

Estimador Neuro-borroso, con reducción de complejidad, de las temperaturas de un campo solar cilindro-parabólico

Escaño, J.M.^{a,*}, Sánchez, A.J.^a, Ceballos, M.^b, Gallego, A.J.^a, Camacho, E.F.^a

^aDepartamento de Ingeniería de Sistemas y Automática, Universidad de Sevilla, Camino de los Descubrimientos s/n, 41092 Sevilla, España.

^bDepartamento de Ingeniería, Universidad Loyola Andalucía, Avda. de las Universidades s/n, Dos Hermanas, 41704 Sevilla, España.

To cite this article: Escaño, J.M., Sánchez, A.J., Ceballos, M., Gallego, A.J., Camacho, E.F. 2021. Neuro-fuzzy estimator, with complexity reduction, of the temperatures of a parabolic-trough solar field. Revista Iberoamericana de Automática e Informática Industrial 18, 138-149. <https://doi.org/10.4995/riai.2020.13261>

Resumen

La estimación de estados no observables de un proceso es importante cuando se aplican técnicas de control automático basadas en el espacio de estados. El diseño y uso de estos controladores conlleva suponer que los valores de los estados se podrán obtener de una u otra forma. Cuando todos los estados son medibles, no existe la necesidad de aplicar observadores. El caso de plantas solares cilindro-parabólicas usando modelos de parámetros distribuidos presenta el problema de no poder medir todos los valores de los estados con sensores. En este trabajo se presenta un observador basado en un sistema de inferencia borrosa para estimar los perfiles de temperatura de los lazos que componen el campo solar. Se aplica una técnica de reducción de complejidad basada en el análisis de componentes principales funcionales para que el estimador sea realizable en la práctica sin ocupar mucha memoria o consumir demasiado tiempo tanto en la computación del algoritmo como en la programación en dispositivos industriales.

Palabras clave: Sistemas Neuro Borrosos, Análisis Componentes Principales funcionales, Estimación Espacio Estados, Plantas Solares, Cilindro-Parabólica, Reducción Complejidad.

Neuro-fuzzy estimator, with complexity reduction, of the temperatures of a parabolic-trough solar field

Abstract

The estimation of unobservable states of a process is important when state space control techniques are applied. These controllers assume that states values are known. When all the states are measurable, there is no need to apply any observer. The case of the solar trough plants using a distributed parameters model presents many state variables which cannot be measured with sensors. In this work an observer based on a fuzzy inference system to estimate the temperature profiles of the loops that make up the solar field is presented. A complexity reduction technique based on Functional Principal Analysis is applied to make the estimator realizable in practice without occupying much memory or spend so much time in its programming in industrial devices.

Keywords: Neurofuzzy systems, Functional Principal Component Analysis, State Space Estimation, Solar trough plant, complexity reduction.

1. Introducción

En el control automático de procesos industriales, la información que se puede proporcionar al controlador dependerá, en todos los casos, del tipo de controlador que se haya diseñado. En el caso de los controladores clásicos, como un controlador

Proporcional Derivativo Integral (PID), la única información a recibir es el error entre la referencia y la salida del sistema a controlar. Por lo que el estado de la planta en el controlador está limitado a una señal de error. En otro tipo de controladores más complejos, la información que se puede proporcionar es ma-

*Autor para correspondencia: jescano@us.es

yor. En particular, algunos métodos de control suponen que se conoce el estado del proceso a controlar y su dinámica, determinadas por unas ecuaciones. Dentro de estos, se puede encontrar las técnicas de Control Predictivo basado en Modelo (MPC), las cuales son muy eficientes y muy populares. Los MPC diseñados en el espacio de estados necesitan conocer el valor de las variables del sistema que componen los estados del mismo. Estos estados pueden o no, ser observables, es decir, si las variables de estado pueden o no ser medidas. En caso de que no puedan medirse por imposibilidad física o incluso económica, pueden estimarse y el controlador puede usar las estimaciones como los valores adquiridos por tales variables.

Las plantas solares de tecnología cilindro parabólica son uno de los procesos donde no todos los estados son medibles. Estas plantas están formadas por un gran número de lazos de colectores solares de cientos de metros (Solar Millennium AG, 2018; Guzmán, 2018; Kaxu Solar One, 2018; Solana Generating Station, 2018). Las temperaturas del fluido a lo largo del tubo receptor de cada uno de los lazos que componen la planta solar no son medibles por razones económicas.

Debido a la naturaleza no lineal del proceso, se han diseñado múltiples técnicas de control MPC en el espacio de estado obteniendo buenos resultados. Uno de los campos parabólicos más utilizados en investigación es el campo ACUREX en Almería ((Rubio et al., 2009; Cirre et al., 2010)). En ((Gallego and Camacho, 2012)), los autores proponen un MPC adaptativo en el espacio de estados para el control del campo solar ACUREX realizando la estimación de los estados mediante un Unscented Kalman Filter (UKF). Un MPC avanzado en el espacio de estado se presenta en Gallego et al. (2013), donde se propone el uso de un observador robusto de Luenberguer y la resolución de un LMI para la estimación de los estados. Se propone un algoritmo basado en un Kalman Filter Extendido Iterativo (EKF) en (Karamali and Khodabandeh, 2017) para la estimación de las temperaturas de los colectores y de la entrada, suponiendo que no hay un sensor en la entrada. En este caso los autores utilizan un PID más un Feedforward para realizar el control de la planta. En (Sánchez et al., 2018), los autores proponen una optimización no lineal para controlar las válvulas de entrada y una estimación de los estados mediante el uso de árboles de clasificación y regresión (CART).

Los estimadores lineales, como el observador de Luenberguer, se basan en el modelo lineal de la planta, que es una aproximación del modelo no lineal. Por lo tanto, se esperan errores en la estimación en los estados. Los estimadores basados en el EKF pueden tener problemas de convergencia debido a las no linealidades del proceso. El UKF proporciona, en general, mejores resultados en las estimaciones que el EKF. Los resultados del UKF se pueden mejorar si se hace uso de un modelo no lineal en su estructura, aunque esto conlleva aumentar el tiempo de cómputo. Tanto para el desarrollo del EKF como el UKF es necesario determinar las matrices de covarianzas de ruido que, generalmente, no son conocidas. Es más, la matriz de covarianza asociada al ruido en los estados se suele construir intuitivamente.

Los estimadores basados en datos como los árboles de decisión (CART), aunque proporcionan buenos resultados y con una computación rápida, también son difíciles de obtener debido a la gran cantidad de datos necesarios para su entrenamiento

lo que al final lleva a un estimador que puede ocupar mucho espacio en memoria.

Un enfoque diferente para estimar los estados es el uso de redes neuronales artificiales (ANN), que pueden contener la dinámica del proceso una vez que se entrena adecuadamente. Las ANN se han aplicado con éxito en la estimación en varios campos. En (Rehman and Mohandes, 2008), se propone una ANN para estimar la radiación solar global y en (Blackwell et al., 2014) se desarrolla una ANN para estimar el estado termodinámico atmosférico para el pronóstico del tiempo. Además, las ANN se han combinado con sistemas de lógica borrosa para crear redes neuronales artificiales borrosas (FANN) para la estimación, como en (Li et al., 2007) donde los autores lo propusieron como algoritmo para la estimación del estado de carga de baterías.

Al igual que las ANN, los Sistemas de Inferencia Borrosa (Fuzzy Inference Systems o FIS) son aproximadores funcionales genéricos. Es decir, dado un cierto nivel de error, es posible encontrar un FIS que se aproxime a cualquier función con un error menor que el fijado. Esto hace que el FIS sea adecuado para su uso como estimadores y ni siquiera tienen que basarse necesariamente en el espacio de estados. Se pueden encontrar muchos métodos en la literatura para la identificación de parámetros de un FIS. Uno de los métodos más populares es la formulación de un sistema borroso Takagi-Sugeno (TS) (Takagi and Sugeno, 1985) como una ANN (Jang, 1993), también llamado Sistema de inferencia adaptativo neuro-borroso (ANFIS).

Este trabajo trata de la estimación, basada en un ANFIS, de los estados del campo solar. Es una extensión del trabajo publicado en (Sánchez et al., 2018), donde los estimadores borrosos son del tipo TS, que consisten en j reglas de tipo: **IF** x_1 **is** F_{1j} **and** x_2 **is** F_{2j} ...**and** x_n **is** F_{nj} , **THEN:** $h_j(x) = \gamma_{0j} + \gamma_{1j}x_1 + \dots + \gamma_{nj}x_n$, donde $\gamma_{ij} \in \mathbb{R}$, x_1, \dots, x_n son las entradas y F_{ij} los conjuntos borrosos definidos por funciones de pertenencia Gaussianas del tipo:

$$\mu(x; c, \sigma) = e^{-\frac{1}{2} \left(\frac{x-c}{\sigma} \right)^2} \quad (1)$$

El valor que toma la función μ_{ij} para un determinado x_i se conoce como *grado de pertenencia* de x_i para el conjunto borroso F_{ij} . Para formular matemáticamente el sistema de inferencia borrosa, se debe definir un mecanismo para los operadores, la implicación, la agregación y la defuzificación. El esquema ANFIS en (Jang, 1993) presenta estos mecanismos en las capas de una red. Existen varios algoritmos aplicables a ANFIS que aprenden a actualizar los parámetros de las capas. Notablemente, por ejemplo, Back-propagation (BP) (Werbos, 1974) ha sido muy utilizado en las NN. Hay otros métodos combinados con BP, como la combinación híbrida de mínimos cuadrados y BP, (Jang, 1993; Ghosh and Chakraborty, 2012). Una de las ventajas de los sistemas borrosos sobre las NN es la adición de reglas. Estas reglas son dadas por el conocimiento experto y la observación del sistema por parte del ingeniero.

Como se discutió anteriormente, una de las propiedades más importantes del FIS es su capacidad para aproximar funciones no lineales con error de aproximación acotado. Mejorar la precisión provoca un aumento en el número de reglas. Debe considerarse que un sistema basado en demasiadas reglas no es

práctico y causa una pérdida de comprensión del sistema. El uso de un método de agrupación puede evitar la explosión de reglas y obtener los grupos naturales entre las variables de entrada y salida. Los FIS utilizados para la estimación, también pueden manejar sistemas no lineales y proporcionar conocimiento del sistema que es imposible con el uso de NN. Los modelos basados en ANFIS combinan la ventaja de las ANN, como la capacidad de aprender y adaptarse y la lógica borrosa, es decir, el conocimiento basado en reglas y la incertidumbre de gestión y la importancia del conocimiento. A diferencia de los sistemas basados en ANN, los ANFIS puede incorporar conocimiento a priori para mejorar los resultados del estimador.

Sin embargo, la capacidad de construir aplicaciones de lógica borrosa se ha visto obstaculizada por el conocido problema de la explosión de reglas combinatorias, lo que causa una gran complejidad en el modelado. La existencia de reglas redundantes también puede causar una degradación del rendimiento del FIS (Cordon et al., 2001). En este trabajo, se utiliza una técnica basada en el Análisis de Componentes Principales Funcionales (FPCA) para reducir el número de reglas para resolver este problema.

En este artículo, la técnica FPCA se aplica a los estimadores Neuro Borrosos para obtener estimaciones de las temperaturas de los lazos de un campo solar. Como caso de estudio, se utiliza un modelo del campo Acurex de la Plataforma Solar de Almería (PSA). Los estimadores Neuro Borrosos se entrenan con el modelo de parámetros distribuidos completo para realizar estimaciones de los perfiles de temperatura de los lazos. Se aplica un FPCA sobre los sistemas borrosos para reducir la complejidad y permitir una implementación más idónea y posible en controladores industriales.

La estructura del resto del artículo es la siguiente: la Sección 2 presenta el modelo del campo solar Acurex y los modelos matemáticos utilizados. En la Sección 3, se presentan los Sistemas de Inferencia Borrosos (FIS) entrenados para la estimación de las temperaturas. La reducción de la complejidad del FIS mediante el uso de FPCA se presenta en la Sección 4. Los resultados se muestran en la Sección 5. El artículo finaliza con unas conclusiones en la Sección 6.

2. Modelo del campo solar

El campo solar ACUREX, de la Plataforma Solar de Almería (PSA) está formado por 10 lazos de concentradores o colectores cilindro-parabólicos. La longitud total de cada lazo es de 172 metros. De los 172 metros, 142 metros son de partes activas que reciben radiación, mientras que 30 son partes pasivas (uniones y otras partes que no reciben radiación). En este artículo, se utilizarán dos tipos de modelos matemáticos para describir la planta: se utilizará un modelo de parámetros concentrados para el diseño de un controlador FeedForward en serie y un modelo de parámetros distribuidos para fines de simulación. Ambos modelos se han obtenido a través de pruebas y validaciones realizadas en la planta y han sido utilizados por múltiples autores. Un esquema de la planta se muestra en la Fig. 1. Para obtener una descripción completa de la planta y el procedimiento de modelado, consulte (Carmona, 1985; Camacho et al., 1997).

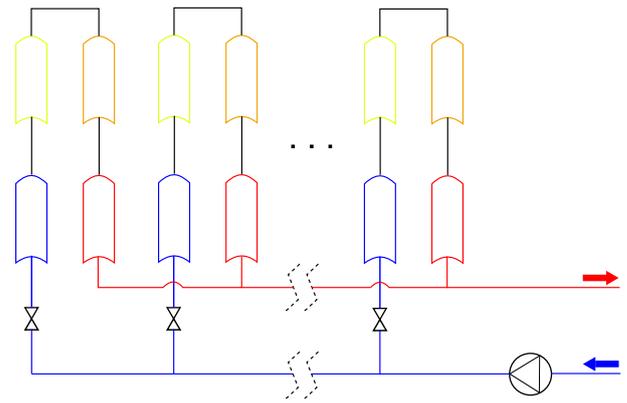


Figura 1: Esquemático general del campo solar Acurex.

2.1. Modelo de parámetros distribuidos

Las dinámicas de un campo solar distribuido se pueden modelar mediante el siguiente sistema de ecuaciones en derivadas parciales que describen un balance energético (Carmona, 1985; Camacho et al., 1997):

$$\rho_m C_m A_m \frac{\partial T_m}{\partial t} = IK_{opt} n_o G - H_l G (T_m - T_a) - LH_t (T_m - T_f) \quad (2)$$

$$\rho_f C_f A_f \frac{\partial T_f}{\partial t} + \rho_f C_f q \frac{\partial T_f}{\partial x} = LH_t (T_m - T_f) \quad (3)$$

donde el subíndice m se refiere al metal y el subíndice f al fluido caloportador (Heat Transfer Fluid o HTF). Los parámetros y unidades del modelo se presentan en la Tabla 1.

Tabla 1: Descripción de parámetros.

| Símbolo | Descripción | Unidad |
|-----------|---|-------------------|
| t | Tiempo | s |
| x | Espacio | m |
| ρ | Densidad | kg/m^3 |
| C | Capacidad calorífica específica | $J/(kg^\circ C)$ |
| A | Area | m^2 |
| $T(x, y)$ | Temperatura | $^\circ C$ |
| $T_a(t)$ | Temperatura Ambiente | $^\circ C$ |
| $q(t)$ | Caudal | m^3/s |
| $I(t)$ | Radiación solar | W/m^2 |
| n_o | Eficiencia geométrica | Adimensional |
| K_{opt} | Eficiencia óptica | Adimensional |
| G | Apertura Colector | m |
| H_l | Coefficiente global pérdidas térmicas | $W/(m^2^\circ C)$ |
| H_t | Coefficiente de transmisión de calor metal-fluido | $W/(m^2^\circ C)$ |
| L | Perímetro tubería | m |

La eficiencia geométrica depende del ángulo horario, la hora solar, la declinación, el día del año, la latitud local y las dimensiones del colector. La densidad ρ , el calor específico C y el coeficiente de transmisión de calor H_t del fluido caloportador dependen de la temperatura del fluido. El coeficiente de transmisión de calor depende de la temperatura y el flujo de aceite (Camacho et al., 1997).

El modelo se discretiza en la dimensión longitudinal del tubo y de esta forma, la dinámica de cada lazo se puede simular como una cadena de submodelos. Se ha elegido una longitud de segmento de 1 metro para la implementación del modelo de simulación (172 segmentos por lazo).

2.2. Modelo de parámetros concentrados

El modelo de parámetros concentrados proporciona una descripción general de todo el campo. La variación en la energía interna del fluido se puede describir mediante la ecuación:

$$C \frac{dT_{out}}{dt} = K_{opt} n_o S I - q P_{cp} (T_{out} - T_{in}) - H_l (T_m - T_a) \quad (4)$$

donde C es la capacidad térmica del lazo, K_{opt} es la eficiencia óptica que tiene en cuenta elementos como la reflectividad y la absorptancia. La eficiencia geométrica n_o está determinada por la posición de los espejos respecto del vector del haz de radiación. El factor P_{cp} tiene en cuenta algunas propiedades geométricas y térmicas del bucle. T_{in} es la temperatura de entrada, H_l es el coeficiente global de pérdidas térmicas, T_m es la temperatura media entre la temperatura de entrada y la de salida, y T_a es la temperatura ambiente. El coeficiente H_l puede aproximarse por $1.05 \text{ kW}/^\circ\text{C}$, P_{cp} por $1,924 \times 10^6 \text{ kJ}/^\circ\text{C}$, C por $2267 \text{ kW}/^\circ\text{C}$, y la superficie reflectante total S toma el valor de 2674 m^2 . Estos valores se han obtenido en base a datos relativos a las medidas de la planta, operando en diferentes puntos de ajuste, mediante análisis de regresión múltiple (Camacho et al., 1997).

3. Estimación del perfil de temperatura mediante FIS

Para la estimación del perfil, se utiliza en este trabajo un ANFIS, el cual tiene una estructura neuronal de cinco capas ((Jang, 1993)), tal como muestra la Figura 2.

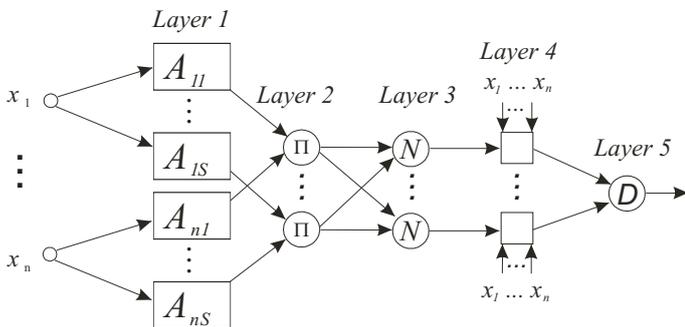


Figura 2: Estructura del ANFIS.

Para entrenar la red, se necesita un conjunto de datos lo más completo posible, es decir, que abarque distintos puntos de trabajo. Este conjunto de datos se dividirá en dos partes: una primera parte se dedicará al entrenamiento del estimador y la segunda parte se usará para la prueba de verificación con el fin de evaluar el error obtenido con el sistema diseñado. El conjunto de datos se creará utilizando el modelo de parámetros distribuidos. El campo solar se simulará modificando los valores de irradiancia (de 400 a 900 W/m^2), eficiencia geométrica (de 0.7 a 0.99), temperatura ambiente (de 20 a 40 $^\circ\text{C}$) y caudal de aceite para un lazo (de 0.2 a 1.2 l/s). Dado que no es factible computacionalmente tener un conjunto de datos que contenga la dinámica no lineal completa de la planta en cualquier punto de operación, el conjunto de datos se limitará al estado estacionario. Una vez que la planta alcanza el estado estable, se obtendrá el valor de la temperatura de salida del campo, así como los valores de temperatura de los segmentos del lazo. Aunque

el conjunto de datos incluye valores de irradiancia, eficiencia geométrica, etc., se ha elegido utilizar solo la temperatura de entrada, salida y caudal como entradas, y las temperaturas de los diferentes segmentos del lazo como salida para obtener el FIS. Básicamente, el observador se entrenará en función de la diferencia térmica entre la temperatura de entrada y salida y el caudal de aceite. De esta manera, dado un caudal y un salto térmico (que incluye implícitamente, para un caudal, la radiación, la eficiencia geométrica y la temperatura ambiente), se puede estimar la temperatura de cada segmento. Esta forma de entrenar el sistema ha sido elegida para reducir el conjunto de datos y evitar la explosión de reglas.

Para obtener el observador FIS, el lazo se dividirá en 16 segmentos ((Gallego et al., 2013)), en lugar de los 172 segmentos en los que el modelo de parámetros distribuidos se divide, por razones computacionales y el tamaño de FIS. La estimación borrosa de cada una de las temperaturas de los 16 segmentos se realiza con el mismo tiempo de muestreo que se usa en el controlador de la planta, generalmente, $T_s = 39\text{s}$, (Camacho et al., 1997).

Inicialmente, para obtener las funciones de pertenencia, es útil utilizar un método de agrupación o *clustering*. Se pueden usar múltiples algoritmos para el análisis de agrupamiento (Everitt et al., 2009; Jain et al., 1999; Berkhin, 2006; Xu and Wunsch, 2005). Un algoritmo rápido de una sola iteración para estimar el número de clústeres y sus centros de un conjunto de datos es el clúster sustractivo (*Subtractive Clustering, SC*) (Chiu, 1994). Esta técnica, como cualquier método de agrupación, se utiliza para obtener las variables lingüísticas apropiadas. El método SC es una modificación del Método *Mountain* (Yager and Filev, 1994).

Después de aplicar el SC y el método BP híbrido, se obtienen seis reglas ((Sánchez et al., 2018)):

IF $x_1(k)$ is F_{1i} AND $x_2(k)$ is F_{2i} , THEN: $y_1(k) = a_{1i} x_1(k) + a_{2i} x_2(k) + a_{3i}$, $1 \leq i \leq 6$

La Figura 3 muestra las funciones de pertenencia resultantes para cada entrada (diferencia térmica y flujo de entrada-salida) y cada segmento. Se pueden observar similitudes entre las funciones de cada lazo. A continuación, se presentan los resultados de las estimaciones de temperatura de los segmentos de los lazos utilizando el observador basado en los FIS. Acurex es una planta que consta de 10 lazos que pueden tener diferentes reflectividades debido a la suciedad. Las simulaciones se han llevado a cabo aplicando un controlador basado en modelo (MPC) para el seguimiento de referencia de temperatura de salida del campo. Dado que la planta consta de diez lazos, la temperatura de salida del campo será el promedio ponderado de las temperaturas de todos los lazos. La consigna de temperatura se modifica para cambiar el punto de operación de la planta y verificar el rendimiento de la estimación en diferentes puntos de trabajo. Para el control, se ha utilizado una técnica de Control Predictivo Generalizado (GPC) junto a un *FeedForward* en serie.

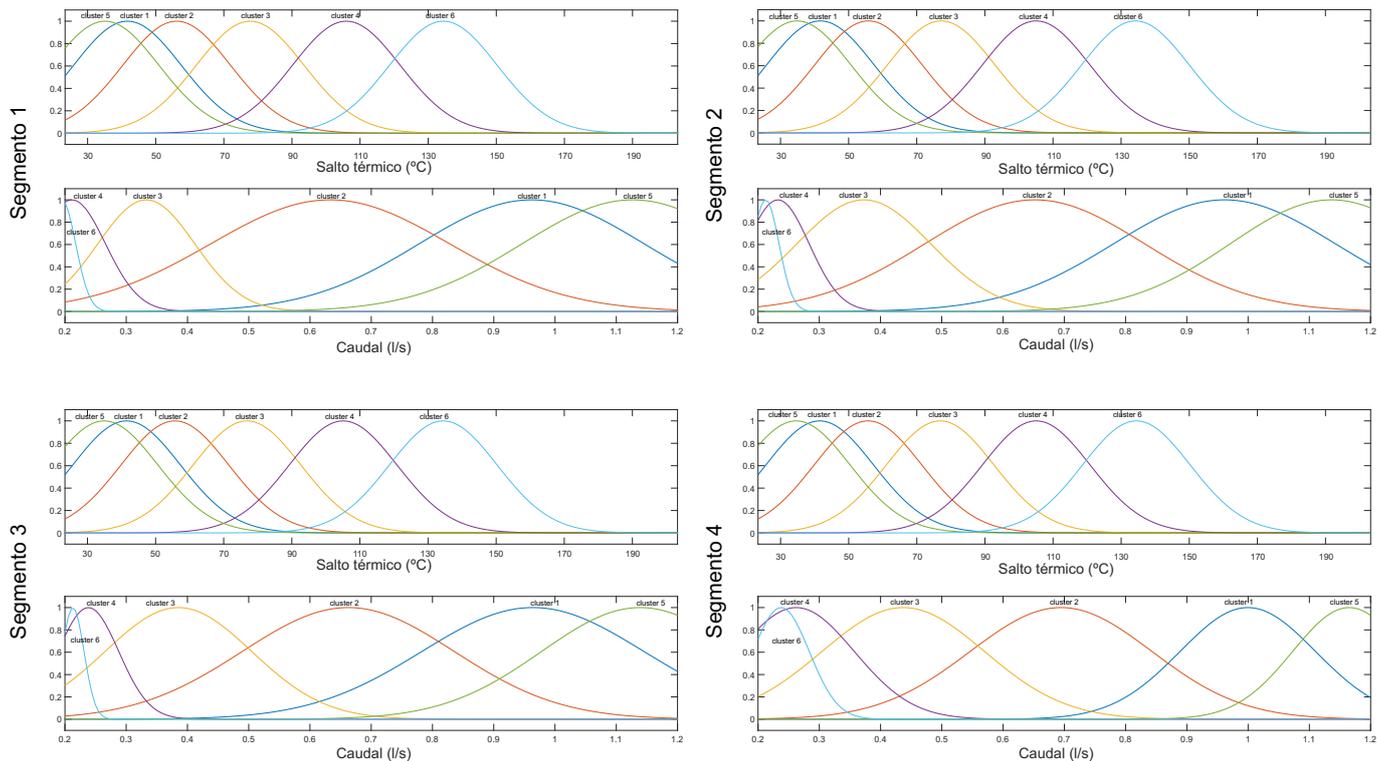
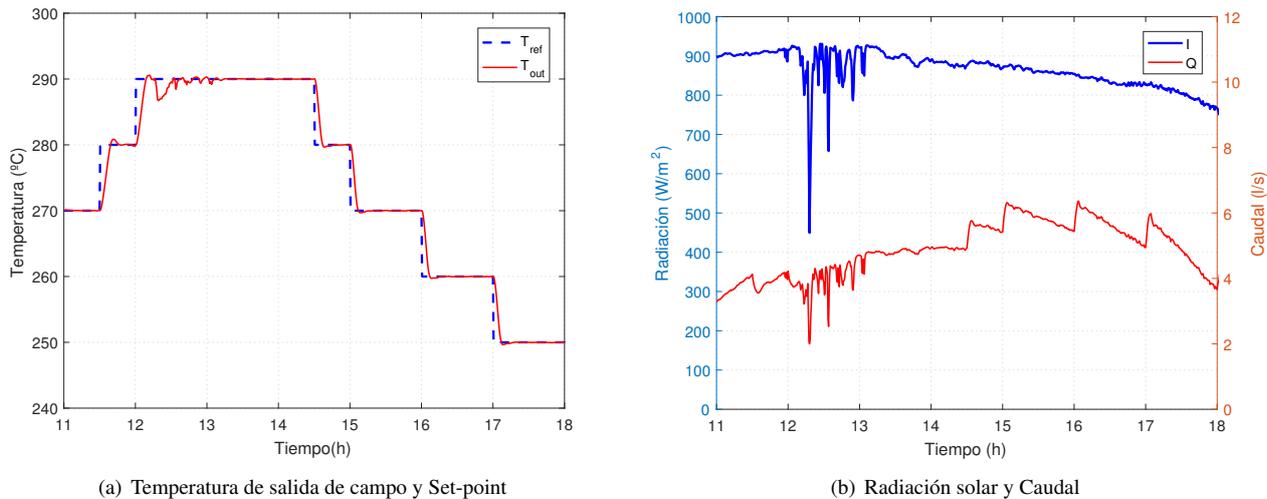


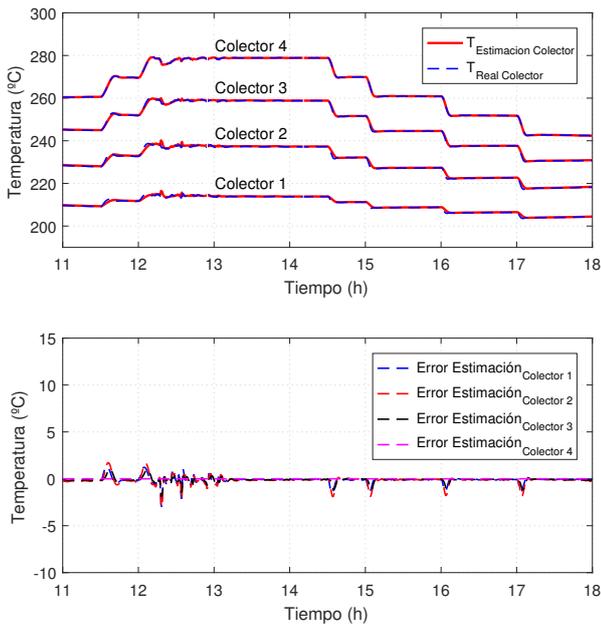
Figura 3: Funciones de pertenencia del observador FIS. Donde el eje de ordenadas representa el grado de pertenencia de las funciones



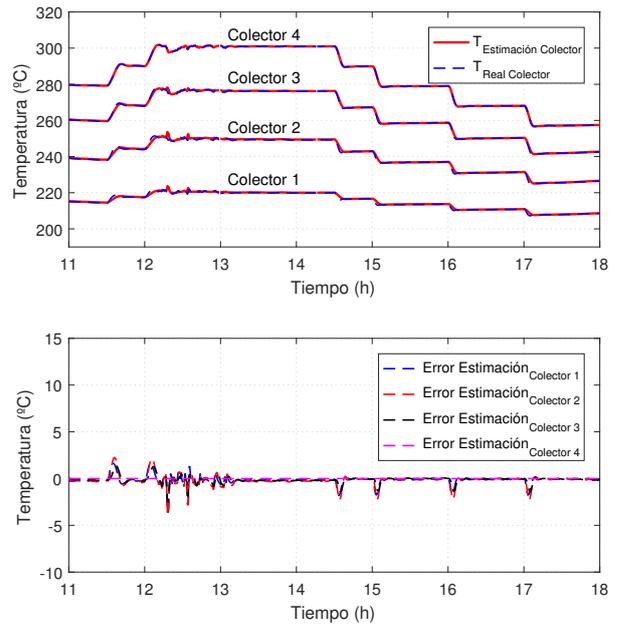
(a) Temperatura de salida de campo y Set-point

(b) Radiación solar y Caudal

Figura 4: Escenario 1. Temperatura de salida de campo (GPC control). Seguimiento de set-point.



(a) Lazo 1, reflectividad: 0.65.



(b) Lazo 10, reflectividad: 0.8.

Figura 5: Escenario 1. Estimación y error de las temperaturas de los colectores usando el observador FIS.

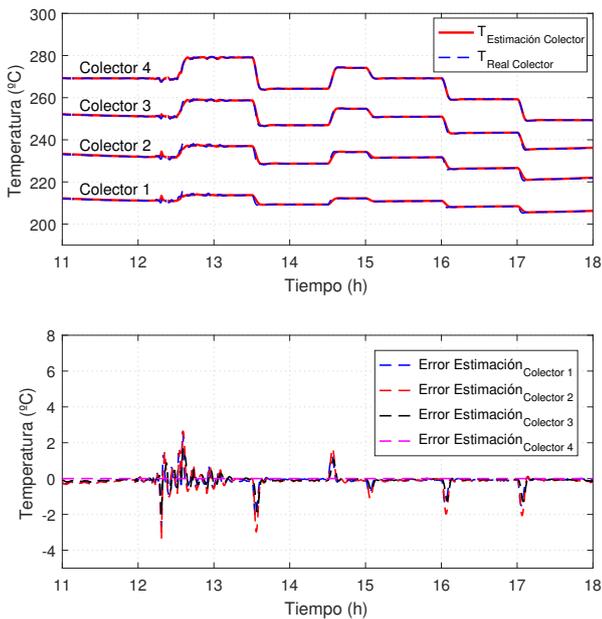


Figura 6: Escenario 2. Lazo 4, reflectividad: 0.74. Estimación y error de las temperaturas de los colectores usando el observador FIS.

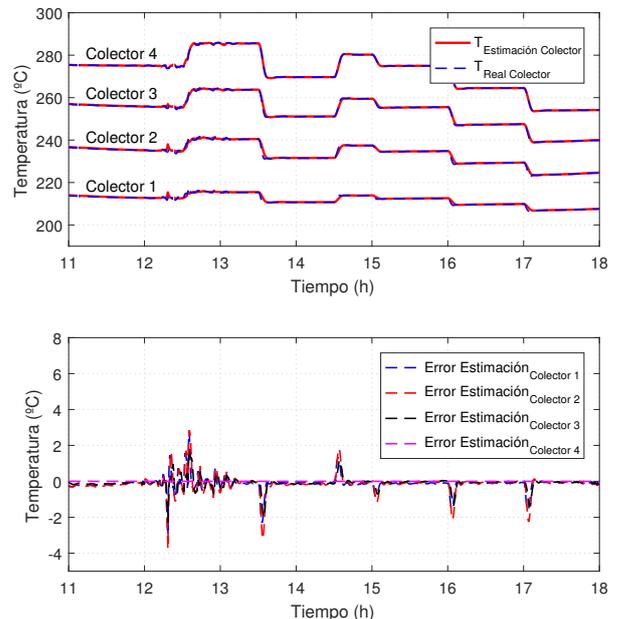


Figura 7: Escenario 2. Lazo 8, reflectividad: 0.79. Estimación y error de las temperaturas de los colectores usando el observador FIS.

Este controlador se basa en funciones de transferencia y considera el campo solar como un solo lazo. Se han simulado dos escenarios diferentes en distintos puntos de trabajo a lo largo del día.

En estas simulaciones, cada lazo tiene una reflectividad diferente, consultar la Tabla 2.

Los lazos se han simulado con diferentes valores de reflectividad, simulando suciedad, para mostrar que el observador propuesto puede proporcionar estimaciones correctas a pesar de que los parámetros de los lazos varíen.

Por razones visuales y de espacio, se presentan los resultados de dos de los diez lazos con diferentes reflectividades. Se presentan las estimaciones de 4 segmentos correspondientes a cada uno de los 4 colectores de los lazos.

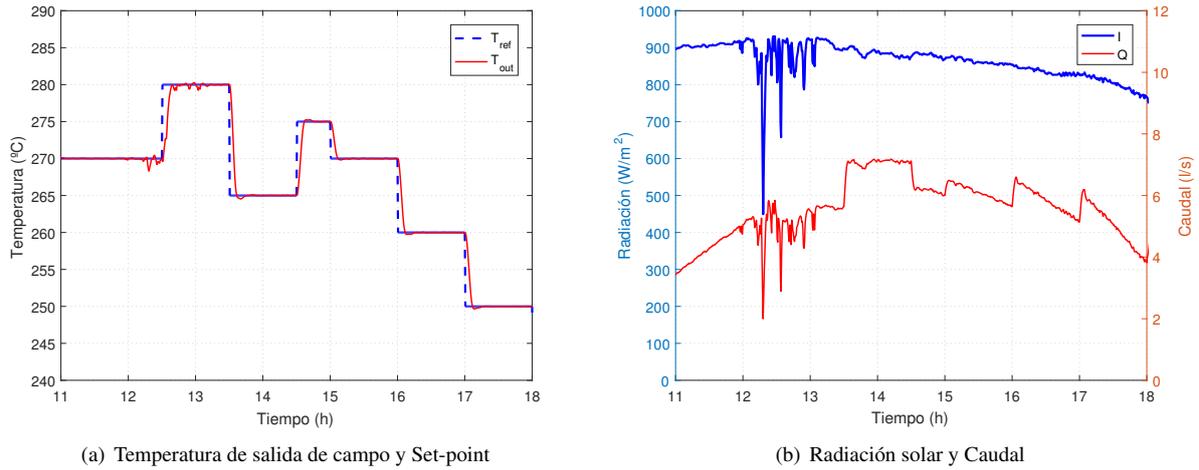


Figura 8: Escenario 2. Temperatura de salida de campo (GPC control). Seguimiento de set-point.

El primer escenario simulado se presenta en las Figuras 4 y 5. La Figura 4 presenta la simulación del funcionamiento del GPC para el caso 1 en la que se puede ver cómo el controlador realiza un buen seguimiento del set-point de la temperatura de salida del campo. La Figura 5 muestra la estimación de las temperaturas/errores de los segmentos de los lazos 1 y 10, con reflectividades 0.65 y 0.8 respectivamente. Se puede observar que el estimador tiene un buen comportamiento.

Tabla 2: Escenarios simulados. Reflectividad de lazos

| Número Lazo | Escenario 1 | Escenario 2 |
|-------------|-------------|-------------|
| 1 | 0.65 | 0.67 |
| 2 | 0.67 | 0.71 |
| 3 | 0.68 | 0.71 |
| 4 | 0.70 | 0.74 |
| 5 | 0.715 | 0.74 |
| 6 | 0.73 | 0.76 |
| 7 | 0.75 | 0.76 |
| 8 | 0.77 | 0.79 |
| 9 | 0.79 | 0.79 |
| 10 | 0.80 | 0.80 |

El primer escenario simulado se presenta en las Figuras 4 y 5. La Figura 4 presenta la simulación del funcionamiento del GPC para el caso 1 en la que se puede ver cómo el controlador realiza un buen seguimiento del set-point de la temperatura de salida del campo. La Figura 5 muestra la estimación de las temperaturas/errores de los segmentos de los lazos 1 y 10, con reflectividades 0.65 y 0.8 respectivamente. Se puede observar que el estimador tiene un buen comportamiento.

Respecto al lazo 10, se observa que, aunque tiene una reflectividad más alta que el lazo 1, el estimador tiene un buen rendimiento ya que las temperaturas de entrada y salida se utilizan como entradas para el sistema borroso. Como se explicó anteriormente, dado que solo se usaron las temperaturas y el caudal de aceite para el entrenamiento, la reflectividad se refleja implícitamente en la diferencia de temperatura entre las temperaturas de entrada y salida.

El segundo escenario simulado se presenta en las Figuras 8, 6 y 7. Como antes, el resultado del funcionamiento del GPC

para el caso 2 se presenta en la Figura 8.

Las Figuras 6 y 7 muestran los resultados de la estimación usando el FIS de los segmentos de los lazos 4 y 8, con 0.74 y 0.79 de reflectividad respectivamente. Una vez más, se puede observar que la estimación es bastante fiel al comportamiento real del lazo, tanto en la zona dinámica como en el estado estable en los diferentes puntos de operación.

4. Reducción del FIS mediante FPCA

Considerando los escenarios previos y tomando el modelo de parámetros distribuidos (2,3) con 172 segmentos, si el número de reglas por segmento es de 6, se tendrán 1032 reglas por cada FIS, lo que hace un total de 10320 reglas. Aunque los modernos PLC tienen una capacidad de memoria grande, se debe tener en cuenta que el tiempo empleado por el programador para escribir todas y cada una de las reglas en cada uno de los FIS, puede que no compense económicamente, comparado con estrategias de control más simples. Se hace necesario reducir el número de reglas. Una manera sistemática de lograrlo es mediante la aplicación de un FPCA sobre los FIS, tal y como se muestra más detalladamente en (Escaño and Bordons, 2014) y (Escaño et al., 2019).

Tomando el operador AND de cada una de las reglas de los FIS, como la multiplicación de los *grados de pertenencia*, con un vector de entrada $\mathbf{x} = \{x_1, x_2, \dots, x_n\}$:

$$\bar{\mu}_j = \prod_{i=1}^n \mu_{ji} \quad (5)$$

Y usando como método de defuzificación la media ponderada, para un sistema TS, la salida de cada FIS será:

$$\frac{\sum_{j=1}^N \bar{\mu}_j(\mathbf{x}) h_j(\mathbf{x})}{\sum_{j=1}^N \bar{\mu}_j(\mathbf{x})} = \sum_{j=1}^N \alpha_j(\mathbf{x}) h_j(\mathbf{x}) \quad (6)$$

Siendo $\alpha_j(\mathbf{x})$ las *funciones antecedentes* y $h_j(\mathbf{x})$ las *funciones consecuentes*. Si $h_j(\mathbf{x}) = \gamma_{0j} + \gamma_{1j}x_1 + \dots + \gamma_{nj}x_n$ son funciones lineales afines, con $\gamma_{ij} \in \mathbb{R}$, la salida es:

$$y(\mathbf{x}) = \sum_{j=1}^N \alpha_j(\mathbf{x}) (\gamma_{0j} + \gamma_{1j}x_1 + \dots + \gamma_{nj}x_n). \quad (7)$$

Que puede ser reescrita como:

$$y(\mathbf{x}) = \tilde{\gamma}_0(\mathbf{x}) + \tilde{\gamma}_1(\mathbf{x})x_1 + \dots + \tilde{\gamma}_n(\mathbf{x})x_n, \quad (8)$$

donde:

$$\tilde{\gamma}_i(\mathbf{x}) = \sum_{j=1}^N \alpha_j(\mathbf{x}) \cdot \gamma_{ji}. \quad (9)$$

El vector de funciones $\tilde{\gamma}$ es:

$$\tilde{\gamma}(\mathbf{x}) = \begin{bmatrix} \tilde{\gamma}_0(\mathbf{x}) \\ \tilde{\gamma}_1(\mathbf{x}) \\ \vdots \\ \tilde{\gamma}_n(\mathbf{x}) \end{bmatrix} = \begin{bmatrix} \gamma_{10} & \gamma_{20} & \dots & \gamma_{N0} \\ \gamma_{11} & \gamma_{21} & \dots & \gamma_{N1} \\ \vdots & \vdots & & \vdots \\ \gamma_{1n} & \gamma_{2n} & \dots & \gamma_{Nn} \end{bmatrix} \cdot \begin{bmatrix} \alpha_1(\mathbf{x}) \\ \alpha_2(\mathbf{x}) \\ \vdots \\ \alpha_N(\mathbf{x}) \end{bmatrix},$$

$$\tilde{\gamma}(\mathbf{x}) = \mathbf{\Gamma} \cdot \boldsymbol{\alpha}(\mathbf{x}). \quad (10)$$

Si se definen las funciones media y covarianza de $\tilde{\gamma}(\mathbf{x})$, como:

$$E[\tilde{\gamma}(\mathbf{x})] = E[\boldsymbol{\gamma}^T] \cdot \boldsymbol{\alpha}(\mathbf{x}) = \tilde{\boldsymbol{\gamma}}^T \cdot \boldsymbol{\alpha}(\mathbf{x}),$$

$$Cov[\tilde{\gamma}(\mathbf{x}), \tilde{\gamma}(\mathbf{s})] = \boldsymbol{\alpha}(\mathbf{x})^T cov(\mathbf{\Gamma})\boldsymbol{\alpha}(\mathbf{s}). \quad (11)$$

definimos también el operador de covarianza como:

$$C(\tilde{\gamma}(\mathbf{x})) = \int_0^X Cov[\tilde{\gamma}(\mathbf{x}), \tilde{\gamma}(\mathbf{z})] \cdot \delta(\mathbf{z})d\mathbf{z}, \quad (12)$$

$$\forall \tilde{\gamma} \in L^2[0, X], \forall x, z \in [0, X]$$

Supongamos que las autofunciones resultantes del análisis FPCA descrito en (Escaño and Bordons, 2014) y (Escaño et al., 2019) son

$$\boldsymbol{\delta}(\mathbf{x}) = \boldsymbol{\alpha}(\mathbf{x})^T \cdot \boldsymbol{\beta}, \quad (13)$$

siendo $\boldsymbol{\beta} \in \mathbb{R}^{N \times N}$. Teniendo en cuenta (11), el operador de covarianza será, entonces:

$$\int_0^X Cov[\tilde{\gamma}(\mathbf{x}), \tilde{\gamma}(\mathbf{z})] \cdot \delta(\mathbf{z})d\mathbf{z} = \quad (14)$$

$$\int_0^X \boldsymbol{\alpha}(\mathbf{x})^T cov(\mathbf{\Gamma})\boldsymbol{\alpha}(\mathbf{z}) \cdot \boldsymbol{\alpha}(\mathbf{z})^T \cdot \boldsymbol{\beta}d\mathbf{z} =$$

$$\boldsymbol{\alpha}(\mathbf{x})^T cov(\mathbf{\Gamma}) \cdot \mathbf{W} \cdot \boldsymbol{\beta}; \quad (15)$$

por tanto, la ecuación integral del análisis FPCA, teniendo en cuenta (13), queda como:

$$\boldsymbol{\alpha}(\mathbf{x})^T cov(\mathbf{\Gamma}) \cdot \mathbf{V} \cdot \boldsymbol{\beta} = \lambda \cdot \boldsymbol{\alpha}(\mathbf{x})^T \cdot \boldsymbol{\beta};$$

$$\Rightarrow cov(\mathbf{\Gamma}) \cdot \mathbf{V} \cdot \boldsymbol{\beta} = \lambda \cdot \boldsymbol{\beta}, \quad (16)$$

donde:

$$\mathbf{V} = \int_0^X \boldsymbol{\alpha}(\mathbf{z}) \cdot \boldsymbol{\alpha}(\mathbf{z})^T d\mathbf{z}. \quad (17)$$

Las funciones $\boldsymbol{\delta}(\mathbf{x})$ son ortogonales, luego

$$\langle \boldsymbol{\delta}_i(\mathbf{x}), \boldsymbol{\delta}_j(\mathbf{x}) \rangle = \boldsymbol{\beta}_i^T \cdot \mathbf{V} \cdot \boldsymbol{\beta}_j = 0.$$

La matriz \mathbf{V} es simétrica por definición, luego, definiendo $\mathbf{u} = \mathbf{V}^{\frac{1}{2}}\boldsymbol{\beta}$,

$$\mathbf{V}^{\frac{1}{2}} \cdot cov(\mathbf{\Gamma}) \cdot \mathbf{V}^{\frac{1}{2}} \cdot \mathbf{u} = \lambda \cdot \mathbf{u}. \quad (18)$$

De esta forma, el problema se reduce a uno simétrico de valores propios. Una vez conocidas las funciones propias (13), la nueva matriz de consecuentes \mathbf{P} , se obtiene de

$$\tilde{\gamma}(\mathbf{x}) = \mathbf{\Gamma} \cdot \boldsymbol{\alpha}(\mathbf{x}) = \mathbf{P} \cdot \boldsymbol{\delta}(\mathbf{x}), \quad (19)$$

Aplicando la técnica de reducción a los FIS que estiman la temperatura de los cuatro colectores a lo largo del primer lazo del escenario 1, se obtienen las siguientes matrices de cambio de base de antecedentes ($\boldsymbol{\beta}_{FISi}$), junto a los autovalores (λ_{FISi}):

$$\boldsymbol{\beta}_{FIS1} = \begin{bmatrix} 0,1329 & 0,0400 & -0,3690 & -0,5631 & 0,1133 & 0,2597 \\ 0,1334 & -0,1246 & 0,2845 & 0,0074 & -0,0941 & -0,1652 \\ 0,1352 & 0,0006 & 0,0582 & 0,1421 & 0,0052 & 0,4935 \\ 0,1414 & 0,3406 & 0,2007 & -0,0383 & 0,6775 & -0,2722 \\ 0,1416 & -0,0443 & 0,1044 & 0,7475 & -0,1161 & -0,3425 \\ 0,1547 & 1,0611 & 0,0328 & -0,1125 & -1,2269 & 0,1277 \end{bmatrix},$$

$$\boldsymbol{\beta}_{FIS2} = \begin{bmatrix} 0,1357 & -0,0273 & -0,0781 & -0,6371 & 0,1755 & 0,0329 \\ 0,1272 & 0,0958 & 0,0913 & 0,1708 & -0,2427 & -0,2222 \\ 0,1308 & 0,0284 & 0,0072 & 0,0667 & 0,4306 & -0,0773 \\ 0,1442 & -0,2435 & -0,6560 & 0,0810 & -0,2210 & -0,0707 \\ 0,1406 & 0,0934 & 0,0929 & 0,6909 & -0,1936 & 0,3160 \\ 0,1698 & -0,8322 & 0,7652 & -0,0124 & 0,0747 & -0,0005 \end{bmatrix},$$

$$\boldsymbol{\beta}_{FIS3} = \begin{bmatrix} 0,1403 & -0,0370 & 0,4681 & 0,3087 & -0,3062 & 0,1702 \\ 0,1215 & 0,0903 & -0,1438 & 0,0738 & 0,3229 & -0,1682 \\ 0,1276 & 0,0348 & 0,2535 & -0,3323 & -0,0607 & -0,0235 \\ 0,1471 & -0,2449 & -0,1326 & 0,0386 & 0,3083 & 0,5850 \\ 0,1423 & 0,1181 & -0,6996 & -0,3434 & 0,0442 & -0,1230 \\ 0,1865 & -0,8935 & 0,0154 & -0,0067 & -0,2255 & -0,7451 \end{bmatrix},$$

$$\boldsymbol{\beta}_{FIS4} = \begin{bmatrix} 0,1329 & 0,0400 & -0,3690 & -0,5631 & 0,1133 & 0,2597 \\ 0,1334 & -0,1246 & 0,2845 & 0,0074 & -0,0941 & -0,1652 \\ 0,1352 & 0,0006 & 0,0582 & 0,1421 & 0,0052 & 0,4935 \\ 0,1414 & 0,3406 & 0,2007 & -0,0383 & 0,6775 & -0,2722 \\ 0,1416 & -0,0443 & 0,1044 & 0,7475 & -0,1161 & -0,3425 \\ 0,1547 & 1,0611 & 0,0328 & -0,1125 & -1,2269 & 0,1277 \end{bmatrix},$$

$$\lambda_{FIS1} = \begin{bmatrix} 3,7277 \cdot 10^5 \\ 325,3 \\ 2,3 \cdot 10^{-11} \\ 2,2 \cdot 10^{-11} \\ 1,5 \cdot 10^{-11} \\ 2 \cdot 10^{-12} \end{bmatrix}, \lambda_{FIS2} = \begin{bmatrix} 1,6806 \cdot 10^5 \\ 681,1 \\ 3,2 \cdot 10^{-11} \\ 9 \cdot 10^{-11} \\ 5,7 \cdot 10^{-12} \\ 6,4 \cdot 10^{-14} \end{bmatrix},$$

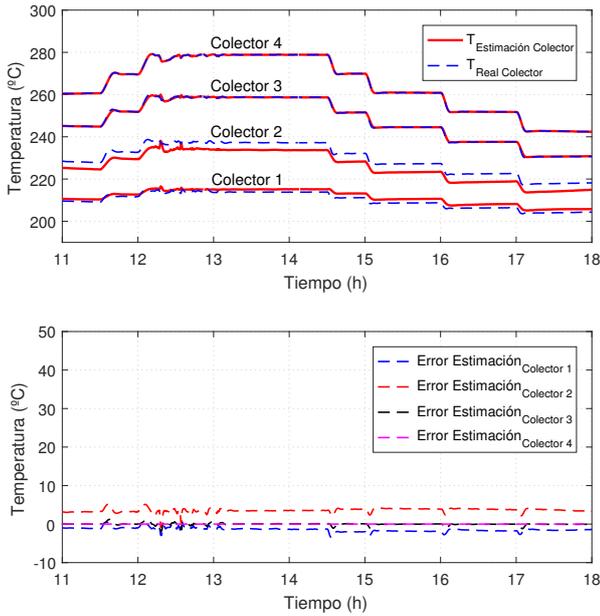
$$\lambda_{FIS3} = \begin{bmatrix} 3,7277 \cdot 10^5 \\ 325,3 \\ 4,8 \cdot 10^{-12} \\ 3 \cdot 10^{-12} \\ 1,5 \cdot 10^{-12} \\ 1,3 \cdot 10^{-12} \end{bmatrix}, \lambda_{FIS4} = \begin{bmatrix} 14,40 \\ 9,8 \cdot 10^{-15} \\ 2 \cdot 10^{-15} \\ 3 \cdot 10^{-16} \\ 8 \cdot 10^{-17} \\ 3 \cdot 10^{-17} \end{bmatrix}.$$

Se puede elegir un nuevo subespacio, usando una nueva base de autofunciones, cuyos autovalores cumplen un criterio de variabilidad, o significancia, por ejemplo

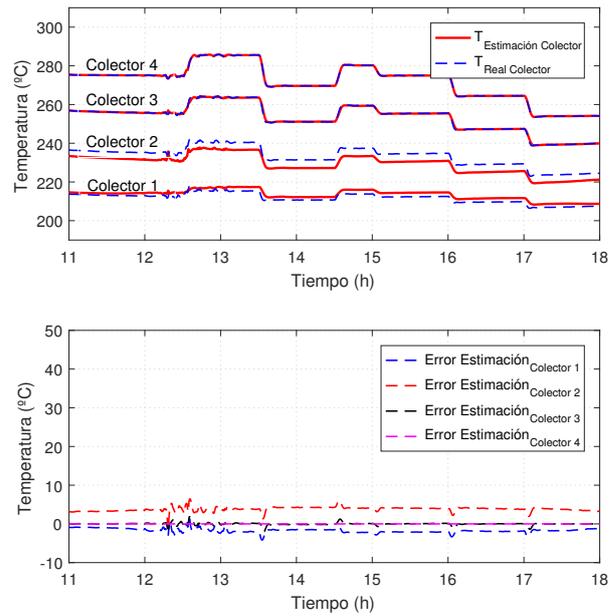
$$\frac{\sum_{i=1}^R \lambda_i}{\sum_{i=1}^N \lambda_i} \geq v, \quad (20)$$

donde $v \in [0, 1]$ es un índice de variabilidad. El valor $v = 1$ corresponde a la máxima variabilidad, la cual correspondería a la dimensión que cubre la suma total de los valores propios. Llamaremos N a la dimensión del espacio original y R a la del reducido.

Usando ese criterio, se observa que el primer valor propio contiene la mayor parte del valor de la suma de todos. Sin embargo, usando solo una regla, se puede observar que los estimadores muy cercanos al último segmento son los únicos que presentan un error menor al estimar la temperatura.



(a) Escenario 1. Lazo 1, reflectividad: 0.65.



(b) Escenario 2. Lazo 8, reflectividad: 0.79.

Figura 9: Reducción FPCA a (2,2,5,1) reglas por colector. Estimación y error de las temperaturas.

5. Resultados

La Figura 10 muestra el valor de la temperatura estimada de los colectores a lo largo del primer lazo del escenario 1 cuando solo se utiliza una regla por cada FIS.

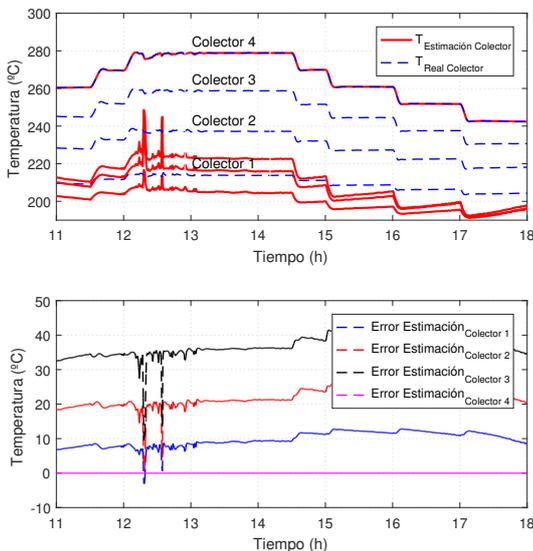


Figura 10: Reducción FPCA. 1 regla por colector. Escenario 1. Lazo 1, reflectividad: 0.65. Estimación y error de las temperaturas.

Es posible comprobar como, con una sola regla por colector, resulta difícil obtener una buena estimación de la temperatura utilizando el FIS, salvo en el caso del último colector. Por ello, los próximos experimentos se realizarán añadiendo más

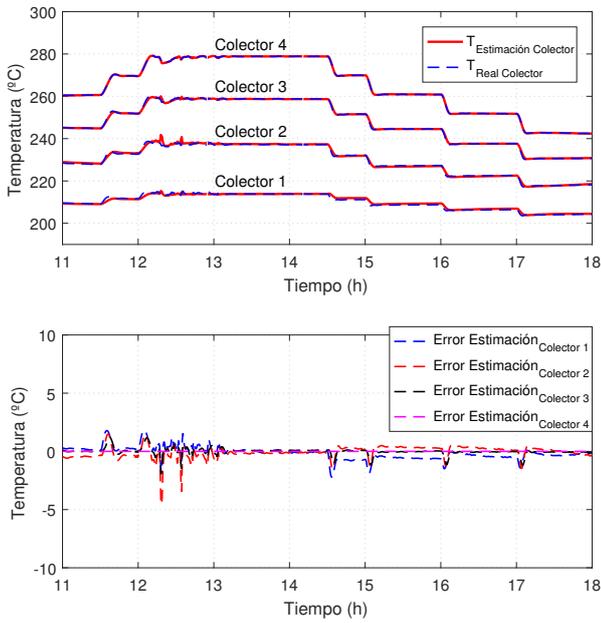
reglas por colector de forma que los errores que se obtengan sean aceptables para su uso.

Utilizando como criterio el número mínimo de reglas que logran un error de estimación aceptable, se llega a la siguiente configuración: 2 reglas para el colector 1-FIS, 2 reglas para el colector 2-FIS, 5 reglas para el colector 3-FIS y 1 regla para el colector 4-FIS (2,2,5,1). Los resultados se muestran en la Figura 9.

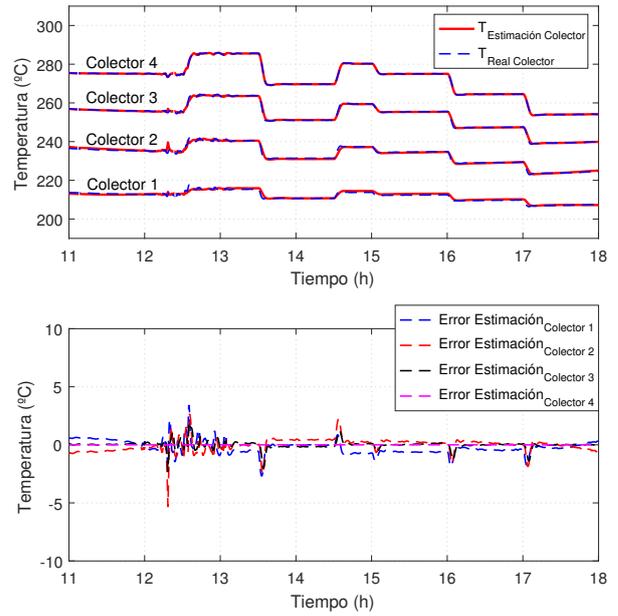
Se comprueba que al añadir más reglas por colector, los resultados mejoran notablemente. Lógicamente, a mayor número de reglas, mejor será la estimación. En este caso, los colectores 3 y 4 presentan unos errores muy cercanos a cero al usar 5 reglas para el colector 3 y 1 para el cuarto colector. Se han añadido más reglas en el tercer colector ya que es en el que se obtuvo un mayor error en la estimación cuando se aplicó una única regla en el caso anterior, Figura 10. Los colectores 1 y 2 presenta unos errores de estimación constante que puede eliminarse. La Figura 11 presenta los resultados después de realizar dicha corrección del error.

La reducción de reglas para el colector 3 implica arrastrar continuamente un gran error, pero aproximadamente constante. La Figura 12 muestra los errores de estimación al considerar una configuración de 2 reglas para colector 1-FIS, 2 reglas para colector 2-FIS, 2 reglas para colector 3-FIS y 1 regla para colector 4-FIS (2,2,2,1), para el escenario 1, lazos 1 y 10.

Las Figuras 13 (a,b,c,d) presentan la estimación de las temperaturas de colectores al eliminar el promedio de los errores obtenidos previamente para los dos escenarios y los lazos 1, 4, 8 y 10. En los resultados, tras la corrección del error medio, se observa que aunque siguen apareciendo errores en la estimación son pequeños. Se puede ver que, en general, el error cometido en la estimación de las temperaturas de los colectores durante la operación, está por debajo de 2,5°C. Se observa

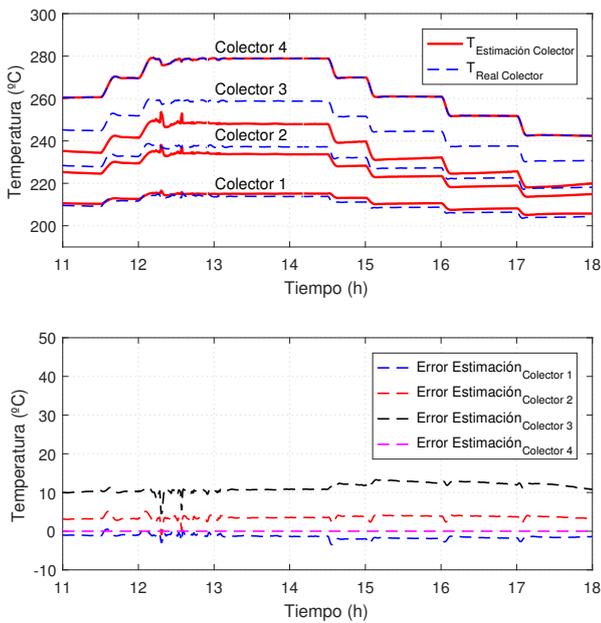


(a) Escenario 1. Lazo 1, reflectividad: 0.65.

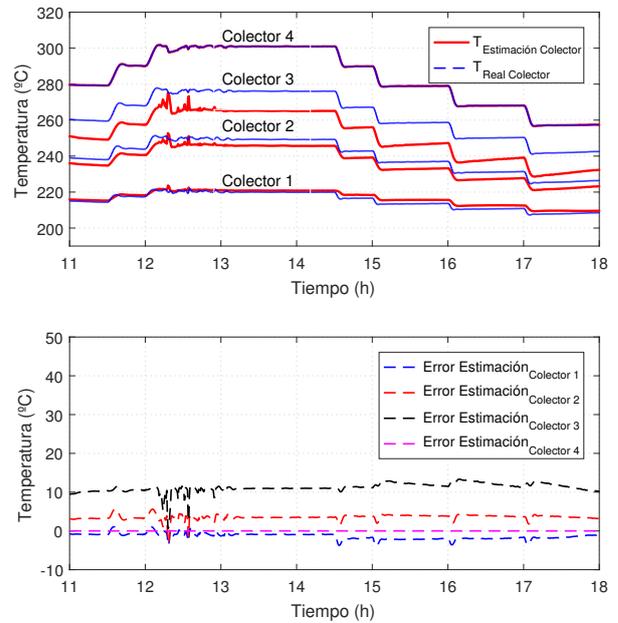


(b) Escenario 2. Lazo 8, reflectividad: 0.79.

Figura 11: Reducción FPCA a (2,2,5,1) reglas por colector y corrección del error medio. Estimación y error de las temperaturas.

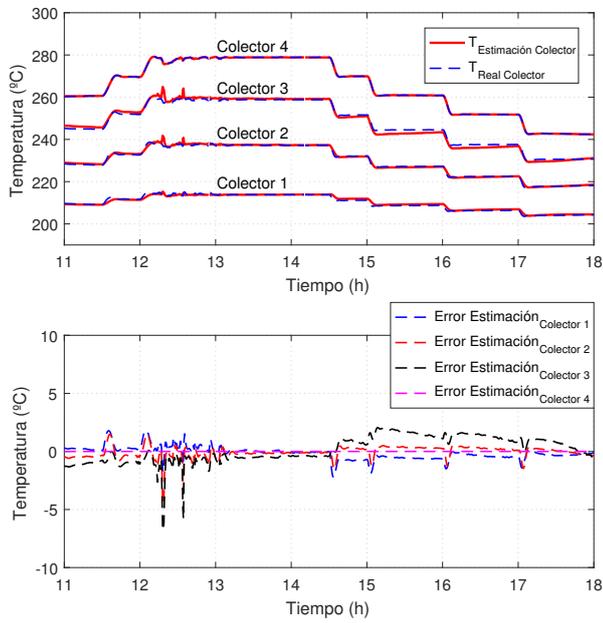


(a) Lazo 1, reflectividad: 0.65.

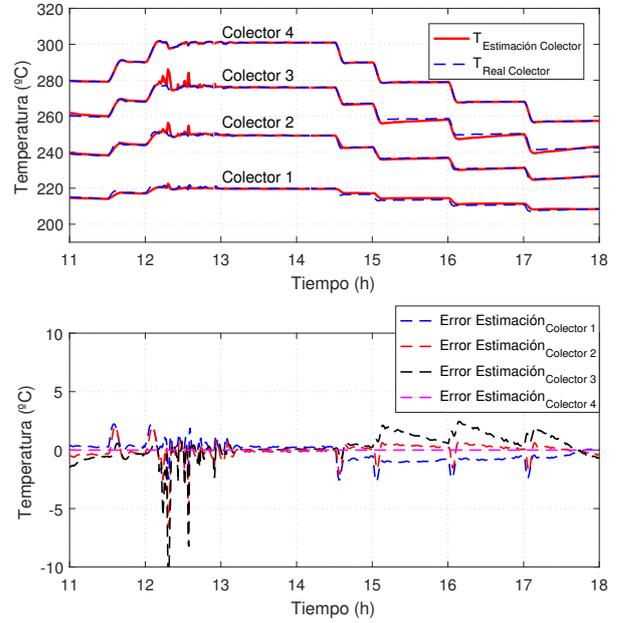


(b) Lazo 10, reflectividad: 0.8.

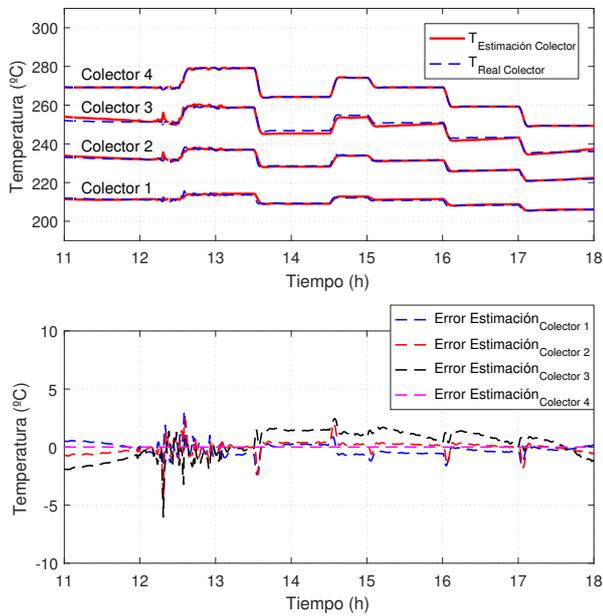
Figura 12: Escenario 1. Reducción FPCA a (2,2,2,1) reglas por colector. Estimación y error de las temperaturas.



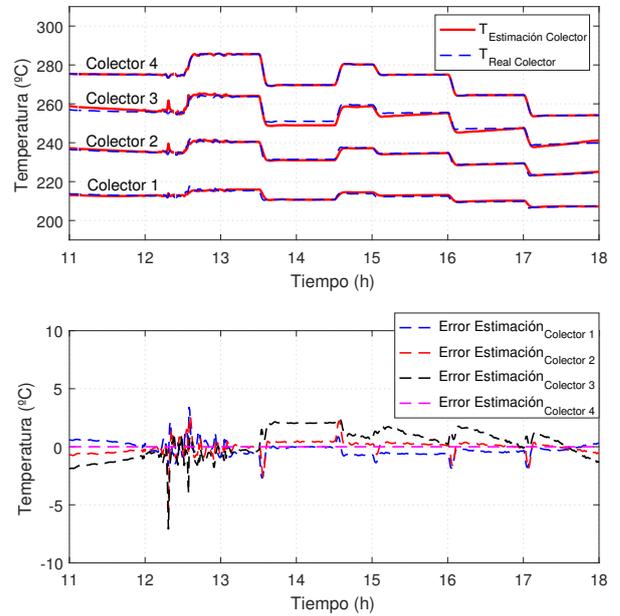
(a) Lazo 1, reflectividad: 0.65.



(b) Lazo 10, reflectividad: 0.8.



(c) Lazo 4, reflectividad: 0.74.



(d) Lazo 8, reflectividad: 0.79.

Figura 13: Resultados del estimador con las reglas (2,2,2,1) y corrección del error medio

un pico de unos 10°C de poca duración durante un fuerte transitorio solar que sufre la planta. En general, el error cometido en la estimación es asumible y menor, en términos generales, que el obtenido con un estimador robusto Luenberger presentado en (Gallego et al., 2013), donde la ganancia del observador se computa mediante la resolución de problemas LMI. En este estudio los autores presentan las estimaciones y errores obtenidos en el perfil de temperatura de los colectores donde se puede comprobar que, en términos generales los errores cometidos son iguales o menores a 7°C con algunos picos de alrededor de 10°C .

6. Conclusiones

En este trabajo se han desarrollado estimadores borrosos, contruidos a partir de datos, utilizando técnicas de agrupamiento. Se han utilizado para estimar la temperatura de cuatro segmentos de una planta solar térmica cilindro-parabólica. Se han simulado dos casos en los que se han aplicado diferentes set-points de temperatura a la salida del lazo a lo largo del día. En estas simulaciones, cada lazo tiene una reflectividad diferente. Se han obtenido resultados de estimación muy satisfactorios en lazos con diferentes reflectividades. Para reducir el número de reglas, se ha aplicado una técnica FPCA. Después de una corrección de error, los resultados de la estimación siguen siendo satisfactorios, lo que permite reducir la memoria y el esfuerzo de programación.

Agradecimientos

Los autores desean agradecer al VI Plan de Investigación y Transferencia de la Universidad de Sevilla (VI PPIT-US), al Ministerio de Economía y Competitividad bajo la subvención MTM2013-40455-P y al European Research Council bajo el proyecto Advanced Research Grant OCONTSOLAR (789051) por financiar este trabajo.

Referencias

- Berkhin, P., 2006. Grouping Multidimensional Data Recent Advances in Clustering. Springer Berlin Heidelberg, Berlin, Heidelberg, Ch. A Survey of Clustering Data Mining Techniques, pp. 25–71.
- Blackwell, W. J., Milstein, A. B., Zavodsky, B., Blankenship, C. B., 2014. Neural network estimation of atmospheric thermodynamic state for weather forecasting applications. In: Schmorow, D. D., Fidopiastis, C. M. (Eds.), Foundations of Augmented Cognition. Advancing Human Performance and Decision-Making through Adaptive Systems. Springer International Publishing, Cham, pp. 93–103.
- Camacho, E. F., Berenguel, M., Rubio, F. R., 1997. Advanced Control of Solar Plants. Springer Science & Business Media.
- Carmona, R., 1985. Analisis, modelado y control de un campo de colectores solares distribuidos con sistema de seguimiento en un eje. Ph.D. thesis. Universidad de Sevilla.
- Chiu, S., 1994. Fuzzy Model Identification based on cluster estimation. Journal of Intelligent Fuzzy Systems 2, 267–278.
- Cirre, C. M., Valenzuela, L., Berenguel, M., Camacho, E. F., 2010. Control de plantas solares con generación automática de consignas. Revista Iberoamericana de Automática e Informática industrial 1 (1), 50–56.
- Cordon, O., Herrera, F., Hoffmann, F., Magdalena, L., 2001. Genetic Fuzzy Systems. World Scientific Publishing Company Singapore.
- Escaño, J., Bordons, C., 01 2014. Fuzzy Modeling and Control: Theory and Applications. Atlantis Computational Intelligence Systems. Atlantis Press, Paris, Ch. Complexity Reduction in Fuzzy Systems Using Functional Principal Component Analysis, pp. 49–65.
- Escaño, J., Bordons, C., Withephanich, K., Gómez-Estern, F., 07 2019. Fuzzy model predictive control: Complexity reduction for implementation in industrial systems. International Journal of Fuzzy Systems.
- Everitt, B. S., Landau, S., Leese, M., 2009. Cluster Analysis, 4th Edition. Wiley Publishing.
- Gallego, A. J., Camacho, E. F., 2012. Adaptive state-space model predictive control of a parabolic-trough field. Control Engineering Practice 20 (9), 904 – 911.
- Gallego, A. J., Fele, F., Camacho, E. F., Yebra, L., 2013. Observer-based model predictive control of a parabolic-trough field. Solar Energy 97, 426 – 435.
- Ghosh, A., Chakraborty, M., 2012. Hybrid optimized back propagation learning algorithm for multi-layer perceptron. International Journal of Computer Applications 57.
- Guzmán, 2018. <https://www.nrel.gov/csp/solarpaces/project_detail.cfm/projectID=18>.
- Jain, A. K., Murty, M. N., Flynn, P. J., Sep. 1999. Data clustering: A review. ACM Comput. Surv. 31 (3), 264–323.
- Jang, J., May 1993. Anfis: adaptive-network-based fuzzy inference system. IEEE Transactions on Systems, Man, and Cybernetics 23 (3), 665–685.
- Karamali, M., Khodabandeh, M., 2017. A distributed solar collector field temperature profile control and estimation using inlet oil temperature and radiation estimates based on iterative extended kalman filter. Renewable Energy 101, 144 – 155.
- Kaxu Solar One, 2018. <https://www.nrel.gov/csp/solarpaces/project_detail.cfm/projectID=245>.
- Li, I.-H., Wang, W.-Y., Su, S.-F., Lee, Y.-S., Sep. 2007. A merged fuzzy neural network and its applications in battery state-of-charge estimation. IEEE Transactions on Energy Conversion 22 (3), 697 – 708.
- Rehman, S., Mohandes, M., 2008. Artificial neural network estimation of global solar radiation using air temperature and relative humidity. Energy Policy 36 (2), 571 – 576.
- Rubio, F. R., Camacho, E. F., Berenguel, M., 2009. Control de campos de colectores solares. Revista Iberoamericana de Automática e Informática industrial 3 (4), 26–45.
- Sánchez, A. J., Gallego, A. J., Escaño, J. M., Camacho, E. F., 2018. Temperature homogenization of a solar trough field for performance improvement. Solar Energy. Elsevier. 165C, 1–9.
- Sánchez, A. J., Escaño, J. M., Bordons, C., Camacho, E. F., 2018. Estimador borroso de una planta solar cilindro-parabólica. In: Actas de las XXXIX Jornadas de Automática, Badajoz, 5-7 de Septiembre de 2018. Universidad de Extremadura, pp. 908–915.
- Solana Generating Station, 2018. <https://www.nrel.gov/csp/solarpaces/project_detail.cfm/projectID=23>.
- Solar Millennium AG, 2018. The construction of the andasol power plants. <http://www.solarmillennium.de/english/archives/technology/references-and-projects/andasol-spain/andasol_artikel.html>.
- Takagi, T., Sugeno, M., Jan. 1985. Fuzzy identification of systems and its applications to modeling and control. IEEE Transactions on Systems, Man, and Cybernetics 15 (1), 116–132.
- Werbos, P. J., 1974. Beyond regression: New tools for prediction and analysis in the behavioral sciences. Ph.D. thesis, Harvard University.
- Xu, R., Wunsch, D., I., May 2005. Survey of clustering algorithms. Neural Networks, IEEE Transactions on 16 (3), 645–678.
- Yager, R. R., Filev, D. P., Aug 1994. Approximate clustering via the mountain method. IEEE Transactions on Systems, Man, and Cybernetics 24 (8), 1279–1284.