv = \frac{2}{100} = 0.02 \frac{\text{m}^3 / \text{s}}{\%CO} \quad 40)$$

$$m_{\bar{f}_i} = \frac{0.2}{0.02} = 10\%CO \quad 41)$$

Se observa que para la condición de estado estable la válvula tiene una señal del 10% con lo que no satisface la condición de simetría requerida.

Para la válvula isoporcentual tenemos que para un $m = 50\%CO$:

$$\alpha = \left(\frac{f_1 \max}{f_1} \right)^{\frac{1}{1-\frac{m}{100}}} = \left(\frac{2}{0.2} \right)^{\frac{1}{1-\frac{50}{100}}} = 100 \quad 42)$$

Con lo cual, debido a que este es un valor posible de α se ha cumplido con lo que se requería. Con lo anterior se puede entonces escribir la ecuación dinámica de la válvula como sigue.

$$0.2 \frac{df_1(t)}{dt} + f_1(t) = 2 * 100^{\frac{m(t)}{100}-1} \quad 43)$$

Escogiendo a τ_v como 0.2 min.

- *Sensor*

Se tiene el rango dinámico de la variable de salida se nos facilita la escogencia del sensor. En primera medida se debe escoger el rango, el cual principalmente se ve limitado por lo que podamos encontrar en el mercado. Debido a la no-linealidad de la mayoría de los sensores no es conveniente colocar el cero del sensor el tope mínimo de la variable de salida, al igual que el máximo del mismo en el máximo de dicha variable. Un rango de 20-400 Kg/m² resultaría adecuado para nuestros propósitos. De aquí se puede calcular a la constante del sensor como sigue:

$$Kt = \frac{100-0}{400-20} = 0.263 \frac{\%TO}{Kg/m^3} \quad 44)$$

Con lo que la ecuación dinámica del sensor seleccionando a τ_t como 0.8 min sería:

$$0.8 \frac{dc(t)}{dt} + c(t) = 0.263 * [c_{a3}(t) - 20] \quad 45)$$

9.1.2. Reactor neutralizador de pH.

Debido a que este proceso será usado para implementar una estrategia multivariable de dos entrada y dos salidas, se debe seleccionar dos válvulas y dos sensores para cada una de las variables de entrada y salida respectivamente.

- *Válvulas*

La primera variable de entrada es el flujo q_3 y la segunda es el flujo q_1 . El proceso que sigue para la escogencia de las válvulas es similar al anterior, por tanto, se tiene que las válvulas escogidas fueron FC proporcional, debido a que en caso de falla del suministro de

energía de las válvulas, la reacción se detenga. A continuación se muestra la selección y el cálculo de los parámetros correspondientes a cada una de las válvulas.

$$K_{V_1} = \frac{30}{100} = 0.3 \frac{ml/s}{\%CO} \quad 46)$$

$$m_{q_3}^- = \frac{15.6}{0.3} = 52\%CO \quad 47)$$

$$\tau_{V_1} = 6s \quad 48)$$

$$K_{V_2} = \frac{31.92}{100} = 0.3192 \frac{ml/s}{\%CO} \quad 49)$$

$$m_{q_1}^- = \frac{16.6}{0.3192} = 52\%CO \quad 50)$$

$$\tau_{V_2} = 6s \quad 51)$$

Las ecuaciones dinámicas de las válvulas con los anteriores parámetros en ellas se muestran a continuación.

○ *Válvula 1*

$$6 \frac{dq_3(t)}{dt} + q_3(t) = 0.3 * m_1(t) \quad 52)$$

○ *Válvula 2*

$$6 \frac{dq_1(t)}{dt} + q_1(t) = 0.3192 * m_2(t) \quad 53)$$

● *Sensores*

Las variables de salidas uno y dos son el pH y la altura h respectivamente. El desarrollo para obtener los parámetros de los sensores es similar al anterior, sin embargo, se debe tener en cuenta ahora las dos variables de entrada para observar los rangos en los cuales se mueven cada una de las variables de salida. El cálculo de los límites máximo y mínimo se hizo mediante pruebas realizadas vía simulación. Las ganancias de cada sensor en conjunto con sus ecuaciones dinámicas se muestran a continuación.

○ *Sensor 1*

$$K_{t_1} = \frac{100}{14} = 0.263 \frac{\%TO}{pH} \quad 54)$$

$$15 \frac{dc_1(t)}{dt} + c_1(t) = 7.1429 * [pH(t) - 0] \quad 55)$$

Seleccionando a $\tau_{t1} = 15s$.

o *Sensor 2*

$$Kt = \frac{100}{40} = 2.5 \frac{\%TO}{cm} \quad 56)$$

$$15 \frac{dc_2(t)}{dt} + c_2(t) = 2.5 * [h(t) - 0] \quad 57)$$

Seleccionando a $\tau_{t2} = 15s$.

9.2. IDENTIFICACIÓN DE LOS PROCESOS Y SINTONIZACIÓN DE LOS CONTROLADORES PID Y DMC

9.2.1. Identificación de los procesos.

En esta parte se busca caracterizar al proceso como un sistema FOPDT, en la cual mediante una prueba escalón se identifican los parámetros dinámicos relevantes de cada uno a saber: ganancia, constante de tiempo y tiempo muerto.

• Tanque Reactor con tanque de homogenización.

El paso escalón que se escogió para identificar al sistema fue de $-20\%CO$ respecto al punto de operación inicial. La grafica de salida y entrada se muestra en la Figura 12.

Con esta curva y mediante el *fit3* implementado en el algoritmo *ajuste_fit3.m* se obtuvo la siguiente la función de transferencia:

$$Gp(s) = \frac{-0.9269 * e^{-142.7718s}}{337.861s + 1} \quad 58)$$

Para corroborar que el modelo obtenido se ajuste a la realidad se probó su respuesta ante el cambio inicial de $-20\%CO$ en su entrada, y compramos la curva del modelo FOPDT contra la del proceso real. Ambas se muestran en la Figura 13.

Se puede observar, que a excepción de la respuesta inversa, el modelo FOPDT es una muy buena aproximación del proceso real para ese punto de operación.

Figura 12. Respuesta del tanque reactor ante una entrada escalón.

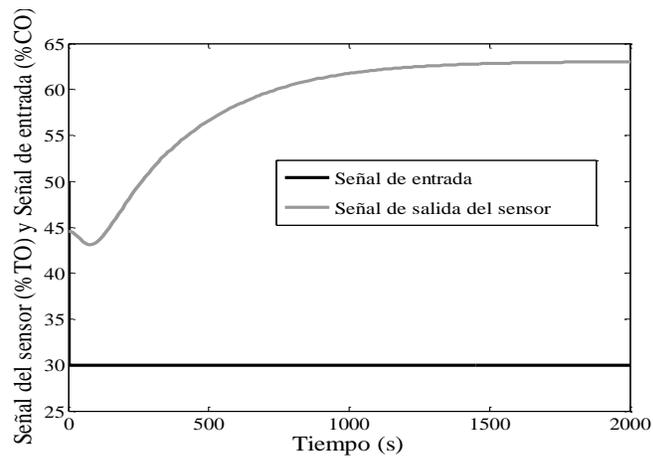
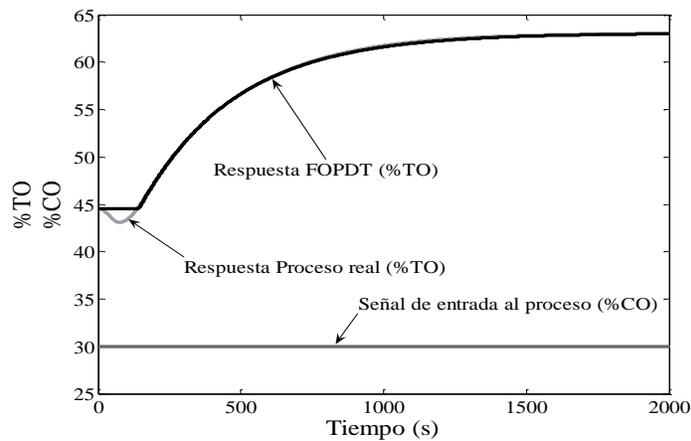


Figura 13. Comparación entre la salida del proceso real y de la aproximación FOPDT.

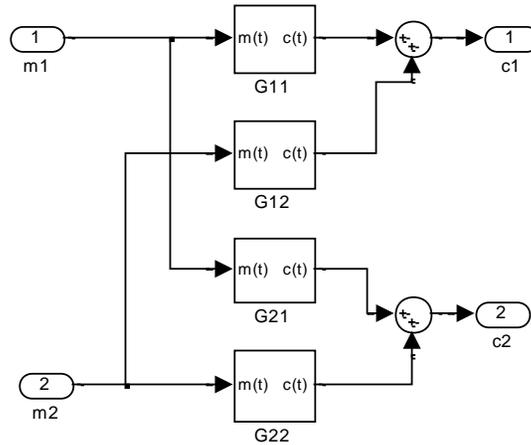


• **Reactor neutralizador de pH.**

A diferencia del proceso anterior, aquí se debe identificar cuatro funciones de transferencia, debido a que se necesita conocer la dinámica de cada par entrada salida en el sistema. Para un sistema MIMO 2 x 2, se tiene el diagrama de bloques mostrado en la Figura 14.

En el diagrama mostrado en la Figura 14, G_{ij} es la función de transferencia correspondiente a la salida i debido a la entrada j . Para este caso de estudio, cada una de las funciones de transferencia será FOPDT. Al igual que en el proceso anterior, se realiza una prueba escalón para hallar mediante *fit3*, los parámetros de cada una de las funciones de transferencia. Los cambios en las señales de entrada fueron $-10\%CO$ y $10\%CO$ para m_1 y m_2 respectivamente.

Figura 14. Diagrama de bloques de un sistema MIMO 2 x 2.



A través de dichas pruebas se obtuvieron las siguientes funciones de transferencia

$$Gp_{11}(s) = \frac{0.7449 * e^{-21.21s}}{105.02s + 1} \quad 59)$$

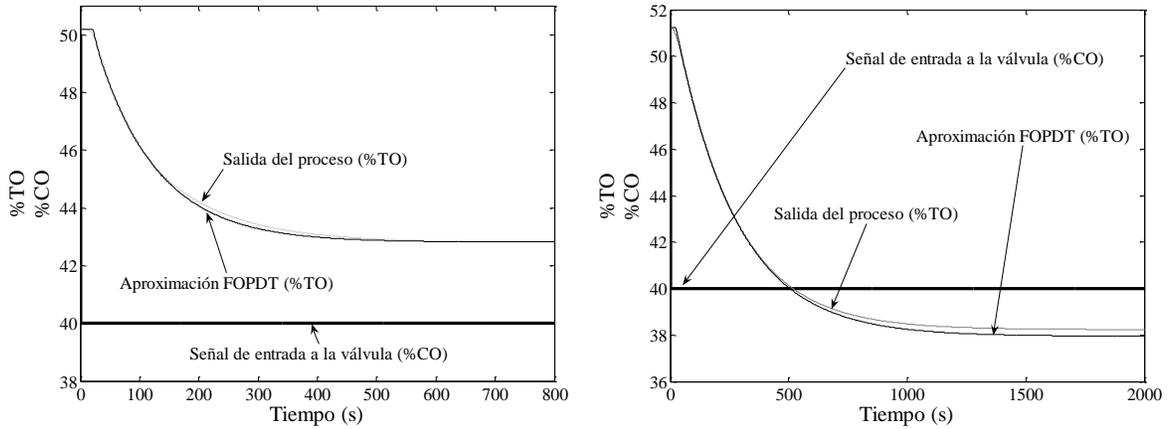
$$Gp_{12}(s) = \frac{-0.786 * e^{-34.22s}}{115.788s + 1} \quad 60)$$

$$Gp_{21}(s) = \frac{0.933 * e^{-22.31s}}{253.806s + 1} \quad 61)$$

$$Gp_{22}(s) = \frac{1.055 * e^{-37.66s}}{277.603s + 1} \quad 62)$$

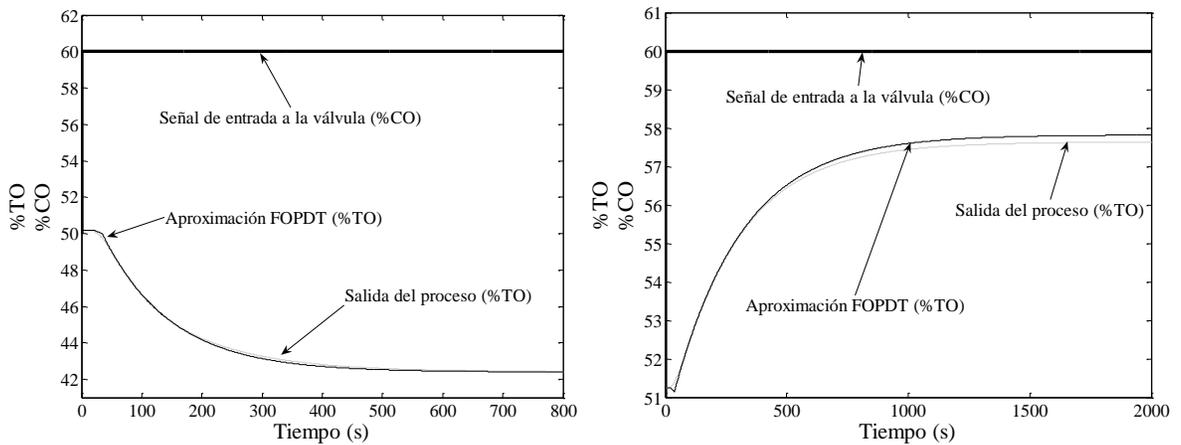
En la Figura 15 se muestran las respuestas comparativas entre el sistema real y el identificado como FOPDT para un cambio en m_1 de $-10\%CO$. Se puede observar que para este punto de operación el modelo lineal exhibe un comportamiento muy similar al del modelo real. Así mismo en la Figura 16 se muestran las respuestas comparativas entre el sistema real y el identificado como FOPDT para un cambio en m_2 de $10\%CO$. Se puede observar que para este punto de operación el modelo lineal representa muy bien el comportamiento el sistema no lineal para ese punto de operación.

Figura 15. Comparación entre la salida uno (izquierda) y dos (derecha) del reactor neutralizador de pH y la aproximación FOPDT para un cambio en la entrada uno.



A continuación se muestra la respuesta comparativa entre el sistema real y el identificado como FOPDT para un cambio en m_2 de 10% CO.

Figura 16. Comparación entre la salida uno (izquierda) y dos (derecha) del reactor neutralizador de pH respectivamente y la aproximación FOPDT para un cambio en la entrada dos.



9.2.2. Sintonización de los controladores PID

- **Tanque reactor con tanque de homogenización.**

El controlador usado aquí es un PID digital, el cual se sintonizará basándose en la respuesta lineal aproximada FOPDT hallada anteriormente, haciendo uso de las fórmulas deducidas en [13] mostradas en el marco teórico, para este tipo de sistemas.

Se calcularon los valores mostrados en la Tabla 2 para el controlador PID usando los valores de K_p , τ y t_o hallados en la sección 2.1.1. Las fórmulas están implementadas en el algoritmo `sintonizacion_PID.m`. El parámetro q es escogido como una fracción de la constante de tiempo y la constante para el filtro derivativo es escogida seleccionando un valor típico.

Tabla 2. Sintonización del PID para el tanque reactor.

Parámetro	Valor
T	71s
K_c	-1.1118 %CO/%TO
τ_I	303.6034 s
τ_D	0 s
α	0.1
q	112.6203

• **Reactor Neutralizador de pH.**

El controlador PID usado aquí es igual al anterior y el procedimiento para calcular los parámetros del mismo es igual. Por consiguiente, usando los valores hallados en la sección 2.1.2, para la función de transferencia G_{11} , se muestran los valores obtenidos en la Tabla 3.

Tabla 3. Sintonización del PID para reactor neutralizador de pH.

Parámetro	Valor
T	10s
K_c	2.1865 %CO/%TO
τ_I	100.1043s
τ_D	0s
α	0.1
q	35.0083

Se usa solamente la función de transferencia G_{11} debido a que el controlador PID será usado para contrastar la estrategia SISO únicamente, y no la MIMO, mientras que el DMC se usará para contrastar ambas.

9.2.3. Sintonización de los controladores DMC.

La sintonización del DMC se hará usando las fórmulas mostradas en la sección 7.2.4, en donde se usa al igual que en el PID una aproximación FOPDT del proceso.

-
- **Tanque Reactor con tanque de homogenización.**

Las fórmulas de sintonización fueron implementadas en el algoritmo `sinto_dmc.m`, en el cual se calculan todos los parámetros del DMC exceptuando el peso de las variables controladas γ . Debido a que es un proceso SISO, este valor no es significativo al momento de sintonizar al controlador y, por tanto, se deja en su valor por defecto, es decir, uno. Los valores de la aproximación FOPDT son los hallados en la sección 9.2.1.

Tabla 4. Sintonización del DMC para el tanque reactor.

Parámetro	Valor
T	71s
Np	27 (períodos de muestreo)
Nu	8 (períodos de muestreo)
λ	0.21102
γ	1

• **Reactor neutralizador de pH.**

El proceso para la sintonización es igual al anterior, sin embargo, para este caso, se deben realizar dos sintonizaciones distintas, una para el caso SISO y otra para el caso MIMO. Para el caso SISO al igual que para el PID sólo se usará la función de transferencia G_{11} , mientras que para el caso MIMO, se usarán todas las funciones obtenidas en la sección 0.□.

○ *SISO.*

Los valores obtenidos son hallados usando las fórmulas mostradas anteriormente implementadas en el algoritmo `sinto_dmc.m`.

Tabla 5. Sintonización del DMC para reactor neutralizador de pH SISO.

Parámetro	Valor
T	10s
Np	56 (períodos de muestreo)
Nu	14 (períodos de muestreo)
λ	0.50699
γ	1

○ *MIMO.*

Los valores obtenidos son hallados usando las fórmulas mostradas anteriormente implementadas en el algoritmo `sinto_dmc_mult.m`.

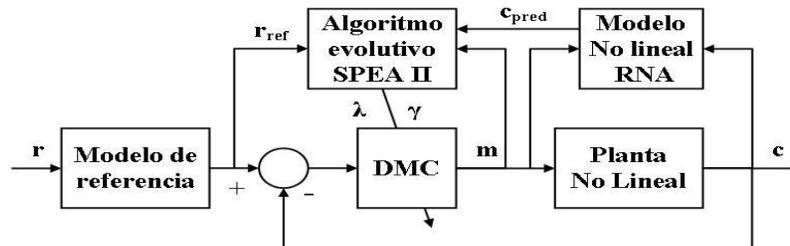
Tabla 6. Sintonización del DMC para reactor neutralizador de pH MIMO.

Parámetro	Valor
T	11s
Np	131 (períodos de muestreo)
Nu	30 (períodos de muestreo)
λ_1	7.5941
λ_2	8.7398
γ_1	1
γ_2	1

9.3. DMC ADAPTATIVO

Para exponer de manera clara la estrategia adaptativa propuesta, se explicará como funciona cada bloque en particular ya que la integración de los mismos se expuso en la descripción general del sistema en la sección 8.3. El diagrama de bloques se muestra a continuación.

Figura 17. Diagrama general de la estrategia adaptativa.



El anterior diagrama de bloques es válido tanto para el modelo SISO como para el MIMO, debido a que la diferencia entre los dos son las señales; para el primero son escalares y para el segundo son vectores.

9.3.1. Modelo no lineal en redes neuronales.

El modelo no lineal para realizar el entrenamiento es el NARX, brevemente explicado en la sección 7.3.3 y el usado para realizar predicciones de más de un período de muestreo es el NOE, expuesto en la misma sección anterior. El horizonte de predicción usado para esta red debe ser menor igual que el horizonte de control del DMC. Esto es debido a que cada predicción consideramos las acciones de control calculadas por el DMC y no la respuesta libre del sistema ante solamente una de ellas.

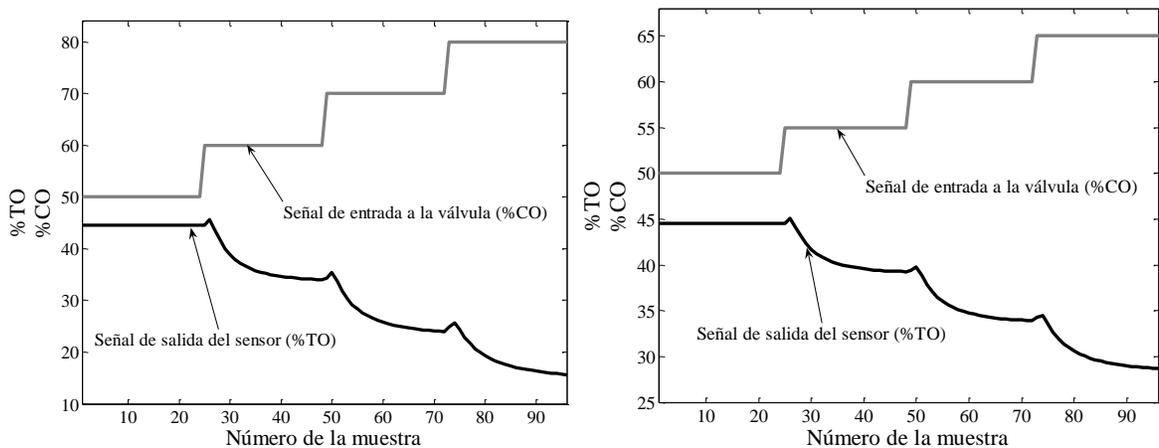
En la sección 7.3.3 se explico como se realiza el entrenamiento de la red neuronal para modelar el comportamiento no lineal del proceso. Aquí abordaremos la obtención de los conjuntos de entrenamiento y validación, la selección de los regresores, así como la implementación del reentrenamiento de la misma.

- **Recolección de datos de entrenamiento y validación.**

Para la implementación de la estrategia SISO, los conjuntos de entrenamiento y validación para cada uno de los procesos, consistieron en una serie de entradas escalones con las cuales se puede aproximar el comportamiento dinámico no lineal de los mismos, sin necesidad de excitar al sistema en todas las frecuencias posibles o con entradas aleatorias binarias que no necesariamente son factibles de implementación en un proceso real. Los conjuntos se obtuvieron vía simulación en el software SIMULINK.

La diferencia entre los escalones de las pruebas para entrenamiento y validación, son el tamaño de los mismos. Las gráficas de cada una de las pruebas, para cada uno de los procesos SISO, se muestran en la Figura 18.

Figura 18. Datos para el conjunto de entrenamiento (izquierda) y validación (derecha), respectivamente del tanque reactor con tanque de homogenización.



Cabe anotar que cada una de las muestras fueron tomadas a una tasa de muestreo igual al período de muestreo del controlador DMC.

Para la implementación MIMO realizada sobre el reactor neutralizador de pH se hizo también una serie de entradas escalón, sin embargo, debido a que ahora tenemos dos entradas y dos salidas se realizaron dos pruebas. Primero se realizaron cambios sobre la primera entrada y después sobre la segunda, de modo que se pudiese capturar el comportamiento dinámico de todas las interacciones del sistema. Los conjuntos de entrenamiento y validación, para los procesos SISO y MIMO del reactor neutralizador de pH, se muestran a continuación.

Figura 19. Datos para el conjunto de entrenamiento (izquierda) y validación (derecha), del reactor neutralizador de pH SISO.

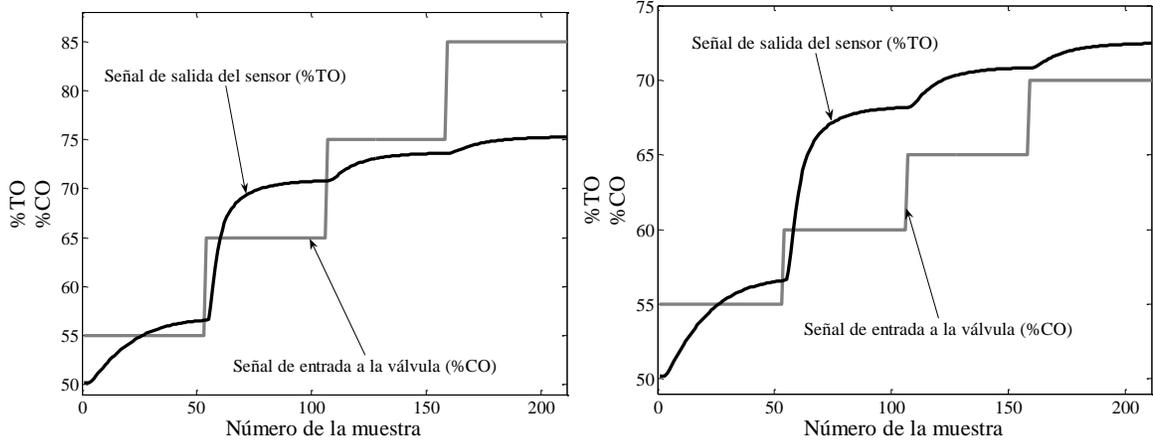
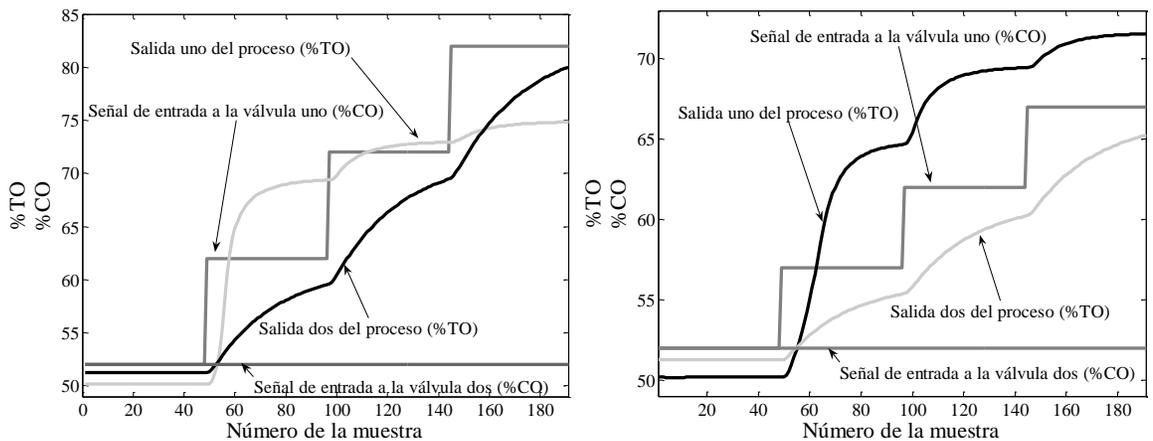
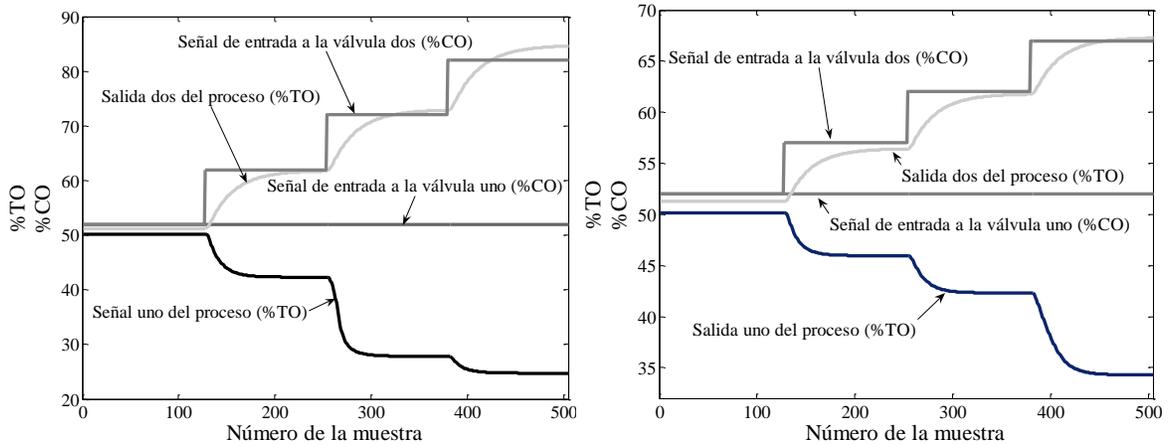


Figura 20. Datos para el conjunto de entrenamiento (izquierda) y validación (derecha), del reactor neutralizador de pH MIMO para cambios en la entrada uno.



Ambos conjuntos de entrenamiento son reducidos, debido a que se usa el algoritmo de mínimos cuadrados recursivos expuesto en la presente sección para re-entrenar a la RNA en línea. El entrenamiento fuera de línea se usa para hallar los pesos de la capa de salida y para inicializar a la matriz P de dicho algoritmo.

Figura 21. Datos para el conjunto de entrenamiento (izquierda) y validación (derecha), del reactor neutralizador de pH MIMO para cambios en la entrada dos.



• **Selección de los regresores para entrenamiento y predicción.**

La selección de los regresores para el modelo no lineal de la red neuronal se hizo con base en experiencias anteriores [22], en las cuales se usaban procesos similares a los usados en el presente trabajo. La selección de los regresores se hace tratando de optimar parámetros como el error cuadrático medio y la complejidad de la red neuronal, medida en el número de nodos en cada capa de la misma.

Los regresores y las salidas usadas en cada modelo se muestran en la Tabla 7.

Tabla 7. Regresores seleccionados para los modelos no lineales.

		Regresores	Salidas
Proceso uno	SISO	$\varphi(\underline{C}) = [h(-1), c(-1)]^T$	$y(\underline{C}) = c(\underline{C})$
Proceso dos	SISO	$\varphi(\underline{C}) = [h(-1), c(-1)]^T$	$y(\underline{C}) = c(\underline{C})$
	MIMO	$\varphi(\underline{C}) = [h_1(-1), m_2(-1), c_1(-1), c_2(-1)]^T$	$y(\underline{C}) = [h_1(\underline{C}), c_2(\underline{C})]^T$

• **Entrenamiento y validación.**

Los conjuntos de entrenamiento para las redes que modelan a los procesos SISO y MIMO se obtuvieron a partir de las pruebas mostradas anteriormente.

Recordando el entrenamiento para RAWNN descrito en la sección 7.3.2 y considerando a los regresores seleccionados en la sección anterior, tenemos que para las redes que modelan a los procesos SISO:

$$X(k) = [m(k), c(k), 1] \quad (63)$$

$$X = \begin{bmatrix} m(1) & \dots & m(k) & \dots & m(N-1) & 1 \\ c(1) & \dots & c(k) & \dots & c(N-1) & 1 \end{bmatrix}^T = [X(1) \dots X(k) \dots X(Ne)]^T \quad (64)$$

$$Y(k) = c(k+1) \quad (65)$$

$$Y = [c(2), c(3), \dots, c(N)]^T = [Y(2), Y(3), \dots, Y(Ne)]^T \quad (66)$$

y para la que modela al proceso MIMO

$$X(k) = [m_1(k), m_2(k), c_1(k), c_2(k), 1] \quad (67)$$

$$X = \begin{bmatrix} m_1(1) & \dots & m_1(k) & \dots & m_1(N-1) & 1 \\ m_2(1) & \dots & m_2(k) & \dots & m_2(N-1) & 1 \\ c_1(1) & \dots & c_1(k) & \dots & c_1(N-1) & 1 \\ c_2(1) & \dots & c_2(k) & \dots & c_2(N-1) & 1 \end{bmatrix}^T = [X(1) \dots X(k) \dots X(Ne)]^T \quad (68)$$

$$Y(k) = [c_1(k+1), c_2(k+1)] \quad (69)$$

$$Y = \begin{bmatrix} c_1(2) & \dots & c_1(k+1) & \dots & c_1(N) \\ c_2(2) & \dots & c_2(k+1) & \dots & c_2(N) \end{bmatrix}^T = [Y(2), \dots, Y(Ne)]^T \quad (70)$$

Donde k es el número del dato tomado a un período T , N es número de datos totales de la prueba y Ne es el número de datos totales de entrenamiento, que para nuestro caso es $N-1$.

Debido a que la generación de los pesos de la capa de entrada se hace de manera aleatoria, recurrimos a realizar iteraciones generando dichos pesos varias veces, con el objetivo de encontrar el menor error cuadrático. Sin embargo, debido a que más iteraciones no aseguran que se encuentren mejores pesos, el número de ellas es pequeño. Cabe anotar que el error que se busca minimizar con estas iteraciones no es el error de predicción para los datos de entrenamiento, sino el error para los datos de validación. Con esto buscamos no un ajuste perfecto a los datos, sino una buena capacidad de generalización de la red.

- **Reentrenamiento en línea.**

Para el reentrenamiento en línea de la red neuronal se usó el algoritmo de mínimos cuadrados recursivos *RLS*, aprovechando el hecho de que los pesos de la capa de salida de las RAWNN se obtienen a través de una solución de OLS.

Para el algoritmo OLS tenemos que

$$\hat{\theta} = (\Phi^T \Phi)^{-1} \Phi^T Y \quad (71)$$

Teniendo a P como $P = (\Phi^T \Phi)^{-1}$, a través de una deducción mostrada en [14] se llega a

$$\hat{\theta}(k) = \hat{\theta}(k-1) + P(k)x^k (y^k - x^k)^T \hat{\theta}(k-1) \quad (72)$$

con

$$P(k) = P(k-1) - P(k)x^k (I + (x^k)^T P(k-1)x^k)^{-1} (x^k)^T P(k-1) \quad (73)$$

En este trabajo se optó por inicializar dicha matriz usando el entrenamiento fuera de línea, como punto inicial de arranque. En resumen tenemos que:

$$P = (V_b^T V_b)^{-1} \quad (74)$$

Usando los datos iniciales de entrenamiento. Para el entrenamiento en línea cada período de muestreo tenemos que:

$$\Phi = V_b \quad (75)$$

$$\hat{\theta} = W^o \quad (76)$$

$$x^k = V(t) \quad (77)$$

$$y^k = Y(t) \quad (78)$$

Cabe anotar que $V(t)$ se obtiene con las entradas correspondientes $\{n, c\}$ para las que modelan a los procesos SISO y $\{n_1, m_2, c_1, c_2\}$ para la que modela al proceso MIMO.

9.3.2. DMC con modelo de referencia.

El DMC implementado en la estrategia adaptativa solo difiere del DMC estándar en la manera como se calcula el error que se usa en el algoritmo de control. Para este problema, dicho error no se calcula con base en la referencia de tipo escalón, sino con base en la respuesta de un modelo de referencia a esta entrada. Con esto, el DMC no busca seguir una referencia ideal, sino una referencia real susceptible de ser seguida por el proceso. Esto se traduce en acciones de control más suaves y en la relajación del proceso de optimización que se lleva a cabo en la estrategia adaptativa como se verá más adelante.

• **Modelo de referencia.**

Los modelos de referencia que se abordan son modelos lineales discretos de primer y segundo orden, debido a alta comprensión del comportamiento de los mismos y por tanto, a la facilidad con la cual se especifica la respuesta de los mismos ante distintas entradas. La función de transferencia general para el sistema de primer orden es:

$$R(z) = \frac{b}{z - a} \quad (79)$$

$$b = 1 - a \quad (80)$$

$$a = e^{-T/\tau} \quad (81)$$

Donde τ es la constante de tiempo del sistema. Para el de segundo orden se tiene:

$$R(z) = \frac{1 - 2b \cos(\omega_n T) + b^2}{z^2 - 2b \cos(\omega_n T)z + b^2} \quad (82)$$

$$a = T\omega_n \sqrt{1 - \xi^2} \quad (83)$$

$$b = e^{-\omega_n T \xi} \quad (84)$$

Donde T es el período de muestreo, ω_n la frecuencia natural de oscilación del sistema y ξ el factor de amortiguamiento.

Para el proceso de primer orden la respuesta se especifica con el tiempo de asentamiento del sistema, el cual se tiene como:

$$T_s = 5\tau \quad (85)$$

De donde se obtiene la constante de tiempo requerida para la función de transferencia. Para el sistema de segundo orden, se especifica la respuesta a través del tiempo de asentamiento y el factor de amortiguamiento requerido, con lo cual se obtiene a ω_n como:

$$\omega_n = \frac{5}{\xi T_s} \quad (86)$$

Para cada uno de estos modelos es calculado un modelo de respuesta escalón de la misma manera se calcula para la planta, con horizonte de predicción igual al de este y con horizonte de control igual a uno.

9.3.3. Algoritmo evolutivo: SPEA II.

- **Codificación, inicialización y operadores.**

El código principal del algoritmo evolutivo usado se expuso en la sección 8.3. Para su implementación en el presente trabajo se tuvieron varios aspectos en cuenta. Entre los primordiales estuvo la velocidad de ejecución y la eficiencia medida en función del número de generaciones y del tamaño de la población necesario para arrojar buenos resultados en la búsqueda. Estos aspectos son cruciales debido a que el controlador es calculado en línea, es decir, el algoritmo evolutivo debe arrojar resultados en menos de un período de muestreo para poder ejecutar el algoritmo en tiempo real.

La codificación usada en real en punto flotante. Fue escogida gracias a su velocidad computacional derivada del hecho de que no hay que hacer codificación y decodificación, evitando igualmente los errores de redondeo de estos proceso, que pueden llevar a cambios en ocasiones significativos sobre los puntos solución encontrados. Para esta implementación se seleccionaron tres operadores, dos de cruzamiento y uno de mutación. La selección se hizo con base en revisión de trabajos anteriores [18] y en criterios expuestos con anterioridad.

La población inicial de controladores se generó a partir de la sintonización inicial para el DMC mostrada en la sección 9.2.3. Para cada período de muestreo se generan miembros uniformemente distribuidos entre los límites dados por las restricciones hasta que se de un cambio en la referencia, lo cual obliga al sistema a volver a la sintonización inicial. Esto se hace para prevenir un crecimiento muy alto en los factores debido a una larga acumulación en el crecimiento de los mismos.

Los operadores de cruzamiento seleccionados para este tipo de cromosoma, fueron el heurístico y el aritmético descritos en la sección 7.5.2. Como último operador, la mutación no uniforme descrita en 7.5.2 fue usada, en donde el parámetro b fue escogido con un valor de dos siguiendo experiencias anteriores [18] y pruebas realizadas.

- **Funciones objetivo.**

Para las implementaciones en sistemas SISO se usaron tres funciones objetivo a optimar, mientras que para el sistema MIMO se usaron seis. La diferencia entre ambos es que para el último al ser 2×2 simplemente se duplican las mismas.

Para los sistemas SISO se tiene

$$f_1(\lambda, \gamma) = \sum_{i=1}^{nu} e_{pred}^2 \quad (87)$$

$$f_2(\lambda, \gamma) = \sum_{i=1}^{np} e_{pred_lin}^2 \quad (88)$$

$$f_3(\lambda, \gamma) = \sum_{i=1}^{nu} \Delta u^2 \quad (89)$$

Para los sistemas MIMO tenemos

$$f_{1,2}(\lambda, \gamma) = \sum_{i=1}^{nu} \left(R_r(i) - c_{pred}^{(i)} \right)_{1,2}^2 = \sum_{i=1}^{nu} e_{pred}^2 \quad (90)$$

$$f_{3,4}(\lambda, \gamma) = \sum_{i=1}^{nu} \Delta u_{1,2}^2 \quad (91)$$

$$f_{5,6}(\lambda, \gamma) = \sum_{i=1}^{np} \left(R_r(i) - c_{pred_lin}^{(i)} \right)_{1,2}^2 = \sum_{i=1}^{np} e_{pred_lin}^2 \quad (92)$$

Sujetas a las siguientes restricciones

$$\Delta \lambda_{\min} \leq \Delta \lambda \leq \Delta \lambda_{\max} \quad (93)$$

$$\Delta \gamma_{\min} \leq \Delta \gamma \leq \Delta \gamma_{\max} \quad (94)$$

$$|\Delta m| \leq \Delta m_{\max} \quad (95)$$

$$\lambda \geq \lambda_{\min} \quad (96)$$

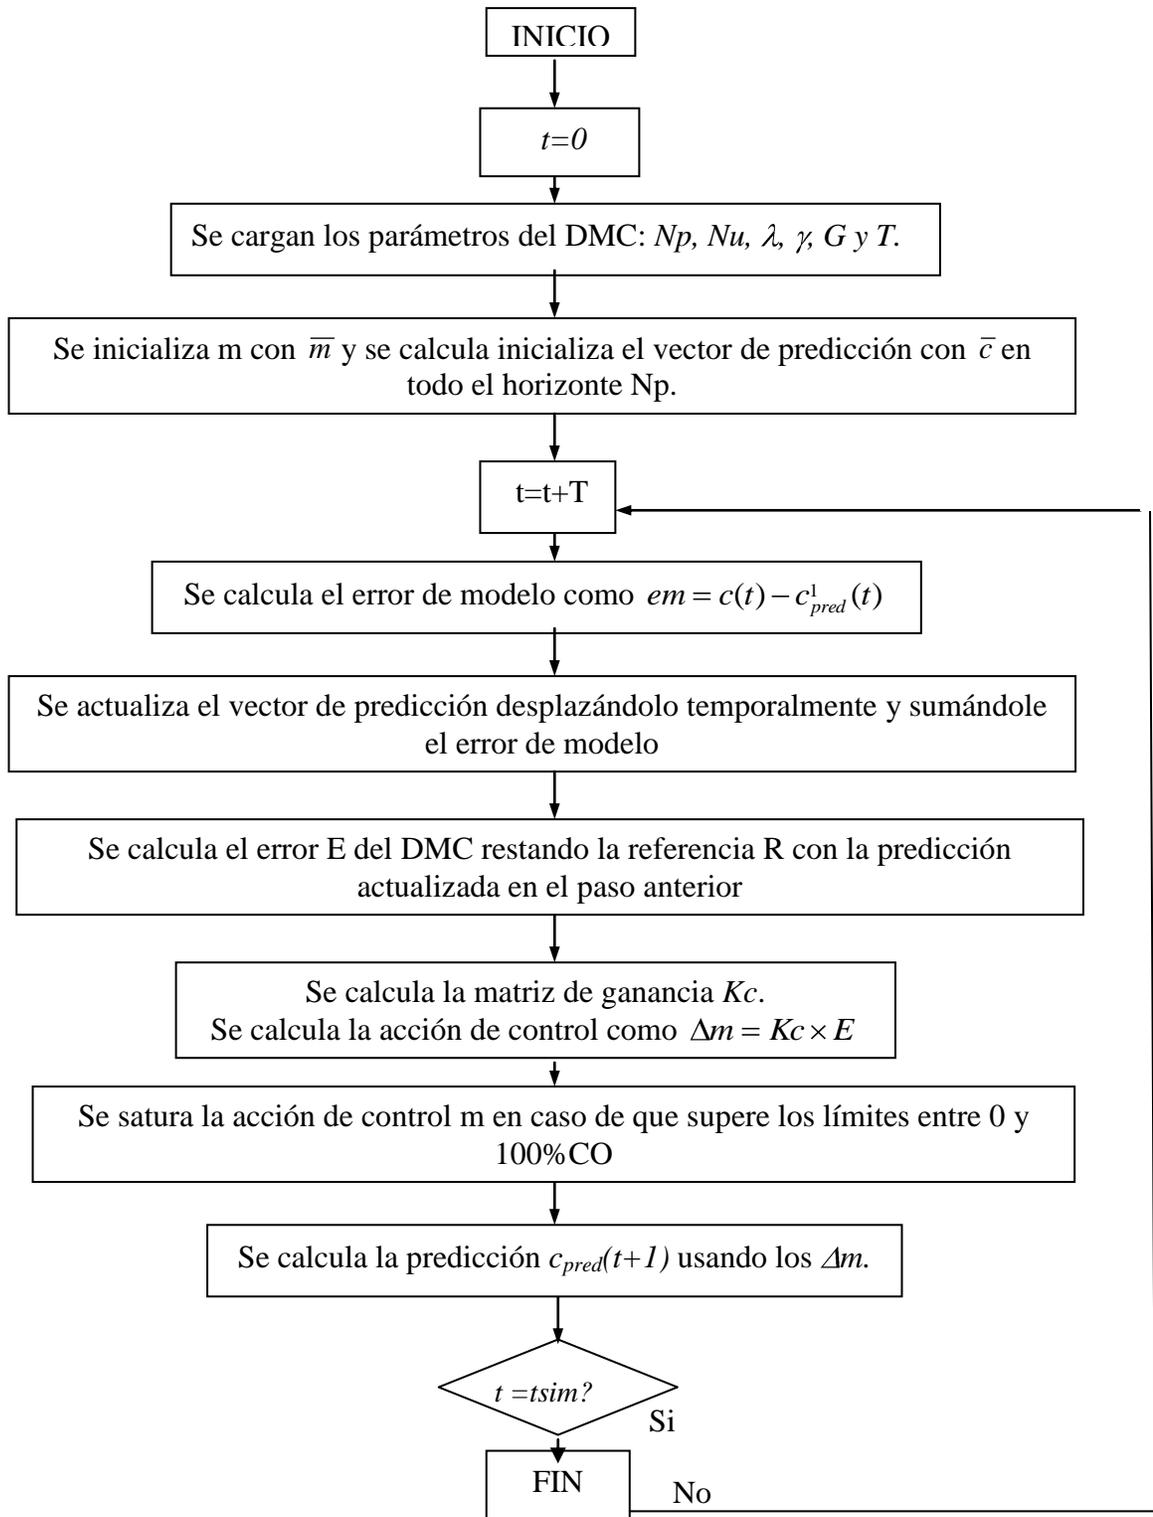
$$\gamma \geq \gamma_{\min} \quad (97)$$

Donde e_{pred} es el error en la predicción de la red neuronal y e_{pred_lin} es el error en la predicción del modelo lineal de la planta, ambos respecto a la salida del modelo de referencia R_r . Los Δu son las acciones de control futuras generadas por el DMC. Los índices 1 y 2 indican cada una de las salidas para el caso de los errores y cada una de las entradas para el caso de los cambios en la acción de control. Para las restricciones $\Delta \lambda_{\min}$, $\Delta \lambda_{\max}$ son los valores en los que puede disminuirse o aumentarse λ respecto al valor actual; lo mismo sucede con γ . Δm_{\max} es el máximo cambio permitido para la acción de control en un período de muestreo. Finalmente λ_{\min} y γ_{\min} son los valores mínimos que pueden tomar dichos parámetros, teniendo condiciones de estabilidad para los mismos.

Estas tres funciones son dependientes de los factores de supresión debido a que estos valores son los que están siendo optimados en el proceso de adaptación y, por tanto, las acciones de control y por ende los errores cambian en función de estos parámetros.

Los valores de las funciones son normalizados usando el máximo valor obtenido para ellas en cada generación. Podría llegar a pensarse que hay comparaciones desiguales entre una generación y otra, pero al calcular el valor de las funciones objetivos para todos los miembros de la población y del archivo nuevamente en cada generación se evita este problema. El diagrama de flujo para el cálculo de las funciones se muestra en la Figura 22.

Figura 22. Diagrama de flujo para el cálculo de las funciones objetivo.



9.3.4. Toma de decisiones sobre el frente pareto.

Debido a que el resultado del proceso de optimización multiobjetivo es un frente pareto optimo, se debe decidir cual punto del frente escoger como el más adecuado para cada período de muestreo, considerando las condiciones en las cuales se encuentra el sistema.

Para tal fin se tomaron dos alternativas. La primera de ellas toma la decisión de la siguiente forma:

$$P'_s \in \langle P'_i | i = 1 \dots N' \rangle \wedge f_s = \min \left(\sum_{j=1}^n f_j \right) \quad (98)$$

Donde f_s es el valor de la función para el punto escogido s representado por la solución P'_s , f_j es el valor de cada una de las funciones ya mencionadas y n el número de funciones del problema.

La segunda alternativa toma la decisión con un FIS TSK cuyo funcionamiento básico se explica en la sección 7.4. Aquí las entradas del sistema de inferencia son: el cambio en las referencias y los errores actuales del sistema entre la referencia y las salidas. Este sistema solo fue implementado en la planta MIMO.

El diagrama general del sistema de inferencia difuso en conjunto con las funciones de pertenencia de las entradas y salidas se muestran a continuación.

Figura 23. Diagrama general del sistema de inferencia difuso TSK usado.

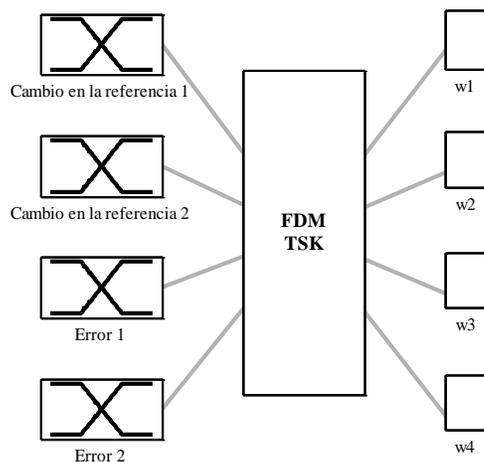
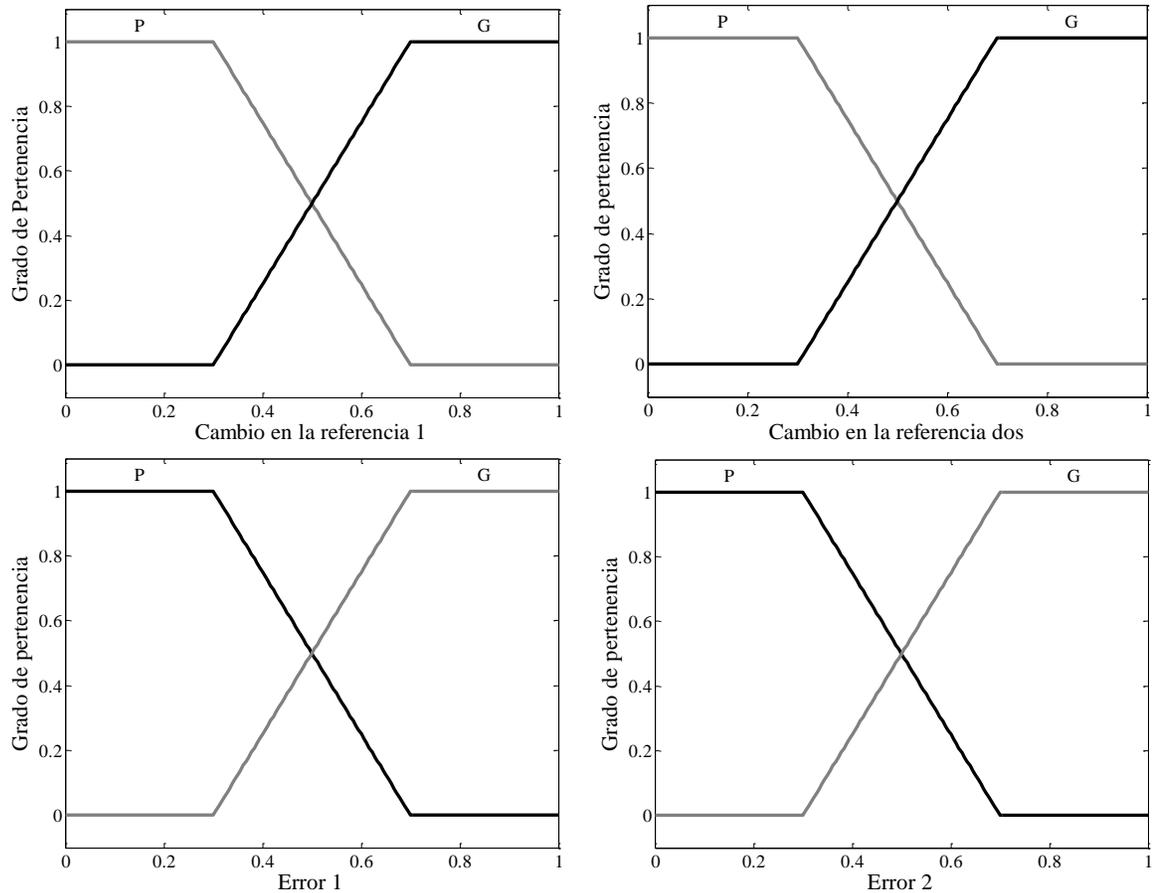


Figura 24. Funciones de pertenencia de las entradas del sistema de inferencia difuso TSK.



Las reglas implementadas se muestran en la Tabla 8. Aquí P y G para las entradas se refieren a las funciones de pertenencia mostradas anteriormente y w_1, w_2, w_3, w_4 , son los pesos para cada una de las funciones objetivo. Los pesos w_5, w_6 son iguales a los pesos w_1 y w_2 . Para las salidas del sistema TKS tenemos que $P = 0.08$ $M = 0.16$ $G = 0.24$.

A partir de la Tabla 8 podemos construir las reglas como en el siguiente ejemplo:

Si el cambio en la referencia 1 es P y el cambio en la referencia 2 es P entonces $w_1=M$, $w_2=M$, $w_3=M$ y $w_4=M$.

Cuando no aparece nada en una casilla en la tabla no se tiene en cuenta esa entrada o salida para construir la regla.

Los valores de los consecuentes se escogieron teniendo en cuenta que son seis funciones objetivo y que los pesos debían cumplir con lo siguiente.

$$\sum_{j=1}^6 w_j = 1$$

99)

Tabla 8. Base de reglas del sistema de inferencia difuso TSK.

ANTECEDENTES				CONSECUENTES			
Cambio en la referencia 1	Cambio en la referencia 2	Error 1	Error 2	w ₁	w ₂	w ₃	w ₄
P	P			M	M	M	M
P	G			P	P	G	P
G	P			M	P	P	G
G	G			G	G	P	P
		P	P	P	P	G	G
		P	G	P	G	P	M
		G	P	G	M	P	M
		G	G	G	G	P	P

Por último la decisión sobre el punto se toma de la siguiente manera:

$$P'_s \in \langle P'_i | i = 1 \dots N' \rangle \wedge f_s = \min \left(\sum_{j=1}^n w_j f_j \right) \quad (100)$$

La cual es una generalización de la primera toma de decisiones asignando de manera dinámica a través de FIS TSK los pesos en cada una de las funciones objetivo. Cabe anotar que no es equivalente resolver el problema por el método de suma de pesos debido a que no se puede asumir que el conjunto solución es convexo en cada período de muestreo. Lo que se hace realmente con esta suma de pesos al final del proceso de optimización es ubicarse sobre alguna parte de la curva, la cual en general puede no ser cóncava, fruto de un conjunto solución convexo.

Por último, notando que las funciones de pertenencia para las entradas se encuentran en un universo de discurso normalizado se hace uso de una normalización en las entradas del sistema de la siguiente manera:

$$I = \begin{bmatrix} R_1 & \Delta R_2 & E_1 & E_2 \end{bmatrix} \quad (101)$$

$$MN = \begin{bmatrix} g_1 & 0 & 0 & 0 \\ 0 & g_2 & 0 & 0 \\ 0 & 0 & g_3 & 0 \\ 0 & 0 & 0 & g_4 \end{bmatrix} \quad (102)$$

$$I_N = I \times MN \quad (103)$$

Donde ΔR_1 y ΔR_2 son los cambios en la referencia uno y dos respectivamente, E_1 y E_2 son los errores uno y dos respectivamente, I_N son las entradas normalizadas y MN es la matriz de normalización compuesta por los g_i los cuales se calculan usando los valores máximos esperados para cada una de las entradas I_e de la siguiente manera:

$$g_i = \frac{1}{\max(I_e(i))} \quad 104)$$

10. PRUEBAS Y RESULTADOS

Las pruebas realizadas a la estrategia adaptativa, se realizan en los dos procesos ya mencionados. Sin embargo, como ya se ha dicho, no se analiza el rendimiento de ella solamente sino que se contrasta con el rendimiento de las estrategias de control PID y DMC estándar.

Algo muy importante que se debe aclarar es el hecho de que para la estrategia hay un número de parámetros a escoger no despreciable, pero lo más delicado es cada uno de ellos puede tener un gran número de posibles valores o infinitos en el peor de los casos. Por esta razón muchos de estos parámetros no serán variados a lo largo de las pruebas y se escogieron ayudándose de experiencias e investigaciones anteriores.

El diseño de las pruebas se centrara en la evaluación de la estrategia ante varias condiciones de operación y no en la variación de todos los parámetros que la componen. Solo serán escogidos parámetros que mostraron ser significativamente relevantes en el momento del desarrollo de la estrategia.

Para cada sistema se realizará el siguiente conjunto de pruebas:

1. Pruebas ante cambios en el punto de operación.
2. Pruebas ante cambios en el punto de operación, sumando ruido a la señal de los sensores.
3. Para el sistema MIMO se probará el rendimiento de los dos sistemas de toma de decisiones sobre el frente pareto.

10.1. PRUEBAS ANTE CAMBIOS EN EL PUNTO DE OPERACIÓN

10.1.1. Tanque reactor con tanque de homogenización.

Los parámetros seleccionados de la estrategia para realizar las pruebas siguientes se resumen en la Tabla 9. La sintonización PID y el DMC estándar fue la hallada en la sección 9.2.2. El resultado de las pruebas para cada uno de los sistemas se muestra en la Tabla 9.

En la Figura 25 se puede observar el rendimiento de la estrategia adaptativa respecto a las otras dos estrategias de control. Claramente se puede ver como las tres respuestas son muy similares justo cuando se realiza un cambio en la referencia, sin embargo cuando avanza el tiempo se observa un sobreimpulso menor por parte de la estrategia adaptativa respecto a las otras dos. Incluso los tiempos de estabilización del sistema para las tres estrategias son bastante similares. Esto puede explicarse en la medida en que la estrategia adaptativa vuelve a su estado inicial en cada cambio de la referencia y por tanto, su comportamiento es básicamente el mismo al DMC no adaptativo justo en el inicio de los cambios pero difiere conforme se efectúa la adaptación sobre el mismo.

Tabla 9. Parámetros para la estrategia adaptativa en el tanque reactor con tanque de homogenización.

	Parámetro	Valor
RNA	Número de nodos en la capa oculta	8
	Iteraciones para el entrenamiento	100
	Horizonte de predicción para el cálculo de las funciones objetivo	7
Modelo de Referencia	Orden	2
	Factor de amortiguamiento (ξ)	0.8
	Tiempo de asentamiento (T_s)	$2*\tau_{\text{sistema}}$
SPEA II	Número de miembros en P	50
	Número de miembros en P'	20
	Probabilidad de cruzamiento (p_c)	0.9
	Probabilidad de Mutación (p_m)	0.3
	Número de generaciones (N_g)	10
Restricciones	$\Delta\lambda_{\min}$	10
	$\Delta\lambda_{\max}$	2
	$\Delta\gamma_{\min}$	10
	$\Delta\gamma_{\max}$	2
	Δm_{\max}	15
	λ_{\min}	0.2
	γ_{\min}	1

En la Figura 26 se observa que la señal de control del DMC adaptativo presenta transiciones más suaves y picos de señal menores a los de las otras dos estrategias, lo cual se traduce directamente en una energía de control menor para lograr resultados similares, así como un aumento de la vida útil de los dispositivos usados para efectuar la acción de control final como las válvulas, al no ser sometidas a cambios bruscos en su posicionamiento cada vez que el controlador ejecuta una acción.

En la Figura 27 se observa un comportamiento bastante interesante debido a que tenemos errores de modelo distintos teniendo el mismo modelo de predicción para los controladores DMC y DMC adaptativo. Las predicciones se realizan usando las acciones de control y en la medida en que estas son distintas para cada controlador, también lo serán sus predicciones.

Figura 25. Respuesta en lazo cerrado del tanque reactor con tanque de homogenización ante cambios en el punto de operación.

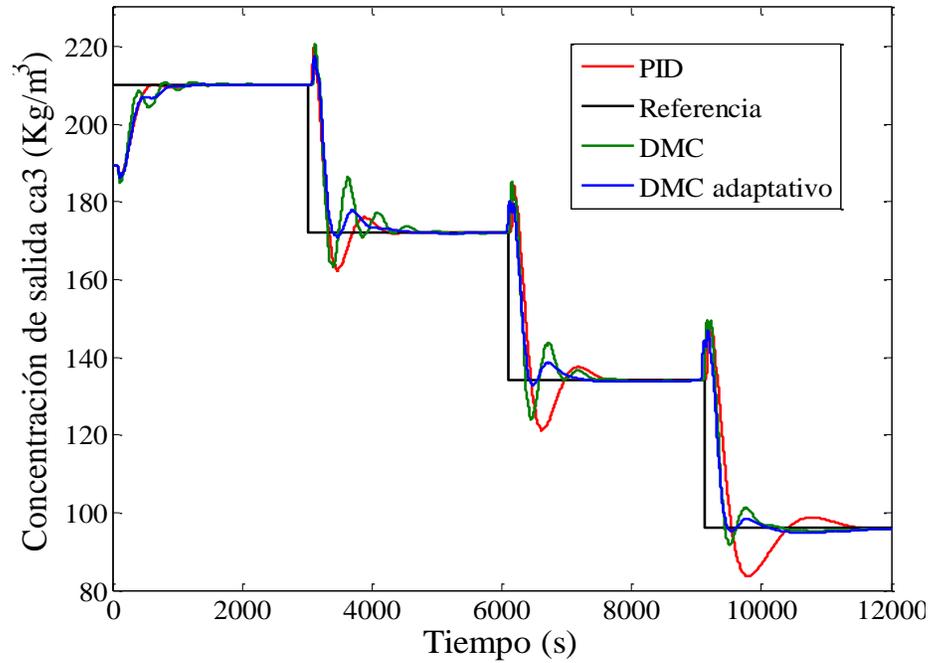


Figura 26. Señal de salida de los controladores ante cambios en la referencia para el tanque reactor con tanque de homogenización.

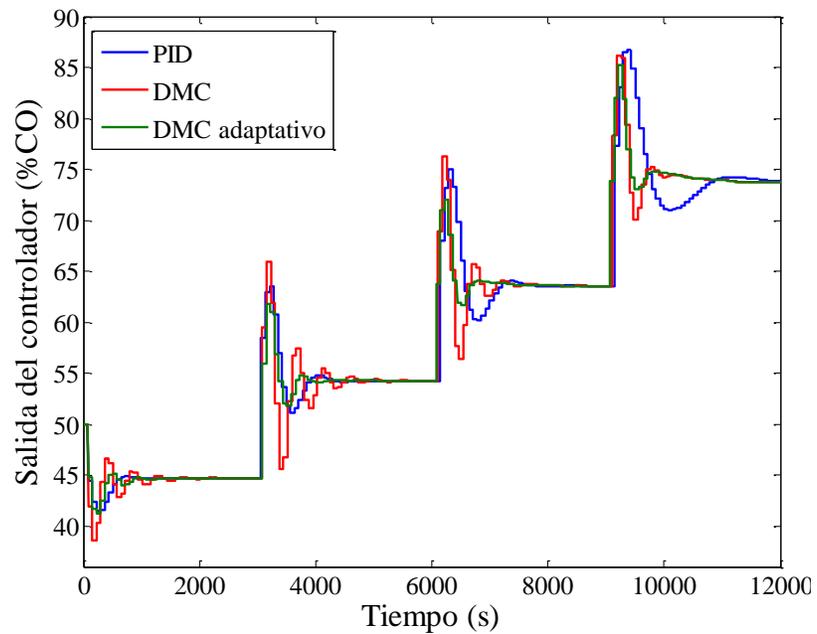


Figura 27. Error de modelo del DMC y del DMC adaptativo para cambios en el punto de operación en el tanque reactor con tanque de homogenización.

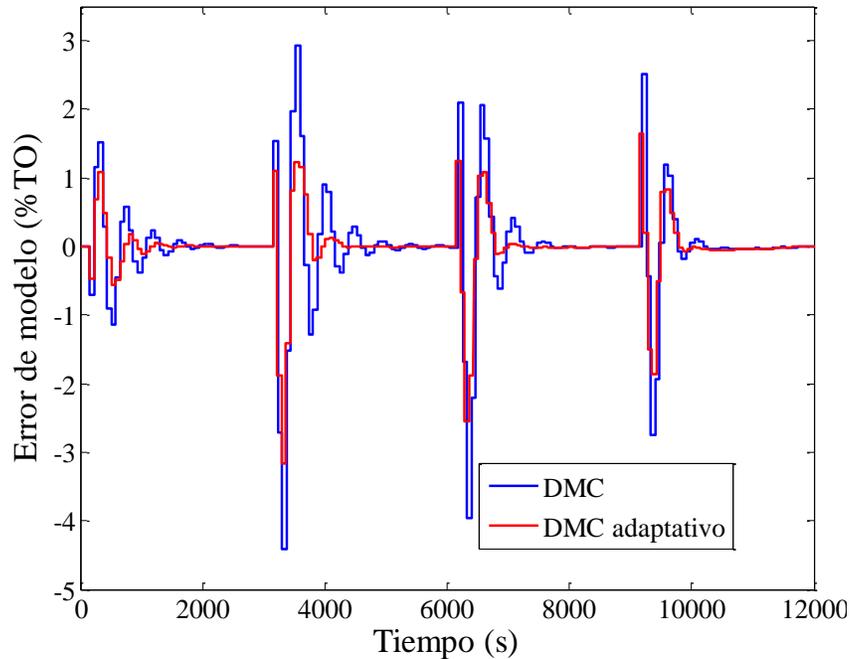
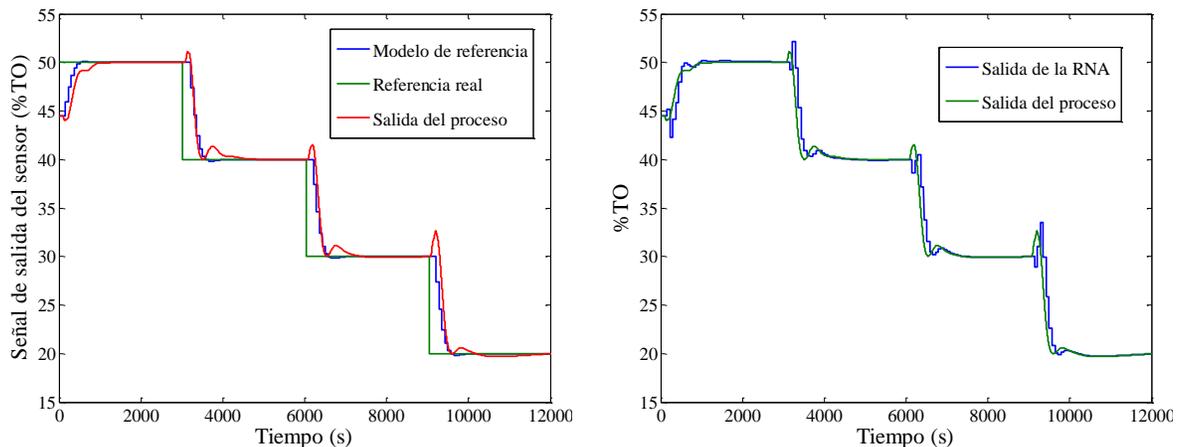
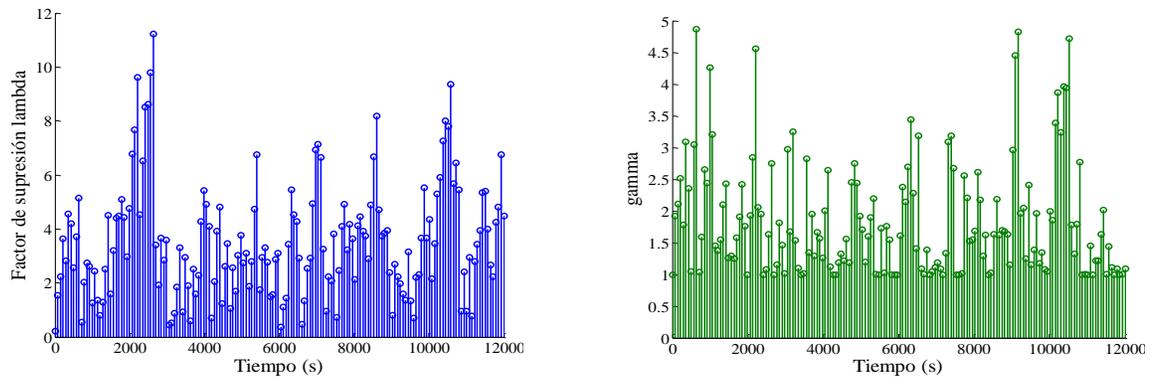


Figura 28. Comparación entre la salida del modelo de referencia (izquierda) y de la RNA (derecha) contra la del proceso.



No obstante, no es solo de interés observar la respuesta global del sistema. En la Figura 28 en la parte izquierda, se puede observar el seguimiento del sistema al modelo de referencia impuesto, el cual es bastante satisfactorio. En la parte derecha de la Figura 28 se puede ver que la red neuronal predice de manera satisfactoria el comportamiento del sistema, con algunas deficiencias en las respuestas inversas del proceso, pero en general con un error de predicción bastante pequeño, lo cual valida de manera significativa la escogencia de los regresores y el re-entrenamiento al cual se somete.

Figura 29. λ (Izquierda) y γ (derecha) en cada período de muestreo.



En la Figura 29 se aprecian los valores de los factores de supresión y ponderación del DMC adaptativo en cada período de muestreo, para la prueba realizada. Se observa como se retorna al valor inicial en los tiempos en donde ocurren cambios en la referencia, al igual que un comportamiento tendiente al alza después de los cambios en la referencia observando que para justo después de dicho cambio se requiere una respuesta rápida por parte del controlador y por tanto los factores de supresión no son grandes, pero una vez esta cerca del punto de operación requerido se trata de minimizar las acciones de control, aumentando la supresión.

Respecto al índice de rendimiento IAE se aprecia un índice menor para la estrategia adaptativa respecto al PID, no obstante respecto al DMC estándar no lo es. Esto se puede explicar observando la parte final de la gráfica mostrada en la Figura 25 en la cual se observa un tiempo de estabilización mayor en el último paso escalón, para la estrategia adaptativa respecto al tiempo de estabilización del DMC estándar.

Tabla 10. Comparación del IAE para las distintas estrategias ante cambios en el punto de operación para el tanque reactor con tanque de homogenización.

CONTROLADOR	IAE
PID	16308
DMC estándar	14266
DMC adaptativo	15101

10.1.2. Reactor Neutralizador de pH SISO.

El rendimiento global de la estrategia sobre este proceso, se puede observar en la Figura 30. Aquí se ve que la estrategia adaptativa supera ampliamente a las otras dos estrategias no adaptativas, debido a que estas presentan un comportamiento oscilatorio marginalmente estable. La estrategia adaptativa presenta un sobreimpulso para todos los cambios en la referencia, no obstante es menor que los sobreimpulsos presentados por los otros dos controladores, cuando estos logran controlar al sistema. También podemos apreciar que en

el último paso escalón las otras dos estrategias presentan muchas más oscilaciones que la estrategia propuesta.

En la Figura 31 se nota una gran diferencia de las acciones de control del DMC adaptativo respecto a la de los otros controladores; se pueden ver picos muchos menores así como movimientos mucho menores, respecto a estos. Con esto se corrobora el cumplimiento de las restricciones impuestas al proceso de optimización destinado a hallar los mejores parámetros del controlador en cada período de muestreo.

Tabla 11. Parámetros para la estrategia adaptativa en el reactor neutralizador de pH SISO.

	Parámetro	Valor
RNA	Número de nodos en la capa oculta	7
	Iteraciones para el entrenamiento	100
	Horizonte de predicción para el cálculo de las funciones objetivo	10
Modelo de Referencia	Orden	2
	Factor de amortiguamiento (ξ)	0.9
	Tiempo de asentamiento (T_s)	$2*\tau_{\text{sistema}}$
SPEA II	Número de miembros en P	40
	Número de miembros en P'	20
	Probabilidad de cruzamiento (pc)	0.9
	Probabilidad de Mutación (pm)	0.2
	Número de generaciones (Ng)	7
Restricciones	$\Delta\lambda_{\min}$	10
	$\Delta\lambda_{\max}$	10
	$\Delta\gamma_{\min}$	10
	$\Delta\gamma_{\max}$	2
	Δu_{\max}	7
	λ_{\min}	0.2
	γ_{\min}	1

Figura 30. Respuesta en lazo cerrado de reactor neutralizador de pH SISO ante cambios en el punto de operación.

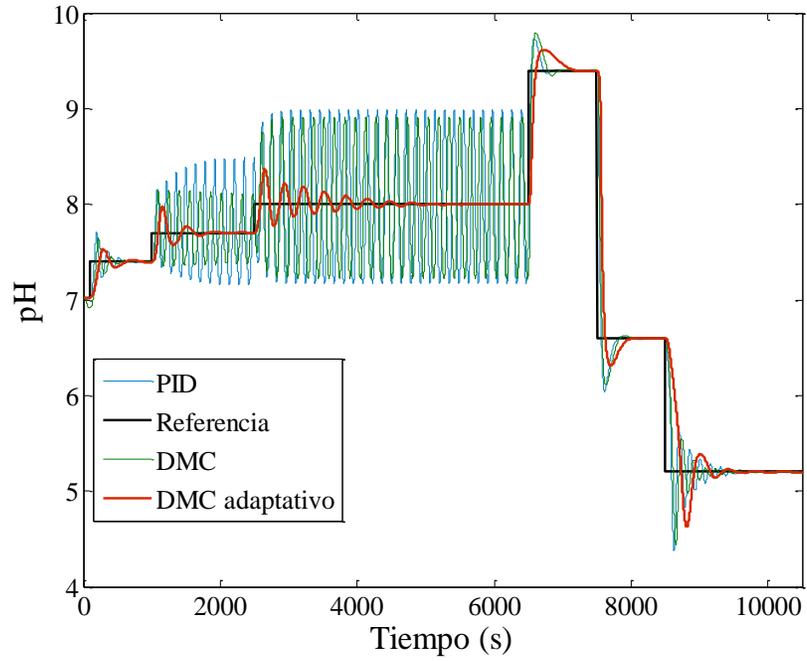


Figura 31. Señal de salida de los controladores ante cambios en el punto de operación para el reactor neutralizador de pH SISO.

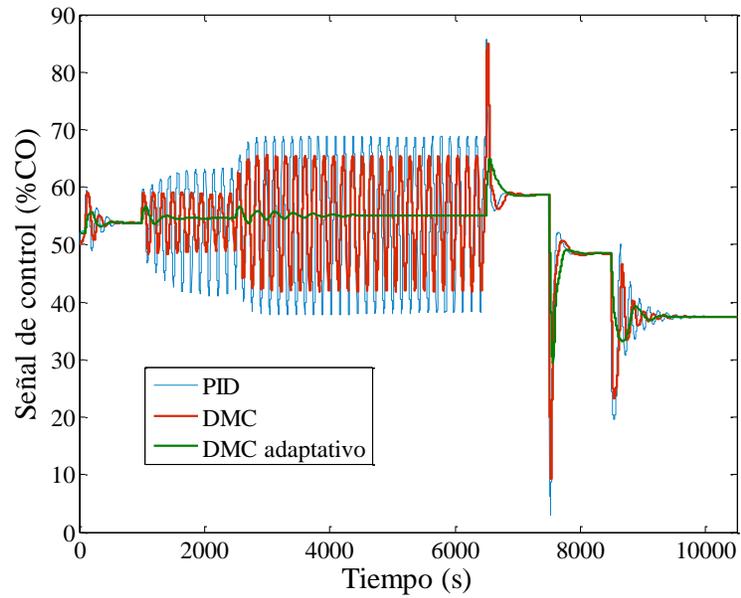
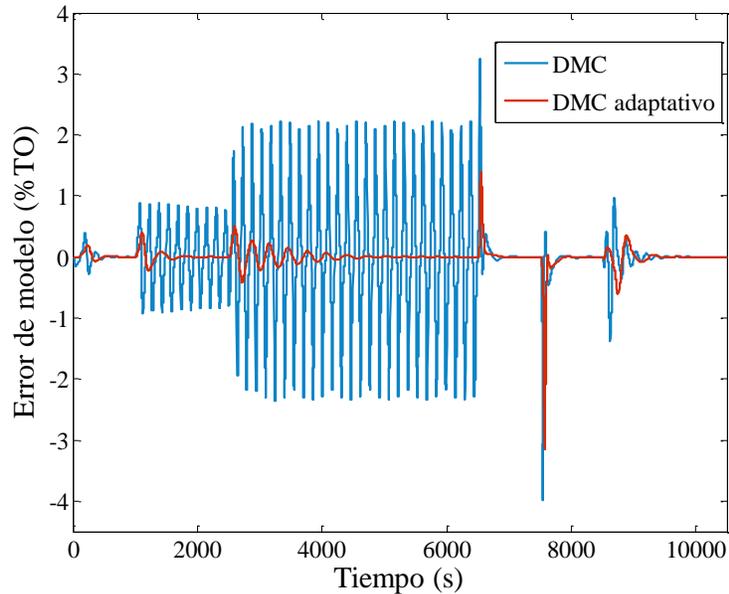
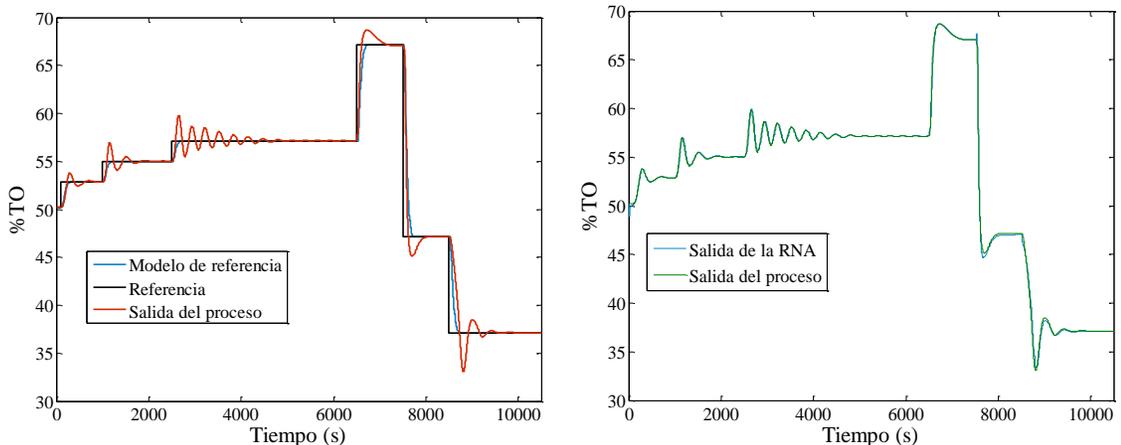


Figura 32. Error de modelo del DMC y del DMC adaptativo para cambios en el punto de operación en el reactor neutralizador de pH SISO.



En la Figura 32 se puede apreciar una diferencia notoria entre el error de modelo del DMC estándar y del DMC adaptativo, la cual se debe a la diferencia en las acciones de control de cada uno de ellos, siendo el error del DMC adaptativo menor en casi toda la prueba.

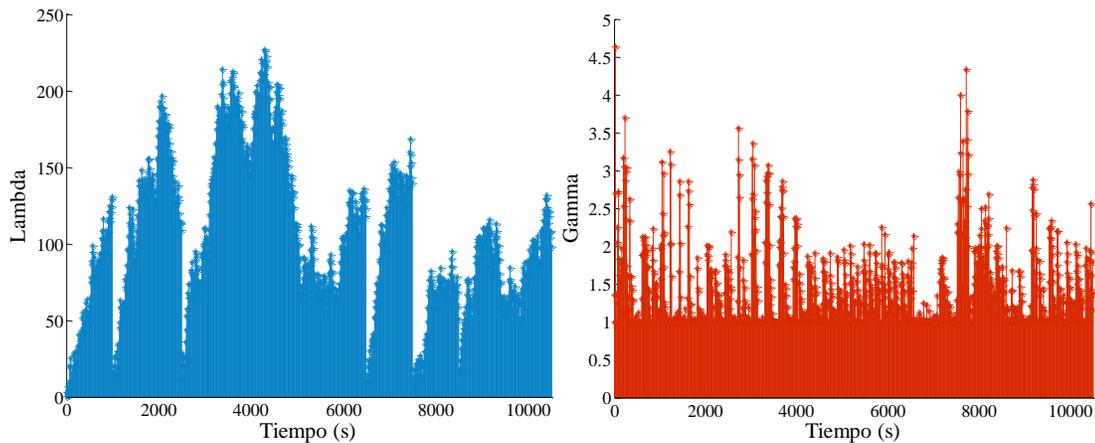
Figura 33. Comparación entre la salida del modelo de referencia (izquierda) y de la RNA (derecha) contra la del reactor neutralizador de pH.



En la Figura 33 (izquierda) se observa que de las características de la respuesta dinámica del modelo referencia, el tiempo de levantamiento es la que el proceso más intenta seguir, debido a que otras características como tiempo de estabilización y sobreimpulso no fueron seguidas por dicho proceso. Esto podría explicarse en la medida en que se podría tener un modelo de referencia que el proceso pudiese seguir mejor, so pena de obtener una repuesta más lenta y por tanto un IAE mayor, lo cual para nuestro caso no era lo deseable.

En la Figura 33 (derecha) se observa como la RNA sigue de manera consistente al comportamiento del sistema validando el entrenamiento fuera de línea que se realizó, así como el entrenamiento en línea que se realiza a medida que corre la simulación.

Figura 34. λ (Izquierda) y γ (derecha) en cada período de muestreo.



En la Figura 34 se puede ver como los factores de supresión y ponderación varían en cada período de muestreo. En el factor de supresión se observa una tendencia al alza debido a que en la parte inicial del cambio se necesitan acciones de control grandes mientras que cuando se llega cerca del punto de operación se necesitan acciones de control pequeñas y sin variaciones, de modo que no se provoquen oscilaciones cerca de dicho punto y se use el menor esfuerzo de control necesario para llegar y mantener la condición señalada. En cuanto al factor de ponderación se puede ver que en cada cambio de la referencia, al igual que el factor de supresión, vuelve a su valor inicial. A diferencia del factor de supresión este no tiene una tendencia muy definida, sino que presenta picos cuando el controlador necesita más agresividad en su acción y debido a la acumulación en los cambios de factor de supresión esta no se puede conseguir modificando el mismo. Desde este punto de vista es que resulta interesante la modificación de dicho factor.

Tabla 12. Comparación del IAE para las distintas estrategias ante cambios en el punto de operación para el reactor neutralizador de pH SISO.

CONTROLADOR	IAE
PID	24884
DMC estándar	22771
DMC adaptativo	7490.1

Se puede observar que en cuanto al índice de rendimiento IAE la estrategia adaptativa presenta un índice mucho menor al de las otras dos estrategias. Esto se debe a la ausencia de oscilaciones cuando los otros tuvieron, y a una respuesta casi igual de rápida a la de las otras dos estrategias en los demás puntos de operación. Por lo anterior se puede decir que el comportamiento de la estrategia es satisfactorio y adecuado para este tipo de procesos en

donde las no linealidades del mismo obligan necesariamente a implementar este tipo de estrategias adaptativas en su lazo de control.

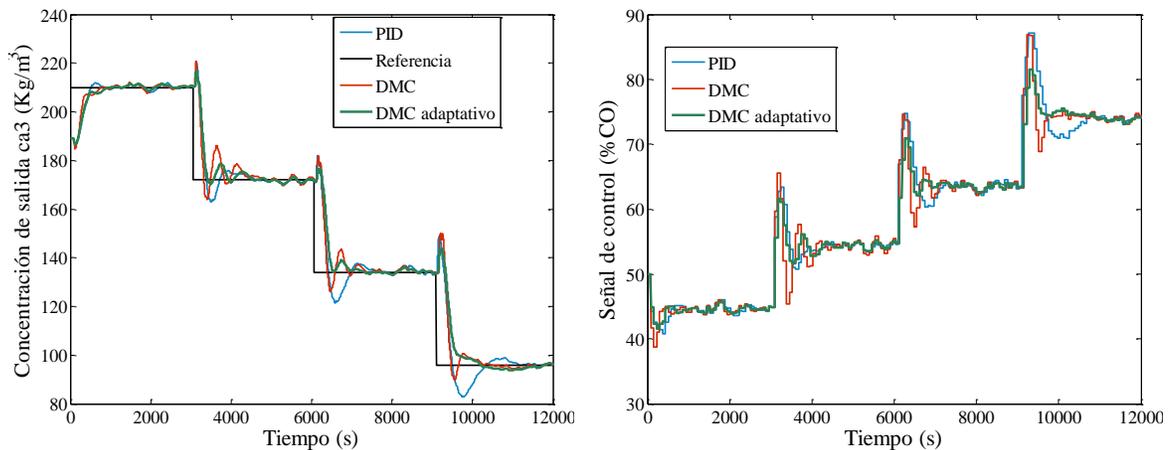
10.2. PRUEBAS ANTE CAMBIOS EN EL PUNTO DE OPERACIÓN, SUMANDO RUIDO EN LA SEÑAL DE LOS SENSORES

Para esta prueba se utilizó la misma configuración del DMC adaptativo realizada para cada uno de los procesos anteriores. En este caso se muestran las pruebas realizadas para el DMC MIMO también. El ruido usado para estas pruebas es ruido blanco gaussiano, de media cero y varianza uno con una potencia de 1 dB.

10.2.1. Tanque reactor con tanque de homogenización.

En la Figura 35 se puede observar como la respuesta del controlador y del sistema en presencia de ruido en el sensor no varían significativamente respecto a las respuestas obtenidas en las figuras 25 y 26. Esto demuestra una robustez del sistema en relación con el ruido. Igualmente se pueden observar algunas oscilaciones cerca del punto de operación en la señal de control cerca al punto de operación, debido a la presencia del ruido que hace que para el caso de los controladores DMC las predicciones sean menos precisas y por tanto el controlador reaccione ante cambios inexistentes debido a la presencia del ruido en la señal del sensor.

Figura 35. Respuesta en lazo cerrado del tanque reactor con tanque de homogenización (izquierda) y señal de salida del controlador (derecha), ante cambios en el punto de operación.



Las comparaciones realizadas en la Figura 36 se hacen con la señal del sensor y por lo tanto tienen el ruido sumado. Si se ve la parte izquierda de la figura en la comparación con el modelo de referencia se puede apreciar que las características de seguimiento de su comportamiento por parte del proceso en cuestión, son muy similares a la de la Figura 28.

Igualmente se puede apreciar en la parte derecha de la Figura 36, que el seguimiento de la RNA al comportamiento del proceso, es muy bueno salvo los casos en donde el proceso tiene unas oscilaciones que la RNA no sigue fielmente. Esto se puede explicar en la medida en que dicha red es entrenada en línea usando la información con ruido y por tanto puede llegar a hacerse inmunes antes oscilaciones pequeñas debido a la generalización implícita en su entrenamiento.

Figura 36. Comparación entre la salida del modelo de referencia (izquierda) y de la RNA (derecha) contra la del tanque reactor con tanque de homogenización.

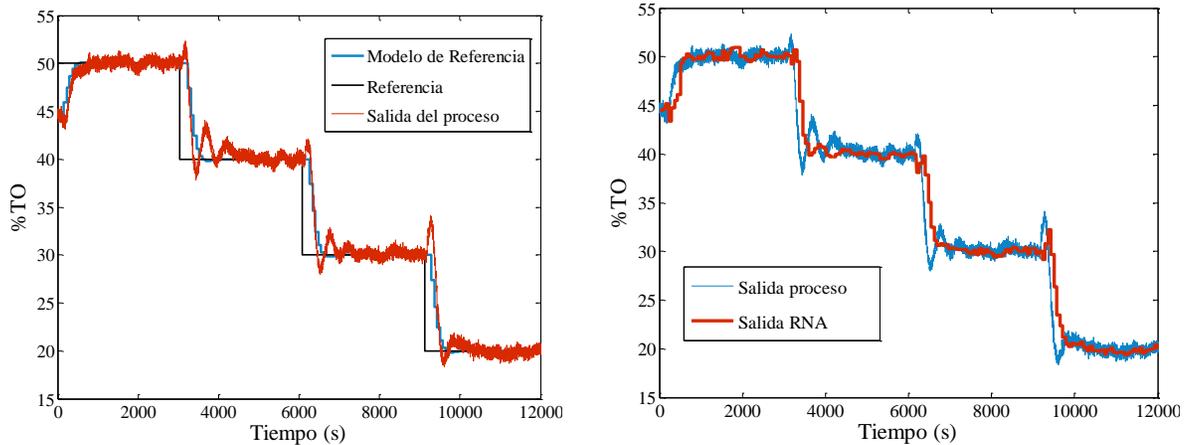


Tabla 13. Comparación del IAE para las distintas estrategias ante cambios en el punto de operación para el tanque reactor con tanque de homogenización, sumando ruido a la señal de los sensores.

CONTROLADOR	IAE
PID	17207
DMC estándar	15051
DMC adaptativo	16600

En la Tabla 13 se puede ver que el rendimiento de la estrategia sigue siendo mejor que el rendimiento del PID pero no mejor que el DMC estándar, tal como ocurrió en la prueba sin ruido en el sensor.

10.2.2. Reactor neutralizador de pH SISO.

En la Figura 37 (izquierda) se observa como la respuesta del sistema es muy similar a la que no presenta ruido en el sensor. No obstante para el caso del DMC adaptativo en el tercer paso escalón, se observa unas pequeñas oscilaciones al final del mismo pero para el resto de ellos, su comportamiento es el mismo al de la prueba sin ruido. Para el caso de la señal de control (parte derecha de la figura) se ven unas pequeñas oscilaciones cerca de la acción de control para cada paso escalón, mostrando claramente la presencia de ruido en el sistema.

Figura 37. Respuesta en lazo cerrado del reactor neutralizador de pH SISO (izquierda) y señal de salida de los controladores (derecha) ante cambios en el punto de operación.

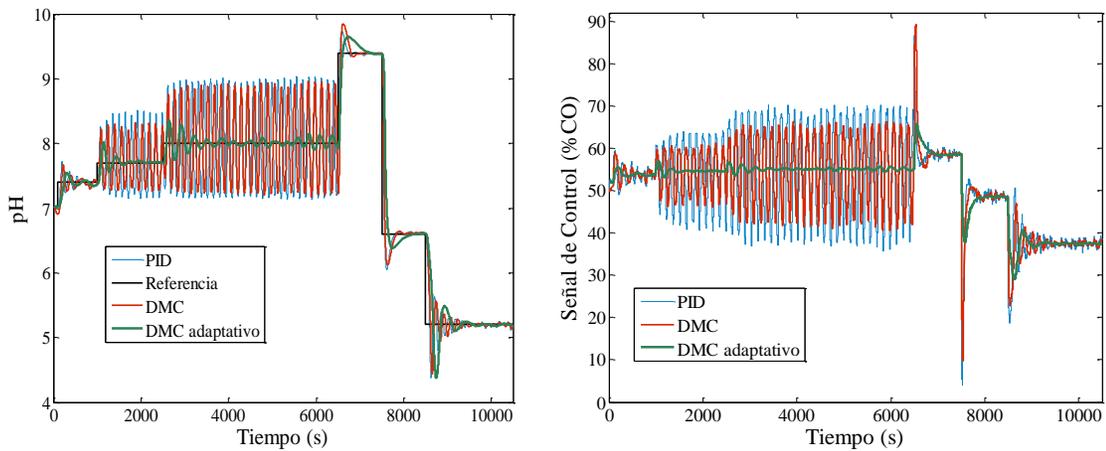
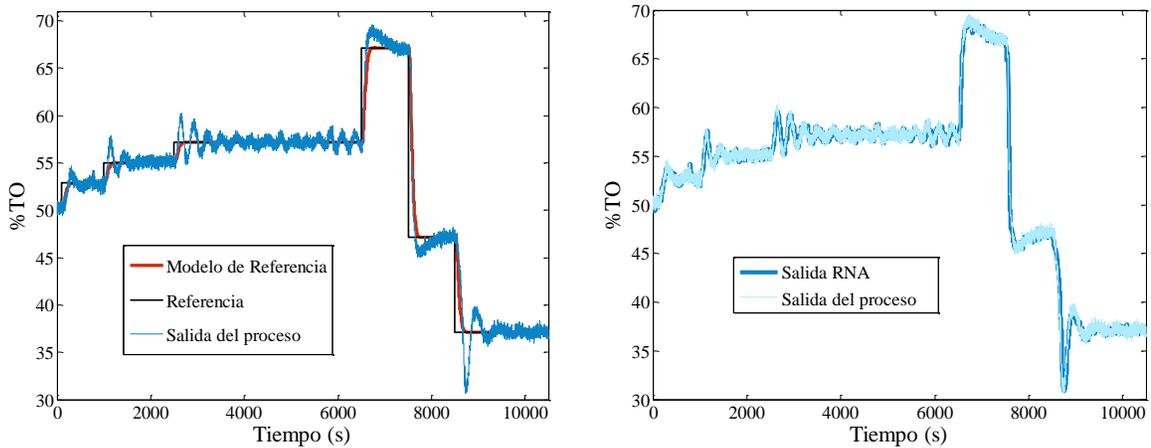


Figura 38. Comparación entre la salida del modelo de referencia (izquierda) y de la RNA (derecha) contra la del reactor neutralizador pH.



En la Figura 38 (izquierda), se observa que el tiempo de levantamiento del modelo de referencia es seguido por el proceso, no obstante no ocurre lo mismo con el resto de los parámetros como sobreimpulso y tiempo de estabilización. La RNA se comporta mejor

para este sistema que para el tanque reactor con tanque de homogenización, debido a que incluso en presencia del ruido, las oscilaciones que presenta el sistema son seguidas por dicho modelo.

Tabla 14. Comparación del IAE para las distintas estrategias ante cambios en el punto de operación para el reactor neutralizador de pH SISO, sumando ruido a la señal de los sensores.

CONTROLADOR	IAE
PID	25729
DMC estándar	24149
DMC adaptativo	8571

En la Tabla 14 se puede apreciar la gran diferencia entre los índices de rendimiento observando una gran similitud entre las dos estrategias no adaptativas y una brecha de más de la mitad del índice por parte de la estrategia adaptativa, razón por la cual la estrategia presenta un comportamiento satisfactorio respecto al objetivo requerido de minimizar el IAE.

10.2.3. Reactor neutralizador de pH MIMO.

En la Figura 39 se observan las respuestas de la estrategia implementada sobre un sistema MIMO. Para el caso de la primera salida mostrada en la Figura 39 (izquierda), se puede apreciar la ausencia de oscilaciones en el segundo paso escalón cuando el DMC estándar se vuelve marginalmente estable. Igualmente se observa que la diferencia en los otros pasos escalones consiste en un amortiguamiento más rápido de las oscilaciones presentadas, observado como un corrimiento de fase, que en últimas termina con un menor tiempo de estabilización. Para el caso de la segunda salida se observa un comportamiento muy similar por parte de las dos estrategias, presentado un poco menos de sobreimpulso la estrategia adaptativa y un tiempo de levantamiento mayor.

Figura 39. Respuesta en lazo cerrado de las salidas uno (izquierda) y dos (derecha) del reactor neutralizador de pH MIMO ante cambios en el punto de operación.

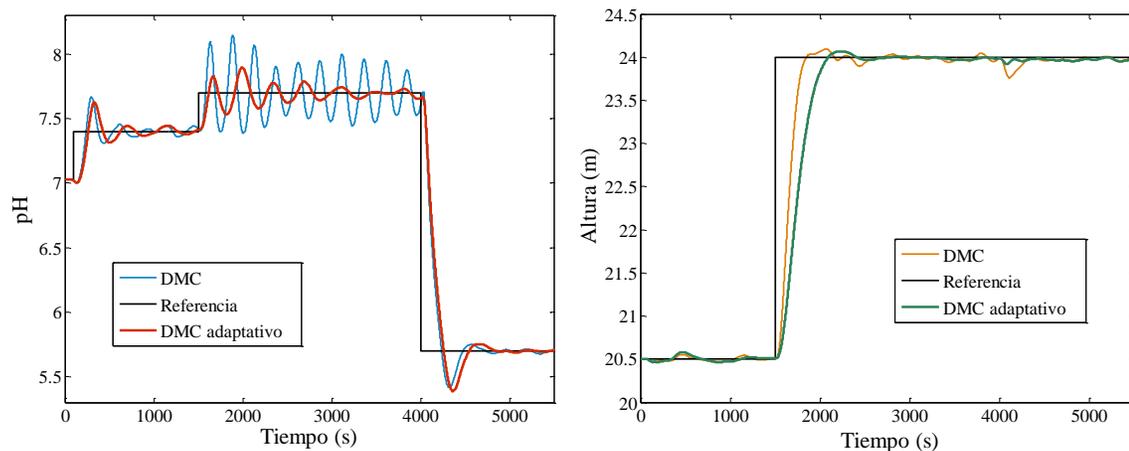
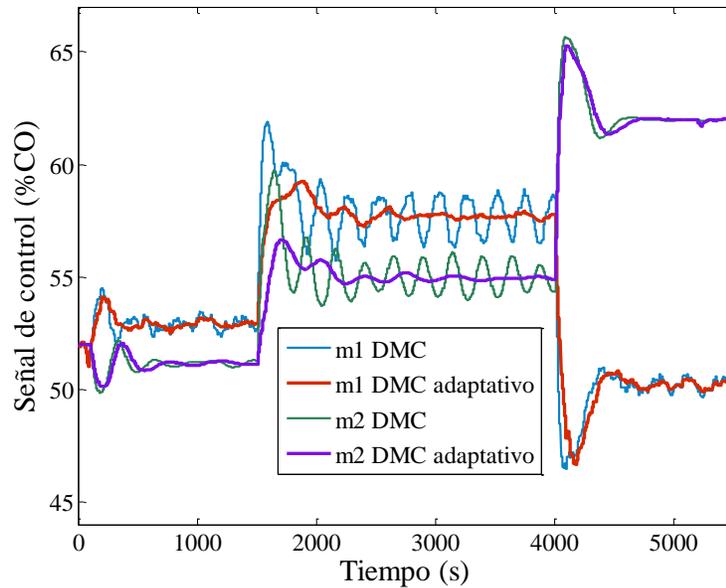


Tabla 15. Parámetros de la estrategia adaptativa para el reactor neutralizador de pH MIMO.

	Parámetro	Valor
RNA	Número de nodos en la capa oculta	10
	Iteraciones para el entrenamiento	100
	Horizonte de predicción para el cálculo de las funciones objetivo	10
Modelo de Referencia uno	Orden	2
	Factor de amortiguamiento (ξ)	0.9
	Tiempo de asentamiento (Ts)	$2*\tau_{11}$
Modelo de Referencia dos	Orden	2
	Factor de amortiguamiento (ξ)	0.9
	Tiempo de asentamiento (Ts)	$2*\tau_{22}$
TSK FDM	g_1	1/10
	g_2	1/10
	g_3	1/10
	g_4	1/10
SPEA II	Número de miembros en P	20
	Número de miembros en P'	10
	Probabilidad de cruzamiento (pc)	0.9
	Probabilidad de Mutación (pm)	0.3
	Número de generaciones (Ng)	7
Restricciones	$\Delta\lambda_{\min}$	5
	$\Delta\lambda_{\max}$	5
	$\Delta\gamma_{\min}$	5
	$\Delta\gamma_{\max}$	2
	$\Delta m_{1\max}$	7
	$\Delta m_{2\max}$	7
	λ_{\min}	0.2
	γ_{\min}	1

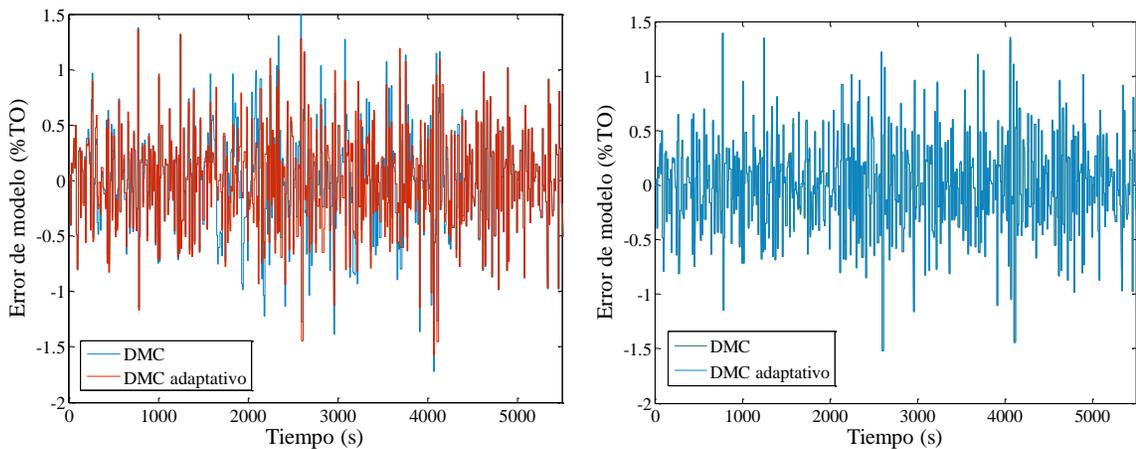
En la Figura 40 se observan las acciones de control para el DMC estándar y el DMC adaptativo en la que podemos apreciar que la estrategia adaptativa presenta menores oscilaciones y picos menores que la estrategia no adaptativa, consiguiendo uno de los objetivos impuestos en las restricciones del proceso de optimización, así como menores oscilaciones cuando se está llegando al punto de operación por parte del proceso.

Figura 40. Señal de salida de los controladores ante cambios en el punto de operación para el reactor neutralizador de pH MIMO.



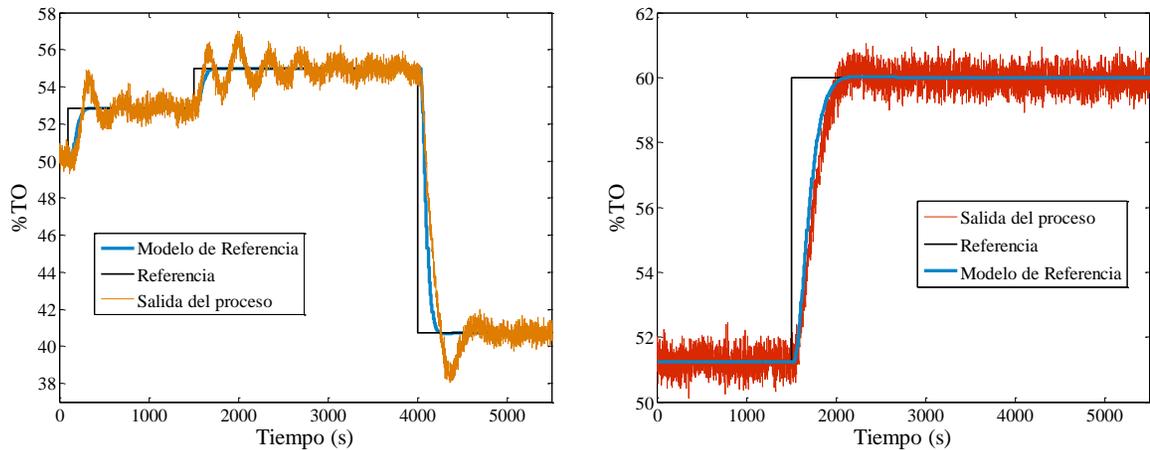
Un hecho bastante particular es que a la luz de la Figura 41, los errores de modelo para ambos controladores son prácticamente los mismos. Esto se ve reflejado en los resultados en donde solamente en el intervalo de tiempo entre 1500s y 4000s se observa una diferencia apreciable en el rendimiento del DMC estándar y del adaptativo.

Figura 41. Error de modelo para la salida uno del reactor neutralizador de pH MIMO, para el DMC y el DMC adaptativo para cambios en el punto de operación.



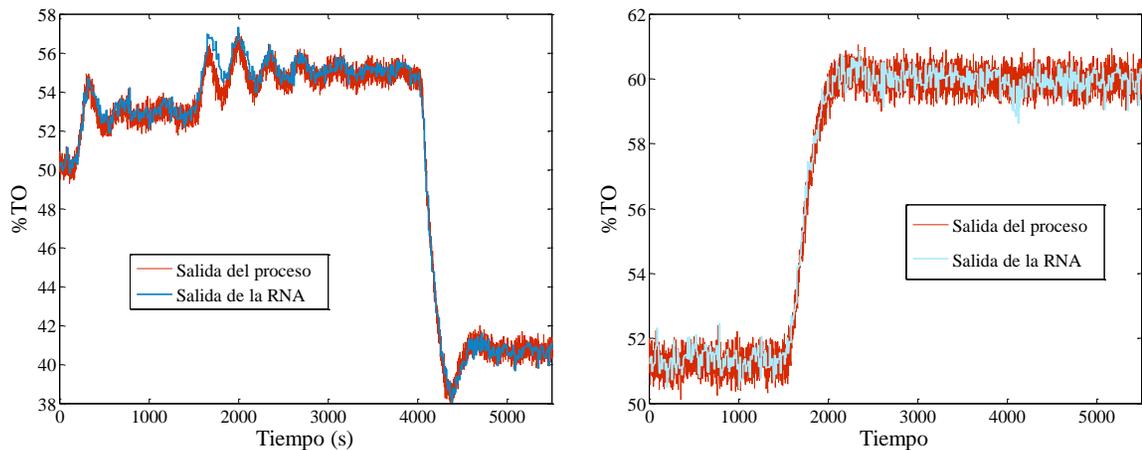
En la figura 42 se observa que para la salida uno al igual que para el proceso SISO sólo se sigue el tiempo de levantamiento del modelo de referencia, mientras que para la salida dos se observa un muy buen seguimiento de todas las características dinámicas impuestas como sobreimpulso, tiempo de estabilización y tiempo de levantamiento, incluso en la presencia de ruido en la señal del sensor.

Figura 42. Comparación entre la salida del modelo de referencia uno (izquierda) y dos (derecha) contra la salida uno y dos del reactor neutralizador de pH MIMO.



En la Figura 43 se aprecia como la RNA sigue al sistema incluyendo sus oscilaciones aun en la presencia del ruido. Esta respuesta de la RNA es similar a la que se obtuvo en este proceso en configuración SISO. Esto valida el entrenamiento en línea para el cual el ruido puede llegar a ser un aliado y el entrenamiento fuera de línea con datos previos a la prueba.

Figura 43. Comparación entre la salida uno (izquierda) y dos (derecha) de la RNA contra la salida uno y dos del reactor neutralizador de pH MIMO.



En las Figuras 44 y 45 se observan los factores de supresión y ponderación del controlador. Su comportamiento es muy similar al que se obtiene en el proceso SISO y por tanto la explicación de su comportamiento es prácticamente la misma. No obstante cabe resaltar que no es posible asociar en este sistema un factor de supresión para cada entrada debido al acople fuerte que hay presente entre ellas, sin embargo sus comportamientos globales tienden a corresponder a los mismos factores.

Figura 44. λ_1 (Izquierda) y λ_2 (derecha) en cada período de muestreo.

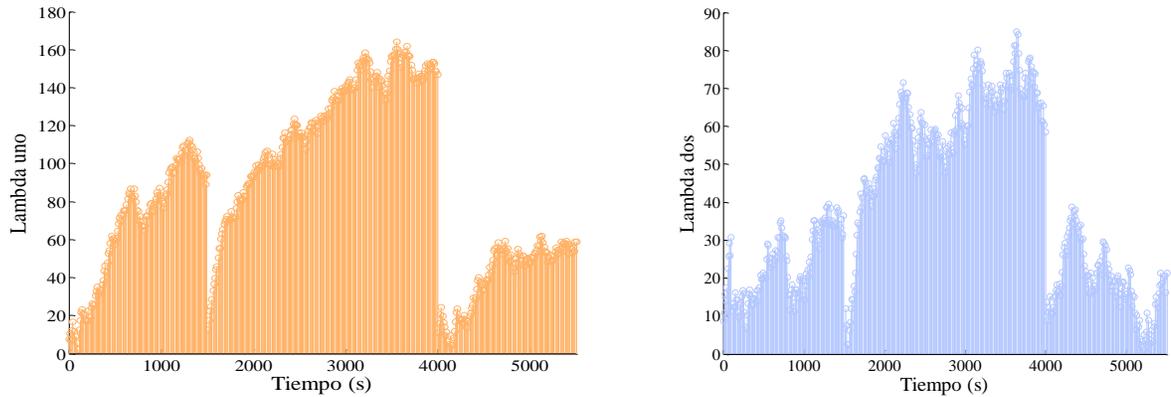


Figura 45. γ_1 (Izquierda) y γ_2 (derecha) en cada período de muestreo.

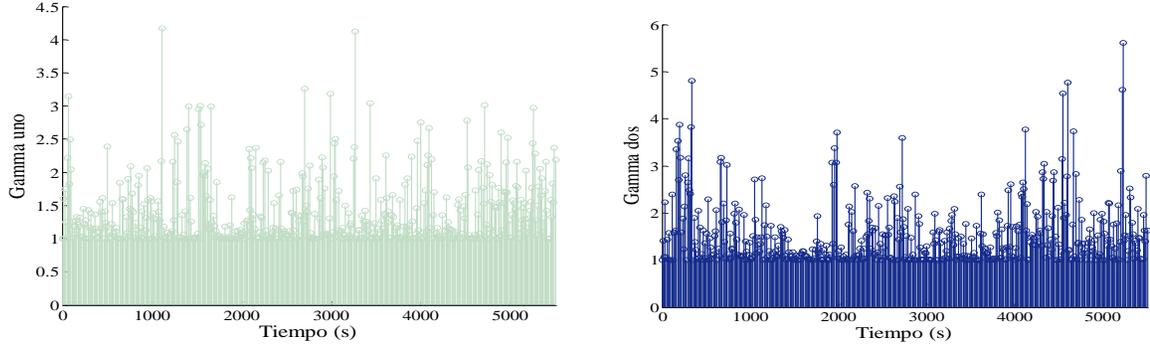


Tabla 16. Comparación del IAE para las distintas estrategias ante cambios en el punto de operación para el reactor neutralizador de pH MIMO, sumando ruido a la señal de los sensores.

CONTROLADOR	IAE1	IAE2
DMC estándar	5709.7	1764.7
DMC adaptativo	4004.8	2518.3

En la Tabla 16 se muestra un comportamiento interesante del sistema, en donde para la primera entrada se obtiene un menor IAE para el caso de la estrategia adaptativa, pero para la segunda este IAE es mayor que para la estrategia adaptativa. Esto se explica en la medida en que en aras de regular las acciones de control para la primera salida y suprimir las oscilaciones en ella, debido a la alta interacción de sistema, se penaliza a la segunda salida con una respuesta un poco más lenta y por tanto su IAE se ve afectado.

10.3. COMPARACIÓN ENTRE LOS SISTEMAS DE TOMA DE DECISIONES SOBRE EL FRENTE PARETO, APLICADO EN EL REACTOR NEUTRALIZADOR DE pH MIMO.

En la Figura 46 se observa como el sistema de toma de decisiones afecta al rendimiento del controlador. Se ve como la segunda salida no presenta mayor cambio respecto a la estrategia en la cual el sistema de toma de decisiones no es el sistema de inferencia TSK. Para la primera salida se observa una atenuación mayor de las oscilaciones en la parte final de la prueba por parte de la estrategia que integra el sistema el sistema de inferencia TSK respecto al sistema que no.

Figura 46. Respuesta de las salidas uno (derecha) y dos (izquierda) en lazo cerrado modificando los sistemas de toma de decisiones sobre el frente pareto.

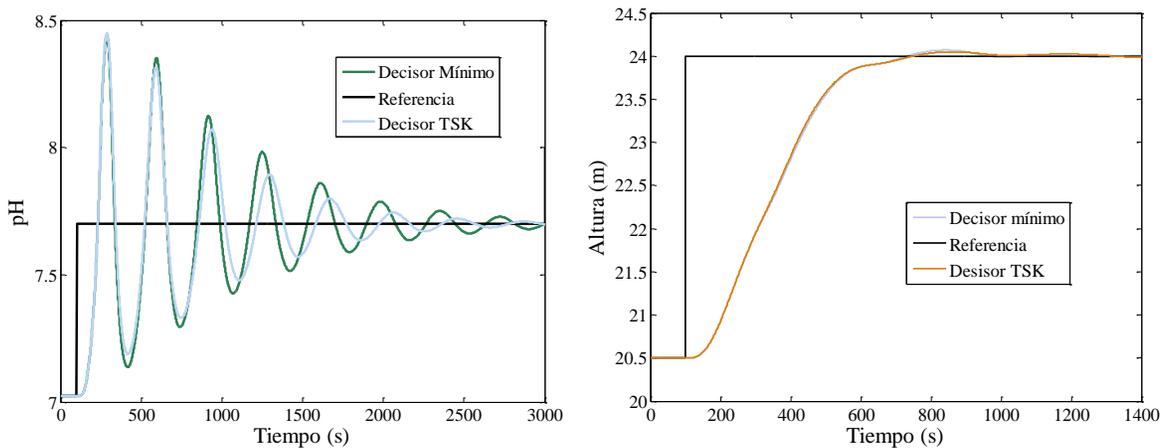
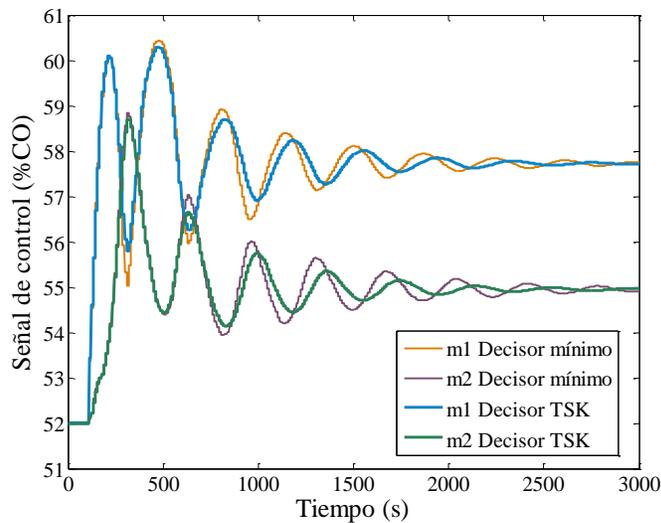


Figura 47. Señal de control modificando los sistemas de decisión sobre el frente pareto.



En la Figura 47 se puede apreciar que para las señales de control se obtiene un comportamiento similar con un decaimiento en la amplitud de las oscilaciones mucho más rápido para el sistema que incluye al decisor TSK.

En la Tabla 19 se observa una diferencia entre los índices de rendimiento para cada salida, concluyendo con un índice menor para la estrategia que incluye al decisor TSK. Esto se explica en la medida en que la amplitud de las oscilaciones para la salida del proceso decaen mucho más rápido y por tanto se obtiene un índice de rendimiento menor al llegar más rápido al punto de operación deseado.

Tabla 17. Comparación del IAE para los distintos sistemas de decisión, para el reactor neutralizador de pH MIMO.

DECISOR	IAE1	IAE2
Decisor mínimo	3412.3	2222.7
Decisor TSK	2982.1	2202.9

11. ADMINISTRACIÓN DEL PROYECTO

El diseño metodológico planteado al inicio de este proyecto se realizó con éxito superando las expectativas iniciales. Esto se debe a la culminación con anterioridad del cronograma inicialmente propuesto, logro de objetivos iniciales en este mismo término y al logro de objetivos distintos en la etapa final de desarrollo del proyecto.

Por ejemplo, se probó la estrategia en dos procesos en vez de ser uno solo aparte de abordar la construcción de un sistema MIMO, no contemplado inicialmente. En el caso de los bloques funcionales tenemos que inicialmente se propuso un algoritmo genético monoobjetivo, que fue reemplazado por un algoritmo genético con codificación en punto flotante para pasar a un algoritmo evolutivo multiobjetivo que arroja resultados mucho mejores a los que se obtienen con el monoobjetivo. Esto se debe a que no se hacen suposiciones como la de convexidad del conjunto solución al implementar la suma de pesos en el proceso de optimización de dos funciones objetivos que se buscaban minimizar inicialmente.

12. CONCLUSIONES

El desarrollo de estrategias de control avanzado usando inteligencia artificial es un tema de investigación bastante atractivo y popular en el ámbito actual. Esto se debe a que simplifica en gran medida el desarrollo de dichas estrategias al no necesitar una matemática tan extensiva para lograr resultados similares o mejores que los de aquellas estrategias que usan métodos matemáticos más complejos.

En este trabajo se desarrolló una estrategia adaptativa para un controlador predictivo usando inteligencia artificial en vez de una formulación matemática extensa que conllevaría a resultados muy similares. Se logró responder de manera satisfactoria ante cambios en la dinámica del sistema debido a sus no linealidades además de lograr plantear y desarrollar un esquema de adaptación general que no se caza en realidad con un controlador en específico y con un tipo de procesos específicos.

Esto se puede corroborar en la medida en que el controlador usado pudo haber sido cualquier otro cuyos parámetros se puedan codificar a partir de número reales, adecuando solamente el cálculo de la función objetivo del algoritmo evolutivo. Así mismo, para entrenar a la red neuronal para otro tipo de procesos, el único requisito bajo el esquema de entrenamiento propuesto es que no sea un proceso integrante.

Igualmente se consiguió un rendimiento satisfactorio, teniendo poca información del proceso y evitando pruebas engorrosas y no susceptibles de ser ejecutadas en un proceso real. Así mismo se mostró como una estrategia usada muy usada en el ámbito industrial, en procesos MIMO como loes el DMC puede ser susceptible de mejoras significativas con el uso de estrategias adaptativas como esta, disminuyendo el tiempo de puesta en marcha de este algoritmo de control en procesos con dinámicas altamente no lineales como las mostradas en los resultados de la investigación.

Como aspecto final a destacar se encuentra el uso de este tipo de algoritmos en proyectos de pregrado, lo cual apunta hacia un mejoramiento en los procesos investigativos al interior de la universidad y un fortalecimiento de las líneas de investigación en esta rama.

13. RECOMENDACIONES

El aspecto crucial de este tipo de desarrollos radica en la complejidad computacional del algoritmo propuesto, el cual se traduce directamente en la velocidad de ejecución del mismo. Este aspecto es importante debido a que impone restricciones sobre el tipo de procesos a ser implementado. Para nuestro caso, conforme crecen las variables de entrada y de salida, este algoritmo se va volviendo claramente ineficiente, debido al recálculo de la inversa de la matriz K_c en la función objetivo del algoritmo evolutivo.

Este problema es fácilmente superable en la medida en que no se use la ley de control preestablecida para el DMC sino que se calculen las acciones de control a través del algoritmo evolutivo desde una perspectiva multiobjetivo. Por el tipo de codificación real, esto haría al algoritmo mucho menos complejo y más eficiente, con lo cual se abrirían las puertas para aplicaciones con un número importante de entradas y salidas.

Sin embargo, debemos tener en cuenta que la inclusión de modelos de optimización más complejos que una red neuronal, más específicamente, modelos continuos que necesiten ser calculados a través de algoritmo de resolución de ecuaciones diferenciales, puede llevar a la disminución de la eficiencia en términos de velocidad. No obstante estos modelos arrojan mejores resultados al momento de predecir el comportamiento del proceso real y por tanto se obtendría un mejor comportamiento final del controlador.

Otra opción disponible son los modelos difusos y los modelos no lineales en tiempo discreto, los cuales serían una alternativa interesante al momento de realizar una investigación futura.

Igualmente mejorar el sistema de inferencia difuso de toma de decisiones u plantear otro es otra alternativa de investigación para trabajos futuros en esta área

BIBLIOGRAFÍA

- [1] Blenis Becerra Lorena José, Sanjuán Mejía Marco. Tesis de pregrado. Controlador Dinámico Matricial (*DMC*) para procesos de ganancia variable ante perturbaciones. Tesis de pregrado. Universidad del Norte.
- [2] D. Dougherty, J. Arbogast, D.J. Cooper, “A Multiple model adaptive control strategy for DMC”, en: *Proc. of the American Control Conference*, Denver, 2003,.
- [3] Barreto Suárez Jair, Rubio Laborde Martín, Sanjuán Mejía Marco.. *Controlador DMC escalable para procesos SISO de ganancia no lineal*. Tesis de pregrado. Universidad del Norte.
- [6] R. Shridhar, D.J. Coop, “Selection of the move suppression coefficients in tuning dynamic matrix control”, en: *Proc. of the American Control Conference*, June 1997.
- [7] A. Rajapakse, K. Furuta, S. Kondo, “Evolutionary Learning of Fuzzy Logic Controllers and their adaptation through Perpetual Evolution”, *IEEE Trans. on Fuzzy Systems*, Junio 2002.
- [8] James R. Gremling, Kevin M. Passino. *Genetic Adaptive State Estimation for a Jet Engine Compressor*. Proceedings of the 12th IEEE International Symposium on Intelligent Control.
- [9] Erika V. Márceles González. Control no-lineal de la concentración en un reactor con tanque de homogeneización, utilizando una red neuronal trabajando en un esquema MPC. Tesis de pregrado. Universidad del Norte.
- [11] P. Schroder, B. Green, N. Grum, P. J. Fleming. *On-line Genetic Auto-Tuning of Mixed H2/Hinfinito, Optimal Magnetic Bearing Controllers*. UKACC International Conference on control.
- [12] Francesco Cupertino, Ernesto Mininno, David Naso, Biagio Turchiano, Luigi Salvatore. *On-Line Genetic Design of Anti-Windup Unstructured Controllers for Electric Drives with Variable Load*. IEEE transactions on evolutionary computation, vol. 8, no. 4.
- [13] Smith Carlos, Corripio Armando. Principles and Practice of automatic Process Control. Segunda edición. John Wiley & Sons, 1997

- [14] Passino Kevin M. Fuzzy Control. Addison-Wesley.1998
- [15] Wang, Li-Xin, A course in fuzzy system and control, Prentice Hall PTR, 1997.
- [16] Sakawa, Masatoshi. Genetics algorithms and fuzzy multiobjective optimisation. Kluwer academic publisher, 2002.
- [17] Henson, M.A, Seborg D.E. Nonlinear process control. Prentice Hall, PTR, 1997.
- [18] Ramírez D.R, Limón D., Gómez J.,Camacho E.F. Model based predictive control using genetic algorithms. Application to a pilot plant.
- [19] Braake H.A.B, Van Can H.J.L, Van Straten G., “Random Activation Weight Neural Net (RAWNN) for Fast Non-iterative Training”, *IFAC Journal of Engineering Applications of Artificial Intelligence*, Feb. 1995.
- [20] Zitzler E., Laumanns M., Thiele L., “SPEA2: Improving the Strength Pareto Evolutionary Algorithm”, Swiss Federal Institute of Technology (ETH), Zurich, Switzerland, May 2001.
- [21] S. Narendara, K. Parthasarathy, “Identification and control of dynamical systems using neural networks,” *IEEE Trans. Neural Networks*, Mar. 1990.
- [22] A. Draeger, S. Engell, H. Ranke, “Model predictive control using neural networks”, *IEEE Control Systems Magazine*, 1995.
- [23] Bordóns C. Control predictivo: metodología, tecnología y nuevas perspectivas. I curso de especialización en automática. Universidad de Sevilla. 2000.

ANEXO A

1. MODELAMIENTO DE SISTEMAS DINÁMICOS

Para implementar un lazo de control en cualquier sistema, primero debemos poder modelar al mismo, de manera que podamos analizar su dinámica. El modelo matemático de un sistema dinámico se define como un conjunto de ecuaciones que representan la dinámica del sistema con algún grado de precisión. Sin embargo, debemos tener en cuenta que un modelo matemático no es único para un sistema determinado.. Este puede ser representado de muchas formas diferentes, por lo que puede tener muchos modelos matemáticos dependiendo de cada perspectiva.

La dinámica de muchos sistemas, ya sea mecánico, eléctrico, térmico, químico, se describen en términos de ecuaciones diferenciales. Dichas ecuaciones diferenciales se obtienen a partir de leyes físicas como las leyes de newton y las leyes dela termodinámica [13].

1.1. Modelo de procesos industriales.

El modelamiento de procesos industriales usualmente comienza con el balance de una cantidad conservativa como la masa o la energía. Dicho balance puede ser escrito de la siguiente manera:

$$\begin{array}{r} \text{Tasa de entrada de masa o} \\ \text{energía dentro} \\ \text{del volumen de control} \end{array} - \begin{array}{r} \text{Tasa de salida de masa o} \\ \text{energía} \\ \text{del volumen de control} \end{array} = \begin{array}{r} \text{Tasa de acumulación de} \\ \text{masa o} \\ \text{energía dentro} \\ \text{del volumen de control [13]} \end{array}$$

En procesos donde reacciones químicas no se presentan, las moles se conservan igualmente. Por tanto en ese tipo de proceso podemos sustituir masas por moles en la ecuación de balance [13].

1.1.1. Procesos térmicos.

Generalmente un análisis no estacionario del contenido dentro del volumen de control es realizado. Esto es

$$\begin{array}{r} \text{Tasa de entrada de energía} \\ \text{dentro} \\ \text{del volumen de control} \end{array} - \begin{array}{r} \text{Tasa de salida de energía} \\ \text{del volumen de control} \end{array} = \begin{array}{r} \text{Tasa de acumulación de} \\ \text{energía dentro} \\ \text{del volumen de control} \\ \text{[13]} \end{array}$$

1.1.2. Procesos de nivel.

Aquí generalmente se realiza un balance de masa del contenido dentro del tanque como sigue:

$$\begin{array}{r} \text{Tasa de entrada de masa} \\ \text{dentro} \\ \text{del volumen de control} \end{array} - \begin{array}{r} \text{Tasa de salida de masa} \\ \text{del volumen de control} \end{array} = \begin{array}{r} \text{Tasa de acumulación de} \\ \text{masa dentro} \\ \text{del volumen de control} \end{array} \quad [13]$$

1.2. Modelo de procesos químicos.

Los balances hechos en reactores químicos son usualmente balances molares en vez de balances realizados para el componente específico i o en el número total de moles. El problema aquí radica en el hecho de que estos balances no pueden describirse por el conjunto de ecuaciones mostradas anteriormente [13]. Esto quiere decir que

$$\begin{array}{r} \text{Tasa de entrada de la} \\ \text{sustancia } i \text{ dentro} \\ \text{del reactor} \end{array} - \begin{array}{r} \text{Tasa de salida de la} \\ \text{sustancia } i \\ \text{del reactor} \end{array} \neq \begin{array}{r} \text{Tasa de acumulación de la} \\ \text{sustancia } i \text{ dentro} \\ \text{del reactor} \end{array} \quad [13]$$

Esto es debido a que debemos considerar el hecho de que para una sustancia i se pueden producir más moles de ella o consumir, debido a una reacción que este ocurriendo. No obstante la masa total siempre se conserva[13]. Por tanto el balance puede ser escrito como

$$\begin{array}{r} \text{Tasa de entrada} \\ \text{de la sustancia } i \\ \text{dentro} \\ \text{del reactor} \end{array} - \begin{array}{r} \text{Tasa de salida} \\ \text{de la} \\ \text{sustancia } i \\ \text{del reactor} \end{array} + \begin{array}{r} \text{Tasa de producción de} \\ \text{la sustancia } i \end{array} = \begin{array}{r} \text{Tasa de} \\ \text{acumulación de la} \\ \text{sustancia } i \text{ dentro} \\ \text{del reactor} \end{array} \quad [13]$$

La tasa de producción de la sustancia i en el reactor esta usualmente dada por: $v_i r_k V$.

Donde v_i es el coeficiente estequiométrico de la sustancia i en la reacción, V es el volumen de la mezcla reactante, y r_k es la tasa de reacción de la sustancia clave en la reacción[13].

Una definición importante es la de la sustancia clave. La sustancia clave puede ser cualquier componente-reactante o producto- dentro de la reacción. El coeficiente estequiométrico, v , de la sustancia clave se escoge igual a uno. Un v_i , indica producción de la sustancia i ; un v_i negativo implica un consumo de la sustancia i . Entonces, la tasa de cambio de cualquier sustancia i es expresada como un múltiplo de la tasa de reacción de la sustancia clave, del volumen de la mezcla reactante y del cambio en número de moles de la sustancia i respecto al de la sustancia clave[13].

El balance molar no estacionario es escrito como:

$$\begin{array}{r} \text{Tasa de entrada} \\ \text{de moles dentro} \\ \text{del reactor} \end{array} - \begin{array}{r} \text{Tasa de salida} \\ \text{de moles} \\ \text{del reactor} \end{array} + \begin{array}{r} \text{Tasa de producción de} \\ \text{moles totales} \end{array} = \begin{array}{r} \text{Tasa de} \\ \text{acumulación de} \\ \text{moles dentro} \\ \text{del reactor [13]} \end{array}$$

Donde

$$\text{Tasa de producción de moles totales} = v_T r_k V \text{ moles/tiempo y } v_T = \sum_i v_i .$$

De la misma manera podemos escribir el balance de energía dada o recibida por la reacción[13]. El balance de energía se escribe como sigue

$$\begin{array}{r} \text{Tasa de entrada} \\ \text{de energía dentro} \\ \text{del reactor} \end{array} - \begin{array}{r} \text{Tasa de salida} \\ \text{de energía} \\ \text{del reactor} \end{array} + \begin{array}{r} \text{Tasa de energía} \\ \text{asociada} \\ \text{con la reacción} \end{array} = \begin{array}{r} \text{Tasa de acumulación} \\ \text{de energía dentro} \\ \text{del reactor [13]} \end{array}$$

Un estado usual de referencia para las entalpías y las energías internas son los componentes puros en sus distintas fases en la cual la reacción toma lugar a una temperatura de 25°C, y la presión del sistema[13]. Usando este estado de referencia podemos escribir

$$\text{Tasa de energía asociada con la reacción} = V r_k \Delta H_r , \text{energía/tiempo}$$

Donde ΔH_r es la entalpía de la reacción evaluada a 25°C en energía/mole de la sustancia clave [13].

ANEXO B

1. ELEMENTOS DE LAZO DE CONTROL.

1.1. Sensores.

Este es uno de los elementos más importantes en lazo de control, debido a que nos proporciona la información necesaria sobre este, en cuanto a su estado actual. El sensor cambia su comportamiento conforme la variable física de interés cambia. En resumen convierte una variable física en otra.

Hay tres términos importantes que debemos tener en cuenta al momento de hablar de un sensor. El primero de ellos es el *rango*, el cual nos determina el valor máximo y mínimo que puede medir de la variable de interés. El *span* es la diferencia entre estos valores. EL valor más bajo de medición es usualmente definido como el *cero* del sensor [13].

El comportamiento del sensor puede ser descrito a través de la siguiente ecuación

$$\tau_T \frac{dc(t)}{dt} + c(t) = K_T (Vp(t) - Vp_{\min}) \quad 1)$$

Donde τ_T , es la constante de tiempo del sensor, $c(t)$ es la señal de salida del mismo en %TO (*Transmitter output*), Vp es la variable de proceso y K_T es la ganancia del sensor calculada como:

$$K_T = \frac{100}{Vp_{\max} - Vp_{\min}} = \frac{100}{span} \quad 2)$$

1.2. Elemento final de control: Válvulas.

Las válvulas son talvez el elemento final de control más común a escala industrial. Ellas realizan la acción en el lazo de control ajustado el o los flujos que afectan a las variables controladas. La señal de control en %CO (*Controller Output*) determina su posición la que en últimas determina la restricción al flujo.

Los tipos de válvulas y en conjunto con sus ecuaciones y parámetros se resumen en la Tabla . La falla de la válvula es uno de los criterios más importantes al momento de escogerla debido a que se determina teniendo en cuenta razones de seguridad en caso de que la alimentación a la válvula falle por alguna razón. Si es falla cerrada (*FC*) en caso de falta de suministro de energía se cerrará y si es falla abierta (*FO*) se abrirá completamente [13].

Tabla 1. Ecuaciones dinámicas y parámetros de las válvulas más comunes

Tipo de falla	Tipo de válvula	Ecuación	Parámetros
FO	Proporcional	$\tau_v \frac{df(t)}{dt} + f(t) = K_v(m(t) - 100)$	$K_v = -\frac{f_{\max}}{100}$
	Isoporcentual	$\tau_v \frac{df(t)}{dt} + f(t) = f_{\max} \alpha^{-\frac{m(t)}{100}}$	$\alpha = 25,50,100$
FC	Proporcional	$\tau_v \frac{df(t)}{dt} + f(t) = K_v m(t)$	$K_v = \frac{f_{\max}}{100}$
	Isoporcentual	$\tau_v \frac{df(t)}{dt} + f(t) = f_{\max} \alpha^{\frac{m(t)}{100} - 1}$	$\alpha = 25,50,100$

Tomado de [13]

1.3. Controlador.

Los controladores usados a escala industrial son controladores realimentados los cuales toman la información del sensor acerca de la variable controlada y se toma una decisión respecto a lo que se debe hacer con la variable manipulada para converger al punto de operación deseado.

ANEXO C

1. IDENTIFICACIÓN DE SISTEMAS DINÁMICOS.

La respuesta dinámica de muchos de los procesos industriales, puede ser aproximada a una función de transferencia *FOPDT* realizando una prueba escalón en su entrada y recolectando los datos de su salida. Los parámetros a identificar en la función de transferencia mostrada a continuación son: La ganancia del proceso (K_p), la constante de tiempo (τ), y el tiempo muerto (t_o).

$$G_p(s) = \frac{C(s)}{M(s)} = \frac{K_p}{\tau s + 1} e^{-t_o s} \quad 1)$$

Dichos parámetros son obtenidos al realizar un ajuste de la curva de respuesta del sistema mediante el método *fit3* mostrado en [13].

Basándose en una curva de respuesta típica mostrada en la Figura 1 para un cambio tipo escalón de amplitud Δm se deben encontrar dos tiempos t_1 y t_2 . El primero es el tiempo en el cual la curva alcanza el 28.3% de su valor final y el segundo es el tiempo en el que la curva alcanza el 63.2% de su valor final tal como se muestra en la

Una vez hallados estos tiempos los parámetros se hallan usando las siguientes fórmulas:

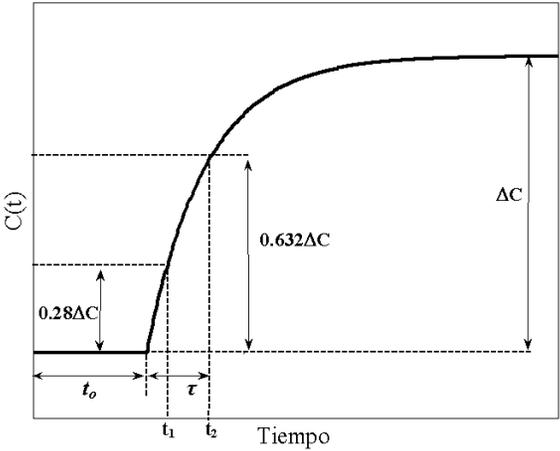
$$\tau = \frac{3}{2} (t_2 - t_1) \quad 2)$$

$$t_o = t_2 - \tau \quad 3)$$

$$K_p = \frac{\Delta c}{\Delta m} \quad 4)$$

Una vez hallados estos parámetros estos son reemplazados en las fórmulas anteriormente mencionadas. Estas se utilizan de acuerdo a lo que se requiere para el proceso, es decir, si se requiere que el proceso siga muchos cambios en el *set point* o que el proceso responda mejor ante las perturbaciones. En nuestro caso se usa la mejor sintonía para seguimiento del punto de operación optimizado para índice de rendimiento IAE. Para ver las fórmulas y las tablas en su totalidad remítase a [13].

Figura 1. Respuesta típica de un proceso de primer orden más tiempo junto con los parámetros para realizar el *fit3*.



Tomado de [13]

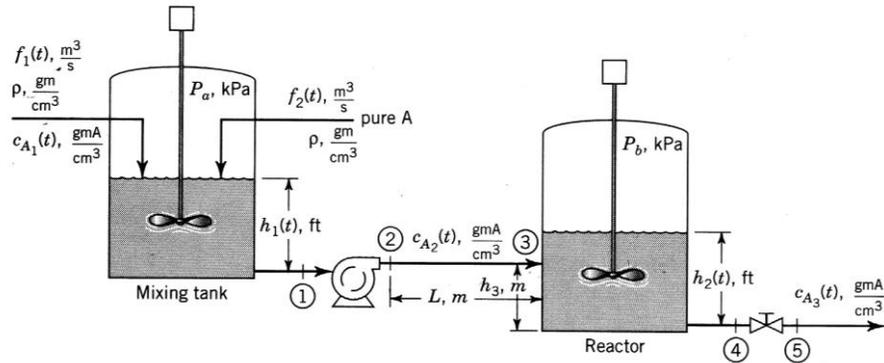
ANEXO D

1. DESCRIPCIÓN Y MODELO MATEMÁTICO DE LOS PROCESOS.

1.1. TANQUE REACTOR CON TANQUE DE HOMOGENIZACIÓN

1.1.1. Descripción del proceso.

Figura 1. Tanque reactor con tanque de homogenización.



Tomado de [13]

Este proceso consiste en un tanque reactor con un tanque de homogenización. El flujo f_1 que entra al primer tanque tiene una concentración ca_1 del producto A con una densidad ρ y el flujo f_2 es de sustancia A pura con la misma densidad del anterior. En el tanque de homogenización, quien se encuentra a una presión interna P_a con un nivel h_1 , los flujos son mezclados con un agitador asegurando la homogeneidad de la mezcla. El flujo de salida de este tanque, llamado f viaja a través de un tubo de longitud L y diámetro D . Al final de este tubo tenemos una concentración del producto A, ca_2 . Este tubo entra al reactor a una altura h_3 .

En el reactor, la reacción $A \rightarrow B$ toma lugar, la cual se asume se produce a una temperatura constante y a una tasa de reacción r_A . La concentración de salida final es ca_3 . En el tanque reactor el fluido se encuentra a una altura h_2 a una presión interna P_b . El flujo de salida del mismo es f_3 .

El flujo a través de la bomba esta dado por la siguiente ecuación:

$$f(t) = A - B \Delta P_p(t), \text{ m}^3/\text{s} \quad 1)$$

La tasa de reacción esta dada por:

$$r_A = kc_A(t), \text{ Kg/m}^3\text{-s} \quad 2)$$

Así mismo, el flujo de salida del reactor esta dado por:

$$f_3(t) = C_v \sqrt{p} \sqrt{h_2(t)}, \text{ m}^3/\text{s} \quad 3)$$

Los valores de estado estable para el proceso están recopilados en la siguiente tabla.

Tabla 1. Valores de estado estable para el tanque reactor con tanque de homogenización

Nombre de la Variable	Símbolo	Valor de	Unidades
Flujo 1	f_1	0.2	m^3/s
Flujo 2	f_2	0.35	m^3/s
Concentración de salida	c_{a3}	189.19	Kg/m^3
Concentración de entrada	c_{a1}	0.5	g/cm^3
Densidad	ρ	1.2	g/cm^3
Altura 3	h_3	0.92	m
Longitud del tubo	L	4	m
Diámetro del tubo	D_P	0.3	m
Diámetro del tanque de	D_{MT}	2.2	m
Diámetro del tanque	D_R	2.8	m
Presión interna del tanque	P_A	220	KPa
Presión interna del reactor	P_B	300	KPa
Capacidad de la válvula de	$C_v \sqrt{p}$	0.1722	$\text{m}^3/\text{s}/\text{m}^{0.5}$
Tasa de reacción	k	0.035	s^{-1}
Constante de la bomba	A	5.05	m^3/s
Parámetro de la bomba	B	0.056377	$\text{m}^3/\text{s}/\text{KPa}$
Constante de tiempo de la	τ_V	0.2	min
Constante de tiempo del	τ_T	0.8	min
Diferencia de presión	ΔP	8	KPa

Tomado de [9]

El objeto de este proceso es controlar la concentración de salida ca_3 a partir del flujo entrada f_j . Por tanto, nuestra variable manipulada es f_j y nuestra variable controlada es ca_3 .

1.1.2. Modelo matemático.

Para modelar este proceso se usarán los balances de masa y energía en el mismo.

Balance de masa

- *Balance de masa para el tanque de homogenización*

$$\rho f_1(t) + \rho f_2(t) - \rho f(t) = \rho A_m \frac{dh_1(t)}{dt} \quad 4)$$

- Ecuación de flujo en el tubo

$$f(t) = A - B \Delta P_p(t) \quad 5)$$

- Hidrostática

$$\Delta P_p(t) = P_B - P_A + \rho g [h_2(t) - h_3 - h_1(t)] \Delta P \quad 6)$$

- Balance de masa en el reactor

$$\rho f(t) - \rho f_3(t) = \rho A_R \frac{dh_2(t)}{dt} \quad 7)$$

- Ecuación de la válvula de salida

$$f_3(t) = C_v \sqrt{v_p} \sqrt{h_2(t)} \quad 8)$$

Balance de masa sobre A

- Balance de masa en A para el tanque de homogenización

$$f_1(t) c_{A1}(t) + \rho f_2(t) - f(t) c_{A2}(t) = A m \frac{d[c_{A2}(t) h_1(t)]}{dt} \quad 9)$$

- Ecuación de retraso para la concentración

$$c_{A2}'(t) = c_{A2} [t - t_o(t)] \quad 10)$$

- Retraso por transporte

$$t_o(t) = A p L \frac{1}{f(t)} \quad 11)$$

- Balance de masa de A en el tanque reactor

$$c_{A2}(t) f(t) - c_{A3}(t) f_3(t) - A r h_2(t) r_A(t) = A r \frac{d[c_{A3}(t) h_2(t)]}{dt} \quad 12)$$

- Tasa de reacción

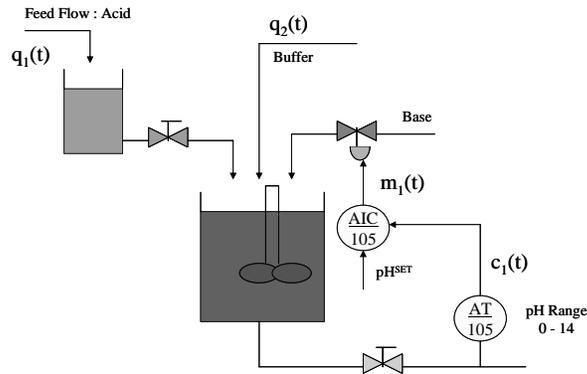
$$r_A(t) = K c_{A3} \quad 13)$$

1.2. REACTOR NEUTRALIZADOR DE PH

1.2.1. Descripción del proceso.

El flujo $q_1(t)$ es una solución acuosa de HNO_3 , la cual se introduce al tanque dos de manera que se eliminen las variaciones significativas de este flujo al entrar al tanque uno. El flujo de salida del tanque dos $q_{1e}(t)$ es una función de la altura del mismo y de las condiciones hidrodinámicas en el tubo de descarga. El flujo $q_2(t)$, es una solución acuosa de NaHCO_3 . El flujo $q_3(t)$ es una solución base compuesta por la mezcla de NaOH y NaHCO_3 . Por último h es la altura del tanque reactor, determinante para el flujo de salida del mismo. Todos los flujos entran al tanque reactor donde se asume una mezcla homogénea, densidad constante y completa solubilidad de los iones [17].

Figura 2. Reactor neutralizador de pH.



El propósito de este proceso para un sistema SISO es neutralizar el flujo ácido, manipulando el flujo base $q_3(t)$ mientras que el flujo $q_2(t)$ permanece constante. En un sistema MIMO tanto el flujo ácido como el flujo base se manipulan para controlar tanto el pH como la altura h del tanque reactor.

Los valores de estado estable se muestran en la siguiente tabla.

Tabla 2. Valores de estado estable para el reactor neutralizador de pH

Variable	Valor de estado	Unidades
q_1	16.6	ml/s
q_2	0.55	ml/s
q_3	15.6	ml/s
W_{a1}	0.003	M
W_{a2}	-0.03	M
W_{a3}	-3.050×10^{-3}	M
W_{a4}	-4.32×10^{-4}	M
W_{b1}	0	M
W_{b2}	0.03	M
W_{b3}	5×10^{-5}	M
W_{b4}	5.28×10^{-4}	M
K_{a1}	4.47×10^{-7}	
K_{a2}	5.62×10^{-11}	
A	207	cm^2
n	0.607	
z	5	cm
C_v	4.5861	$\text{cm}^3/\text{s}/\text{cm}^{0.5}$
h	20.5	cm
pH	7.024	

Tomado de [17]

1.2.2. Modelo matemático.

Las siguientes reacciones químicas toman lugar dentro del reactor:



El equilibrio químico es modelado usando la definición de dos invariantes de reacción: W_a y W_b . La primera invariante W_a , esta relacionada con la cantidad de carga, mientras que W_b esta relacionada con la concentración del ion CO_3^{2-} . A diferencia del pH, estas invariantes don cantidades conservativas. Estas son expresadas de la siguiente manera:

$$W_{ai} = [H^+]_i - [OH^-]_i - [HCO_3^-]_i - 2[CO_3^{2-}]_i \quad 17)$$

$$W_{bi} = [H_2CO_3]_i + [HCO_3^-]_i + [CO_3^{2-}]_i \quad 18)$$

Donde i representa a los flujos implicados en el proceso de uno hasta cuatro. Los balances de las invariantes completan la dinámica del sistema en el termino de acumulación. Estos balances son los siguientes:

$$q_{1e}(t)W_{a1}(t) + q_2(t)W_{a2}(t) + q_3(t)W_{a3}(t) - q_4(t)W_{a4}(t) = A \frac{d \left(\tilde{q}_1(t)W_{a4}(t) \right)}{dt} \quad 19)$$

$$q_{1e}(t)W_{b1}(t) + q_2(t)W_{b2}(t) + q_3(t)W_{b3}(t) - q_4(t)W_{b4}(t) = A \frac{d \left(\tilde{q}_1(t)W_{b4}(t) \right)}{dt} \quad 20)$$

El pH es calculado mediante la siguiente ecuación:

$$pH'(t) = -\log[H^+](t) \quad 21)$$

Donde,

$$\overset{\sim}{[H^+]}(t) = W_b \frac{\frac{K_{a1}}{[H^+](t)} + \frac{2K_{a1}K_{a2}}{[H^+](t)^2}}{1 + \frac{K_{a1}}{[H^+](t)} + \frac{K_{a1}K_{a2}}{[H^+](t)^2}} + W_a + \frac{K_w}{[H^+](t)} \quad 22)$$

Por ultimo la altura en el tanque reactor esta modelada como:

$$\dot{h} = \frac{1}{A} [q_1 + q_2 + q_3 - C_v \sqrt{h + z}]^n \quad (23)$$

Donde A es el área del tanque, C_v es la capacidad de la válvula, n es el exponente de la válvula, y z es la distancia vertical entre el fondo del tanque y el orificio de salida de flujo.

Dependiendo de donde se encuentre el transmisor hay que considerar un retraso en la medición dado por

$$t_0(t) = \frac{L A p}{q_4(t)} \quad (24)$$

Donde L y A_p don la distancia desde el fondo del reactor hasta el sitio donde se realiza la medición y el área de la sección transversal del tubo respectivamente.

ANEXO E

1. PRUEBA DE RESPUESTA ANTE LAS PERTURBACIONES SUMANDO RUIDO EN LA SEÑAL DE LOS SENSORES

1.1. TANQUE REACTOR CON TANQUE DE HOMOGENIZACIÓN

Figura 1. Respuesta en lazo cerrado del sistema (izquierda) y salida de los controladores (derecha) ante la perturbación en el flujo 2 de 20%.

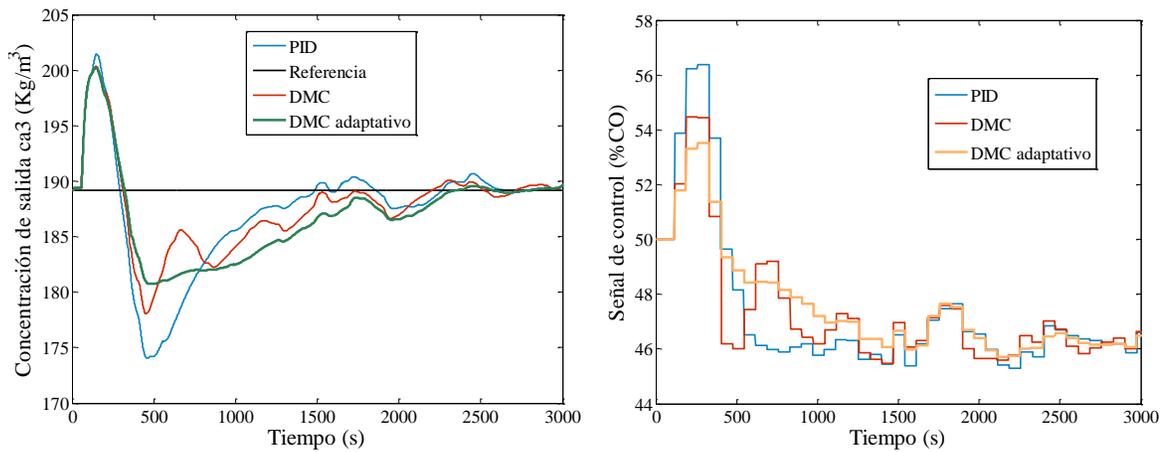


Figura 2. Comparación entre los errores de modelo para el DMC y el DMC adaptativo (izquierda). Comparación entre la salida de la RNA y la del proceso (derecha).

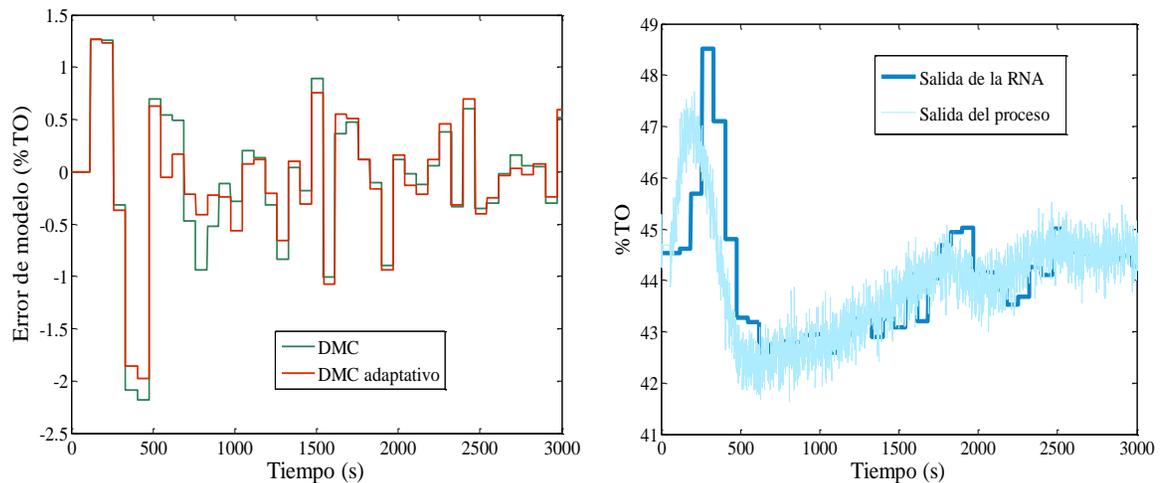


Figura 3. λ (Izquierda) y γ (derecha) en cada período de muestreo.

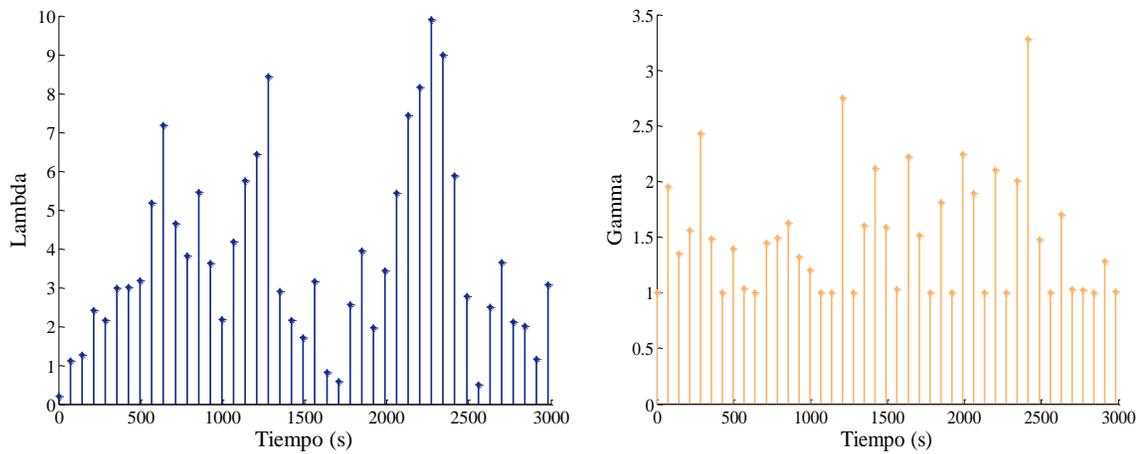


Tabla 1. Comparación del IAE para las distintas estrategias ante una perturbación en el flujo 2 de 20%, para el proceso uno, sumando ruido a la señal de los sensores.

CONTROLADOR	IAE
PID	2524.8
DMC estándar	2234
DMC adaptativo	2699

1.2. REACTOR NEUTRALIZADOR DE PH SISO

Figura 4. Respuesta en lazo cerrado del sistema (izquierda) y salida de los controladores (derecha) ante la perturbación en el flujo ácido de 20%.

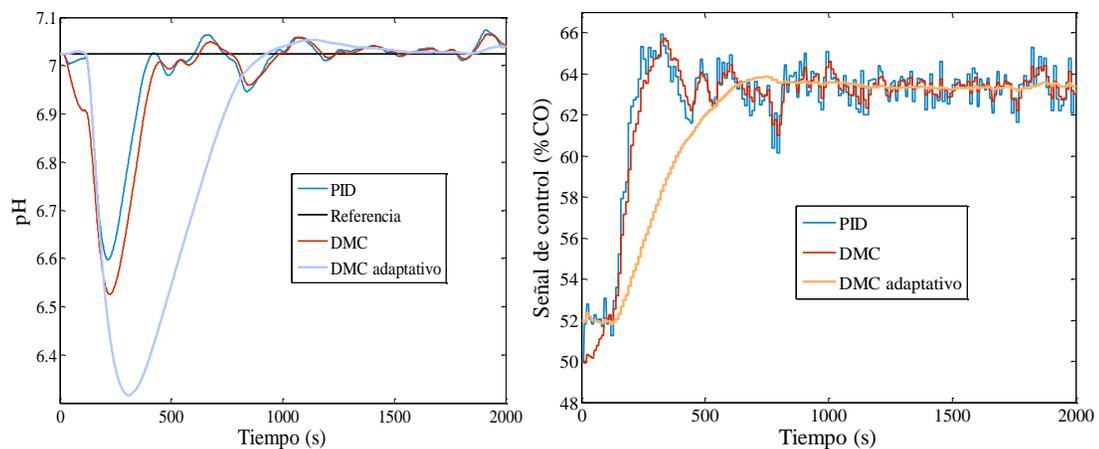


Figura 5. Comparación entre los errores de modelo para el DMC y el DMC adaptativo (izquierda). Comparación entre la salida de la RNA y la del proceso (derecha).

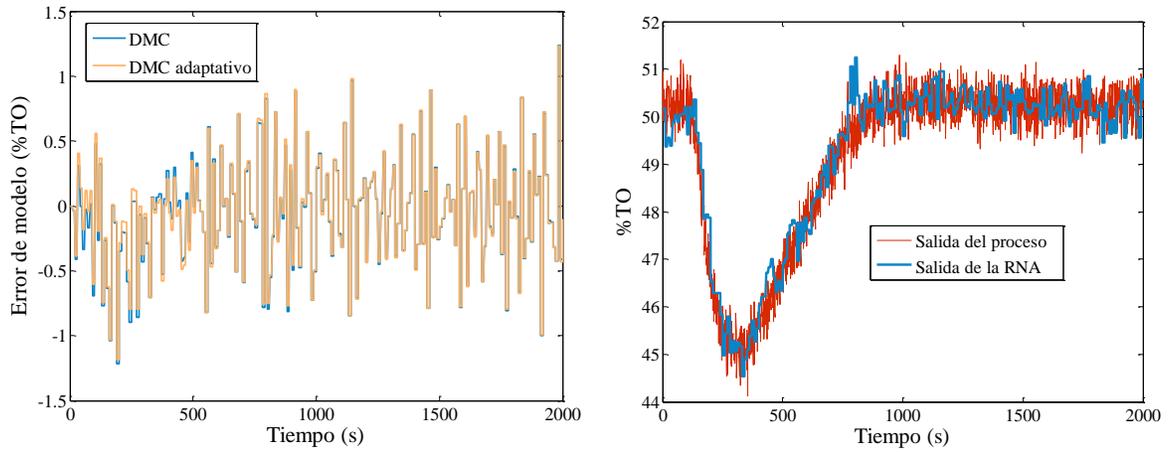


Figura 6. λ (Izquierda) y γ (derecha) en cada período de muestreo.

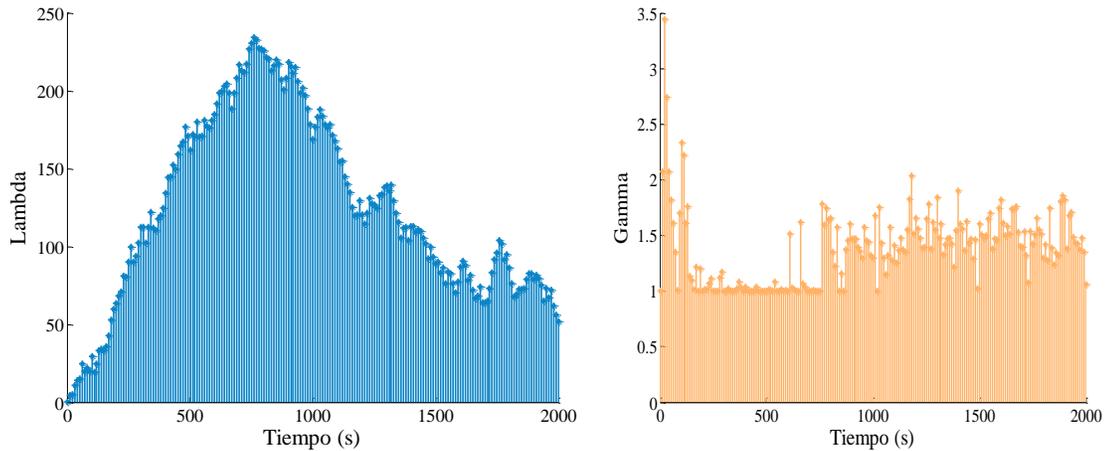


Tabla 2. Comparación del IAE para las distintas estrategias ante una perturbación en el flujo ácido de 20%, para el proceso dos SISO, sumando ruido a la señal de los sensores.

CONTROLADOR	IAE
PID	682.8
DMC estándar	893.3
DMC adaptativo	1815

ANEXO F

1. MANUAL DE USUARIO

Las interfaces gráficas de usuario diseñadas para la estrategia adaptativa, muestran el correcto funcionamiento de a estrategia así como permiten modificar los parámetros más importantes de ella a través de una interfaz intuitiva y sencilla de manejar. Debido a que la estrategia fue probada en tres procesos, dos SISO y uno MIMO, se diseñaron interfaces gráficas para cada uno de ellos. Sin embargo, la interfaz gráfica de los procesos SISO es la misma, por tanto sólo se explicará el funcionamiento de una de ellas, que será suficiente para manejar la otra.

En la Figura se muestra la interfaz del sistema. La interfaz fue diseñada en el programa MATLAB bajo WINDOWS XP. Para ejecutar el programa se recomiendan 512MB de memoria RAM y un procesador de 1.6GHz. Para hacer aparecer esta interfaz primero debe buscarse el programa dentro de su computador tal como se muestra en la Figura. Antes debe copiar en el directorio de trabajo de matlab la carpeta correspondiente al desarrollo llamada ADMC. Después mediante la ventana de *current diretory* en MATLAB se busca la carpeta ADMC después siso y después Reactor. Al final debe aparcer la ventana mostrada en la Figura. Después se debe buscar el archivo interfaz2.m dar doble clic sobre él y correrlo presionando la tecla F5 una vez aparezca lo mostrado en la Figura.

Figura 1.



Figura 2.

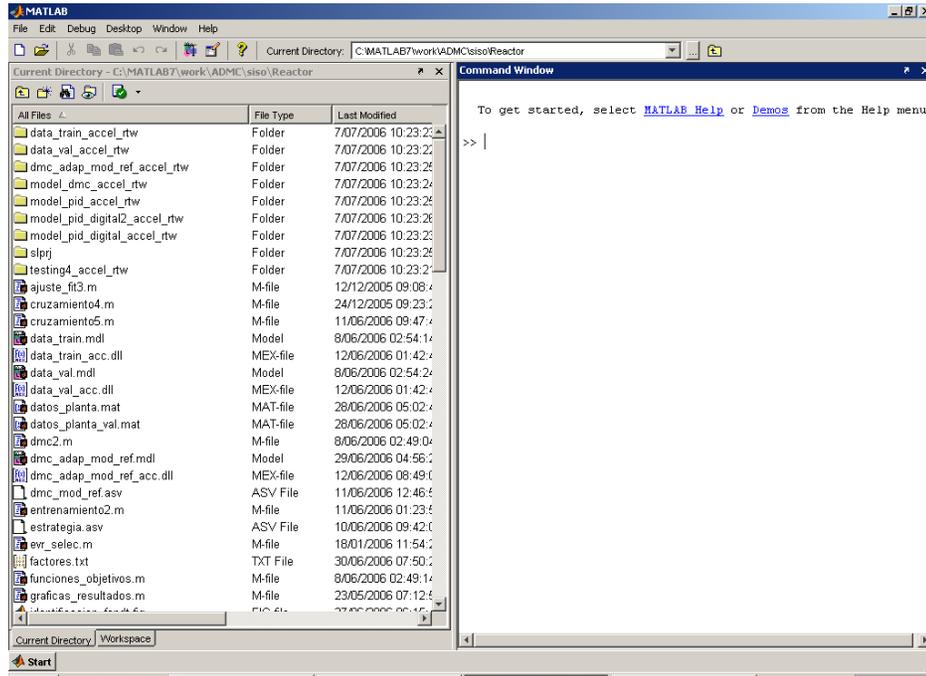


Figura 3.

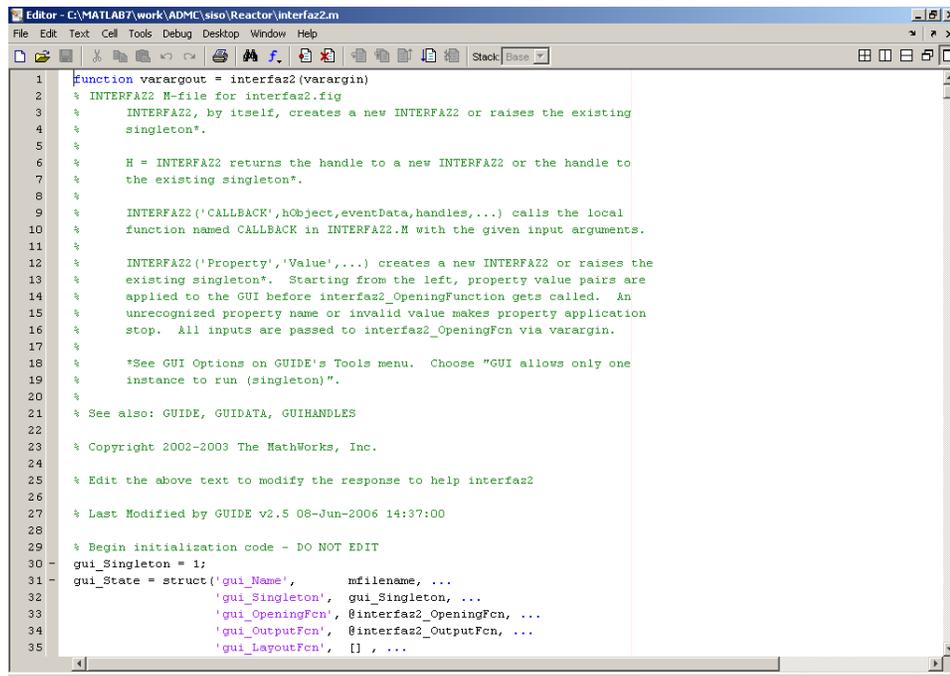
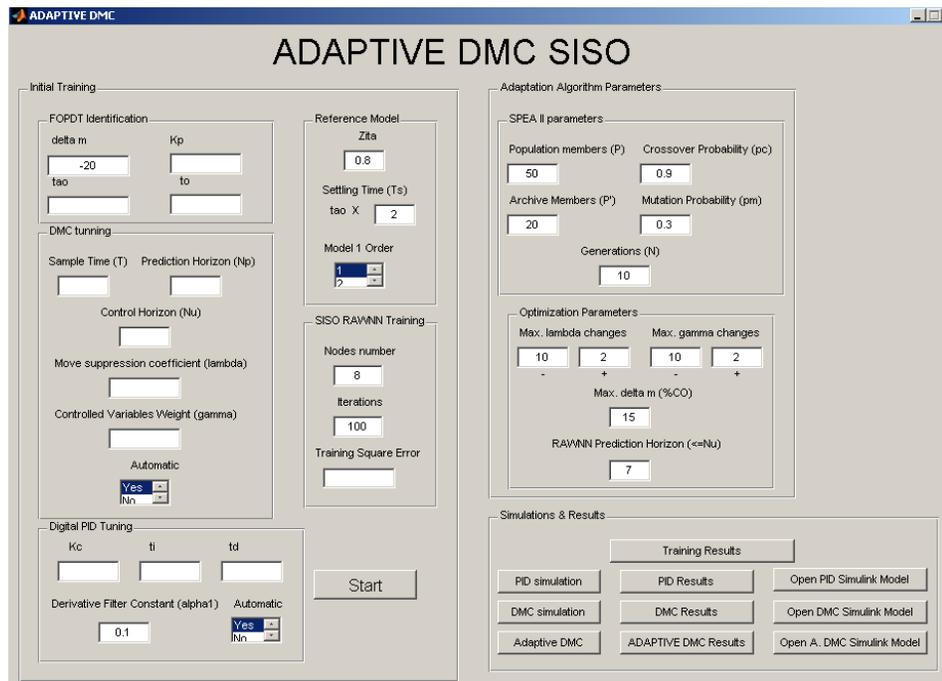
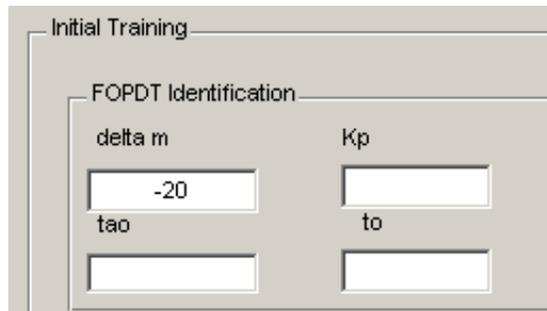


Figura 4. Interfaz de usuario gráfica para la estrategia adaptativa SISO.



Una vez aparezca la interfaz gráfica podemos observar cada uno de los parámetros para cada módulo de la estrategia. Para el caso de la identificación observamos lo siguiente:

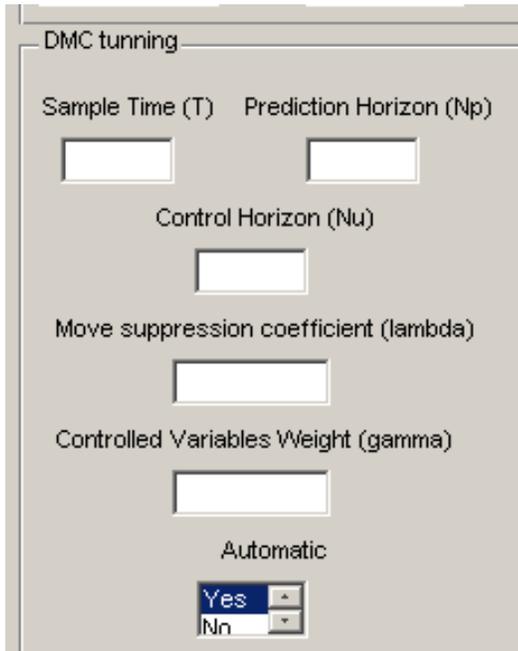
Figura 5.



Aquí se puede configurar el tamaño del paso escalón dado para el proceso de identificación en la casilla llamada delta m. Las otras casillas no se pueden modificar. Estas arrojan los resultados del proceso una vez se entrene al sistema, aspecto que tocaremos más adelante.

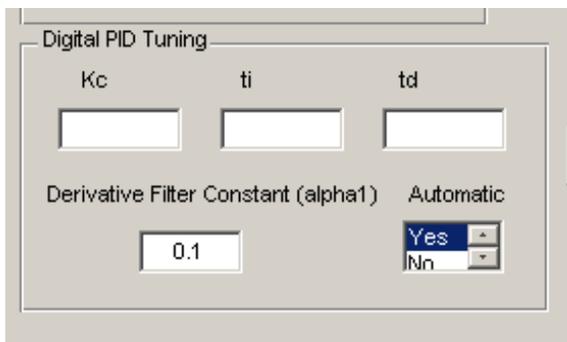
También observamos la sección dedicada a la sintonización del DMC en la Figura en la cual se puede seleccionar si se quiere dar los parámetros de manera manual seleccionando en *Automatic* la opción *no* ó *si*, si se quiere que se sintonice automáticamente basado en la identificación FOPDT anterior usando las fórmulas de sintonización mostradas en el trabajo.

Figura 6.



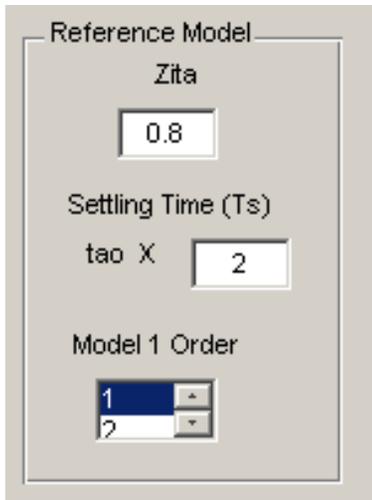
Igualmente podemos observar en la Figura la sección dedicada a la sintonización del PID digital usado para contrastar la estrategia adaptativa. Aquí al igual que para el DMC se pueden dar los parámetros de manera automática usando al identificación FOPDT y las fórmulas mostradas en el trabajo o manual ingresando los parámetros deseados seleccionando en *Automatic yes* o *no* respectivamente. Cuando se selecciona *Yes* en *Automatic* se debe esperar hasta entrenar al sistema para que aparezcan los parámetros hallados.

Figura 7.



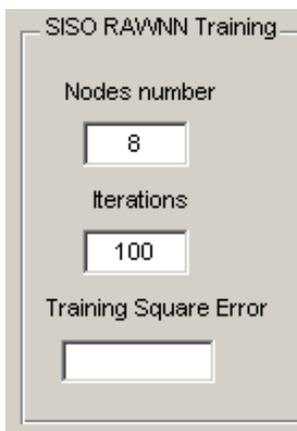
Para el caso de los parámetros del modelo de referencia sólo resta ingresar los parámetros de respuesta deseados en Zita y Settling Time, el cual siempre es un múltiplo de la constante de tiempo hallada en el proceso de identificación., El orden del modelo se escoge simplemente seleccionando entre 1 para primer orden y dos para un modelo de segundo orden.

Figura 8.



Para el caso de la red neuronal los parámetros a escoger son el número de nodos en la capa oculta en *Nodes number* así como el número de iteraciones para encontrar los pesos finales en *iterations*. Al final del proceso de entrenamiento se muestra el error de entrenamiento en el cuadro *training square error*.

Figura 9.



Para realizar el entrenamiento inicial del sistema solo resta oprimir el botón *Start* mostrado en la Figura . Una vez se oprima el botón aparece una barra que indica porque parte del proceso va. Al final se muestra un mensaje de anuncio indicando la finalización del proceso. Tal como se muestra en la Figura .

Figura 10.

The image shows a software interface titled "Initial Training" with several configuration panels:

- FOPDT Identification:** Includes input fields for δ (value: -20), τ , K_p , and t_0 .
- Reference Model:** Includes input fields for Z_{ita} (value: 0.8) and $\tau \times$ (value: 2). A "Model 1 Order" dropdown menu is set to 1.
- DMC tuning:** Includes input fields for Sample Time (T), Prediction Horizon (N_p), Control Horizon (N_u), Move suppression coefficient (λ), and Controlled Variables Weight (γ). An "Automatic" dropdown menu is set to "Yes".
- SISO RAWNN Training:** Includes input fields for Nodes number (value: 8), Iterations (value: 100), and Training Square Error.
- Digital PID Tuning:** Includes input fields for K_c , t_i , t_d , and Derivative Filter Constant (α_1) (value: 0.1). An "Automatic" dropdown menu is set to "Yes".

A "Start" button is located at the bottom right of the interface.

Después de esto se pueden ver los resultados del entrenamiento en la interfaz gráfica en los cuadros que se encontraban vacíos. También podemos ver el resto de los resultados oprimiendo en el botón *training results* el cual nos lleva a una serie de gráficas informativas sobre el entrenamiento inicial. Las gráficas que se arrojan una vez se oprime el botón se muestran en la Figura . Si se quiere volver a la venta inicial simplemente se oprime el botón *back* que se encuentra en la parte inferior de la ventana.

Figura 11.

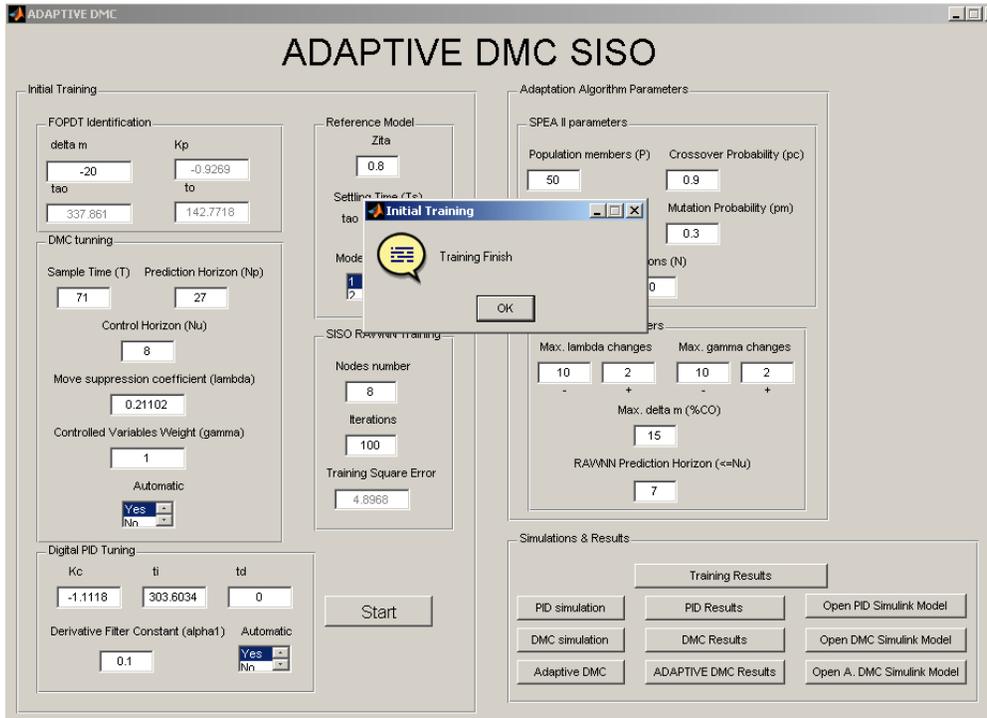
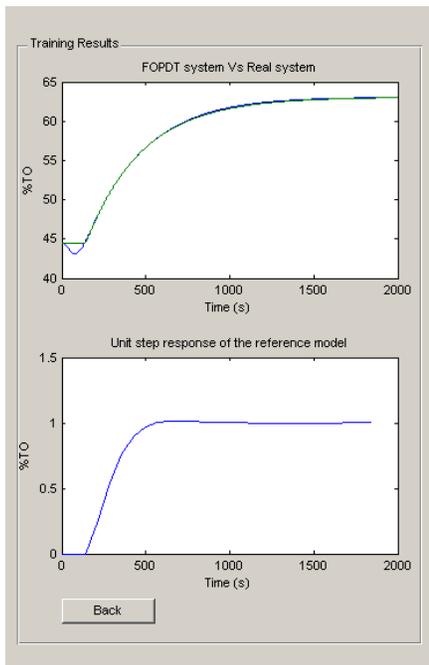


Figura 12.



Antes de ir a la sección de pruebas sólo nos resta ingresar los parámetros del algoritmo evolutivo y del proceso de optimización. En la Figura se muestra el cuadro donde se puede

ingresar Los miembro de la población P y P' la probabilidad de cruzamiento y mutación así como el número de generaciones del mismo. También podemos ingresar las restricciones del algoritmo mostradas en el trabajo. Dichas restricciones son los cambios hacia arriba y hacia abajo que pueden tener λ y γ denotados por $-$ y $+$ respectivamente así como el máximo cambio permitido en la señal de control dado por *max. Delta m(%CO)*. El último parámetro no es una restricción y es el horizonte de predicción para la red neuronal mostrado como *RAWNN prediction horizon($\leq Nu$)*, que no puede sobrepasar al horizonte de control ingresado o hallado para el DMC.

Figura 13.

Adaptation Algorithm Parameters

SPEA II parameters

Population members (P) Crossover Probability (pc)

50 0.9

Archive Members (P') Mutation Probability (pm)

20 0.3

Generations (N)

10

Optimization Parameters

Max. lambda changes Max. gamma changes

10 2 10 2

- + - +

Max. delta m (%CO)

15

RAWNN Prediction Horizon ($\leq Nu$)

7

Finalmente solo resta simular a los sistemas para observar su rendimiento. En la Figura se muestra el panel destinado para este fin. Aquí se puede simular cualquiera de los tres controladores sobre el tanque reactor con tanque de homogenización o sobre el reactor neutralizador de pH, dependiendo de la carpeta escogida inicialmente. Para simular cualquiera de los controladores solo hace falta oprimir el botón *PID simulation*, *DMC simulation* ó *Adaptive DMC* par el caso del PID, el DMC y el DMC adaptativo respectivamente. Una vez se oprime el botón resta esperar a que el mensaje de aviso de finalización de simulación aparezca, como se muestra en la Figura , antes de intentar realizar cualquier operación.

Figura 14.

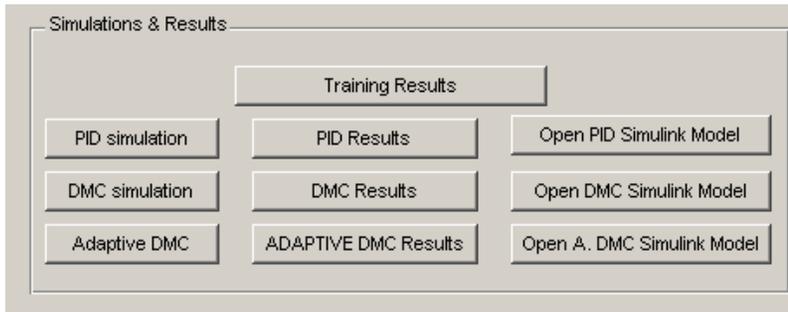
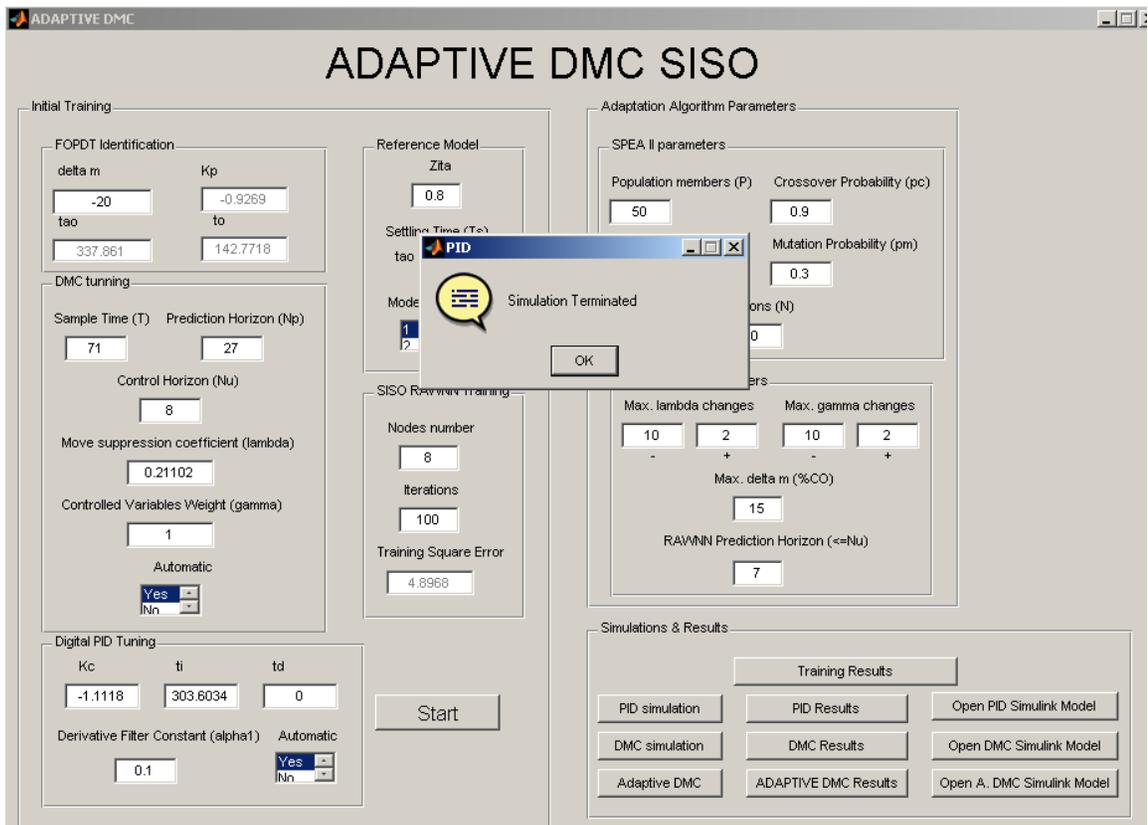
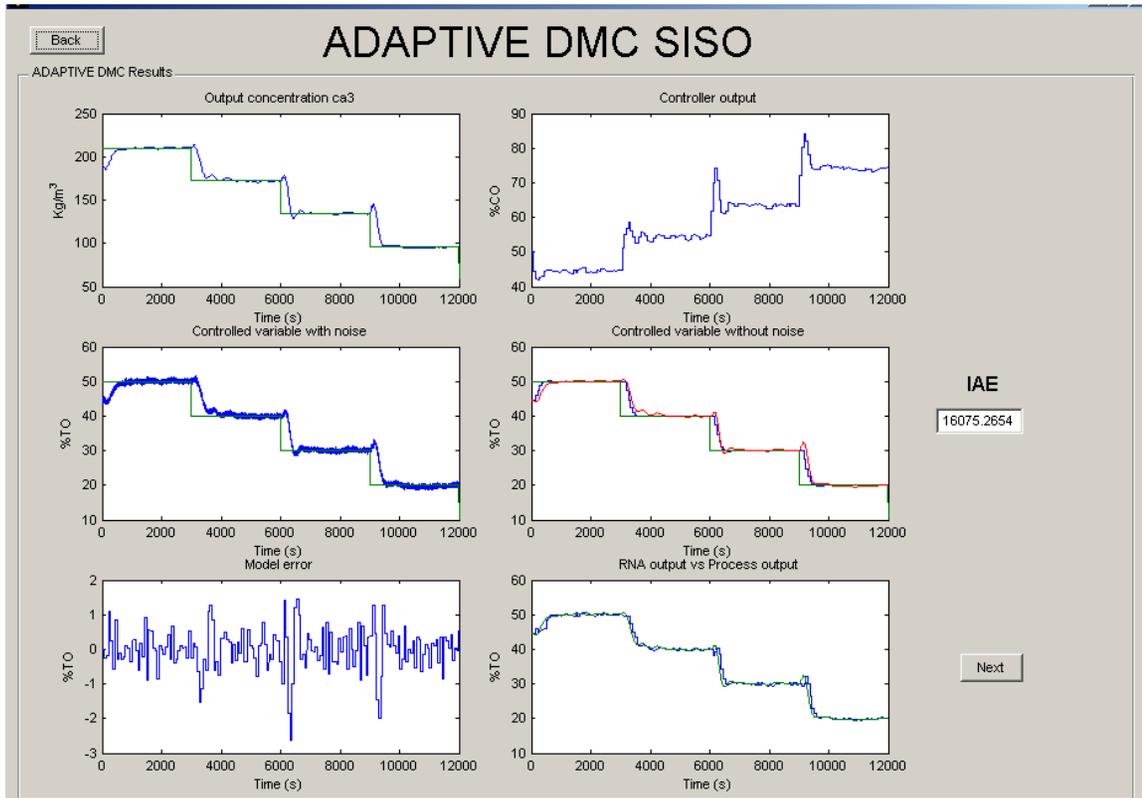


Figura 15.



Para observar los resultados de la simulación se debe oprimir el botón que se encuentra al lado derecho de los botones de simulación para cada estrategia de control. Aquí se puede observar una ventana como la de la Figura para el caso de la estrategia adaptativa.

Figura 16.



Para esta y las otras estrategias de control, aparecerá un botón *back* en la parte superior izquierda que servirá para volver a la ventana inicial. No obstante para el caso de la estrategia adaptativa tenemos más gráficas, las cuales se pueden ver presionando el botón *next* que aparece en la parte inferior derecha. Para este caso aparece la ventana mostrada en la Figura . Por último se ofrece la opción de acceder al modelo de SIMULINK creado para simular cada una de las estrategias oprimiendo los botones que se encuentran al lado derecho de los botones para mostrar los resultados de cada una de las estrategias. Para el caso del PID es el botón *open DMC simulink model*, para el PID es *open pid simulink model* y para el DMC adaptativo es *open A. DMC simulink model*, todos estos ubicados en la parte inferior derecha de la interfaz. En la Figura se muestra uno de los modelos de simulink construidos para este fin.

Para el caso de la estrategia multivariable se usa de la misma manera como se usa la interfaz sobre la que se ha trabajado. Las diferencias entre la una y la otra se mostrarán a continuación.

En primera instancia el nombre del archivo a ejecutar es *interfaz.m*. El resultado de la ejecución es la ventana que se muestra en la Figura . Aquí se pueden seleccionar todos los parámetros que se pueden seleccionar para la estrategia SISO, solamente considerando las modificaciones referentes a las dos entradas que tenemos y las dos salidas. Por tanto ahora

Figura 19.

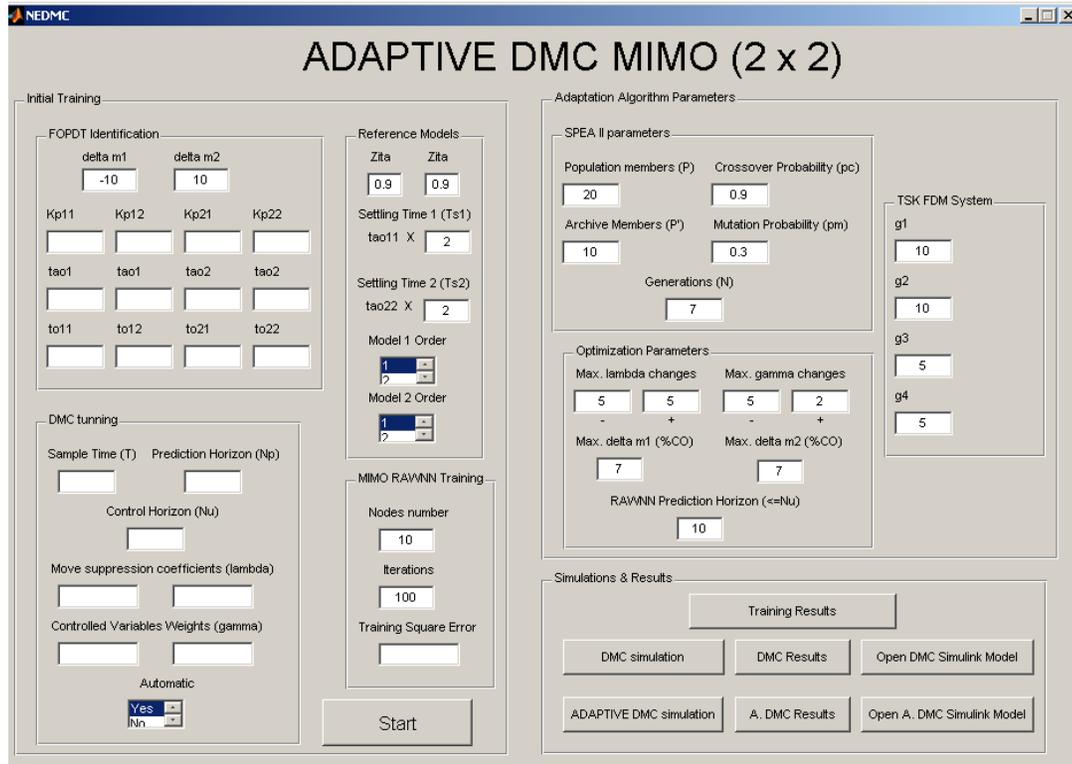
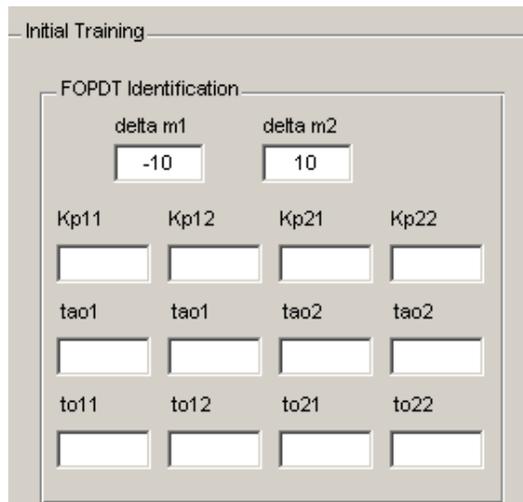


Figura 20.



Otro cambio es en la parte de los modelos de referencia ya que ahora se tienen dos modelos en vez de unos solo. Por tanto hay que especificar los parámetros de cada uno de ellos. Las modificaciones se muestran en la Figura .

Figura 21.

Para la red neuronal no hay grandes modificaciones, al igual que para los parámetros del algoritmo evolutivo. Hay cambios en las restricciones de la optimización en donde ahora hay que especificar la restricción correspondiente a la salida dos del controlador llamada *max. Delta m2(%CO)*. Los cambios se muestran en la Figura .

Figura 22.

Un cambio significativo se encuentra en la inclusión del módulo de decisión TSK sobre el frente de pareto en donde se puede ajusta el valor de cada una de las ganancias a través del módulo mostrado en la Figura 23. Las simulaciones se ejecutan de la misma manera y se debe esperar a la misma ventana de confirmación para hacer alguna otra operación. De la

misma manera se accede y se navega por los resultados usando los botones *back* y *next*. Igualmente se puede abrir el modelo de SIMULINK que genera las simulaciones con los botones dados para este fin, cuyos nombres son los mismos que para el caso SISO con la ligera diferencia que para este caso no hay simulación de controladores PID.

Figura 23.

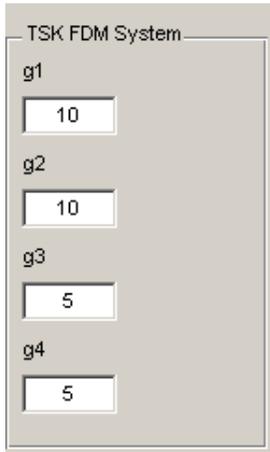
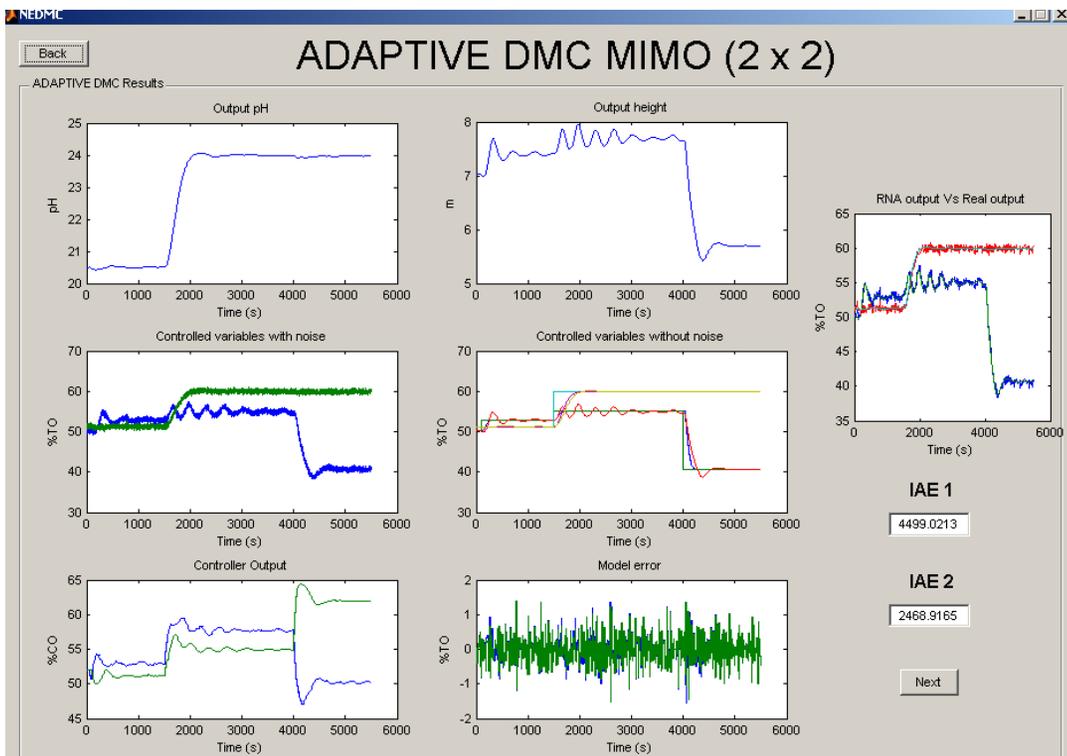


Figura 24.



En la Figura se muestra un caso típico para los resultados de la estrategia MIMO adaptativa. Aquí observamos claramente que aparecen dos resultados para el IAE de la

prueba, esto es, uno para cada salida, así como el botón de *next* indicando la presencia de más gráficas.

ANEXO G

CÓDIGOS DE LOS PROGRAMAS DE MATLAB