

UNIVERSIDAD CENTRAL “MARTA ABREU” DE LAS VILLAS
FACULTAD DE INGENIERÍA ELÉCTRICA
DEPARTAMENTO DE AUTOMÁTICA Y SISTEMAS COMPUTACIONALES



TRABAJO DE DIPLOMA

Control Predictivo Basado en Modelos Difusos

Autor: Ariel López Ferrer

Tutor: M. Sc. Boris Luis Martínez Jiménez

Santa Clara

2004

"Año del 45 Aniversario del Triunfo de la Revolución"

Universidad Central “Marta Abreu” de Las Villas

Facultad de Ingeniería Eléctrica

Departamento de Automática y Sistemas Computacionales



TRABAJO DE DIPLOMA

Control Predictivo Basado en Modelos Difusos

Autor: Ariel López Ferrer

E-mail: ferrer@uclv.edu.cu

Tutor: M. Sc. Boris Luis Martínez Jiménez

Prof. Auxiliar, Dpto. Automática y Sist. Computacionales

Facultad de Ing. Eléctrica. UCLV.

E-mail: boris@fie.uclv.edu.cu

Santa Clara

2004

"Año del 45 aniversario del triunfo de la revolución"



Hago constar que el presente trabajo de diploma fue realizado en la Universidad Central “Marta Abreu” de Las Villas como parte de la culminación de estudios de la especialidad de Automática autorizando a que el mismo sea utilizado por la Institución para los fines que estime conveniente, tanto de forma parcial como total y que además no podrá ser presentado en eventos ni publicado sin autorización de la Universidad.

Firma del Autor

Los abajo firmantes certificamos que el presente trabajo ha sido realizado según acuerdos de la dirección de nuestro centro y el mismo cumple con los requisitos que debe tener un trabajo de esta envergadura referido a la temática señalada.

Firma del Autor

Firma del Jefe de Departamento
donde se defiende el trabajo

Firma del Responsable de
Información Científico-Técnica

PENSAMIENTO

En la ciencia no existen calzadas reales, y quien aspire a remontar sus luminosas cumbres; ha de estar dispuesto a escalar la montaña por senderos escabrosos.

KARL MARX

DEDICATORIA

A la memoria de mi Abuelo

AGRADECIMIENTOS

Quisiera, ante todo, agradecer la paciencia y la incondicional y siempre valedera ayuda de mi tutor Boris Luis Martines Jiménez y de mi amigo y hermano Roy Reyes Calvo.

También quiero agradecer a mi familia que siempre estuvo presente y pendiente de lo que yo necesitara sin importar lo que fuera.

Agradezco la felicidad *desestresante* que me ha proporcionado Yailin durante todo este tiempo y a su familia.

A todos mis amigos, muchísimas gracias.

Ariel López Ferrer

Santa Clara. Julio. 2004.

TAREA TÉCNICA

Para el desarrollo de este trabajo, nos propusimos las siguientes tareas:

1. Revisión bibliográfica sobre el Control Predictivo Basado en Modelos Difusos
2. Análisis, desarrollo y programación de un algoritmo de Control Predictivo Basado en Modelos Difusos.
3. Simulación del algoritmo propuesto. Ajuste y evaluación del algoritmo desarrollado sobre un sistema.
4. Análisis de los resultados obtenidos.
5. Elaboración del informe final.

Firma del Autor

Firma del tutor

RESUMEN

El control predictivo ha solucionado situaciones complejas donde los métodos tradicionales no son eficientes, por esto ha alcanzado gran aceptación en la industria, solucionando exigencias de calidad, seguridad y gestión económica. Pero el control predictivo lineal no siempre funciona adecuadamente en sistemas no lineales. Esto ha conducido al desarrollo de controladores predictivos basados en modelos no lineales. Estos controladores, aunque precisos en un amplio rango de trabajo, son complejos y requieren de mucho esfuerzo computacional.

La modelación difusa es una estrategia válida para el modelado de sistemas que presentan dinámicas complejas. Los modelos difusos son eficientes y permiten capturar el conocimiento de expertos.

Con el objetivo de minimizar la complejidad de la solución para el caso no lineal, en este trabajo se aplica una estrategia de control predictivo lineal que utiliza un modelo difuso no lineal, del cual se obtienen modelos lineales locales en lugar de estimar recursivamente un modelo lineal en cada instante de muestreo. Las ventajas son que se retienen las propiedades del control predictivo lineal y que es fácil de resolver el problema de optimización.

Para la validación, se selecciona el proceso de neutralización del pH en un tanque de agitación continua, proceso con dinámica compleja y no lineal.

TABLA DE CONTENIDOS

<i>INTRODUCCIÓN</i>	1
Descripción del contenido de la tesis	3
<i>CAPÍTULO 1. CONTROL PREDICTIVO Y MODELOS DIFUSOS</i>	5
1.1 Evolución del control predictivo basado en modelos.....	5
<i>1.1.1 Primeros métodos</i>	6
1.2 El control predictivo basado en modelos.....	6
<i>1.2.1. Características e importancia del control predictivo basado en modelos</i>	6
<i>1.2.2. El uso de modelos no lineales en CPBM</i>	7
<i>1.2.3. Algunas soluciones al CPBM no lineal</i>	8
1.3 Los modelos difusos	9
<i>1.3.1. Etapas de la modelación difusa</i>	10
<i>1.3.2. Importancia de los modelos difusos</i>	11
1.4 El control predictivo basado en modelos difusos	11
1.5 Conclusiones del capítulo.....	12
<i>CAPÍTULO 2. ALGORITMO DE CONTROL PREDICTIVO DIFUSO UTILIZADO</i>	14
2.1 Los modelos difusos Takagi-Sugeno.....	14
<i>2.1.1 El mecanismo de inferencia</i>	15
2.2 El Control Predictivo	16
<i>2.2.1 Estrategia del control</i>	17
2.3 El control predictivo usando modelos difusos.....	19
<i>2.3.1 Estructura del regulador</i>	19
<i>2.3.2 Algoritmo de implementación del controlador predictivo</i>	20
2.4 Conclusiones del capítulo.....	22

<i>CAPÍTULO 3. EL CPBM APLICADO A UN PROCESO DE PH</i>	24
3.1 Ejemplo de la Aplicación	24
3.1.1 <i>El problema de control</i>	24
3.2 Modelo difuso del proceso	26
3.3 Control convencional.....	28
3.4 Controlador CPBM difuso.....	29
3.5 Conclusiones del capítulo.....	31
<i>CONCLUSIONES</i>	32
<i>RECOMENDACIONES</i>	34
<i>REFERENCIAS BIBLIOGRÁFICAS</i>	

INTRODUCCIÓN

Durante años se ha reconocido el importante papel jugado por las estrategias de Control Predictivo Basado en Modelos (CPBM), las cuales han tenido un desarrollo vertiginoso, especialmente desde la esencial contribución de Clarke y otros (1987), han sido ampliamente aplicadas en la industria, fundamentalmente en el área del control de procesos, y han tenido una gran aceptación tanto en el área industrial como en la comunidad de investigadores del control (Camacho y Bordons, 1995; Richalet, 1993). Las principales razones de esta aceptación se deben al reducido número de parámetros de sintonía, a su buen desempeño, a que son fáciles de entender con un mínimo de conocimientos de control y que la sintonía del regulador es intuitiva (Richalet, 1993). Además, se puede agregar que pueden manejar problemas de control multivariables en forma natural, pueden tener en cuenta las limitaciones de los actuadores y permiten una operación del proceso más cerca de las restricciones (Maciejowski, 2000).

Como se intuye por su nombre, el funcionamiento del CPBM depende, en gran medida, del modelo de predicción seleccionado. Este debe ser capaz de predecir con exactitud las salidas futuras del proceso, debe ser sencillo de implementar, de un costo efectivo para la simulación y de fácil comprensión. Consecuentemente, la mayor parte del tiempo, del esfuerzo del diseño y del costo en CPBM está relacionado con el modelado y la identificación del modelo del proceso utilizado por el controlador.

Por otro lado, el uso de modelos difusos ha sido reconocido como una estrategia práctica para el control y el modelado. Los últimos años han sido testigo de un rápido crecimiento en el uso de controladores basados en lógica difusa para controlar procesos complejos y mal definidos. Desde un principio y hasta ahora, la mayoría de los controladores difusos desarrollados han sido de tipo basado en reglas (Driankov y otros, 1993) debido a su capacidad de capturar el conocimiento de expertos, donde la base de reglas del controlador

pretende modelar la respuesta del operador de un proceso en particular. Un método alternativo es usar los modelos difusos o los modelos difusos inversos en el control de procesos (Abonyi y otros, 2001; Babuska, 1998; Huang y otros, 2000) porque frecuentemente es más fácil obtener información acerca de cómo responde un proceso a una entrada en particular que modelar cómo y por qué un operador responde a una situación determinada. Es por esto que en la última década se han desarrollado varios algoritmos para generar modelos difusos a partir de datos de entrada-salida (Babuska, 1998; Zhao y otros, 1994), y nuevos algoritmos para combinar información numérica y de los expertos (Abonyi y otros, 2000b; Abonyi, 2003)

Debido a que los sistemas complejos, no lineales y parcialmente conocidos no son favorables a la aplicación del CPBM convencional ya que modelos adecuados de estos procesos no pueden obtenerse usando métodos convencionales, la amplia aceptación de estas estrategias, ha motivado a los investigadores a formular una estrategia de control que las combine, por lo que el uso de los modelos difusos en el CPBM no lineal se ha convertido en tema de estudio (Abonyi y otros, 2000a; Abonyi y otros, 2001; Espinosa y Vandewalle, 1999; Marsili-Libelli y Giunti, 2002; Zamarreño y González, 1998). Esta estrategia ha pasado a ser una técnica poderosa, especialmente si se trata de procesos no lineales y se le ha llamado Control Predictivo Basado en Modelos Difusos (CPBMD).

El CPBM ha sido ampliamente investigado y en el caso lineal sin restricciones, la solución es un problema cuadrático lineal. Cuando la dinámica del proceso es no lineal y hay restricciones, aumenta considerablemente la complejidad del problema, la solución analítica es difícil de encontrar y se prefiere una solución numérica, la cual presenta un alto costo de cómputo generalmente.

En la práctica, la mayoría los sistemas ingenieriles son no lineales y para lidiar con el aumento de la complejidad de la solución, en los últimos años se han empleado varias aproximaciones para resolver el problema de control mediante la linealización del modelo no lineal (Abonyi y otros, 2001; Piñón y otros, 2002; Lussón y otros, 2003).

La teoría de control ha sido extensamente desarrollada para sistemas lineales, sin embargo, la estrategia de control basada en modelos lineales ha tenido un pobre funcionamiento cuando se aplica a sistemas no lineales. Sin embargo, a diferencia de los modelos

convencionales, los modelos difusos también pueden representar procesos altamente no lineales y pueden igualmente, integrar el conocimiento obtenido de datos del proceso.

Utilizando las ventajas de la modelación difusa y con la idea de minimizar la complejidad de la solución, este trabajo aplica una estrategia de Control Predictivo Lineal que utiliza un modelo difuso no lineal.

El algoritmo CPBM que se presenta en este trabajo se basa entonces en un modelo difuso no lineal del proceso, a partir del cual se obtiene un modelo lineal local en cada punto de operación de interés, utilizando las propiedades de los sistemas difusos empleados. Aquí en lugar de estimar recursivamente un modelo lineal en cada instante de muestreo, se extrae del modelo difuso un modelo lineal. La principal ventaja de esta forma es que retiene las propiedades del CPBM lineal y es fácil de resolver el problema de optimización.

Para alcanzar los objetivos propuestos de lograr la formación en esta temática (CPBMD), y para desarrollar técnicas de control predictivo difuso en MATLAB, que incluye la programación de algoritmos de CPBMD, la aplicación y análisis de estos, se realizaron las siguientes tareas:

1. Revisión bibliográfica sobre el Control Predictivo Basado en Modelos Difusos
2. Análisis, desarrollo y programación de un algoritmo de Control Predictivo Basado en Modelos Difusos.
3. Simulación del algoritmo propuesto. Ajuste y evaluación del algoritmo desarrollado sobre un sistema.
4. Análisis de los resultados obtenidos.
5. Elaboración del informe final.

Descripción del contenido de la tesis

En el Capítulo 1 se realiza una revisión de las principales técnicas utilizadas en la tesis: Control Predictivo Basado en Modelos (CPBM) y los modelos difusos Takagi-Sugeno (TS). Se mencionarán también algunas de las características más importantes de ambas técnicas y se analizará cómo los modelos difusos se han combinado con el Control Predictivo para formar una novedosa técnica que está teniendo mucho auge en la actualidad: la técnica de Control Predictivo Basado en Modelos Difusos (CPBMD).

En el Capítulo 2 se muestran los métodos que se utilizaron para formar la estrategia de Control Predictivo Basado en Modelos Difusos. Primeramente se describe el Modelo

Difuso Takagi-Sugeno, el cual se puede expresar como un modelo lineal dependiente de las entradas, que se utilizará como modelo lineal local del sistema en cada instante de muestreo dentro del Control Predictivo. También se describe la estrategia de Control Predictivo de forma general, así como sus principales características y para finalizar se muestra de forma detallada la estrategia de CPBMD que se desarrolla haciendo uso de las técnicas planteadas anteriormente.

El Capítulo 3 muestra los resultados obtenidos al aplicar la técnica planteada en el capítulo anterior a un reactor de tanque agitado (CSTR, *Continuous Stirred Tank Reactor*) donde ocurre un proceso de neutralización de pH, para esto obtenemos el modelo difuso del sistema real para luego utilizarlo en el controlador predictivo. También se hace una comparación entre los resultados obtenidos utilizando esta técnica y los resultados que se obtienen al emplear un controlador convencional (PI digital).

CAPÍTULO 1. CONTROL PREDICTIVO Y MODELOS DIFUSOS

En este capítulo se realizará una revisión de las principales técnicas utilizadas en la tesis: Control Predictivo Basado en Modelos (CPBM) y los modelos difusos Takagi-Sugeno (TS). Se mencionarán algunas de las características más importantes de ambas técnicas y se analizará cómo los modelos difusos se han combinado con el control predictivo para formar una novedosa técnica que esta teniendo mucho auge en la actualidad: la técnica de control predictivo basado en modelos difusos.

En la sección 1.1 y 1.2 se tratará lo referente al control predictivo, cuáles fueron los primeros métodos que surgieron y algunas de las características fundamentales que hacen de esta técnica una herramienta poderosa. En la sección 1.3 se hablará de los modelos difusos así como de su importancia en el modelado de sistemas no lineales con dinámica compleja y para finalizar este capítulo en la sección 1.4 se hará referencia a algunos de los trabajos realizados en la actualidad en los cuales la modelación de sistemas mediante métodos difusos y el control predictivo se combinan en una sola técnica.

1.1 Evolución del control predictivo basado en modelos

A finales de la década de los 70 aparecieron varios artículos mostrando un interés incipiente en la aplicación industrial del CPBM. Desarrollos industriales en Europa y en Estados Unidos dieron lugar, en ese mismo período, al primer paquete comercial de Control Predictivo usando explícitamente un modelo del proceso para predecir y controlar sus variables. Simultáneamente, aunque independientemente, algunos grupos académicos europeos, iniciaron el desarrollo de controladores basados en predictores multipaso.

Muy cerca de los finales de los 80, el interés por el CPBM creció gradualmente y ya al inicio del año 1990, se produjo un *boom* en la diversidad de aplicaciones reportadas en Estados Unidos y Japón y actualmente en Europa.

Originalmente CPBM se desarrolló para cubrir necesidades de control de plantas de energía y refinerías pero hoy día está extendido a una gran variedad de áreas que incluyen plantas químicas, de automoción, metalúrgicas y muchas otras en las cuales esta técnica ha tenido resultados excelentes (Benites, 2004).

1.1.1 Primeros métodos

Los primeros métodos fueron desarrollados en Europa (*MAC*: Algoritmo de Control en base al Modelo) por Richalet y en Estados Unidos (*DMC*: Control por Matriz Dinámica) por Cutler y Damaker.

A partir de 1980 y sobre la base de las dos estructuras planteadas anteriormente, se desarrollaron numerosas técnicas y a principios de los 90 ya se habían sumado el *UPC* (*Unified Predictive Control*), *PFC* (*Predictive Funcional Control*), *SMCA* (*Setpoint Multivariable Control Architecture*), *OPC* (*Optimum Predictive Control*), *PCT* (*Predictive Control Technology*).

1.2 El control predictivo basado en modelos.

El Control Predictivo Basado en Modelos (CPBM) es una metodología de control que usa un modelo del proceso en línea para calcular las predicciones y optimizar las acciones de control, es de naturaleza abierta, con muchas contribuciones en lo académico como en el mundo industrial. (De Prada y otros, 2004).

Muchas aplicaciones de control predictivo son usadas en la actualidad en todos los campos de la actividad industrial. El buen rendimiento de esas aplicaciones ha generado un creciente interés en esta metodología.

1.2.1. Características e importancia del control predictivo basado en modelos

El control predictivo basado en modelos se basa en las siguientes ideas (Gamero, 1999):

1. Se utiliza un modelo del proceso para predecir el comportamiento futuro sobre un horizonte de predicción. Los valores predichos de las salidas, dependen de los valores pasados de las entradas y las salidas y de los valores futuros de las señales de control.

2. Se calculan los valores futuros de control de manera que se minimice una cierta función de coste de los errores de predicción. Normalmente se añade una estructuración en la ley de control, introduciendo un horizonte de control.
3. El primer elemento del vector de control óptimo se aplica a la planta. Los elementos restantes no se consideran y al siguiente instante de muestreo se repite todo el procedimiento. Esto nos da una nueva ley de control que es diferente de la señal de control calculada anteriormente.

El CPBM se puede considerar como un buen compromiso entre comportamiento y simplicidad y puede ofrecer una herramienta eficaz y fácilmente accesible para los ingenieros de control. Desde el punto de vista de las aplicaciones industriales, el método tiene algunas ventajas importantes sobre otras técnicas de control:

- Permite tratar de forma sencilla sistemas multivariantes con distinto número de entradas y salidas.
- Incorpora de forma natural la compensación *feedforward*, proporciona varianza mínima en las variables controladas y puede utilizarse en sistemas de dinámica difícil, con retardos y respuesta inversa.
- Es posible la introducción de restricciones en las variables de entrada y salida.
- Es conceptualmente simple de comprender y ajustar por el personal técnico
- El CPBM es una metodología abierta, basada en ciertos principios, que permite extensiones, contribuciones, alternativas y mejoras desde fuentes muy diferentes.

Las ventajas del control predictivo en relación con otros métodos de control están dadas a que sus principios son *intuitivos* y los parámetros de diseño son *flexibles* a los requerimientos de las aplicaciones (De Prada, 1997).

1.2.2. El uso de modelos no lineales en CPBM

Algunas plantas con un grado de no linealidad de mediano a alto, no pueden ser controladas exitosamente con la estrategia de CPBM lineal. El CPBM no lineal ha sido propuesto como una alternativa al CPBM lineal para este tipo de plantas, manteniendo las capacidades de compensación de interacciones y perturbaciones, además del manejo de restricciones propio del CPBM lineal. El problema del diseño de tales leyes de control para sistemas no

lineales ha encontrado solución, por ejemplo, cuando el sistema es equivalente por realimentación a un sistema lineal. Como muchos sistemas no lineales no son equivalentes por realimentación a un sistema lineal se ha potenciado el estudio de técnicas alternativas para el control

Los sistemas de Control Predictivo Basados en Modelo para sistemas No Lineales (CPBMNL) presentan inconvenientes cuando el modelo del sistema tiene errores de modelado. Los inconvenientes que se presentan están básicamente en la convergencia del algoritmo de optimización, y en la estabilidad y robustez del sistema. Con respecto a la convergencia de los algoritmos de optimización se puede notar que el problema de optimización pasa de ser convexo a no convexo, además de surgir múltiples mínimos locales en el funcional de costo del controlador. Debido a la complejidad de estos aspectos, el desarrollo teórico de los mismos está en sus comienzos y constituye un tema actual de investigación y desarrollo. La no solución de estos problemas trae aparejado que las aplicaciones reales de dichos esquemas no estén tan difundidas como el Control Predictivo Basado en Modelos Lineales.

1.2.3. Algunas soluciones al CPBM no lineal

El marco común del CPBM no lineal es la introducción de un modelo no lineal dentro del algoritmo de control. Esto presenta diferentes problemas desde el punto vista teórico y computacional. Desde el punto de vista computacional, el problema de optimización que debe resolverse en cada instante de muestreo puede llegar a ser tan intensivo (particularmente para sistemas con alta dimensionalidad), que las aplicaciones en línea para sistemas de dinámica rápida se hacen imposibles. Se han realizado varias modificaciones a la estructura básica del CPBM para extender la técnica a sistemas no lineales. Las tres aproximaciones iniciales y que por lo tanto marcaron un camino son: linealización tabulada, extensión del control por matriz dinámica y programación no lineal para utilizar directamente un modelo no lineal.

Otras alternativas se están explorando para ampliar cada vez más el uso de modelos no lineales en el CPBM, una de las más difundidas es el uso de herramientas de inteligencia artificial, con el fin de obtener modelos compactos y con buen grado de precisión. De Prada y otros (1998) han estudiado el uso de redes neuronales como modelos internos en el controlador predictivo orientado a procesos altamente no-lineales. Waller y Toivonen

(2002) utilizaron un control predictivo basado en modelo para controlar un proceso altamente no lineal como es el proceso de neutralización de pH. Para la aplicación de esta técnica se basaron en la obtención de un modelo neuro-difuso, el cual es capaz de modelar el comportamiento de este proceso altamente no lineal con una alta precisión, la estructura de modelación neuro-difusa que utilizaron esta dada por la obtención de un modelo lineal de la entrada con respecto a la salida y como la técnica de control predictivo que se utilizaron para llevar a cabo el trabajo es control predictivo lineal, se utiliza en cada momento un modelo lineal para encontrar la respuesta adecuada. Cristea y otros (2000) presentaron una alternativa aproximada al control predictivo no lineal de una columna de destilación de etanol, para esto desarrollaron una aproximación que emplea una linealización del proceso en cada periodo de muestreo para calcular una respuesta optimizada, que sería similar a la respuesta forzada de los métodos del Control Predictivo basado en modelos lineales (CPBML). Este procedimiento se aplica iterativamente hasta que se alcanza la solución no lineal. González y otros (2000) obtuvieron buenos resultados al usar control predictivo basado en modelo lineal a un proceso de *fed-batch*, el proceso es no lineal por lo que se obtuvo un modelo global del sistema no lineal compuesto por múltiples modelos lineales locales, de esta forma podían aplicar estos modelos al (CPBML) que es una estrategia de mucha aceptación. Los resultados obtenidos demostraron que estos modelos locales que describen el comportamiento del sistema no lineal.

Otro ejemplo para solucionar el problema de las no linealidades es el objetivo de nuestro trabajo en el cual se realiza el control predictivo basado en modelos lineales locales, los cuales se obtienen de un modelo difuso del proceso no lineal en cada instante de muestreo.

1.3 Los modelos difusos

La lógica difusa (*fuzzy logic*) surgió en los '60 como un recurso para modelar la incertidumbre del lenguaje natural; con lógica difusa, las proposiciones pueden ser representadas con grados de veracidad o falsedad. La lógica difusa es entonces definida como un sistema matemático que modela funciones no lineales, que convierte unas entradas en salidas acordes con los planteamientos lógicos que usan el razonamiento aproximado (Baena y otros, 2001).

Los modelos difusos generalmente se pueden clasificar en tres categorías: los lingüísticos (Mamdani), los Takagi-Sugeno (TS) y los de ecuaciones relacionales. En los modelos

lingüísticos el antecedente y el consecuente son conjuntos difusos, mientras que en el modelo TS el antecedente consiste de conjuntos difusos, pero el consecuente está compuesto de funciones. Los modelos de ecuaciones relacionales difusas tienen como objetivos formar matrices relacionales difusas según los datos de entrada-salida del proceso (Salehfar y otros, 2000)

Los sistemas difusos, en general, son funciones matemáticas flexibles que pueden aproximar funciones o datos (mediciones) con la precisión deseada. Comparada con otras técnicas de aproximación de funciones modernas como las redes neuronales artificiales, los sistemas difusos brindan una representación más transparente del sistema bajo estudio, debido fundamentalmente a la posibilidad de interpretación lingüística en forma de reglas. La estructura lógica de las reglas facilita el entendimiento y el análisis del modelo de forma semi-cualitativa, similar al razonamiento humano.

1.3.1. Etapas de la modelación difusa

La modelación difusa se ejecuta en dos etapas. En la primera se identifica la estructura superficial del sistema y en la segunda la estructura profunda (Bello, 2004)

Primera etapa:

- Seleccionar las variables de entrada y salida relevantes.
- Seleccionar un tipo específico de sistema de inferencia difuso (SID).
- Determinar la cantidad de términos lingüísticos asociados con cada variable de entrada o salida (para el modelo de Sugeno determinar el grado de la función consecuente).
- Definir el conjunto de reglas borrosas.

Segunda etapa:

- Seleccionar una familia apropiada de funciones de pertenencia (FP) parametrizadas.
- Determinar los parámetros de las FP usadas (y los coeficientes de las funciones consecuentes si se usa el modelo de Sugeno).
- Refinar los parámetros de las FP usando técnicas de regresión y optimización (si hay un conjunto de datos de entrada-salida).

1.3.2. Importancia de los modelos difusos

El uso de modelos difusos ha sido reconocido como una estrategia práctica para el control y el modelado. Desde un principio, los modelos difusos han sido muy atractivos por su capacidad de capturar el conocimiento de expertos. En los últimos años se han desarrollado varios algoritmos para generar modelos difusos a partir de datos de entrada-salida (Babuska, 1998), y nuevos algoritmos para combinar información numérica y de los expertos (Abonyi y otros, 2000; Abonyi, 2003).

En la industria tienen un amplio uso como modelos del proceso a controlar. Estas técnicas tienen sus orígenes en los primeros trabajos de Takagi y Sugeno sobre la identificación de sistemas difusos y sus aplicaciones al modelado del sistema.

La aplicación de las técnicas de modelado precisa una serie de simplificaciones sobre los parámetros, relativos a antecedentes y consecuentes. En los modelos Takagi Sugeno (TS) se emplean reglas en donde los consecuentes están descritos por combinaciones lineales de las entradas. Este modelo puede ser realizado fuera de línea o en tiempo real.

Las metodologías de modelación e identificación difusas han sido utilizadas exitosamente en varias aplicaciones. El modelo TS se ha empleado a menudo en la modelación e identificación de procesos no lineales a partir de datos medidos. Ejemplo de ello es la modelación de un horno de fundición de vidrio (Zhao y otros, 1994). La modelación difusa se ha utilizado en aplicaciones como la obtención de Penicilina-G (Babuska y otros, 1996), predicción del flujo de agua de un río (Sugeno y Tanaka, 1991), eliminación de suciedad en procesos de lavado (Kaymak, 1994), o modelación del crecimiento de algas en lagos (Setnes y otros, 1997).

1.4 El control predictivo basado en modelos difusos

La amplia aceptación del control predictivo basado en modelos y los modelos difusos ha motivado la formulación de una estrategia de control que las combine, por lo que el uso de los modelos difusos en el CPBM no lineal se ha convertido en tema de estudio (Zamarreño y González, 1998; Abonyi, 2003). A esta estrategia se la ha llamado Control Predictivo Basado en Modelos Difusos. Los conjuntos difusos se pueden utilizar en CPBM de varias formas, en el nivel de modelado, en la función objetivo o en las especificaciones de los objetivos de control (Babuska, 1998). En este trabajo se utilizan en el nivel de modelado.

Los resultados obtenidos al combinar estas dos técnicas han tenido relevancia en el ámbito industrial. Huang y otros (2000) obtuvieron resultados significativos usando control predictivo basado en modelos difusos para controlar un sistema altamente no lineal. El modelo del proceso que se utilizó es un modelo difuso Takagi- Sugeno al cual le aplican una entrada tipo impulso para obtener el modelo de convolución que luego será utilizado en el control predictivo en cada instante de muestreo.

Altamiranda y Colina (2004) proponen el diseño de controladores predictivos generalizados para sistemas no lineales, usando modelos basados en una estructura llamada neurona difusa recurrente a partir de la cual se obtiene en línea una aproximación lineal del sistema. Sánchez y otros (2002) aplican una estructura de control que combina control predictivo y modelado difuso tipo Takagi-Sugeno (TS) al arranque de caldera de una planta termo-eléctrica. La técnica de control predictivo emplea en su diseño modelos lineales para estimar la salida de la planta. La metodología difusa Takagi-Sugeno se usa para modelar sistemas no lineales. En ella, las dinámicas de un sistema no lineal son obtenidas mediante la linealización en diferentes puntos de operación o mediante identificación alrededor de estos puntos. Una vez que los modelos lineales son obtenidos, las metodologías de control lineal se utilizan para diseñar los controladores para cada modelo local. Los resultados obtenidos fueron satisfactorios

Espinosa y Vandewalle (1999) obtuvieron un controlador predictivo no lineal robusto, para obtener la información del sistema se usó un modelo difuso Takagi-Sugeno del sistema. Para la optimización obtuvieron un Programa Cuadrático robusto mediante programación semidefinida. Entre las ventajas obtenidas con este método se incluye un funcionamiento robusto del problema.

Abonyi y otros (2000a) desarrollaron un controlador predictivo basado en un modelo llamado HFCM (*hybrid fuzzy convolution model*), el cual está compuesto por un modelo difuso de estado estable y un modelo de respuesta al paso llamado ganancia independiente.

1.5 Conclusiones del capítulo

En este capítulo se plantearon las principales técnicas que se utilizarán para solucionar el problema de control que se plantea en el capítulo 3. También se analizan algunos trabajos realizados que utilizan estrategias similares a la propuesta en este trabajo y que han servido de base para la investigación.

En lo adelante se profundizará más en la materia y se muestra la base matemática del algoritmo implementado en esta tesis.

CAPÍTULO 2. ALGORITMO DE CONTROL PREDICTIVO DIFUSO UTILIZADO

Este capítulo aborda el diseño de un algoritmo de control predictivo basado en un modelo difuso del proceso. En la sección 2.1 se trata el modelo difuso que utilizaremos para analizar el comportamiento de la planta, el conocido Takagi-Sugeno (TS). Una vez obtenido el modelo difuso TS del proceso con suficiente exactitud, este se usa en el diseño de un controlador no lineal para el proceso bajo estudio formando parte de un esquema de control basado en modelos. En este caso, el esquema de control seleccionado es el control predictivo, el cual se explica en la sección 2.2.

En CPBM con modelos no lineales, generalmente debe ser resuelto un problema de optimización no convexo en cada período de control, lo cual limita la aplicabilidad del CPBM no lineal. Para evitar este problema, en la sección 2.3 se explica el algoritmo de implementación que hemos desarrollado, el cual se basa en utilizar la estrategia de control predictivo lineal utilizando un modelo lineal obtenido del modelo difuso no lineal. Finalmente, en la sección 2.4 se realiza una recapitulación de los temas aquí tratados.

2.1 Los modelos difusos Takagi-Sugeno

Los modelos difusos exhiben características tanto cualitativas como cuantitativas. Las predicciones numéricas son semejantes a otras técnicas de identificación. La principal diferencia radica en que la estructura basada en reglas de los sistemas difusos permite la interpretación y el análisis del comportamiento del proceso en una forma más clara y directa, y que el conocimiento impreciso *a priori* del proceso puede expresarse en forma de reglas y ser incorporado en el modelo.

Un modelo difuso conveniente para la aproximación de una gran cantidad de sistemas dinámicos no lineales fue introducido por Takagi y Sugeno (1985). En el modelo Takagi-Sugeno (TS), los consecuentes son funciones reales de las entradas del modelo:

$$\begin{aligned} R_i: & \text{ If } x_1 \text{ is } A_{i1} \text{ and } \dots x_p \text{ is } A_{ip} \\ & \text{ Then } y_i = f_i(\mathbf{x}), \quad i = 1, 2, \dots, L \end{aligned} \quad (2.1)$$

donde R_i denota la regla i , L es el número de reglas del modelo, $\mathbf{x} = [x_1, \dots, x_p]^T$ es el vector de entrada, A_{ij} son conjuntos difusos caracterizados por las funciones de pertenencia $\mu_{A_{ij}}(x_i)$, y_i es la salida de la regla i y cada f_i es una función real. Las funciones f_i de un modelo son generalmente de la misma estructura y solo cambian los parámetros de cada regla. Una parametrización del consecuente útil en la práctica es la forma:

$$y_i = f_i(\mathbf{x}) = \mathbf{a}_i^T \mathbf{x} + b_i \quad (2.2)$$

$$\mathbf{a}_i = [a_{i1}, \dots, a_{ip}]^T \quad (2.3)$$

donde \mathbf{a}_i es un vector de parámetros y b_i es un escalar. Esta forma, llamada sistema difuso TS afín, es una aproximación multi-modelo en la cual modelos lineales simples se combinan para describir el comportamiento global del sistema, lo cual permite el análisis en un marco similar al de los sistemas lineales. (Babuska, 1998).

El entrenamiento de estos modelos o la extracción del modelo usando datos de entrada-salida han sido estudiados por varios autores (Babuska, 1998, Abonyi, 2003, Martínez y Herrera, 2003). Además, desde el punto de vista de la implementación, los modelos difusos TS son simples y computacionalmente eficientes (Babuska, 1998).

2.1.1 El mecanismo de inferencia

La salida del sistema difuso Takagi-Sugeno es un promedio ponderado de los valores de los consecuentes de las reglas. La fórmula de inferencia es:

$$y = \frac{\sum_{i=1}^L w_i(\mathbf{x}) y_i}{\sum_{i=1}^L w_i(\mathbf{x})} = \frac{\sum_{i=1}^L w_i(\mathbf{x}) (\mathbf{a}_i^T \mathbf{x} + b_i)}{\sum_{i=1}^L w_i(\mathbf{x})} \quad (2.4)$$

donde y es la salida total del sistema y w_i es el nivel de impacto de la regla i . Si se genera w_r utilizando como operador AND el producto, queda que:

$$w_i(\mathbf{x}) = \mu_{A_{i1}}(x_1) \times \mu_{A_{i2}}(x_2) \times \dots \times \mu_{A_{ip}}(x_p) \quad (2.5)$$

Definiendo el nivel de impacto normalizado

$$\bar{w}_i(x) = \frac{w_i(x)}{\sum_{i=1}^L w_i(x)} \quad (2.6)$$

la ecuación 3 puede describirse

$$y = \left(\sum_{i=1}^L \bar{w}_i(x) a_i^T \right) x + \sum_{i=1}^L \bar{w}_i(x) b_i \quad (2.7)$$

$$y = \mathbf{a}_i^T(x) \mathbf{x} + b(x)$$

donde se aprecia que el modelo TS puede expresarse como un modelo lineal con parámetros dependientes de las entradas.

2.2 El Control Predictivo

El Control Predictivo Basado en Modelos (CPBM) es una metodología general para resolver problemas de control en el dominio del tiempo. Se basa en tres aspectos fundamentales (García y otros, 1989):

1. Un modelo, el cual describe al proceso y se usa para predecir la salida del proceso en instantes de tiempo futuros en un *horizonte de predicción* (H_p)
2. Una secuencia de acciones de control futuras, las cuales se calculan sobre un *horizonte de control* (H_c) y minimizan una función objetivo dada (J),
3. Solo la primera acción de control de la secuencia calculada se aplica, el horizonte se mueve hacia el futuro y la optimización se repite.

Debido al método de optimización y al uso explícito de un modelo, el CPBM puede realizar un control óptimo, lidiar con procesos no lineales y manejar eficientemente las restricciones. El CPBM es aplicable a un amplio rango de procesos, incluyendo sistemas multivariables, con tiempos de retardo, de fase no mínima o sistemas inestables. Puede además, hacer un uso eficiente de las referencias futuras si estas son conocidas en el seguimiento de trayectorias, control de procesos en lotes, etc. Finalmente, es una tecnología abierta a las extensiones y nuevas metodologías en el modelado de procesos y la optimización (Camacho y Bordons, 1995).

El modelo predictor es la piedra angular del CPBM y de él depende en gran medida el correcto desenvolvimiento de esta estrategia. El modelo seleccionado debe ser capaz de predecir con exactitud las salidas futuras del proceso, debe ser fácil de implementar, de un

costo efectivo para la simulación y de fácil comprensión. Los sistemas complejos, no lineales y parcialmente conocidos no son favorables a la aplicación del CPBM convencional, toda vez que modelos adecuados de estos procesos no pueden obtenerse usando métodos convencionales. Es por ello que resulta natural la aplicación de modelos difusos como predictores de estos procesos (Abonyi, 2003; Abonyi y otros, 2001; Marsili-Libelli y Giunti, 2002; Zamarreño y González, 1998).

2.2.1 Estrategia del control

Las metodologías de diseño de sistemas de control actuales se basan en la formulación de modelos lineales y no lineales para reflejar el comportamiento dinámico del proceso. La aplicación de un modelo permite conocer con antelación la evolución del proceso en un horizonte de predicción ante cualquier valor de la entrada; dicha evolución estará afectada por la influencia del pasado y del futuro.

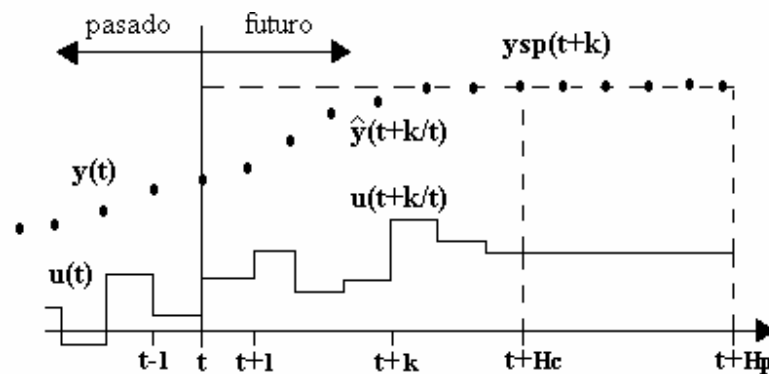


Figura 2.1. Estrategia del control predictivo

La notación usada en la figura anterior es la siguiente:

- t : Denota el índice de tiempo discreto ($t = 0, 1, 2, \dots$).
- $u(t)$: Denota la variable manipulada del proceso.
- $y(t)$: Denota la variable controlada del proceso.
- $y_{sp}(t)$: Denota la trayectoria deseada o «*Set-Point*».
- $u(t+k/t)$: Denota los valores futuros de la entrada de control, postulados en el tiempo t , es decir $\{u(t/t), u(t+1/t), \dots\}$.
- $\hat{y}(t+k/t)$: Denota los valores predichos o futuros de la salida basados en:

- a) Mediciones disponibles en el tiempo t y para diferentes valores de k . Estas mediciones son: $\{y(t), y(t-1), \dots, u(t-1), u(t-2), \dots\}$.
- b) Valores futuros de la entrada: $\{u(t/t), u(t+1/t), \dots\}$.

Con relación a la figura 2.1, el principio del CPBM se caracteriza por la siguiente estrategia (Benites, 2004):

1. A cada momento t , la salida del proceso $y(t+k)$ se pronostica sobre un horizonte de tiempo $k=1, \dots, H_p$. Los valores predichos son indicados por $\hat{y}(t+k/t)$ y el valor H_p se denomina el horizonte de predicción. La predicción se determina por medio de un modelo del proceso; se asume que el modelo está disponible. El pronóstico depende de las entradas y salidas pasadas, pero también del escenario del control futuro: $u(t+k/t)$, con $k=1, \dots, H_c$
2. El vector de control $u(t+k/t)$, con $k=1, \dots, H_c$, se calcula para minimizar una función de costo específica que depende de los errores de control pronosticados: $[y_{sp}(t+k/t) - y(t+k/t)]$, con $k=1, \dots, H_p$
3. Sólo el primer elemento $u(t/t)$ del vector de control óptimo $u(t+k/t)$, con $k=0, \dots, H_c$ se aplica al proceso real. Todos los otros elementos del vector de control no participan. Sin embargo, al siguiente instante de muestreo, todas las secuencias de tiempo son desplazadas; una nueva medición de la salida $y(t+1)$ es obtenida y el procedimiento íntegro se repite. Este procedimiento conduce a una nueva entrada de control $u(t+1/t+1)$, que es generalmente diferente a $u(t+1/t)$ calculado previamente. Este principio se denomina la estrategia de «horizonte recesivo».

La estructura básica de CPBM se muestra en diagrama de bloques siguientes (figura 2.2)

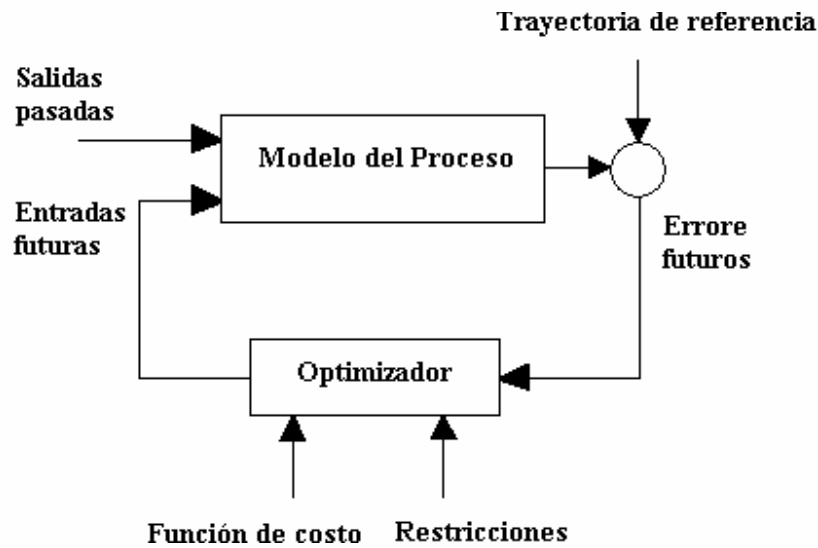


Figura 2.2. Estructura del CPBM

2.3 El control predictivo usando modelos difusos

El CPBM ha sido ampliamente investigado y en el caso lineal sin restricciones, la solución es un problema cuadrático lineal. Cuando la dinámica del proceso es no lineal y hay restricciones, aumenta considerablemente la complejidad del problema, la solución analítica es difícil de encontrar y se prefiere una solución numérica, la cual presenta un alto costo de cómputo generalmente. El algoritmo CPBM que se presenta en este trabajo se basa en modelos difusos no lineales, a partir del cual se obtiene un modelo lineal local en cada instante de muestreo, utilizando las propiedades de los sistemas difusos empleados. Aquí, en lugar de estimar recursivamente un modelo lineal en cada instante de muestreo, un modelo lineal se extrae del modelo difuso. La principal ventaja de esta forma es que retiene las propiedades del CPBM lineal y es fácil de resolver el problema de optimización.

2.3.1 Estructura del regulador

El esquema de control predictivo basado en modelo difuso implementado se muestra en la figura 2.3.

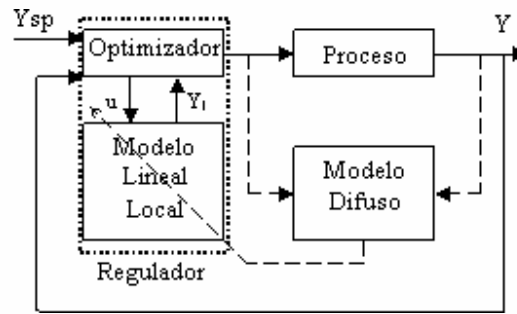


Figura 2.3. Estructura del controlador implementado.

Esta estructura sugiere que la aplicación de los algoritmos de linealización implementados podrían usarse en otros métodos de diseño de controladores lineales (Abonyi, 2001). Aquí, como se menciona anteriormente, se toma el CPBM lineal como estrategia de diseño del regulador

2.3.2 Algoritmo de implementación del controlador predictivo

El Control Predictivo Basado en Modelos (MBPC) es una estrategia de control óptima que utiliza el concepto de horizonte deslizante. Como se vio anteriormente, el MBPC calcula una secuencia de variables manipuladas para optimizar el comportamiento futuro de la planta. Las salidas futuras son determinadas sobre un horizonte de predicción (H_p). Las salidas predichas, $\hat{y}(t+k/t)$ con $k=1, \dots, H_p$ dependen de los valores de la salida y la entrada en el tiempo t y las señales de control futuras $u(t+k/t)$, $k=0, \dots, H_c$ que son los valores que debemos calcular. H_c es el horizonte de control sobre el cual se obtienen los valores de $u(t+k/t)$. El objetivo del control es mantener la salida $y(t+k)$ tan cerca como sea posible de la referencia $y_{sp}(t+k)$. La función de costo utilizada para evaluar la «distancia» entre la referencia y la salida es:

$$J = \sum_{k=1}^{H_p} [y_{sp}(t+k) - y(t+k/t)]^2 + \sum_{k=1}^{H_c} \rho \Delta u(t+k-1/t)^2 \quad (2.8)$$

Una vez calculada la secuencia «óptima», solo $u(t/t)$ se aplica al proceso y en el próximo instante de tiempo, $(t+1)$, se obtiene un nuevo valor de la salida, $y(t+1)$ y se calculan nuevos valores de entradas.

Las salidas futuras predichas están dadas por la ecuación:

$$y(t + k/t) = y_{\text{forzada}}(t + k/t) + y_{\text{libre}}(t + k/t) \quad (2.9)$$

donde $y_{\text{forzada}}(t + k/t)$ solo depende de las entradas futuras y $y_{\text{libre}}(t + k/t)$ depende de las entradas y salidas pasadas. En nuestro caso los valores de y_{libre} están dados por:

$$y_{\text{libre}}(t + k/t) = f(\hat{y}(t + k - 1), \dots, \hat{y}(t + k - m), u(t + k - 1), \dots, u(t + k - n)) \quad (2.10)$$

donde $u(t) = u(t + 1) = \dots = u(t + k - 1) = u(t - 1)$ es equivalente a simular el sistema asumiendo todas las entradas futuras constante e igual a la última entrada aplicada $u(t - 1)$.

La y_{forzada} se obtiene de la siguiente manera:

$$y_{\text{forzada}}(t + k/t) = \sum_{i=0}^{k-1} g_i \Delta u(t + k - i - 1/t) \quad (2.11)$$

donde g_i son los coeficientes de la respuesta al paso de la planta, los cuales se calculan en el punto de operación presente mediante la respuesta al paso del modelo linealizado de la planta. El problema de optimización en forma matricial se puede representar de la siguiente forma:

$$\mathbf{Y} = \mathbf{G}\Delta\mathbf{U} + \mathbf{Y}_{\text{libre}} \quad (2.12)$$

donde

$$\mathbf{Y} = \begin{bmatrix} y(t + 1/t) \\ y(t + 2/t) \\ \vdots \\ y(t + h p/t) \end{bmatrix} \quad (2.13)$$

$$\mathbf{G} = \begin{bmatrix} g_0 & 0 & \dots & 0 \\ g_1 & g_0 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ g_{hc-1} & g_{hc-2} & \dots & 0 \\ \vdots & \vdots & \vdots & \vdots \\ g_{hp-1} & g_{hp-2} & \dots & g_{hp-hc-1} \end{bmatrix} \quad (2.14)$$

$$\Delta\mathbf{U} = \begin{bmatrix} \Delta u(t/t) \\ \Delta u(t + 1/t) \\ \vdots \\ \Delta u(t + hc - 1/t) \end{bmatrix} \quad (2.15)$$

$$\mathbf{Y}_{sp} = \begin{bmatrix} y_{sp}(t) \\ y_{sp}(t+1) \\ \vdots \\ y_{sp}(t+hp) \end{bmatrix} \quad (2.16)$$

$$\mathbf{Y}_{libre} = \begin{bmatrix} y_{libre}(t+1/t) \\ y_{libre}(t+2/t) \\ \vdots \\ y_{libre}(t+hp/t) \end{bmatrix} \quad (2.17)$$

$$y_{libre}(t+k/t) = f(\hat{y}(t+k-1), \dots, \hat{y}(t+k-m), \hat{u}(t+k-1), \dots, \hat{u}(t+k-n))$$

$$\text{con : } \hat{u}(k) = \begin{cases} u(t-1) & \forall k > t-1 \\ u(k) & \text{Los demás valores} \end{cases} \quad (2.18)$$

De lo anteriormente planteado podemos expresar la siguiente función de costo:

$$J = \mathbf{E}^T \mathbf{E} + \rho \Delta \mathbf{U}^T \Delta \mathbf{U} \quad (2.19)$$

$$J = (\mathbf{Y}_{sp} - \mathbf{Y})^T (\mathbf{Y}_{sp} - \mathbf{Y}) + \rho \Delta \mathbf{U}^T \Delta \mathbf{U} \quad (2.20)$$

$$J = (\mathbf{Y}_{sp} - \mathbf{G}\Delta\Delta + \mathbf{Y}_{libre})^T (\mathbf{Y}_{sp} - \mathbf{G}\Delta\Delta + \mathbf{Y}_{libre}) + \rho \Delta \mathbf{U}^T \Delta \mathbf{U}$$

Los valores mínimos de la función de costo J pueden ser calculados buscando los valores

de $\Delta \mathbf{U}$ tal que $\frac{\partial J}{\partial \Delta \mathbf{U}} = 0$

$$\frac{\partial J}{\partial \Delta \mathbf{U}} = 2\mathbf{G}^T (\mathbf{Y}_{libre} - \mathbf{Y}_{sp}) - 2(\mathbf{G}^T \mathbf{G} + \rho \mathbf{I}) \Delta \mathbf{U} = 0 \quad (2.21)$$

entonces los valores óptimos de $\Delta \mathbf{U}$ son

$$\Delta \mathbf{U} = (\mathbf{G}^T \mathbf{G} + \rho \mathbf{I})^{-1} \mathbf{G}^T (\mathbf{Y}_{sp} - \mathbf{Y}_{libre}) \quad (2.22)$$

después de calcular la secuencia de valores de $\Delta \mathbf{U}$, la próxima entrada que se aplica a la planta en el tiempo t es:

$$u(t) = u(t-1) + \Delta u(t) \quad (2.23)$$

donde $\Delta u(t)$ es el primer elemento del vector $\Delta \mathbf{U}$.

2.4 Conclusiones del capítulo

En este capítulo se explicaron las características fundamentales de los modelos difusos Takagi-Sugeno y la técnica de control predictivo. Estas técnicas se combinan al utilizar el modelo difuso como modelo de predicción dentro de la estrategia de CPBM. En este

capítulo se propuso una estructura de control y se analizó, teóricamente, la forma de implementación del controlador predictivo difuso que se utilizará para solucionar el problema de control que se presenta en el próximo capítulo.

CAPÍTULO 3. EL CPBM APLICADO A UN PROCESO DE pH

En este capítulo se muestran los resultados de la aplicación del algoritmo explicado en el capítulo anterior en el cual se combina la técnica de control predictivo con los modelos difusos. El proceso tomado como ejemplo de aplicación es un proceso de neutralización del pH en un tanque de agitación continua (*CSTR - Continuos Stirred Tank Reactor*), el cual se explica en la sección 3.1.

Para llevar a cabo el procedimiento planteado anteriormente en esta tesis, en la sección 3.2 se mostrará el modelo difuso del sistema que será utilizado dentro de la estrategia que desarrollamos en 2.3.2, y cuyos resultados se exponen en la sección 3.4 cuando se lleva a cabo el control del CSTR. Además, en la sección 3.3 se analiza una solución convencional que se usa con el objetivo de comparar su respuesta con la de la estrategia implementada.

3.1 Ejemplo de la Aplicación

El control del pH en un CSTR (*Continuos Stirred Tank Reactor*) es tomado como caso de estudio no lineal «real» para la aplicación del algoritmo propuesto, el cual presenta complejidades debido a las grandes variaciones de la dinámica de este proceso.

3.1.1 El problema de control

El control del pH en un CSTR es un problema bien conocido (McAvoy y otros, 1972; Waller y Toivonen, 2002). En la Figura 3.1 se muestra esquemáticamente el proceso aquí utilizado. El CSTR tiene dos flujos de entradas, uno contiene hidróxido de sodio (NaOH) y otro ácido acético (HAC). El modelo dinámico del pH en el tanque se obtiene usando la aproximación presentada por McAvoy y otros (1972).




Figura.3.1 Esquema del proceso.

Escribiendo el balance de materiales en $[N_a^+]$ y acetato total $[HAC + AC^-]$ y asumiendo que las relaciones de equilibrio ácido-base y la electroneutralidad se cumplen en el mismo, tenemos que:

Balance total de acetato:

$$F_{HAC}[HAC]_{be} - (F_{HAC} - F_{NaOH})[HAC + Ac^-] = V \frac{d[HAC + Ac^-]}{dt} \quad (3.1)$$

Balance del ión sodio:

$$F_{NaOH}[NaOH]_{be} - (F_{HAC} + F_{NaOH})[Na^+] = V \frac{d[Na^+]}{dt} \quad (3.2)$$

Equilibrio de HAC:

$$\frac{[Ac^-][H^+]}{[HAC]} = K_a \quad (3.3)$$

Equilibrio del agua:

$$[H^+][OH^-] = K_w \quad (3.4)$$

Electroneutralidad:

$$[Na^+] + [H^+] = [OH^-] + [Ac^-] \quad (3.5)$$

Las ecuaciones 3.1 a la 3.5 constituyen un conjunto de ecuaciones independientes que describe completamente el comportamiento dinámico del CSTR.

El pH puede ser calculado a partir de estas ecuaciones de la siguiente manera:

$$[H^+]^3 + [H^+]^2(K_a + [Na^+]) + [H^+]([Na^+]K_a - [HAC + Ac^-]K_a - K_w) - K_wK_a = 0 \quad (3.6)$$

$$pH = -\lg[H^+] \quad (3.7)$$

Los parámetros usados en la simulación son los mismos que en Bhat y McAvoy (1990) y se muestran en la siguiente tabla.

Tabla 1. Parámetros usados en la simulación

Parámetros	Descripción	Valores Nominales
V	Volumen del tanque	1000 l
F_{HAC}	Flujo de ácido acético	81 l/min.
F_{NaOH}	Rango estable del flujo de NaOH	515 l/min.
$[\text{NaOH}]_{\text{be}}$	Concentración de NaOH en la entrada	0.05 mol/l
$[\text{HAC}]_{\text{be}}$	Concentración de HAC en la entrada	0.32 mol/l
$[\text{Na}^+]$	Concentración inicial de Na en el CSTR	0.0432 mol/l
$[\text{HAC} + \text{Ac}^-]$	Concentración inicial de acetato en el CSTR	0.0432 mol/l
Ka	Constante de equilibrio del ácido	$1.75 \cdot 10^{-5}$
Kw	Constante de equilibrio del agua	10^{-4}

3.2 Modelo difuso del proceso

El proceso de pH utilizado puede ser correctamente identificado como un sistema de primer orden (Abonyi y otros, 2001), por lo que la estructura seleccionada para las reglas es:

$$\begin{aligned}
 &\text{Ri: If pH}(k-1) \text{ is } A_{i1} \text{ and } F_{\text{NaOH}}(k-1) \text{ is } A_{i2} \\
 &\quad \text{Then} \\
 &\quad \text{pH}_i(k) = a_{i1}\text{pH}(k-1) + a_{i2}F_{\text{NaOH}}(k-1) + b_i
 \end{aligned}
 \tag{3.8}$$

La base de datos de entrenamiento se obtiene mediante una señal de entrada F_{NaOH} uniformemente distribuida en el rango de 515-525 l/min. y un período de muestreo $\Delta t = 0.2$ min, de acuerdo a Abonyi y otros (2001). El modelo se obtiene utilizando el método propuesto por Martínez y Herrera (2003).

El modelo obtenido fue validado con un conjunto de datos distinto al de entrenamiento, los resultados se muestran en Figura 3.2. En la Figura 3.3 se observan las curvas de tiritación ‘real’ y la del modelo.




Figura.3.2 Respuesta del modelo difuso ante datos de validación (en línea continua y azul el proceso, en línea discontinua y verde el modelo)

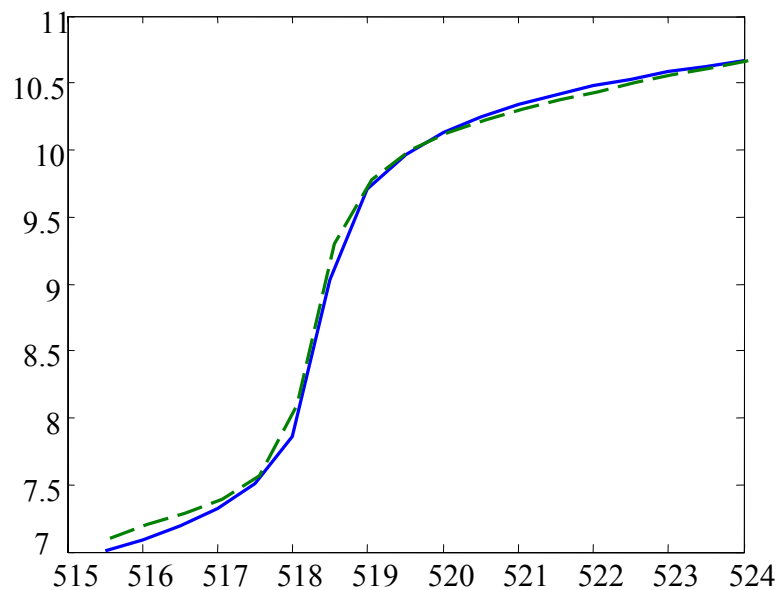


Figura.3.3 Respuesta en estado estable (curva de titulación). En línea continua y azul el proceso y en línea discontinua y verde el modelo.

Además de la exactitud de aproximación, el modelo difuso TS proporciona información de la dinámica no lineal del sistema como un conjunto de modelos lineales válidos localmente. La región de validez de estos modelos está definida por las funciones de pertenencia del antecedente. Por ejemplo, podría observarse la variación de los parámetros de los modelos locales (en este caso, ganancia y constante de tiempo) convirtiendo los modelos de los

consecuentes en modelos continuos (Babuska, 1998). Para el ejemplo que se analiza, los resultados de ganancias K y constantes de tiempo τ para los tres primeros modelos de los consecuentes son:

$$\begin{aligned} K &= \{0.1590, 0.0677, 0.1064\} \\ \tau &= \{0.2933, 1.4521, 0.1102\} \end{aligned} \tag{3.9}$$

De las respuestas al paso estos tres modelos individuales que se muestran en la Figura 3.4, se puede tener una idea del comportamiento del modelo en cada región en particular.

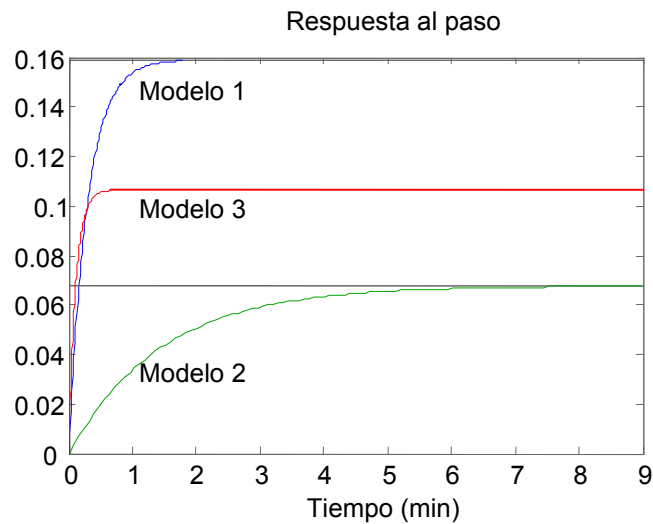


Figura.3.4 Respuesta al paso de los tres primeros modelos de consecuente.

3.3 Control convencional

Para comparar el desempeño del algoritmo de control utilizado se utiliza el criterio Error Integral Absoluto (*IAE - Integral Absolute Error*), el cual está dado por:

$$IAE = \sum_{k=1}^{N_t} |e(k)| \tag{3.10}$$

donde $e(k) = y_{sp}(k) - y(k)$ es el error en el tiempo de muestreo k , $N_t = t_{max} / \Delta t$ es el número de iteraciones y $\Delta t = 0.2$ min. es el período de muestreo.

Entre las posibles soluciones convencionales que servirían para la comparación con el algoritmo de control propuesto, se selecciona un controlador PI discreto formulado por Aström y Wittenmark (1990):

$$u(k) = u(k-1) + q_0 \cdot e(k) + q_1 \cdot e(k-1) \tag{3.11}$$

$$q_0 = K \left(1 + \frac{\Delta t}{T_i} \right), \quad q_1 = -K \tag{3.12}$$

Los valores de los parámetros del PI fueron determinados mediante optimización por Abonyi y otros (2001) bajo condiciones libres de ruidos. Estos autores obtuvieron los siguiente ajustes:

$$K = 3.715 \quad T_i = 0.7193 \tag{3.13}$$

3.4 Controlador CPBM difuso

El modelo difuso obtenido se utiliza en la arquitectura de control explicada en la sección 2.3. Inicialmente, se analiza el efecto que sobre el comportamiento del controlador propuesto tienen los valores de los parámetros de sintonía: horizonte de predicción (Hp); horizonte de control (Hc) y el peso (ρ).

En la tabla 3.1 se observan los valores del índice de comportamiento IAE (*Integral Absolute Error*) para distintos valores de Hp, Hc y ρ en condiciones libres de ruidos y con un cambio en el valor deseado del pH de 8 a 8.5. Bajo estas mismas condiciones, el controlador PI presenta un índice IAE = 1.2729.

Tabla 3.1. Efecto de los valores de los parámetros de sintonía (Hp, Hc y ρ) en el comportamiento del controlador propuesto.

Hc	1				3				5			
ρ	0.05	0.1	0.5	1	0.05	0.1	0.5	1	0.05	0.1	0.5	1
Hp												
2	2.02	3.05	4.03	4.17								
3	1.49	<u>0.98</u>	3.06	3.63	1.19	<u>0.98</u>	3.07	3.63				
5	26.1	15.6	1.45	1.99	13.4	4.02	1.45	2.06	14.8	5.83	1.44	2.06
10	31.1	29.9	16.7	2.26	18.4	16.2	2.52	2.07	15.1	11.4	1.97	2.03

Se puede observar que las mejores prestaciones con un ajuste más sencillo se alcanzan con un horizonte de predicción de tres pasos, un horizonte de control de uno y con un peso de 0.1. En la Figura 3.5 se muestra la respuesta para esta sintonía.

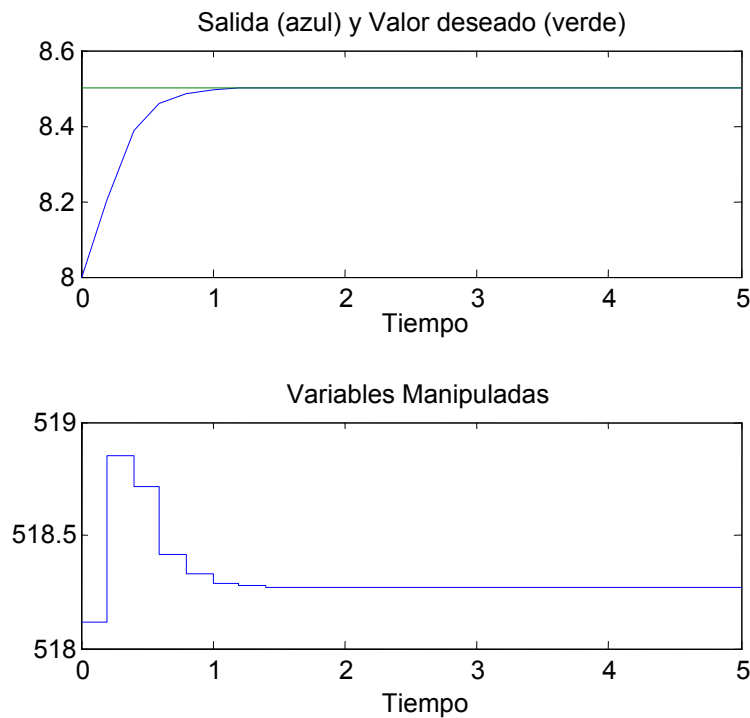


Figura 3.5 Respuesta para un valor deseado del pH de 8.5 con $H_p = 3$, $H_c = 1$, $\rho = 0.1$.

En la tabla 3.2 se tabulan los valores del índice IAE para distintos valores de H_p , H_c y ρ donde un ruido fue añadido a la salida del sistema. Se mantiene un cambio en el valor deseado del pH de 8 a 8.5. Bajo estas mismas condiciones, el controlador PI presenta un índice IAE = 13.3858.

Tabla 3.2. Efecto de los valores de los parámetros de sintonía (H_p , H_c y ρ) sobre el comportamiento del controlador propuesto ante un 5% de error

Hc	1				3				5			
ρ	0.05	0.1	0.5	1	0.05	0.1	0.5	1	0.05	0.1	0.5	1
Hp												
2	5.38	5.37	4.08	4.51								
3	8.62	4.27	3.73	4.08	6.62	4.61	3.18	3.70				
5	23.9	15.1	4.28	3.79	16.8	10.1	5.49	3.15	15.1	9.30	3.89	3.70
10	31.1	30.5	14.7	7.19	19.2	17.6	7.52	6.64	15.4	15.4	7.39	5.16

Se aprecia que el mejor desempeño se alcanza para valores mayores de los horizontes. En este caso se alcanzan mejores prestaciones con un horizonte de predicción de cinco pasos, un horizonte de control de tres y con un peso de uno.

En resumen, con el controlador predictivo difuso implementado se obtienen resultados satisfactorios, fundamentalmente en el caso de la presencia de ruidos donde la diferencia entre los comportamientos es más marcada.

A continuación, en la Figura 3.6 se muestran los resultados del controlador predictivo difuso con la sintonía seleccionada ($H_p=3$, $H_c=1$, $\rho=0.1$) comparados con el PI óptimo.

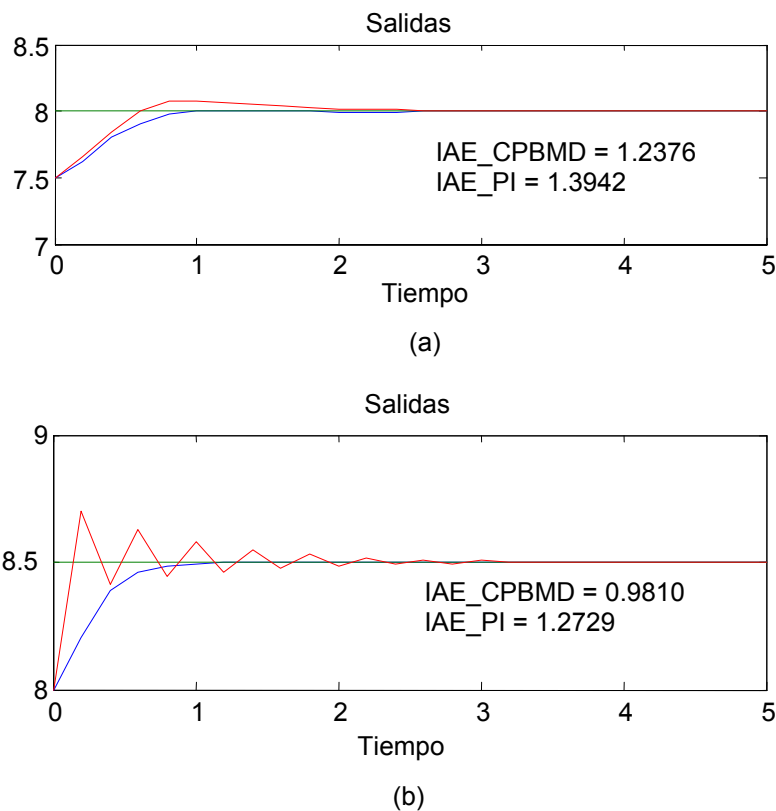


Figura 3.6 Respuesta ante distintos valores deseados del controlador predictivo difuso propuesto con $H_p=3$, $H_c=1$, $\rho=0.1$ (en azul) y del PI óptimo (en rojo)

3.5 Conclusiones del capítulo

En este capítulo se plantearon

CONCLUSIONES

En el desarrollo del presente trabajo se ha mostrado la factibilidad de aplicar una estrategia de control predictivo basada en modelos difusos en el control de un proceso no lineal. La capacidad de aproximación y la simplicidad de estos modelos, unido al buen funcionamiento del control predictivo motivaron el diseño de esta estrategia. El esquema de control propuesto fue aplicado satisfactoriamente, a nivel de simulación, en un proceso de naturaleza no lineal: el proceso de neutralización del pH que ocurre en un tanque de agitación continua (*CSTR - Continuous Stirred Tank Reactor*).

Haciendo un análisis del trabajo realizado, se arriba a las siguientes conclusiones:

- El control predictivo no lineal basado en modelos difusos es, en los últimos años, un área de estudio muy atractiva y activa. Es de suponer que en el futuro se logren nuevos desarrollos teóricos que permitan esquemas de control con mejores especificaciones de estabilidad y desempeño, así como de métodos de sintonía más sencillos para los controladores.
- Se comprueba que es factible utilizar un modelo difuso dinámico TS en la identificación de un proceso de pH. Este modelo presenta una estructura matemática simple, lo cual facilita el análisis y desarrollo del sistema de control propuesto para el proceso en cuestión
- El modelo difuso obtenido pueden utilizarse no solo como predictor dentro de la estrategia de control predictivo (u otra técnica de control basada en modelos), sino que proporciona información del proceso.
- La técnica de modelación difusa es una alternativa eficiente para el problema del control predictivo no lineal. Específicamente en la estrategia propuesta, la eficiencia está dada por la utilización de los modelos lineales locales obtenidos del modelo difuso no lineal del sistema dentro de la formulación del algoritmo, el cual es bastante simple desde el

Conclusiones

punto de vista del esfuerzo computacional y de la implementación. Esto conlleva a que la sencillez sea comparable con el control predictivo basado en modelos lineales pues permite usar un algoritmo de optimización lineal.

- El esquema de control predictivo basado en modelo difuso implementado tiene un comportamiento positivo en cuanto al seguimiento de las referencias establecidas al compararlo con el comportamiento del mismo sistema ante un controlador convencional. Los resultados obtenidos son comparables a otros trabajos similares.

RECOMENDACIONES

Se recomienda que en próximos trabajos encaminados a lograr una mayor profundización en el tema tratado en la presente tesis, se estudie lo referente a la capacidad de manipulación de las restricciones de estos algoritmos porque es un requisito importante a tener en cuenta a la hora de ir a la práctica. Además, queda pendiente aplicar estos algoritmos a casos reales, ya sean a nivel de laboratorio o en empresas de la producción, lo cual validaría y enriquecería este trabajo.

REFERENCIAS BIBLIOGRÁFICAS

- Abonyi, J. (2003) *Fuzzy Model Identification for Control*, Birkhauser Boston.
- Abonyi, J., Á. Bódizs, L. Nagy. y F. Szeifert. (2000a) *Hybrid Fuzzy Convolution Model and its application in Predictive Control*, Department of Chemical Engineering Cybernetics, University of Veszprém
- Abonyi, J., R. Babuska, H.B. Verbruggen y F. Szeifert (2000b). “Incorporating Prior Knowledge in Fuzzy Model Identification”, *International Journal of Systems Science*, **31** (5): 657-667.
- Abonyi, J., L. Nagy y F. Szeifert. (2001). “Fuzzy Model Based Predictive Control by Instantaneous Linearisation”, *Fuzzy Sets and Systems*, **120**(1): 109-122.
- Altamiranda, E. y E. Colina. (2004). “Control Predictivo Generalizado para sistemas no lineales utilizando una neurona difusa recurrente”, *ISSN 0122-9966.*, 3: 1-85
- Aström K. y B. Wittenmark. (1990). *Computer Controlled Systems: Theory and Design*. Prentice-Hall International Inc., London.
- Babuska, R. (1998) *Fuzzy modeling for control*, Kluwer Academic Publishers, Boston
- Babuska, R., H.B. Verbruggen. y H.J.L. van Can. (1996). *Fuzzy modeling of enzymatic Penicillin-G conversion*. In: Preprints 13th IFAC World Congress, San Francisco, USA, :479-484.
- Baena, J., M. Gallo. y M Vallejo. (2001). *Desarrollo de un controlador difuso para sistemas embebido utilizando lenguaje C*. Noviembre del 2001.
- Bello, R. (2004). Conferencia #12: Sistemas de inferencia borrosos. Disponible en http://www.mfc.uclv.edu.cu/ia/Inteligencia_Artificial/Conferencia/Conferencia_No_12_Sistemas_de_inferencia_borrosa.htm, accedido el 10/4/2004.
- Benites, R. (2004). Control Predictivo Basado en Modelos (MBPC), disponible en http://fiec.uni.edu.pe/wdoc/200004A/cont_pred_1.html, accedido el 10/4/2004

Referencias bibliográficas

- Bhat, N. y T. J. McAvoy. (1990). "Use of Neural Nets for Dynamic modeling and control of chemical process systems", *Computers chem. Eng.* 14(4/5): 573-583.
- Camacho, E., C. Bordons (1995). *Model predictive control in the process industry*, Springer Verlag London Limited, London, Great Britain.
- Clarke, D., C. Mohtadi y P. Tuffs (1987) Generalized predictive control - Part1: The basic algorithm, Part 2: Extension and interpretations, *Automatica* **23**(2), 137-160
- Cristea, S., A. Rueda. y C. de Prada. (2000). *Control Predictivo no Lineal aplicado a Columnas de destilación de Etanol*. Centro de Tecnología Azucarera. Universidad de Valladolid, España.
- De Prada, C. (1997) "Fundamentos de Control Predictivo de Procesos", *Ingeniería Química*
- De Prada, C., T. Álvarez, S. Cristea. y J. Zamarreño. (1998). Introducción al Control Predictivo Basado en Modelos, disponible en http://www.isa.cie.uva.es/Control_Predictivo/cpbm.html, accedido el 10/4/2004.
- Driankov, D., H Helerndoorn y M. Reinfrank (1993). *An introduction to Fuzzy Control*. Springer Verlag, Berlin, Germany.
- Espinosa, J.J. y J. Vandewalle. (1999) Nonlinear Predictive Control using Fuzzy Model and Semidefinite Programming, *International Conference of the North American Fuzzy Information Processing Society*.
- Gamero, I. (1999). Control Predictivo aplicado a un Microrobot Autónomo, disponible en <http://eia.udg.es/~gamero/index0e.html>, accedido el 10/4/2004.
- García, C., D. Prett and M. Morari (1989) Model predictive control: Theory and practice survey, *Automática* **25**: 35-348.
- González, A.S., J. Tor Arne, J. Zamarreño. (2000). *Nonlinear Multiple Model Predictive Control in a fed-batch Reactor*. Universidad de Valladolid, Dpto. Ingeniería de sistemas y Automática, Facultad de Ciencias, España.
- Huang, Y.L., H.H. Lou, J.P. Gong, y T.F. Edgar. (2000). "Fuzzy Model Predictive Control", *IEEE Transactions on fuzzy systems.*, 8 (6): 665-679.
- Kaymak, U. (1994). *Application of fuzzy methodologies to a washing process*. Chartered designer thesis, Delft University of Technology, Control Lab., Faculty of El. Eng., Delft.

Referencias bibliográficas

- Lussón, A., O.E. Agamennoni y J.L. Figueroa (2003). Aplicación de MPC no lineal en el control de un reactor CSTR. En: *Simposio de Ingeniería Eléctrica SIE'2003*, Santa Clara.
- Maciejowski, J. M. (2000). *Predictive Control with Constraints*, Prentice Hall, Inglaterra
- Marsili-Libelli S., L. Giunti (2002). Fuzzy predictive control for nitrogen removal in biological wastewater treatment. *Water Sci. Tech.* **45**(4-5):37 - 44.
- Martínez, B.L., F. Herrera (2003). “Estrategia para la Construcción de Modelos Difusos utilizando Clustering y Transformación Ortogonal”. En: *Taller Internacional sobre Control por Computadora de Sistemas Industriales: Teoría y Aplicación, X Convención Internacional INFORMATICA 2003*. Ciudad de La Habana
- McAvoy, T.J., E. Hsu y S. Lowenthal. (1972). “Dynamics of pH controlled stirred tank reactor”, *Ind. Eng. Chem. Process. Des. Develop.* **11** (1): 68-70.
- Piñón, S., M. Peña y B. Kuchen. (2002) Control Predictivo con Restricciones para el Clima de un Invernáculo. *Revista DYNA*, No 135.
- Richalet, J. (1993) Industrial applications of model based predictive control. *Automatica* **29** (8), 1251-1274.
- Salehfar, H., N. Bengiamin. y J. Huang. (2000). *A Systematic Approach to Linguistic Fuzzy Modeling Based on Input-Output Data*. Department of Electrical Engineering, University of North Dakota, Grand Forks, U.S.A.
- Sánchez, E.N., M. Moheno, D.A. Suárez. y A. Quintero. (2002). *Arranque de Caldera de una Planta Termo-Eléctrica usando Modelado Difuso Takagi-Sugeno*. CINVESTAV. Unidad Guadalajara, México.
- Setnes, M., R. Babuska, H.B. Verbruggen, M.D. Sánchez y H.F.P. van den Boogaard (1997). “Fuzzy modeling and similarity analysis applied to ecological data”, *In Proceedings FUZZ- IEEE.*, Barcelona, Spain, 415-420.
- Sugeno, M. Y K. Tanaka. (1991). “Successive identification of a fuzzy model and its application to prediction of a complex system”, *Fuzzy Sets and Systems*, **42**: 315-334.
- Takagi, T. y M. Sugeno. (1985). “Fuzzy identification of systems and its applications to modelling and control”, *IEEE Transaction. On Systems, Man, and Cybern.*, **15** (1): 116-132.

Referencias bibliográficas

- Waller, J.B y H.T. Toivonen. (2002). *A Neuro-Fuzzy Model Predictive Controller applied to a pH-Neutralization Process*. Department of Chemical Engineering, Abo Akademi University, Finland.
- Zamarreño, J.M. y A.I. González. (1998). Revisión del estado del arte en Control Predictivo No-lineal y procesos batch. En: *Workshop Ariadna*. Barcelona
- Zhao, J., V. Wertz. y R. Gorez. (1994). *A fuzzy clustering method for the identification of fuzzy models for dynamical systems*. In 9th IEEE International Symposium on Intelligent Control, Columbus, Ohio, USA