

# Fuzzy Predictive Control Strategy for a Distributed Solar Collector Plant

C. Ponce, D. Sáez, *Senior Member IEEE*, A. Núñez, *Member IEEE*

**Abstract**— This paper presents the design and evaluation of a fuzzy predictive controller for a distributed solar collector (DSC) plant. A Takagi and Sugeno (T&S) fuzzy model of the DSC plant is identified and used for characterizing and predicting the nonlinear behavior of the system. The proposed fuzzy predictive control strategy is compared with conventional control techniques. Simulation results indicate that the fuzzy predictive controller captures adequately the nonlinearities of the process, which in turn provides a promising control approach to improve the performance of the DSC plant.

**Keywords**— Solar power plant, Distributed Solar Collector, Predictive control, Fuzzy modeling.

## I. INTRODUCCIÓN

EL SIGNIFICATIVO aumento de la demanda energética en los últimos años, además de la creciente preocupación por la protección del medio ambiente y del cambio climático global, hacen necesario el estudio de nuevas tecnologías de generación de energía eléctrica, que sean menos contaminantes, tales como las energías renovables. Las principales energías renovables en las que se trabaja actualmente a nivel global son: energía eólica, energía hidráulica, energía oceánica o mareomotriz, energía geotérmica, biomasa y energía solar [1]. Esta última, es recolectada de forma directa a alta temperatura en centrales solares, o mediante paneles térmicos domésticos. Cabe destacar que cada año la radiación solar aporta a la Tierra la energía equivalente a varios miles de veces la cantidad de energía que consume la humanidad [2], por lo que el desarrollo de sistemas eficientes de control que aprovechen esta fuente de energía es crucial.

Las plantas solares de generación de energía, se caracterizan porque su fuente de energía primaria, la radiación solar, no puede ser manipulada. Además, debido a diversos factores, su predicción se ve influenciada por diversos factores tales como: la hora del día, la nubosidad, la época del año, la transparencia de la atmósfera y la humedad del aire. Por ello, es que en este tipo de procesos, es fundamental tener un sistema de control eficiente y eficaz que aproveche al máximo el recurso disponible. Este trabajo se enfoca en el control de una planta de colectores cilindro-parabólicos o colectores solares distribuidos (DSC: Distributed Solar Collectors), los que se construyen con espejos comunes y tienen un foco lineal y seguimiento solar en

un solo eje. Poseen un tubo ubicado en el foco, que contiene un fluido que se calienta con la radiación recibida (HTF: Heat Transfer Fluid), y que generalmente se utiliza para generar vapor sobrecalentado que alimenta una turbina de vapor. Los sistemas de colectores solares distribuidos, corresponden a una tecnología solar térmica capaz de producir electricidad comercialmente [3].

El objetivo de un sistema de control para una planta de colectores solares distribuidos, es mantener la temperatura de salida del fluido HTF en una referencia adecuada para la producción del vapor sobrecalentado, a pesar de la existencia de las perturbaciones, tales como los cambios en la radiación solar producidos por la presencia de nubes, la reflectividad de los espejos y la temperatura de entrada del fluido. Esto se realiza manipulando el flujo de ese fluido que circula por los colectores, generando las variaciones necesarias, y considerando la dinámica del proceso [3]. Para lograr este objetivo, se han desarrollado diferentes estrategias de control para plantas solares. En [4] desarrollan una estrategia para controlar la temperatura de colectores solares que usan sal fundida como fluido de transferencia de calor (HTF). Por medio de un esquema de control adaptivo híbrido, basado en un filtro Kalman y un controlador predictivo de múltiples tasas de muestreo, se logra controlar efectivamente la temperatura del HTF. En [5] proponen un esquema de control no lineal adaptivo indirecto, utilizando la teoría de regulación de la salida, cuyo principal objetivo es derivar una ley de control tal que el sistema de lazo cerrado sea estable y el error de seguimiento sea cero. Para ello, modelan la ecuación de regulación por medio de redes neuronales recurrentes. En [6] describen un controlador adaptivo basado en múltiples modelos para una planta DSC. En esta propuesta se diseña un controlador predictivo para cada modelo y se conmuta entre controladores dependiendo del punto de operación de la planta solar. En [7] se presenta un método de realimentación linealizada para el control de una planta solar, en donde se obtiene una forma lineal para la dinámica del sistema de lazo cerrado, lo que permite aplicar cualquier método de control lineal.

Una estrategia de control avanzado muy usada en la actualidad es la basada en lógica difusa. El control difuso proporciona una base conceptual para problemas prácticos donde las variables de procesos están representadas como variables lingüísticas, que deben ser procesadas usando una serie de reglas difusas [8], [9]. En cuanto a la aplicación de estrategias de control difuso para plantas solares, en [10] se muestra el diseño de un controlador considerando como sus entradas el error de seguimiento y su incremento y la acción de control está dada por la variación adecuada en la señal de control. En [11] desarrollan un controlador PI difuso, donde

C. Ponce, Electrical Engineering Department, Universidad de Chile, Santiago, Chile, cponce@userena.cl

D. Sáez, Electrical Engineering Department, Universidad de Chile, Santiago, Chile, dsaez@ing.uchile.cl

Se agradece al proyecto FONDECYT 1110047 y Solar Energy Research Center (SERC) CONICYT: FBO16, CONICYT/FONDAP/15110019.

A. Núñez, Section of Railway Engineering, Delft University of Technology, Delft, The Netherlands, a.a.nunezvicencio@tudelft.nl

todos sus parámetros son actualizados en línea, como una función de las condiciones de operación de la planta controlada, logrando así un desempeño superior al de controladores PI de parámetros fijos. Gordillo *et al.* [12], desarrollan un controlador difuso para una planta solar, cuyos parámetros son sintonizados utilizando algoritmos genéticos. Por otro lado, en Tang *et al.* [13] diseñan un controlador PID difuso cuyas ganancias proporcional, integral y derivativa son funciones no lineales de las señales de entrada. Los parámetros del controlador son obtenidos mediante una optimización multi-objetivo utilizando algoritmos genéticos. Así mismo, en Luk *et al.* [14], utilizan algoritmos genéticos para optimizar el número de reglas de un controlador difuso diseñado para una planta solar DSC. Cardoso *et al.* [15], [16], presentan dos sistemas de control supervisor difuso para plantas solares. En el primer caso se desarrolla una estrategia de conmutación a nivel supervisor, implementada por medio de un modelo de Takagi & Sugeno (T&S) para un controlador PID. En el segundo caso, se modelan además, en forma difusa las perturbaciones accesibles del sistema. En Cirre *et al.* [17] se describe el diseño e implementación de una estrategia de control jerarquizado para una planta de colectores solares. En el nivel supervisor se calcula la temperatura de referencia del fluido HTF de los colectores solares, teniendo en cuenta restricciones de seguridad, condiciones de entrada, además de minimizar los costos de producción.

Dentro de las metodologías de control estudiadas para plantas solares, se encuentran los controladores predictivos basados en modelos (MPC), los que han presentado buenos resultados debido su gran flexibilidad para caracterizar los objetivos del sistema de control y sus restricciones. Camacho *et al.* [3] y Rubio *et al.* [9] desarrollan estrategias MPC, con aplicaciones a plantas de colectores solares distribuidos. En este caso se aplica un modelo CARIMA (Controller Auto-Regressive Integrated Moving Average) para modelar las perturbaciones aleatorias del sistema. Flores *et al.* [18] presentan un controlador predictivo basado en modelos (MPC) con optimización difusa, para una planta solar. El controlador propuesto se basa en una caracterización difusa de los objetivos y de las restricciones, dentro de un esquema de optimización difusa que permite satisfacer multi-objetivos.

En los últimos años se ha desarrollado con fuerza el MPC difuso basado en modelos de T&S para sistemas no lineales complejos. Se ha demostrado que los modelos de T&S pueden aproximar con buena precisión, cualquier sistema no lineal. La linealidad local de los modelos de T&S simplifica de gran manera el análisis de estabilidad y diseño del controlador para sistema no lineales complejos [19].

Aunque en la literatura existen muchas estrategias de control de plantas solares, no se ha encontrado el desarrollo de control predictivo difuso, que utilice un modelo de T&S para describir la planta solar. Este trabajo presenta el diseño y evaluación de una estrategia MPC difusa para una planta de colectores solares considerando una modelación difusa de T&S. Para poder comparar la estrategia del control predictivo difuso, se diseña un control predictivo basado en un modelo ARX (Auto-Regressive model with eXogenous variable) para la planta solar. También se comparan los resultados con un controlador

PI clásico de la planta, dado en Camacho *et al.* [3].

La estructura de este trabajo incluye en la sección II una descripción de la planta solar considerada y el simulador con el que se desarrolla este trabajo. En la sección III se describe el método de identificación difusa utilizado. En la sección IV se muestra la aplicación realizada a la planta solar. En la sección V se presentan los aspectos prácticos para la implementación del controlador MPC. Finalmente, se presentan las conclusiones.

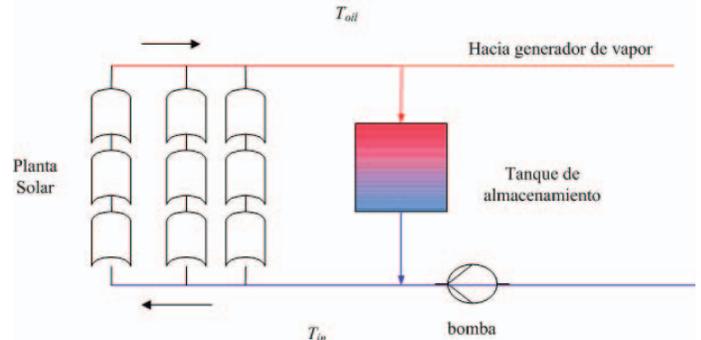


Figura 1. Esquema planta de colectores solares distribuidos Acurex.

## II. SIMULADOR DE PLANTA DE COLECTORES SOLARES DISTRIBUIDOS

### A. Descripción de la planta DSC

El sistema considerado para el diseño y evaluación del control predictivo difuso, es la planta colectores solares distribuidos Acurex, ubicada en Almería, España. Esta planta utiliza como fluido (HTF) aceite y dada su característica dinámica no lineal, ha sido usada para muchas aplicaciones de algoritmos de control modernos [3].

El campo consiste de 480 colectores solares distribuidos, arreglados en 20 filas, los cuales forman 10 lazos paralelos. Cada lazo tiene un largo de 172m y la superficie total de apertura es de 2672m<sup>2</sup>. Una bomba saca el aceite frío del estanque de almacenamiento, desde su parte inferior y lo lleva a los colectores solares. Éste, a medida que circula por los colectores, se calienta y es inyectado nuevamente al estanque, en su parte superior, donde se ubica el aceite caliente. Esto provoca que la temperatura del aceite suba sobre 110°C. La planta está habilitada para entregar un peak de potencia térmica de 1.2MW. Un esquema de esta planta se aprecia en la Fig. 1, donde  $T_{oil}$  corresponde a la temperatura de salida del aceite del campo de colectores y  $T_{in}$  corresponde a la temperatura de entrada del aceite al campo de colectores. El objetivo de control en este caso es mantener el valor  $T_{oil}$ , en un valor determinado por la temperatura de referencia  $T_{oilr}$ .

### B. Simulador de la planta DSC.

Para probar las características del controlador predictivo difuso, se utilizó el simulador de la planta de colectores solares distribuidos desarrollado en la Universidad de Sevilla para la planta solar Acurex [20]. La planta solar se representa por medio de un conjunto de ecuaciones no lineales de parámetros distribuidos, obtenidos por medio de un balance de masa y energía, que representan la dinámica del proceso. Bajo ciertas condiciones [20], la temperatura en el campo está dada por:

$$\rho_m c_m A_m \frac{\partial T_m}{\partial t} = I \eta_o D - h_L G (T_m - T_a) - L h_T (T_m - T_f) \quad (1)$$

$$\rho_f c_f A_f \frac{\partial T_f}{\partial t} + \rho_f c_f \dot{V} \frac{\partial T_f}{\partial x} = L h_T (T_m - T_f)$$

donde los subíndices  $m$  y  $f$  corresponden al metal y al fluido, respectivamente. Además  $t$  es tiempo,  $x$  posición,  $\rho$  densidad del aceite,  $c$  calor específico del aceite,  $A$  sección transversal de la tubería,  $T$  temperatura de salida del aceite,  $I$  radiación solar,  $\eta_o$  eficiencia óptica,  $D$  ancho del espejo,  $h_L$  coeficiente total de pérdidas térmicas,  $G$  diámetro exterior de la tubería,  $T_a$  temperatura ambiente,  $L$  diámetro interno de la tubería,  $h_T$  coeficiente de transferencia fluido-metal,  $\dot{V}$  razón de flujo volumétrico del aceite. La Fig. 2, muestra un esquema del simulador. El controlador prealimentado tiene como objetivo disminuir el efecto de las perturbaciones medibles, tales como las variaciones de la radiación solar ( $I_{rr}$ ) y la temperatura de entrada del aceite al campo de colectores ( $T_{in}$ ). Además,  $u_{oil}$  es el flujo de aceite de los colectores, cuya razón de flujo volumétrico sería el término  $\dot{V}$  de la ecuación (1), además de ser la variable manipulada. La variable controlada es la temperatura de aceite  $T_{oil}$  que corresponde a  $T_f$  en el último segmento del tubo que contiene el fluido.

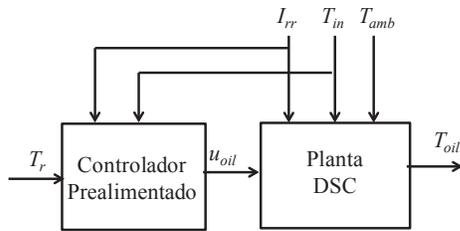


Figura 2. Simulador de la planta solar con bloque de pre-alimentación.

### III. DISEÑO DE UN CONTROLADOR PREDICTIVO DIFUSO

Todas las plantas de generación eléctrica son procesos multivariables que deben ser controlados, y una de las estrategias que han sido estudiadas y se siguen desarrollando es MPC. Este interés se basa en el hecho de que los procesos actuales necesitan ser operados bajo especificaciones de funcionamiento cada vez más estrictas y al mismo tiempo cada vez se necesita satisfacer más restricciones, por ejemplo de tipo ambiental y consideraciones de seguridad [21].

El MPC se refiere a una clase de algoritmos de control que se basan principalmente en tres conceptos: 1) el uso de un modelo de predicción, 2) optimización de una función objetivo, y 3) el principio de horizonte deslizante, en donde en cada instante de muestreo se calcula una secuencia de control pero solo se aplica la primera componente  $u(k)$  [22] (ver Fig. 3). En este trabajo se utiliza un modelo difuso Takagi & Sugeno (T&S) de la planta solar para las predicciones, y la función objetivo considera el error de seguimiento y energía de control. A continuación se explica el procedimiento de identificación difusa para la obtención del modelo, y luego el diseño del controlador MPC difuso propuesto.

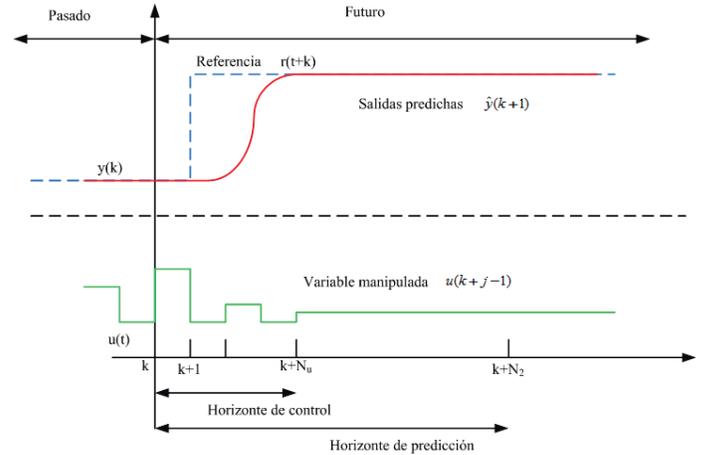


Figura 3. Horizonte deslizante MPC.

#### A. Identificación difusa

La identificación de sistemas no lineales se puede realizar exitosamente por medio de modelos difusos. En este caso se realiza la identificación, ocupando modelos difusos de T&S, que están basados en reglas con premisas difusas, y las consecuencias son modelos lineales para diferentes puntos de operación [23]. La descomposición del sistema no lineal en conjuntos de modelos lineales locales, se realiza por medio del clustering difuso. El diagrama de la Fig. 4 muestra las etapas que se realizan para la identificación de un modelo difuso de T&S.

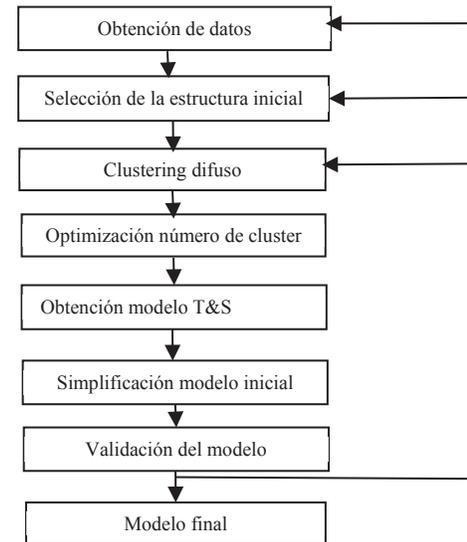


Figura 4. Procedimiento de identificación difusa.

Al inicio de la identificación, se obtienen los datos y se dividen en tres conjuntos: entrenamiento, validación y test. Utilizando el primer conjunto se escoge una estructura inicial del modelo difuso de T&S que tiene la forma [23]:

$$y(k) = f_{T\&S}(y(k-1), \dots, y(k-n_a), u(k-n_d-1), \dots, u(k-n_b-n_d)) \quad (2)$$

donde  $y(k)$  corresponde a la salida del sistema,  $u(k)$  es la entrada,  $n_a$  y  $n_b$  están asociados al orden del modelo y  $n_d$  es retardo. En este modelo, la regla  $i$  se define como:

$$\begin{aligned}
R_i : & \text{ if } y(k-1) \text{ is } A_1^i \text{ and } \dots \text{ and } y(k-n_a) \text{ is } A_{n_a}^i \text{ and} \\
& u(k-n_d-1) \text{ is } A_{n_a+1}^i \text{ and } \dots \text{ and } u(k-n_b-n_d) \text{ is } A_{n_a+n_b}^i \text{ then} \\
y_i(k) = & g_0^i + g_1^i y(k-1) + \dots + g_{n_a}^i y(k-n_a) + g_{n_a+1}^i u(k-n_d-1) \\
& + \dots + g_{n_a+n_b}^i u(k-n_b-n_d)
\end{aligned} \quad (3)$$

donde  $A_j^i$  es el conjunto difuso de la regla  $i$  y del regresor  $j$ ,  $g_j^i$  son los parámetros de las consecuencias,  $y_i$  es la salida de la regla  $i$ . Finalmente, la salida del sistema  $y(k)$  viene dada por:

$$y = \frac{\sum_{i=1}^M \omega_i y_i(k)}{\sum_{i=1}^M \omega_i} \quad (4)$$

donde  $\omega_i$  corresponde al grado de activación de la regla  $i$  y  $M$  es el número de reglas del modelo difuso. Para realizar el clustering difuso, en este trabajo se ocupa el algoritmo de Gustafson & Kessel [24]. Este emplea una norma de la distancia adaptiva cuyos parámetros, al ser variables de optimización, logran ajustarse de mejor forma a la geometría de datos. Para determinar el número de clusters óptimo, se evalúa el modelo obtenido, según un índice que penalice tanto el error de predicción como el número de parámetros del modelo, y se varía el número de clusters en un rango determinado. El modelo que obtenga menor índice determinará el número de clusters [25]. Luego, se realiza la simplificación del modelo, determinando los autoregresores más significativos. Para ello se calcula la sensibilidad de cada autoregresor con respecto a la salida del modelo [25]. El modelo obtenido, se evalúa en los conjuntos de entrenamiento, validación y test. Obteniéndose un modelo final de T&S de la forma dada en (2).

### B. Control predictivo difuso

Dependiendo del algoritmo utilizado para MPC, existen diferentes funciones de costo para obtener la ley de control, pero el objetivo general es que la salida futura pueda seguir una determinada referencia en un horizonte considerado, y que el esfuerzo de control necesario para llevar a cabo esta acción sea penalizada [26]. Por lo tanto, la función de costo generalizada de la forma:

$$J = \sum_{j=N_1}^{N_2} \delta(j) [\hat{y}(k+j) - r(k+j)]^2 + \sum_{j=1}^{N_u} \lambda(j) [\Delta u(k+j-1)]^2 \quad (5)$$

donde  $\hat{y}(k+j)$  es la predicción de la salida en el instante  $k+j$  obtenida con el modelo y datos conocidos hasta el instante  $k$ ,  $r(k+j)$  es la referencia en  $k+j$ , la variación de la acción de control es  $\Delta u(k+j) = u(k+j) - u(k+j-1)$ ,  $N_1$  y  $N_2$  determinan el horizonte de predicción,  $N_u$  es el horizonte de control,  $\delta(j)$  y  $\lambda(j)$  son secuencias de pesos que penalizan los errores de seguimiento y el esfuerzo de control. El horizonte de predicción y las secuencias de pesos son parámetros de sintonización del controlador. Si el modelo que representa el sistema no lineal, corresponde a un modelo difuso, entonces se denomina controlador predictivo difuso (MPC difuso).

Dado que el controlador MPC difuso resuelve en cada instante el problema de optimización de la función objetivo (5)

considerando el modelo difuso (2), es posible agregar no solo restricciones técnicas, sino también económicas. La diversidad de procesos en donde se ha aplicado este tipo de estrategia de control y los beneficios reportados, motivan en este trabajo el evaluar los beneficios en el caso de las plantas colectores solares distribuidos.

## IV. APLICACIÓN AL CONTROL DE UNA PLANTA DSC

### A. Modelo de T&S

Para diseñar la estrategia de control predictivo de la planta solar, primero es necesario derivar el modelo difuso. Según el procedimiento de identificación difusa, descrito en III.A., utilizando el simulador de la planta [3], en primer lugar se obtuvo un conjunto de datos con un tiempo de muestreo de 39 segundos, donde la variable de entrada es la temperatura de referencia  $u(k) = T_r(k)$  y la variable de salida es la temperatura de salida del aceite del campo de colectores  $y(k) = T_{oil}(k)$ . Los datos obtenidos se dividieron en tres conjuntos: entrenamiento, validación y test. Con los dos primeros se obtuvo un modelo difuso de T&S de la forma especificada en (2) para la planta solar. Dada las características del sistema, se consideró suficiente utilizar los parámetros  $n_a=n_b=10$ , y  $n_d=0$  para construir el modelo inicial de T&S. Así el modelo tiene la siguiente estructura inicial:

$$T_{oil}(k) = f_{T\&S}(T_{oil}(k-1), \dots, T_{oil}(k-10), T_r(k-1), \dots, T_r(k-10)) \quad (6)$$

donde la función  $f_{T\&S}$  está dada por la estructura del modelo difuso. Siguiendo el procedimiento de identificación, se realizó la optimización del número de cluster y la optimización del número de parámetros. Para determinar el número de cluster óptimo, se calculó el error RMS (Root Mean Square) del modelo inicial y se varió el número de clusters de 2 hasta 20. Se obtiene que el número de clusters óptimo es 3. Luego, se optimizó su estructura. Para ello, se calculó la sensibilidad de cada autoregresor con respecto a la salida del modelo difuso usando el método propuesto en [25]. Con esta información se obtuvo un modelo de T&S con 3 reglas (3 clusters) para la planta solar, de la forma dada por:

$$\begin{aligned}
R^i : & \text{ If } T_{oil}(k-1) \text{ is } A_1^i \text{ and } T_{oil}(k-2) \text{ is } A_2^i \text{ and } T_{oil}(k-3) \text{ is } A_3^i \\
& \text{ and } T_{oil}(k-4) \text{ is } A_4^i \text{ and } T_{oil}(k-5) \text{ is } A_5^i \text{ and } T_{oil}(k-6) \text{ is } A_6^i \\
& \text{ and } T_{oil}(k-7) \text{ is } A_7^i \text{ and } T_{oil}(k-8) \text{ is } A_8^i \text{ and } T_{oil}(k-9) \text{ is } A_9^i \\
& \text{ and } T_r(k-1) \text{ is } A_{10}^i \text{ and } T_r(k-2) \text{ is } A_{11}^i \text{ and } T_r(k-3) \text{ is } A_{12}^i \text{ then} \\
T_{oil}(k) = & g_0^i + g_1^i T_{oil}(k-1) + g_2^i T_{oil}(k-2) + g_3^i T_{oil}(k-3) + \\
& g_4^i T_{oil}(k-4) + g_5^i T_{oil}(k-5) + g_6^i T_{oil}(k-6) + \\
& g_7^i T_{oil}(k-7) + g_8^i T_{oil}(k-8) + g_9^i T_{oil}(k-9) + \\
& g_{10}^i T_r(k-1) + g_{11}^i T_r(k-2) + g_{12}^i T_r(k-3), i = 1, 2, 3
\end{aligned} \quad (7)$$

donde las funciones de pertenencia son Gaussianas, dadas por el clustering difuso.

La Fig. 5 muestra la predicción a 10 pasos, realizada con el modelo T&S, de la temperatura de salida del aceite de la planta solar  $y(k) = T_{oil}(k)$  comparada con su valor real. Se muestra además, un acercamiento del día 1.

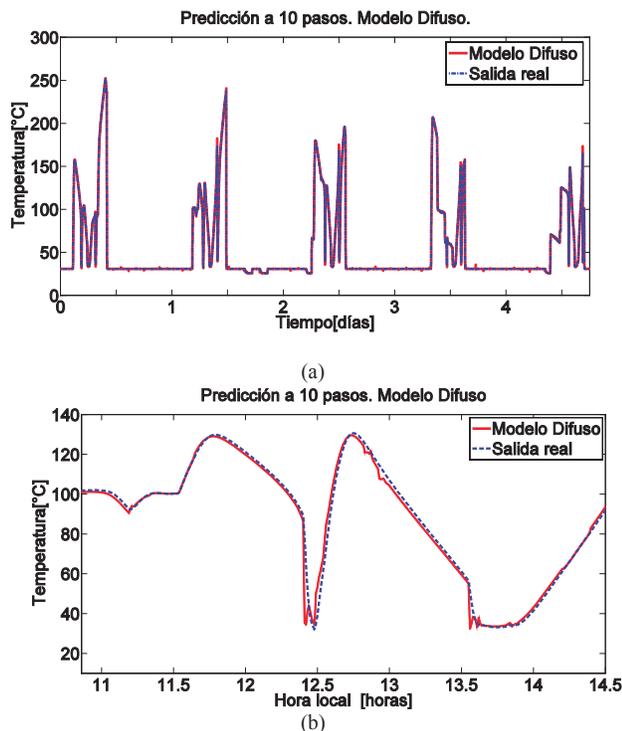


Figura 5. Predicción a 10 pasos con modelo T&S de temperatura de salida del aceite. (a) Señal completa. (b) Acercamiento.

Para comparar el modelo difuso se obtuvo el siguiente modelo lineal ARX de la planta:

$$T_{oil}(k) = 0,00647T_{oil}(k-1) - 0,0039T_{oil}(k-2) - 0,00213T_{oil}(k-3) - 0,0003T_{oil}(k-4) + 4,9e-05T_{oil}(k-5) + 0,00023T_{oil}(k-6) + 0,00043T_{oil}(k-7) - 5,4e-05T_{oil}(k-8) - 0,0006T_{oil}(k-9) + 2,33T_r(k-1) - 1,86T_r(k-2) + 0,52T_r(k-3) + 0,0241 + e(k) \quad (8)$$

Se calcularon los errores RMS para ambos modelos los que se entregan en las Tablas I y II. De las tablas se aprecia que el modelo de T&S tiene en general, menores valores de errores que el modelo ARX, aunque las diferencias no sean significativas. En particular los errores obtenidos en la predicción a 10 pasos, hacen que el modelo de T&S sea adecuado para el diseño de un controlador predictivo.

TABLA I. ÍNDICES DE ERROR RMS DE PREDICCIÓN A UN PASO.

Modelo	ARX 1 paso [°C]	T&S 1paso [°C]
Conjunto de datos		
Identificación	1.0374	1.0354
Validación	0.7305	0.7313
Test	0.8777	0.7510

TABLA II. ÍNDICES DE ERROR RMS DE PREDICCIÓN A 10 PASOS.

Modelo	ARX 10 pasos [°C]	T&S 10 pasos [°C]
Conjunto de datos		
Identificación	12.1035	11.9842
Validación	11.0674	10.7587
Test	11.8731	10.7761

### B. Control predictivo difuso

Se diseñaron dos MPC para la planta solar, el primero utilizando el modelo difuso de T&S y un segundo controlador utilizando el modelo ARX. La configuración propuesta para

estos controladores se muestra en la Fig. 6.

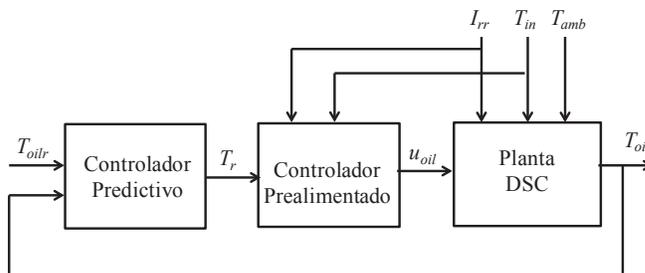


Figura 6. Diagrama de lazo cerrado del MPC.

La función objetivo utilizada para el control predictivo aplicado a la planta solar está dada por:

$$J = J_y + \lambda J_{\Delta u} \quad (9)$$

$$J_y = \sum_{j=N_1}^{N_2} [\hat{T}_{oil}(k+j) - T_{oilr}]^2, J_{\Delta u} = \sum_{j=1}^{N_u} [\Delta u_{oil}(k+j-1)]^2$$

la cual tiene la misma forma que en (5), con  $\delta(j)=1$  y  $\lambda(j)=\lambda$ , y los horizontes de predicción y control dados por  $N_1=1$  y  $N_2=N_u=10$ . En este caso, por la función objetivo usada, se mantendrá la temperatura de salida del aceite  $T_{oil}$  lo más parecida a la referencia  $T_{oilr}$ , con la menor variación del flujo de aceite  $u_{oil}$ . De esta forma  $J_y$  corresponde al término de regulación de la temperatura de salida del aceite,  $J_{\Delta u}$  representa la optimización del esfuerzo de control,  $\hat{T}_{oil}(k+j)$  es la predicción a  $j$ -pasos de la temperatura de salida del aceite, y  $\Delta u_{oil}(k+j-1)$  es el esfuerzo de control futuro.

A partir de los resultados obtenidos durante todo el tiempo de simulación  $T_{sim}$ , se ocupan como estadísticas de desempeño el error de regulación y la energía total de control:

$$\bar{J}_{Toil} = \frac{1}{T_{sim}} \sum_{k=1}^{T_{sim}} (T_{oil}(k) - T_{oilr}(k))^2 \quad (10)$$

$$\bar{J}_{\Delta uoil} = \frac{1}{T_{sim}} \sum_{k=1}^{T_{sim}} \Delta u_{oil}^2(k) \quad (11)$$

En las Tablas III y IV se muestran los resultados por simulación, ocupando distintos parámetros de sintonización  $\lambda$  dentro de un rango de valores que entregaban el mejor desempeño. La Fig. 7a muestra la salida del controlador MPC ARX y la Fig. 7b lo hace para el controlador MPC difuso. Comparando los valores obtenidos para  $\bar{J}_{Toil}$  y  $\bar{J}_{\Delta uoil}$ , se aprecia que los del modelo ARX son mucho mayores, lo que significa que el costo de control del MPC ARX es mayor.

TABLA III. DESEMPEÑO CONTROLADOR MPC ARX.

$\lambda$ Lambda	$\bar{J}_{Toil}$	$\bar{J}_{\Delta uoil}$
0.2	13.013	1.983x10 <sup>-7</sup>
0.26	10.465	1.974x10 <sup>-7</sup>
<b>0.3</b>	<b>8.778</b>	<b>1.975x10<sup>-7</sup></b>
0.35	9.508	1.979x10 <sup>-7</sup>

TABLA IV. DESEMPEÑO CONTROLADOR MPC DIFUSO.

$\lambda$ Lambda	$\bar{J}_{Toil}$	$\bar{J}_{\Delta uoil}$
36	3.083	$1.838 \times 10^{-7}$
44	2.496	$1.837 \times 10^{-7}$
<b>48</b>	<b>2.374</b>	<b><math>1.838 \times 10^{-7}</math></b>
56	3.426	$1.865 \times 10^{-7}$

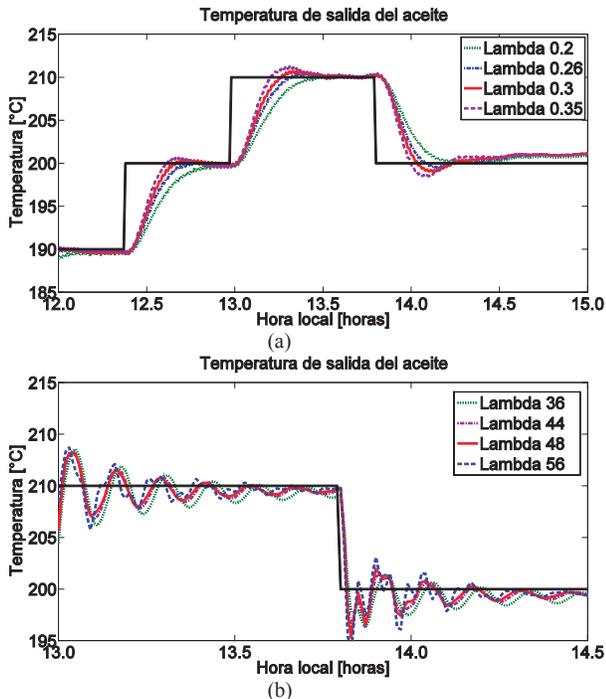


Figura 7. (a) Temperatura de salida del aceite MPC ARX, (b) Temperatura de salida del aceite MPC difuso, para diferentes valores de  $\lambda$ .

A partir de estos resultados, se selecciona el valor de  $\lambda$ , más apropiado para cada controlador, considerando los valores de  $\bar{J}_{Toil}$  y  $\bar{J}_{\Delta uoil}$ . Para el controlador ARX  $\lambda=0.3$  y para el controlador T&S  $\lambda=48$ , los que aparecen en negrita en las tablas correspondientes. Con los controladores ya sintonizados con estos valores de  $\lambda$ , éstos se compararon entre sí, además de compararlos con los resultados de una configuración de control tradicional con un controlador PI, implementado por Camacho *et al.* [3]. La Fig. 8 muestra el comportamiento de la variable controlada  $T_{oil}$ , cuando la referencia varía con un escalón de subida (Fig. 8a), y cuando la referencia cambia con un escalón de bajada (Fig. 8b). La temperatura de entrada del aceite al campo de colectores solares, la temperatura ambiente y la radiación solar del día correspondiente, varían de la forma presentada en las Figuras 9 y 10.

A partir de estos resultados, se calcularon diferentes índices para los tres controladores, de forma de evaluarlos y compararlos. Las tablas V y VI, entrega los valores de sobrepaso  $M_p$ , tiempo de elevación  $T_e$  y tiempo de estabilización  $T_s$ .

De los valores de  $T_s$  y  $T_e$  se aprecia que el controlador T&S es más rápido que los otros dos controladores. Sin embargo, el sobrepaso es mayor para el controlador T&S.

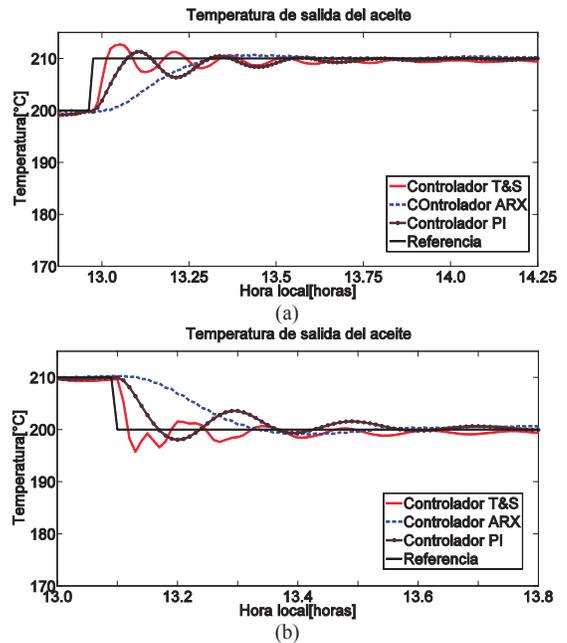


Figura 8. Comparación controladores- (a) Caso escalón de subida en la referencia. (b) Caso escalón de bajada en la referencia

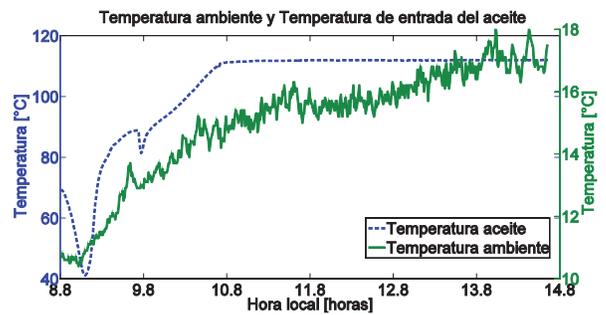


Figura 9. Temperatura de entrada del aceite  $T_{in}$  y Temperatura ambiente  $T_{amb}$ .

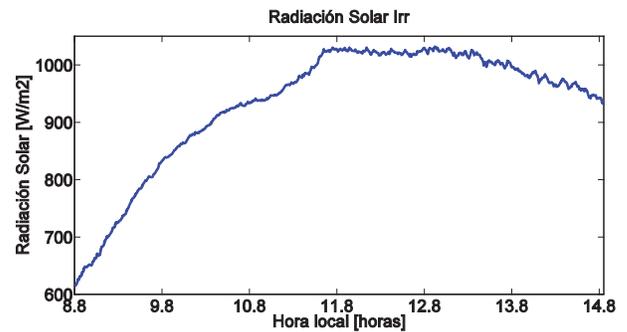


Figura 10. Radiación solar.

TABLA V. ÍNDICES DE EVALUACIÓN DE CONTROLADORES ESCALÓN DE SUBIDA EN LA REFERENCIA.

	PI	MPC ARX	MPC T&S
$M_p$ %	0.001	0.143	1.369
$T_e$ (min)	87.977	43.110	0.519
$T_s$ (min)	40.300	61.100	30.550

TABLA VI. ÍNDICES DE EVALUACIÓN DE CONTROLADORES. ESCALÓN DE BAJADA EN LA REFERENCIA

	PI	MPC ARX	MPC T&S
$M_p$ %	4.859	4.594	4.957
$T_e$ (min)	2.896	7.653	0.927
$T_s$ (min)	66.300	58.500	48.750

## V. ASPECTOS PRÁCTICOS

En la implementación del control predictivo difuso propuesto en la planta DSC, se consideraron diversos aspectos prácticos asociados a las etapas de diseño y sintonización de la estrategia de control presentadas en las secciones IV. A (Identificación del modelo difuso) y IV. B (Diseño del controlador MPC) de este trabajo.

La primera etapa: identificación del modelo difuso que va a ser utilizado como modelo de predicción en la estrategia de control (sección IV. A), juega un rol fundamental en el desempeño de la planta en lazo cerrado [27]. Con el fin de obtener un modelo que represente adecuadamente el comportamiento dinámico de la planta, se debió hacer un correcto diseño de experimentos, ya que esto permitió obtener información suficiente de la dinámica del proceso, información de gran relevancia en la selección de la estructura del modelo de predicción. El diseño de experimentos, la selección de la estructura, y la identificación de los parámetros del modelo a partir de los datos recopilados fue la etapa que más tiempo tomó en la implementación de la estrategia de control, llegando a sobrepasar el 50% del tiempo que tardó tal implementación. Este resultado está de acuerdo a lo reportado en [28]. Cabe resaltar que el diseño de experimentos debe garantizar la obtención de la mayor cantidad de información del proceso, por tanto, se debe asegurar que el sistema pase por diferentes puntos de operación, y que al menos en una oportunidad alcance un estado estacionario. Esto afecta directamente el diseño de las entradas que serán aplicadas en el proceso real, ya que se tiene que tener en cuenta el funcionamiento de actuadores, la disponibilidad de sensores, y las restricciones de seguridad. De acuerdo con lo reportado en [28], además de los factores ya mencionados se deben tener en cuenta en el proceso de identificación los siguientes aspectos:

- Fragmentación de datos: determina la sección de datos que es incluida o excluida en la identificación.
- Pre procesamiento de datos: incluye opciones tales como la eliminación de peaks, corrección de offset, prefiltrado, eliminación de tendencias, desplazamientos de datos en base a retardos conocidos, etc.
- Selección de entradas y salidas: las entradas incluyen tanto a las variables manipuladas como las variables controladas.
- Estructura del modelo: esto incluye decisiones como el tipo de modelo y el orden del modelo.
- No-linealidades: verificar si las no-linealidades justifican un modelado adicional.

La segunda etapa: diseño del controlador MPC (Sección IV. B), involucra la selección y formulación de los objetivos de control, mediante una función objetivo, la sintonía de factores de ponderación, si así lo requiere la función objetivo, y la determinación de los horizontes de predicción y control. La correcta identificación del modelo sumado a la adecuada selección de los objetivos de control, de los factores de ponderación y de los horizontes de control y de predicción permitió el éxito en la implementación de la estrategia de control predictivo difuso en la planta DSC, ya que el optimizador en su conjunto, debe contar con información suficiente del comportamiento dinámico de la planta DSC para resolver el problema de optimización asociado a la implementación del MPC [29].

Con respecto a la selección y sintonización de la función objetivo, se utilizan criterios de regulación, seguimiento y robustez. En el caso del algoritmo de optimización para el MPC difuso, éste requiere manejar optimización no convexa, debido a que el modelo difuso es no-lineal. Avances en el desarrollo de algoritmos rápidos para optimización no lineal son promisorios y han sido reportados por ejemplo en [30], [31].

Para asegurar un comportamiento adecuado de una aplicación de MPC y mantener sus beneficios en el tiempo, es necesario realizar un mantenimiento y evaluación con pruebas en planta, con el fin de decidir si el modelo (o parte de él) deben ser actualizados cuando el comportamiento del sistema se deteriora, debido a cambios en el proceso [28]. En particular, la identificación difusa propuesta en este trabajo, requiere la adquisición de datos experimentales de la planta DSC, con un tiempo adecuado de muestreo y un filtrado de las señales adquiridas. El optimizador del MPC difuso propuesto trabaja con tiempo de muestreo de 39 segundos, lo cual es implementable en el PLC de la planta Acurex. Para realizar la optimización, se utilizó la función *fmincon* de Matlab®, con algoritmo de solución SQP (Sequential Quadratic Programming). Se destaca que el simulador de la planta empleado en este trabajo, ha sido utilizado para el desarrollo de diversas estrategias de control, las que han sido validadas en la plataforma experimental Acurex, como se presenta recientemente en [17] y [32].

## VI. CONCLUSIONES

En este trabajo se propone el diseño de una estrategia predictiva difusa para plantas de colectores solares distribuidos.

Para el diseño de las estrategias de control predictivo se analizaron diferentes enfoques de modelación. De este análisis, se observa que el modelo difuso permite predecir a 7 minutos (10 pasos) el comportamiento de la temperatura del campo de colectores solares, con un error del 10.7%, mejorando el desempeño con respecto a una modelación lineal (modelo ARX). Por lo tanto, los resultados muestran que el uso de un modelo difuso de T&S es muy adecuado para representar las no lineales que caracterizan a las plantas solares.

En cuanto al diseño de la estrategia de control predictivo, se implementaron dos enfoques para la planta solar, el controlador MPC difuso y un controlador MPC ARX. Con respecto al análisis comparativo de las estrategias de control propuestas, se aprecia que la función de seguimiento es un 73% mejor para el MPC difuso, comparado con el caso MPC lineal (ver función de costo de control según Tablas III y IV, con  $\lambda=0.3$  y  $\lambda=48$  respectivamente). A su vez, se observa un 7% de disminución en el esfuerzo de control con el controlador MPC difuso. Por lo tanto, la evaluación de las funciones de costo tanto de error de seguimiento, como de la función de costos de control presentan valores que hacen muy conveniente el uso de MPC con modelos T&S para planta solares.

Actualmente, está en desarrollo un simulador de una planta ciclo combinado con colectores solares distribuidos integrados (ISCC), y se espera extender esta estrategia MPC basado en modelos difuso a la planta ISCC, ya que, ha demostrado ser efectiva en la planta DSC.

## REFERENCIAS

- [1] I. I., 2009. [Online]. Available: <http://www.aven.es/energía/index.html>. [Accessed 1 Octubre 2009].
- [2] R. Román, «Surface Area Utilization for Different Solar Energy Conversion Technology,» Departamento de Ingeniería Mecánica. Universidad de Chile, Santiago, 2008.
- [3] E. Camacho, M. Berenguel y M. Rubio, *Advanced Control of Solar Plants*, Primera ed., London: Springer-Verlag, 1997.
- [4] G. Pin, M. Falchetta and G. Fenu, "Adaptive Time-Warped Control of Molten Salt Distributed Collector," *Control Engineering Practice*, vol. 16, pp. 813-823, 2008.
- [5] J. Henriques, P. Gil, A. Cardoso, P. Carvlho and A. Dourado, "Adaptive Neural Output Regulation Control of Solar Power Plant," *Control Engineering Practice*, vol. 18, pp. 1183-1196, 2010.
- [6] K. Narendra and O. Driollet, "Adaptive Control Using Multiple Models, Switching and Tuning," *Adaptive System for Signal Processing, Communications and Control Symposium 2000. AS-SPCC. The IEEE 2000*, 2000.
- [7] C. Cirre, L. Valenzuela, M. Berenguel and E. Camacho, "Feedback Linearization Control for a Distributed Solar Collector Field,," *Control Engineering Practice*, vol. 15, pp. 1533-1544, 2007.
- [8] E. Camacho, F. Rubio, M. Berenguel and L. Valenzuela, "A Survey on Control Schemes for Distributed Solar Fields. Part II. Advanced Control Approaches," *Solar Energy*, vol. 81, pp. 1252-1272, 2007b.
- [9] F. Rubio, E. Camacho and M. Berenguel, "Control de Campos de Colectores Solares," *Revista Iberoamericana de Automática e Informática Industrial*, vol. 3, no. 4, pp. 26-45, 2006.
- [10] F. Rubio, M. Berenguel and E. Camacho, "Fuzzy Logic Control of Solar Power Plant," *IEEE Transaction on Fuzzy Systems*, vol. 3, no. 4, pp. 459-468, 1995.
- [11] M. Berenguel, E. Camacho and F. Rubio, "Incremental Fuzzy PI Control for a Solar Power Plant," *IEEE Proceeding. Control Theory Application*, vol. 144, no. 6, pp. 596-604, 1997b.
- [12] F. Gordillo, F. Rubio, E. Camacho, M. Berenguel and J. Bonilla, "Genetic Design of a Fuzzy Logic Controller for a Solar Power Plant," *Proceeding of the 4th European Control Conference*, 1997.
- [13] K. Tang, K. Man and G. Chen, "Solar Plant Control Using Genetic Fuzzy PID Controller," *Industrial Electronic Society 2000. IECON. 26th Annual Conference of the IEEE*, pp. 1686-1691, 2000.
- [14] P. Luk, L. Lai and T. Tong, "GA Optimization of Rule Base in a Fuzzy Logic Control of a Solar Power Plant," *International Conference on Electric Utility Deregulation and Restructuring and Power Technologies*, 2000.
- [15] A. Cardoso, J. Henriques and A. Dourado, "Fuzzy Supervisor of PID Controllers for Acurex Field at PSA,," *Second Annual Workshop. Plataforma Solar de Almería. España*, 1998.
- [16] A. Cardoso, J. Henriques and A. Dourado, "Fuzzy Supervisor and Feedforward Control of Solar Power Plant," *Proceeding of the European Control Conference ECC'99*, 1999.
- [17] C. Cirre, M. Berenguel, L. Valenzuela and R. Klempos, "Reference Governor Optimization and Control of a Distributed Solar Collector Field," *European Journal of Operational Research*, vol. 193, pp. 709-717, 2009.
- [18] A. Flores, D. Sáez, J. Araya, M. Berenguel and A. Cipriano, "Fuzzy Predictive Control of a Solar Power Plant,," *IEEE Transaction on Fuzzy Systems*, vol. 13, no. 1, pp. 58-68, 2005.
- [19] Y. Zhao, H. Gao and T. Chen, "Fuzzy Constrained Predictive Control of Non-Linear Systems with Packet Dropouts," *IET Control Theory and Applications*, vol. 4, no. 9, 2010.
- [20] M. Berenguel, E. Camacho and F. Rubio, "Simulation Software Package of the Acurex Field," E.S.I. of Sevilla, Internal Report, Sevilla, 1993.
- [21] F. Allgöwer, R. Findeisen and C. Ebenbauer, "Nonlinear Model Predictive Control," *Control Systems, Robotics and Automation*, vol. 11, 2011.
- [22] S. Joe Qin and T. Badgwell, "A Survey of Industrial Model Predictive Control Technology," *Control Engineering Practice*, vol. 11, pp. 733-764, 2003.
- [23] R. Babuska, *Fuzzy Modeling for Control*, Primera ed., Kluwer Academic Publishers, 1998.
- [24] D. Gustafson and W. Kessel, "Fuzzy Clustering with a Fuzzy Covariance Matrix," *Proceeding of the IEEE Conference on Decision and Control including the 17th Symposium on Adaptive Processes*, pp. 761-766, 1978.
- [25] D. Sáez and A. Cipriano, "A New Method for Structure Identification of Fuzzy Models and its Application to a Combined Cycle Power Plant,," *Engineering Intelligent Systems*, vol. 9, no. 2, pp. 101-107, 2001.
- [26] E. Camacho and C. Bordón, *Model Predictive Control*, Primera ed., Londres: Springer-Verlag, 2004.
- [27] Y. Zhu, R. Patwardhan, S. Wagner and J. Zhao, "Toward a Low Cost and High Performance MPC: The Role of System Identification," *Computers and Chemical Engineering*, vol. 52, pp. 124-135, 2013.
- [28] M. Darby and M. Nikolau, "MPC: Current Practice and Challenges," *Control Engineering Practice*, vol. 20, pp. 328-342, 2012.
- [29] B. Huyck, H. Ferreau, M. Diehl, J. De Brabanter, J. Van Impe, B. De Moor and F. Logist, "Towards Online Model Predictive Control on a Programmable Logic Controller: Practical Considerations," *Mathematical Problems in Engineering*, vol. 23, 2012.
- [30] S. Gros, R. Quirynen y M. Diehl, «Aircraft Control based on Fast Non-linear MPC & Multiple-shooting,» *Proceedings of the IEEE 51 st Annual Conference on Decision and Control (CDC), Maui, USA*, pp. 1142-1147, 2012.
- [31] Y. Wang y S. Boyd, «Fast Model Predictive Control Using Online Optimization,» *IEEE Transactions on Control Systems Technology*, vol. 18, n° 2, pp. 267-278, 2010.
- [32] E. Camacho, M. Berenguel, F. Rubio and D. Martínez, *Control of Solar Energy Systems*, Primera ed. ed., London: Springer, 2012.



**Carolina Ponce** is Civil Engineer, major in Electrical Engineering from Universidad de Concepción, Chile, in 1987. In 1999 received the M.Sc. degree in "Técnicas de Energías Renovables en la Ingeniería, Arquitectura, y Agricultura" from Univ. Internacional de Andalucía, España. She is currently a PhD candidate in Electrical Engineering at Universidad de Chile. Her current research interests are fuzzy identification, renewable energy and predictive control design.



**Doris Sáez** received the M.Sc. and Ph.D. degrees in electrical engineering from the Pontificia Universidad Católica de Chile, in 1995 and 2000, respectively. She is currently an associate professor at the Electrical Engineering Department, Universidad de Chile. She is associate editor of IEEE Transactions on Fuzzy Systems and Soft Computing. She is co-author of Springer-Verlag books: "Hybrid Predictive Control for Dynamic Transport Problems" (2013) and "Optimization of Industrial Processes at Supervisory Level: Application to Control of Thermal Power Plants" (2002). Her research fields are predictive control, fuzzy control design, fuzzy identification, control of power generation plants and control of transport systems.



**Alfredo Núñez** received his Ph.D. degree in electrical engineering from Universidad de Chile, Santiago, Chile, in 2010. He is co-author of the book "Hybrid Predictive Control for Dynamic Transport Problems" in the Series of Advances in Industrial Control, published by Springer-Verlag (2013). He was a postdoctoral researcher with the Delft Center for Systems and Control, and currently he works in the group of Road and Railway Engineering, Delft University of Technology, Delft, The Netherlands. His current research interests include monitoring of railway infrastructure, modeling and control of traffic and transportation systems, model predictive control, and fuzzy systems.