

Control predictivo de sistemas ciberfísicos

José María Maestre^{a,b,*}, Paula Chanfreut^a, Javier García Martín^a, Eva Masero^a, Masaki Inoue^b, Eduardo F. Camacho^a

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

^bGraduate School of Science and Technology, Keio University Address: 3-14-1 Hiyoshi, Kohoku-ku, Yokohama, Kanagawa, Japan.

To cite this article: Maestre, J. M., Chanfreut, P., García Martín, J., Masero, E., Inoue, M., Camacho, E. F. 2022. Predictive Control of Cyber-Physical Systems. Revista Iberoamericana de Automática e Informática Industrial 19, 1-12. <https://doi.org/10.4995/riai.2021.15771>

Resumen

El control predictivo engloba a una familia de controladores que replanifican continuamente las entradas del sistema durante un cierto horizonte temporal con el fin de optimizar su evolución esperada conforme a un criterio dado. Esta metodología tiene entre sus retos actuales la adaptación al paradigma de los llamados sistemas ciberfísicos, que están compuestos por computadoras, sensores, actuadores y entidades físicas de diversa índole entre las que se incluyen robots e incluso seres humanos que intercambian información con el objetivo de controlar procesos físicos. Este tutorial presenta los conceptos centrales de la integración del control predictivo en este tipo de sistemas mediante el repaso a una serie de ejemplos que explotan la versatilidad de este marco de diseño de controladores para resolver los desafíos que presentan las aplicaciones del siglo XXI.

Palabras clave: Control predictivo basado en modelo, Control de robots y sistemas multi-robot, Sistemas ciber-físicos en control, Interacción persona máquina en sistemas de control automático, Control coalicional.

Predictive Control of Cyber-Physical Systems

Abstract

Predictive control encompasses a family of controllers that continually replan the system inputs during a certain time horizon to optimize their expected evolution according to a given criterion. This methodology has among its current challenges the adaptation to the paradigm of the so-called cyber-physical systems, which are composed of computers, sensors, actuators and physical entities of various kinds, including robots and even human beings who exchange information to control physical processes. This tutorial introduces the core concepts for the application of predictive control to cyber-physical systems by reviewing a series of examples that exploit the versatility of this design framework so as to solve the challenges presented by 21st century applications.

Keywords: Model Predictive Control, Robots and Multi-robot Systems Control, Cyber-Physical Systems Control, Human-Machine Interaction in Automatic Control Systems, Coalitional Control.

1. Introducción

Cuando en 1948 Norbert Wiener definió la cibernética como “*la materia referente al control y teoría de la comunicación, tanto en la máquina como en el animal*” (Wiener, 1948), difícilmente podía imaginar que seis décadas más tarde se acuñaría el concepto de Sistemas Ciber-Físicos (SCF) para referirse a entornos en los que dispositivos como computadoras, sensores y actuadores interactúan con procesos e incluso con agentes de

diversa naturaleza –como robots y seres humanos– con un fin determinado. Procedente del griego, el vocablo cibernética denomina el arte de gobernar una embarcación y de alguna manera evoca al timonel de la nave, que la dirige siguiendo los *objetivos* marcados por el capitán, considerando además el *estado* de la misma y el de los elementos que la rodean (la mar, el viento, etc.) (Martínez, 2004). Por tanto, pone en relieve el papel fundamental desempeñado por el *controlador* de la nave. Esta idea nuclear sigue presente en el ámbito de los SCF, que

*Autor para correspondencia: pepemaestre@us.es
Attribution-NonCommercial-ShareAlike 4.0 International (CC BY-NC-SA 4.0)

pese a –algunos dirán que precisamente por– la plasticidad del sintagma,¹ encierran una serie de problemas desafiantes y actuales en el campo del control relacionados con la integración e interacción entre los diferentes tipos de elementos que componen el sistema. Es por ello que los SCF se han convertido en un campo de investigación de gran importancia con sus numerosas aplicaciones, que incluyen, entre otras, redes inalámbricas de sensores (Wu et al., 2011), redes eléctricas inteligentes (Wolf, 2009), redes de agua urbana (Sun et al., 2020), fotobioreactores (Guzmán et al., 2020), sistemas de destilación (Gil et al., 2020), sistemas de tráfico (Jianjun et al., 2013), sistemas de monitorización médica y cirugía (Dey et al., 2018), procesos agrícolas (Ramírez-Arias et al., 2012) y edificios inteligentes (Schmidt and Åhlund, 2018; Castilla et al., 2010). Además, existen grandes esperanzas de que se constituyan en la tecnología vertebradora de lo que se conoce como industria 4.0 (Lee et al., 2015), propiciando con ello una revolución industrial.

De entre las múltiples metodologías y tecnologías necesarias para abordar la miríada de retos de integración planteados en el ámbito de los SCF, el control predictivo (CP) (Camacho and Bordons, 1999) está llamado a desempeñar un papel relevante, pues representa a una familia de controladores que utiliza un modelo matemático del sistema para predecir su comportamiento durante un cierto horizonte temporal y así calcular una secuencia de actuaciones óptima con la que obtener una evolución deseada, característica esta que le permite reforzar de forma natural en el vínculo entre el controlador y el proceso. Por otra parte, al tratarse de una técnica de control por computador, el CP se nutre directamente de los avances en las tecnologías de información y comunicaciones (TIC) y puede ser programado para funcionar en red, ya sea para intercambiar información con otros controladores o con la nube. Asimismo, puede incorporar de forma natural y explícita aspectos difíciles de gestionar con otras técnicas de control como son, por ejemplo, las restricciones en las variables del problema, los retardos en la dinámica del sistema, las perturbaciones o la existencia de múltiples objetivos de optimización. Por tanto, cabría esperar que el CP proporcionase una solución óptima para el control de los SCF. Sin embargo, su utilización en este ámbito puede no resultar directa debido, fundamentalmente, a las siguientes razones:

- i) dada la naturaleza heterogénea de los elementos del sistema, el problema de control resultante puede ser difícil de formular y, más aún, imposible de resolver en tiempo real desde una perspectiva centralizada;
- ii) el SCF puede estar compuesto por diferentes entidades autónomas con capacidad de decisión y objetivos diferentes, lo que genera conflictos en el intercambio de información y la toma de decisiones.

Ello obliga a abordar esta problemática explotando la enorme versatilidad del CP. Por una parte, se requieren estrategias de control con capacidad para gestionar dinámicas híbridas; por otra, los controladores deberán preservar la autonomía y objetivos de los elementos integrantes del sistema si fuera necesario. En este sentido, se han propuesto gran cantidad de esquemas descentralizados y distribuidos dentro del CP con buenas ca-

racterísticas de escalabilidad y robustez, y un rendimiento global comparable al que se obtendría si se emplearan estrategias centralizadas (Maestre and Negenborn, 2014; Negenborn and Maestre, 2014). Sin embargo, todavía quedan numerosos retos relacionados con la heterogeneidad dentro de los SCF, muy singularmente cuando se considera de forma explícita la presencia de humanos en el bucle de control. Pese a la existencia de algunos resultados aislados relacionados con el modelado (Hatanaka et al., 2015; Hara et al., 2020) y el comportamiento de los operadores (Protte et al., 2020), la investigación en este ámbito todavía es incipiente y se atisban oportunidades claras de investigación en este contexto.

El objetivo de este tutorial es introducir al lector dentro del marco conceptual del control predictivo y su utilización en el contexto de los SCF. Para ello se emplearán una serie de ejemplos prácticos de creciente *carácter ciberfísico* como vehículo de presentación de enfoques y posibilidades en este ámbito. Nótese que la propia abstracción y plasticidad del concepto dificultan enormemente la definición de mecanismos y arquitecturas generales, requiriendo por tanto soluciones especializadas para cada problema.

El resto del artículo se estructura de la siguiente manera: la Sección 2 introduce de manera sencilla y general el control predictivo. La Sección 3 presenta una serie de ejemplos de aplicación que se han estructurado en torno a tres posibilidades diferentes de interacción del controlador predictivo: i) controlador-controlador, ii) controlador-robot y iii) controlador-persona. Finalmente, el artículo concluye con una serie de reflexiones y comentarios acerca del presente y futuro del CP de SCF.

2. Control predictivo.

El CP se ha convertido por méritos propios en una de las técnicas más utilizadas dentro de la industria (Qin and Badgwell, 2003). Su capacidad para incorporar de manera explícita aspectos esenciales en un problema de control como las restricciones, los retardos en la dinámica de los procesos controlados o la existencia de diferentes objetivos de optimización, constituyen la base de su éxito.

Un controlador predictivo comprende los siguientes elementos:

- **Modelo $f(\cdot)$:** describe la evolución temporal del proceso a controlar en términos matemáticos. Se trata de un elemento central del CP porque proporciona el mecanismo para predecir el comportamiento esperado del sistema. Por ejemplo, el siguiente modelo establece la evolución del estado del sistema en el siguiente instante de muestreo ($x(k+1)$) como una función de las entradas ($u(k)$), las perturbaciones ($w(k)$) y del propio estado del sistema en el instante k :

$$x(k+1) = f(x(k), u(k), w(k)). \quad (1)$$

De la misma forma que un cuadro puede ser fotorrealista o consistir en unos simples trazos en función de la intencionalidad y la pericia del pintor, la expresión matemática de $f(\cdot)$ varía con la naturaleza, complejidad y

¹No existe una definición universalmente aceptada de SCF, aunque todas mantienen como elementos nucleares conceptos propios de la teoría de control como el de realimentación y apuntan a la necesidad de que esta nueva generación de controladores funcione en red.

precisión del modelo. Así, mientras que la industria tiene preferencia por los modelos en función de transferencia –más sencillos de caracterizar experimentalmente–, la academia suele abordar el modelado con un enfoque en espacio de estados porque facilita la obtención de propiedades teóricas del controlador. Por otra parte, los modelos más exactos son también más complejos, hasta el punto de que pueden dificultar la ejecución de los cálculos requeridos para la toma de decisiones en tiempo real. Por ello, la disminución en la precisión de los cálculos al emplear un modelo sencillo puede ser compensada con creces por la rapidez con la que el controlador calculará las actuaciones del sistema.

- **Horizonte de predicción** N_p : es un parámetro que determina cuántos instantes de tiempo futuro deben ser considerados en la predicción del controlador. Valores altos se asocian a una mayor *proactividad* del controlador, que puede así anticiparse a cambios en el futuro esperable del sistema tales como una variación en la referencia. Sin embargo, ello va asociado también a una mayor carga computacional para el cálculo de la secuencia de acciones de control y a una mayor sensibilidad frente a los errores de modelado, que acrecentarán sus efectos a medida que sus predicciones se proyecten hacia el futuro. En el otro extremo, valores bajos de este parámetro se asocian a una mayor *reactividad* de la ley de control, que se centrará más en corregir el estado actual del sistema. Por tanto, debe escogerse un valor lo suficientemente alto como para preservar la naturaleza *predictiva* del controlador ponderando, también, el coste computacional resultante y la precisión del modelo. En ocasiones se emplea el horizonte de predicción conjuntamente con un horizonte de control $N_c < N_p$ como mecanismo para rebajar el coste de computación. De este modo, se calculan las acciones de control únicamente durante los primeros N_c instantes del horizonte de predicción, manteniéndose constantes desde ese momento. Ello permite reducir notablemente el número de variables de optimización, con el consiguiente ahorro de tiempo de cálculo. Por este motivo, se trata de un recurso habitual tanto en la literatura como en la práctica.
- **Función objetivo** J : captura en una fórmula matemática las preferencias del diseñador en la toma de decisiones, creando un mapa entre secuencias de actuación y un valor escalar que es interpretado en términos de coste o utilidad. En el primer caso, la elección de la secuencia óptima lleva a un problema de minimización, mientras que en el segundo la optimización requiere maximizar. Generalmente esta función evalúa en cada instante de tiempo del horizonte un coste o utilidad de etapa $\ell(\cdot)$ que depende tanto de la entrada aplicada como del estado o la salida esperada. Es común también que se introduzcan parámetros de ponderación que permitan priorizar algunas de sus componentes. Asimismo, suelen escogerse formas matemáticas que confieran a la optimización propiedades de interés. Por ejemplo, una elección habitual para el coste de etapa es una función cuadrática definida positiva

$$\ell(x(k+1), u(k)) = x(k+1)^\top Qx(k+1) + u(k)^\top Ru(k), \quad (2)$$

lo que lleva a una función objetivo

$$J = \sum_{l=0}^{N_p-1} \ell(x(k+l+1), u(k+l)), \quad (3)$$

que garantiza la convexidad del problema de optimización resultante, agilizando notablemente su resolución por parte del controlador. En (2), Q y R son matrices que priorizan respectivamente la regulación del estado al origen y el esfuerzo de control.

- **Restricciones** \mathcal{X}, \mathcal{U} : establecen los límites físicos u operacionales de las variables del problema, ya que el controlador debe garantizar que se cumpla

$$x(k) \in \mathcal{X}, \quad u(k) \in \mathcal{U}, \quad (4)$$

a lo largo del horizonte de predicción. En este sentido, si la función objetivo J indica lo que es deseable, las restricciones decretan lo que es *factible*, acotando el universo de secuencias de actuación

$$u(k : k + N_p - 1) = \{u(k), u(k+1), \dots, u(k + N_p - 1)\}. \quad (5)$$

Se trata de un elemento clave del CP, ya que es frecuente que sean las restricciones las que determinen la ubicación del óptimo de J . Por tanto, trabajar explícitamente con el conocimiento de las restricciones incrementa el rendimiento del controlador.

- **Información adicional**: el control predictivo es la forma más general de definir problemas de control en el dominio del tiempo y permite incorporar al problema de optimización otros elementos que pueden mejorar el rendimiento como valores esperados o distribuciones estadísticas de perturbaciones y otras fuentes de incertidumbre.

El problema de optimización que el CP define en cada instante de tiempo es

$$\min_{u(k:k+N_p-1)} J, \quad (6)$$

y debe ser resuelto considerando las restricciones en las variables del problema (4) y la evolución del sistema determinada por su modelo (1) a partir de la medición o estimación del estado actual. Como resultado se obtiene la secuencia de acciones óptimas $u^*(k : k + N_p - 1)$ y se aplica al sistema su primer elemento, que corresponda con la actuación óptima para el instante actual $u^*(k)$. El resto de la secuencia se descarta, ya que el problema vuelve a ser formulado y resuelto al siguiente instante de tiempo con la información más actual disponible. A esta forma de proceder del CP se la denomina estrategia de horizonte deslizante debido a su continua actualización del periodo para el que se calculan las acciones de control.

Como puede verse, el control predictivo consiste en una planificación continua de la secuencia de acciones a implementar que se adapta constantemente a la información disponible acerca del presente y el futuro del sistema. De este modo se contraponen a controladores clásicos como el PID, que ponen el foco en el presente y el pasado del sistema para establecer la actuación actual. Bien podría decirse que el ingeniero de control acude al PID en busca de *realimentación* para corregir lo que no funciona y al CP en busca de *prospección* y *consejo* para escoger el mejor curso de acción presente y futuro.

3. Interacciones de controladores predictivos en SCF

Como se indicó anteriormente, esta sección recopila una serie de ejemplos de aplicación del CP en SCF en orden de carácter ciberfísico creciente. Comienza con un problema relativamente convencional, el de la coordinación de controladores predictivos en plantas termosolares, y continúa con la introducción de robots dentro del bucle para mejorar la información que los controladores utilizarán en sus predicciones. Finalmente, la sección concluye con una serie de aplicaciones caracterizadas por la interacción entre humanos y controladores predictivos.

3.1. Controlador-controlador

Este tipo de interacción es la más convencional y ha sido ampliamente estudiada dentro del CP distribuido (Maestre and Negenborn, 2014; Negenborn and Maestre, 2014). En general, se considera que el sistema global está compuesto por un conjunto de subsistemas cuyos controladores locales intercambian información para coordinar sus acciones de control, evitando así la generación de interacciones indeseadas dentro del conjunto.

En los últimos años el CP predictivo distribuido ha evolucionado hacia métodos que permiten a los controladores agruparse dinámicamente con el fin de cooperar únicamente en los momentos en los que el acoplamiento aumenta, trabajando de forma descentralizada el resto del tiempo (Fele et al., 2017; Jain et al., 2018; La Bella et al., 2021; Chanfreut et al., 2021). Este enfoque es de gran interés dentro del contexto de los SCF ya que aumentan la escala de las aplicaciones en las que el CP puede ser aplicado. Para ilustrarlo, se empleará el ejemplo de una central termosolar cilindro-parabólica, un sistema distribuido de gran escala en el que multitud de espejos parabólicos concentran los rayos solares en una tubería por la que se hace fluir un aceite térmico (Figura 1). Este fluido caloportador (FC) es transportado hasta un intercambiador de calor donde se genera vapor de agua que alimenta una turbina de vapor, generando así energía eléctrica.



Figura 1: En la imagen se pueden ver los lazos compuestos por espejos parabólicos y sus puntos de conexión con los colectores de fluido caloportador (FC) frío y caliente. La imagen se corresponde con la *Solana Station Energy* en Phoenix, Arizona: <https://n9.cl/a0grx>

El control tradicional de estas plantas se basa en la actuación sobre el caudal del FC mediante bombas en función de la

irradiancia solar directa, también llamada DNI (Direct Normal Irradiance) –medida a través de pirheliómetros– y la temperatura del FC. De esta forma, cuando hay menos energía solar que aprovechar, el sistema disminuye el caudal bombeado para que el FC alcance mayor temperatura (dentro de los límites operacionales de la planta). Sin embargo, en ocasiones la irradiancia no es homogénea, por ejemplo, como consecuencia de una nube que cubre parcialmente el campo, por lo que una distribución equitativa del FC entre los lazos puede provocar un excesivo aumento de temperatura en las zonas no sombreadas, lo que puede obligar a desenfocar los espejos para evitar daños físicos en la planta (Camacho and Berenguel, 2012; Camacho et al., 1997).

Para atajar el problema de la distribución no homogénea de la DNI, algunos autores proponen incorporar válvulas a cada uno de los lazos (Sánchez et al., 2018; Masero et al., 2020, 2022), obteniendo así la capacidad de disminuir el caudal de FC únicamente en las partes sombreadas. La potencial ganancia de rendimiento de este método puede verse empañada por el incremento exponencial del tiempo de cálculo del controlador, que debe gestionar muchas más variables (un campo solar puede tener cientos de lazos). Es por ello que se opta por estrategias descentralizadas (Frejo and Camacho, 2020), que permiten mejorar el rendimiento de la planta de manera simple, ya que proporcionan un ajuste del flujo específico para las características particulares de cada lazo, considerando factores como la irradiancia recibida y la reflectividad, que puede aumentar tras operaciones de limpieza. Asimismo, es posible incrementar el rendimiento permitiendo asociaciones entre controladores si se permite compartir el flujo de FC entre pares de lazos de forma dinámica (Masero et al., 2020). Es decir, los lazos sombreados pueden alcanzar su rendimiento óptimo sin activar sus restricciones de flujo y, por tanto, el sobrante puede ser compartido con aquellos que reciben mayor irradiancia para que mejoren su rendimiento gracias al incremento en sus límites locales de FC. Aquí se plantea formar estas coaliciones asociando los lazos que maximicen la diferencia de FC: el que más consume con el que menos, el segundo que más consume con el segundo que menos, y así sucesivamente, consiguiendo una distribución más homogénea del flujo total del campo. El problema de CP que cada coalición de lazos C resuelve puede plantearse como (Masero et al., 2020):

$$\min_{q_C(k:k+N_p-1)} \sum_{n=k}^{k+N_p-1} \left(-W_C(n+1) + \alpha_C \Psi_C(T_{N_{\text{seg}},j}^f(n+1)) + \beta_C \sum_{j \in C} (\Delta q_j)^2 \right), \quad (7)$$

donde n es un índice temporal que indica el instante en el horizonte de predicción N_p , W_C representa la potencia térmica de la coalición, N_{seg} es el número de segmentos en el que se divide cada lazo, α_C es el peso que penaliza la violación de las restricciones de temperatura del FC (representada mediante la función $\Psi_C(T_{N_{\text{seg}},j}^f)$, siendo $T_{N_{\text{seg}},j}^f$ la temperatura de FC de salida del lazo), y por último, β_C es el factor de peso que penaliza el sumatorio de las variaciones de flujo $\Delta q_j = q_j(n) - q_j(n-1)$ de los lazos de la coalición entre dos instantes consecutivos. Para la coalición C , la variable de optimización $q_C(k : k + N_p - 1)$ es la secuencia de flujo de FC a lo largo del horizonte. Finalmente, el problema (7) se resuelve considerando la dinámica de la coa-

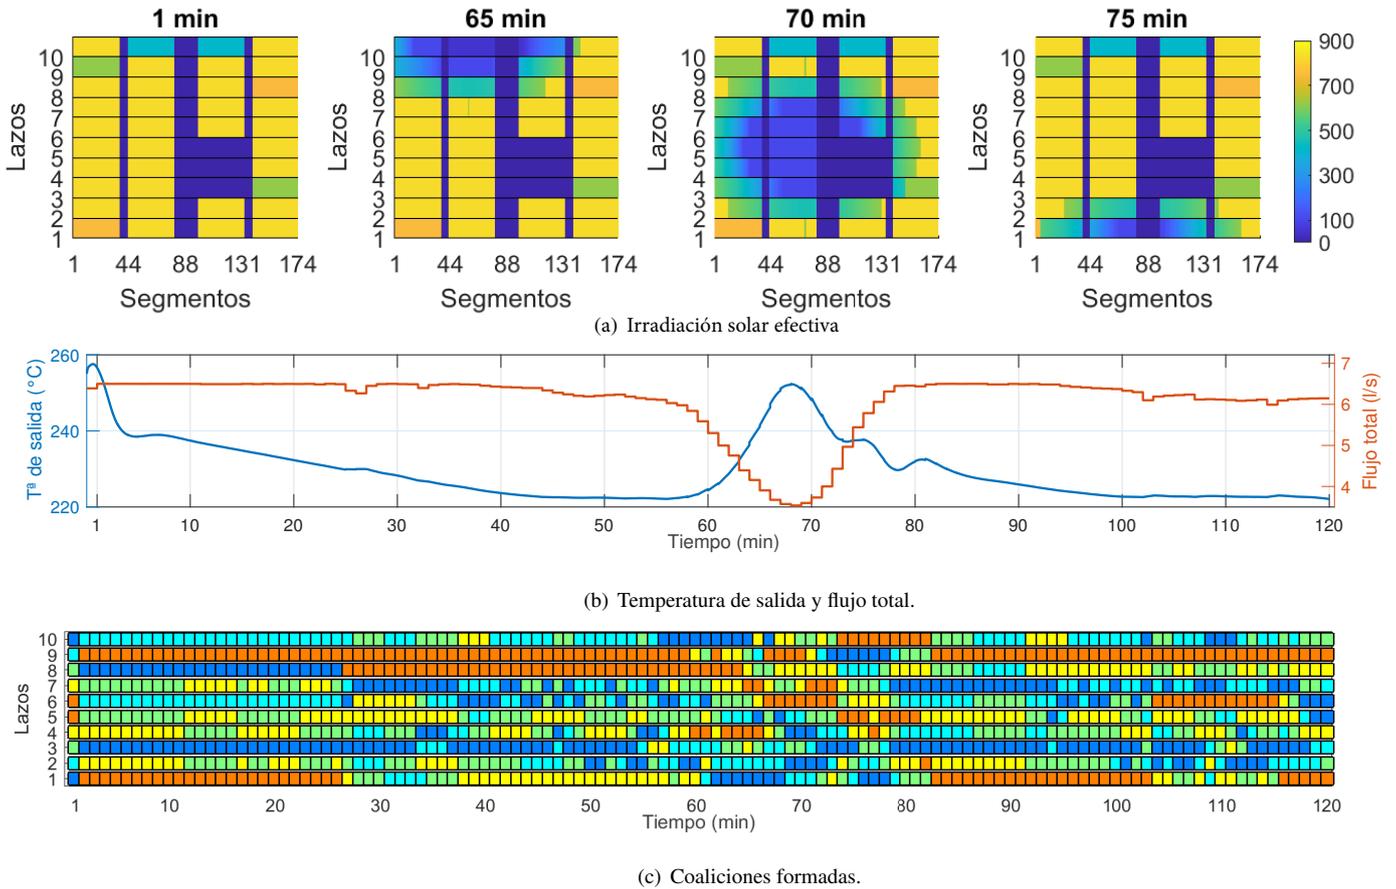


Figura 2: Ejemplo de simulación de un campo termosolar cilindro-parabólico compuesto por diez lazos.

lición, la restricción de temperatura del FC: $T^{f,\min} \leq T_{N_{seg,j}}^f \leq T^{f,\max}$ y la restricción de flujo máximo: $q_C^{\max} = q_T^{\max} |C| / N_{loop}$, donde q_T^{\max} , $|C|$ y N_{loop} son, respectivamente, el flujo máximo total, el tamaño de la coalición y el número de lazos del campo solar.

La Figura 2 representa un ejemplo de simulación de 120 minutos de un campo compuesto por diez lazos. Como se muestra en la Figura 2(a), se ha considerado un perfil sintético de irradiación efectiva en el que una nube cubre parcialmente el campo entre los minutos 65 y 75. La Figura 2(b) muestra cómo el flujo total disminuye y la temperatura de salida de FC sube durante el periodo en el que la nube cubre el campo acorde al objetivo establecido de maximizar la potencia térmica resultante. Finalmente, la Figura 2(c) muestra la formación dinámica de grupos de pares de lazos para mejorar el rendimiento conforme a las diferencias en irradiación y eficiencia de los espejos. Por otro lado, la potencia térmica media resultante de la estrategia coalicional es de 1130 kW, resultado superior al de un CP centralizado que repartiera el flujo por igual entre los lazos (1118,6 kW) y al del CP descentralizado (1126,6 kW). Solo el CP centralizado con ajuste de válvulas individualizado permite mejorar los resultados (1131,3 kW), pero con un coste computacional sensiblemente superior incluso en una planta de diez lazos. En concreto, el tiempo de muestreo habitual de los controladores en plantas comerciales es de entorno 60 segundos, límite que las estrategias descentralizadas y coalicional pueden respetar sin sobresaltos (Masero et al., 2020).

3.2. Controlador-robot

A continuación, se examinará el uso de robots dentro del bucle para mejorar la información de los controladores basándonos en el ejemplo anterior, que requieren una estimación espacialmente distribuida de la irradiancia y, por tanto, el despliegue de una red de sensores de irradiancia por el campo. Sin embargo, el elevado precio de los pirheliómetros, unido a la vasta extensión de este tipo de plantas, hacen inviable esta posibilidad. Por ello, el proyecto OCONTSOLAR (*Optimal Control of Thermal Solar Energy Systems (Advanced Grant, ref. 789051)*) propone la utilización de una flota de robots (tanto terrestres como aéreos) como red de sensores móviles (Akyildiz et al., 2002; Koubâa and Khelil, 2014). En concreto, se integrarán sensores de irradiancia como los de la Figura 3, en robots similares a los de la Figura 4.



Figura 3: Sensor de bajo coste de DNI. Se puede encontrar más información en <https://www.solar-mems.com/>.



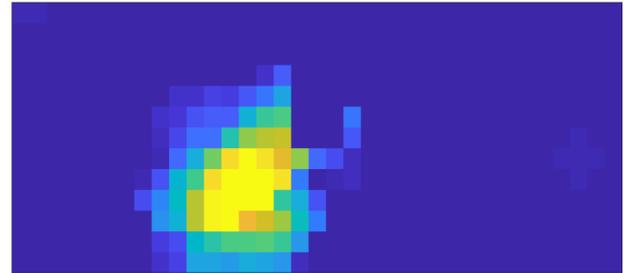
Figura 4: Drone con sensor de DNI integrado.

Sin embargo, el ahorro de sensores para construir la estimación deseada plantea los siguientes retos como consecuencia de la introducción del conjunto de robots móviles dentro del bucle de realimentación:

- Decidir, en función de la información disponible tanto del estado actual como de la evolución esperada del sistema, en qué puntos de la planta hace falta tomar tu nuevas medidas, priorizando además unas localizaciones frente a otras como consecuencia de su importancia relativa. En este punto conviene destacar que los pronósticos acerca de la evolución esperada del sistema están sujetos a errores que deben ser considerados en los cálculos.
- Asignar la lista de tareas generadas a los robots según su posición y parámetros como la importancia de la tarea, el tipo de robot, su velocidad y nivel de batería, etc. (Khamis et al., 2015). En trabajos como (Martín et al., 2021b), se ha planteado este problema en el contexto de una planta termosolar. Puesto que la posición de las tareas y de los robots es dinámica, debe realizarse atendiendo tanto a la situación actual de los mismos como a su evolución esperada, que, por otro lado, depende de la propia asignación que se va a realizar.
- Actualizar la estimación distribuida de la irradiancia recibida en la planta según la información recolectada por los robots.

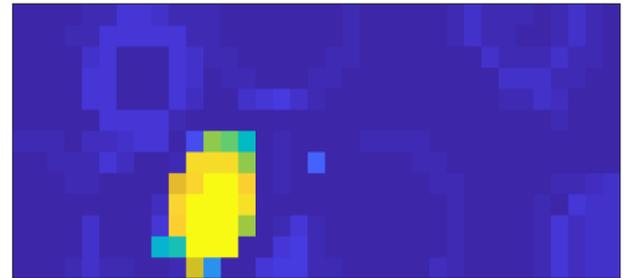
Martín et al. (2021c) abordan esta problemática desde una perspectiva de inferencia Bayesiana considerando que en cada punto del campo hay una distribución de probabilidad asociada a la estimación de la irradiancia local, que puede ser actualizada por un conjunto de M medidas $\mathcal{M} = \{m_1, m_2, \dots, m_j, \dots, m_M\}$ en el que se asocia una importancia ϕ_j a cada medida j en función de aspectos como el tiempo transcurrido desde la última medida en la zona, la velocidad y posición conocida de las nubes o la entropía de Shannon. En particular, se asume que cada medida aporta información sobre el *área* en el que fue tomada, disminuyendo la incertidumbre del valor de irradiancia estimado con proporcionalidad inversa a la distancia del punto de medida.

La Figura 5 muestra un ejemplo del algoritmo en simulación. En la Figura 5(a) puede verse la irradiancia real de la planta en un instante concreto a través del coeficiente CF (del inglés *Cloud Factor*). Este coeficiente vale 0 cuando la irradiancia se corresponde con la máxima del día y 1 cuando la irradiancia es nula. Además, en la Figura 5(b) puede verse el *Cloud Factor* estimado en este momento y en Figura 5(c) puede verse la posición real de los robots en este instante y los puntos en los que el sistema estima oportuno realizar mediciones.



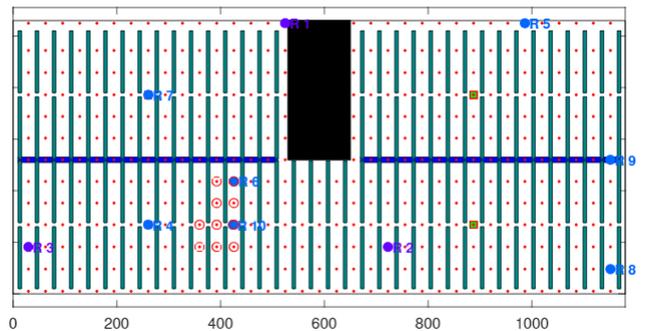
CF^R

(a) Distribución del *Cloud Factor* real en la planta termosolar.



CF^{est}

(b) Distribución del *Cloud Factor* estimado en la planta termosolar.



(c) Posiciones de los robots aéreos (azul), terrestres (magenta) y de localizaciones a medir (círculos rojos).

Figura 5: Ejemplo de simulación en un instante.

La asignación las medidas \mathcal{M} al conjunto de robots $\mathcal{R} = \{r_1, r_2, \dots, r_i, \dots, r_R\}$ se realiza mediante un algoritmo genético que minimiza una función de coste multi-criterio dada por (Martín et al., 2021a):

$$J^{TA}(U) = \sum_{j=1}^M \phi_j \cdot t_j(U) + \sum_{i=1}^R \lambda_i \cdot d_i(U) + \Omega(U), \quad (8)$$

donde $U = [u_1, \dots, u_R]$ contiene los vectores $u_i \in \mathbb{R}^{1 \times N_p}$ que

representa la asignación y secuencia en el tiempo de las medidas que el robot i debe tomar. La función $J^{TA}(U)$ evalúa i) la prioridad ϕ_j y el tiempo necesario $t_j(U)$ para ejecutar la medida j , ii) una penalización λ_i por usar el robot i junto a la distancia recorrida $d_i(U)$ por el robot i en la asignación U , y iii) una función $\Omega(U)$ que promueve la factibilidad de la asignación U desde el punto de vista energético. En la función de coste (9) la variable U representa la secuencia de asignaciones de todos los robots. Asumiendo que se dispone de una estimación del movimiento de las tareas $q_j = q_j(t) \in \mathbb{R}^2$ y de la posición de los robots $p_i = p_i(t) \in \mathbb{R}^2$, se puede construir una estimación de $d_i(U)$, $t_j(U)$ y $\Omega(U)$. Por tanto, el problema a resolver puede expresarse como:

$$\begin{aligned} & \text{mín}_U J^{TA}(U), \\ & \text{sujeto a} \\ & u_i(n) \in \mathcal{M} \cup \{0\} \forall i \in \mathcal{R}, n \in \{1, \dots, N_p\}. \end{aligned} \quad (9)$$

El número de tareas a asignar para cada robot puede ser considerado como un análogo del horizonte de predicción. Cuando aumenta este valor, el coste computacional del problema (9) crecerá dado que la dimensión de U será mayor. Dos configuraciones especiales son $N_p = M$, que permite explorar soluciones en las que un único robot se encarga de realizar todas las tareas, y $N_p = 1$, que es equivalente a un algoritmo voraz en el que en cada iteración se le asigna una tarea a cada robot.

Finalmente, la naturaleza predictiva en la asignación de tareas proviene del carácter de la replanificación continua con la que se resuelve este problema. En particular, en cada instante de tiempo se obtiene una planificación U^* para los robots y se aplica únicamente la primera misión de dicha planificación. Tras un periodo de tiempo, se realiza de nuevo el cálculo a partir de la información más actual del sistema y el correspondiente pronóstico de la evolución de los robots y las tareas. Esta forma de proceder puede superar en desempeño a otros enfoques empleados para la asignación de tareas en la aplicación considerada (por ejemplo, asignaciones metaheurísticas basadas en algoritmos genéticos), con ganancias de hasta en un 18,9% en optimalidad en función de la configuración del controlador empleada.

3.3. Controlador-humano

Esta subsección cubre sin lugar a dudas el aspecto más desafiante en lo referente a la utilización del CP en SCF. La integración del papel desempeñado por los operadores en este contexto es complicada y pueden encontrarse enfoques diferentes en la literatura. Es por ello que la subsección se dividirá en tres apartados de creciente integración del operador con el marco del CP.

3.3.1. Operador como sensor-actuador móvil

Para este apartado se revisará la aplicación de la gestión de canales con operadores en el bucle. Los canales de riego son las vías fluviales empleadas para transportar agua dulce desde una fuente, por ejemplo, un lago, hacia los agricultores. Desde un punto de vista de control, el objetivo es regular el nivel del agua a lo largo de los diferentes tramos que componen el canal dentro de una determinada banda objetivo. En particular, debe asegurarse un nivel mínimo para garantizar un suministro adecuado

de agua dulce y la navegabilidad en grandes canales; el nivel máximo se introduce para minimizar el desperdicio de este preciado recurso y reducir el riesgo de inundaciones en caso de fuertes lluvias. Para ello, es posible manipular estructuras como las compuertas que separan los tramos del canal, regulando así el flujo y los niveles de agua en las secciones aguas arriba y aguas abajo del canal (Figura 6). Pese al buen desempeño de los métodos de control automático para canales de riego (Negenborn et al., 2009; Zafra-Cabeza et al., 2011; Fele et al., 2014; Conde et al., 2021), la operación manual prevalece debido a los altos costos de instalación y mantenimiento de la instrumentación, especialmente en países no desarrollados, por lo que no es infrecuente que haya operadores viajando a lo largo del canal para ajustar las compuertas en función de las entregas de agua programadas. Como consecuencia, los agricultores tienen que adaptar sus cultivos al rendimiento de la operación manual, llegando incluso a explotar recursos hídricos subterráneos para obtener agua dulce adicional.

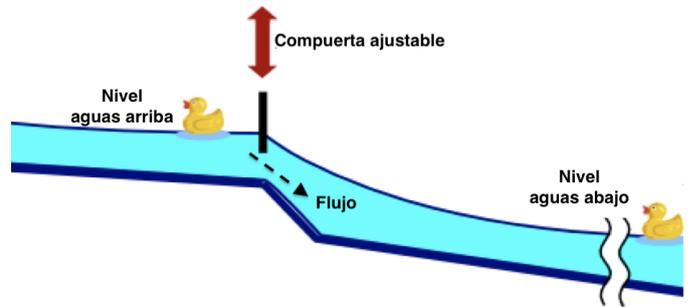


Figura 6: Esquema de dos tramos consecutivos en un canal.

Para hacer frente a estos problemas, durante los últimos años se han propuesto diferentes métodos de CP con humanos en el bucle (Maestre et al., 2014; Van Overloop et al., 2015; Sadowska et al., 2015), que plantean el siguiente problema de optimización:

$$\begin{aligned} & \text{mín}_{u(k:k+N_c), p_v} J_s + J_h, \\ & \text{sujeto a} \\ & x(l+1) = Ax(l) + Bu(l) + w(l), \\ & p_v \in \mathcal{P}_v, \\ & u_i(l) = 0, \quad l \in \{k, \dots, k + N_c\} : a(p_v, l) = 0, \\ & x(l) \in \mathcal{X}, \\ & u(l) \in \mathcal{U}, \end{aligned} \quad (10)$$

donde el criterio de optimización está compuesto por elementos relacionados con la gestión del agua (J_s) y la acción de los operadores (J_h). Además de la habitual optimización de la secuencia de acciones $u(k : k + N_c)$ –limitada a un horizonte de control $N_c < N_p$ debido a la existencia de retardos de transporte– sujeta a restricciones en el estado (\mathcal{X}) y la actuación (\mathcal{U}), se optimiza también con respecto a la ruta p_v^i que sigue el operador, que debe estar contenida dentro de un conjunto predefinido de posibilidades \mathcal{P}_v . La elección de la ruta no es baladí, ya que determina los momentos y lugares en los que puede actuar el operador a través de la función auxiliar $a(p_v, l)$, que recibe el valor 1 si el operador está disponible para actuar en el instante l y 0 en caso contrario. Por ejemplo, dado un sistema con dos compuertas, la secuencia resultante del problema (10) para un operador que

fuera de la compuerta 1 a la 2 y de ahí regresara a la 1 tendrá un aspecto similar a:

$$u^*(k : k + N_c) = \{u_1^*(k), \underbrace{0, \dots, 0}_{\text{tiempo de desplazamiento}}, 0, u_2^*(k + 2), \underbrace{0, \dots, 0}_{\text{tiempo de desplazamiento}}, u_1^*(k + N_c), 0\}.$$

La metodología resultante es explotada comercialmente por la empresa *Mobile Water Management* y comprende los siguientes pasos: i) el operador llega a una compuerta y envía al sistema de control una fotografía del agua en el punto de medida habilitado; ii) el controlador resuelve el problema y devuelve al operador instrucciones sobre la manipulación de la compuerta actual y la ruta que debe seguir; iii) el operador implementa la acción recibida y se dirige a la siguiente compuerta, donde el proceso comienza de nuevo.

Finalmente, cabe destacar que el rendimiento de esta metodología es ligeramente inferior al del CP tradicional cuando se examinan indicadores de rendimiento relacionados con la deficiencia hídrica experimentada por los agricultores (Van Overloop et al., 2015), incluso a pesar de la incapacidad de actuar todas las compuertas en cada instante de tiempo. Por otro lado, esta metodología también está abierta a considerar diversos aspectos relacionados con el bienestar del operador dentro de la función de coste (Sadowska et al., 2015).

3.3.2. Operador en sinergia con el controlador

En este apartado se examina relaciones de sinergia entre el operador y el CP en dos aplicaciones: la gestión de inventarios en farmacia hospitalaria y la gestión de energía en comunidades.

1) *Gestión de inventarios en farmacia.* Las limitaciones de los recursos financieros y logísticos del hospital exigen estrategias eficientes que minimicen la cantidad de unidades a almacenar, asegurando, con un cierto grado de certeza, la satisfacción de la demanda clínica mientras se consideran a su vez costes de adquisición, almacenamiento y mantenimiento, así como las restricciones de espacio, fundamentalmente para fármacos que requieren refrigeración.

Así pues, esta tarea requiere encontrar un equilibrio entre objetivos contrapuestos: i) satisfacción de las necesidades clínicas, ii) reducción de los costes de inventario, y iii) reducción de la carga de trabajo del personal. Las técnicas más ampliamente utilizadas se basan en una revisión continua donde se establece un cierto *punto de pedido* o *reorden* (s, S). A grandes rasgos, estos métodos se basan en la realización de pedidos para tener S artículos almacenados siempre que las existencias sean inferiores a otra cantidad fijada s , lo que implica que la cantidad de artículos a pedir es prácticamente fija. Otra posibilidad, es la política de inventario (R, S) , en las que se establecen un cierto periodo de revisión del stock R , e, igualmente, un nivel de inventario deseado S (Angulo et al., 2004). Actualmente, las nuevas tecnologías, y en particular, la creciente capacidad de computación y almacenamiento de información facilitan la aplicación de métodos de control óptimos para la gestión de inventarios, así como la explotación de datos para mejorar su rendimiento (Wang et al., 2016; Zhong et al., 2016).



Figura 7: Estructura del método implementado en (Fernández García et al., 2021) para la gestión de inventario en farmacias hospitalarias. El sistema consta de cuatro elementos principales que interactúan entre sí: 1) el personal farmacéutico responsable de la gestión de inventario; 2) los proveedores de medicamentos; 3) el almacén de la farmacia, con los correspondientes niveles de stock para cada medicamento; y 4) el sistema informatizado de apoyo a la decisión, que suministra los resultados mencionados en la Sección 3.3.2.

En este contexto, adquiere especial relevancia el CP y su capacidad para considerar explícitamente las restricciones sobre el sistema (Maestre et al., 2018), riesgos (Maestre et al., 2013), y la presencia de incertidumbres mediante formulaciones estocásticas (Jurado et al., 2016). Sin embargo, hay elementos cualitativos que son más difíciles de trasladar al problema, por ejemplo, aquellos relacionados con la carga de trabajo del personal de farmacia, que está sujeta a variaciones drásticas por la dinámica propia de la actividad hospitalaria. Pese a la existencia de algún trabajo en el que se integra al farmacéutico en el bucle (Maestre et al., 2018), en esta aplicación es preferible la participación del mismo dentro del proceso de toma de decisiones tal y como Fernández García et al. (2021) realizaron en el Hospital San Juan de Dios de Córdoba (véase la Figura 7). Dentro de este esquema, se plantea un sistema de soporte a la decisión en el que la labor de control se reparte de la siguiente forma:

- CP: explota los registros históricos de inventario con el fin de proporcionar información útil para establecer el tamaño y el momento en el que deben realizarse los pedidos considerando las unidades disponibles en *stock*. En particular, el sistema proporciona los siguientes resultados para un rango de horizontes de predicción N_p determinado: cantidad mínima de cada medicamento i que debe llegar a la farmacia para obtener un 0% de probabilidad de desabastecimiento; coste total del pedido que asegura un 0% de probabilidad de desabastecimiento para todos los medicamentos; probabilidad de desabastecimiento para cada medicamento i suponiendo que no se realiza ningún pedido; y probabilidad de que no se agoten las existencias de todos los medicamentos en el mismo supuesto anterior.
- Operador: toma las decisiones finales y actualiza la información disponible en el sistema de apoyo a la decisión, permitiendo así un aprendizaje continuo a medida que se dispone de nuevos registros.

En otras palabras, el controlador genera una serie de secuencias factibles para garantizar el abastecimiento de la farmacia

durante diversos horizontes y avisa del riesgo en el que se incurre si no se realizan pedidos. La elección entre los diversos cursos de acción posibles la realiza el farmacéutico basándose en su experiencia y conocimiento de la actividad de la farmacia. Por tanto, el problema clásico de CP se resuelve a través de la sinergia entre operador y controlador, que en este caso queda relegado a un sistema de soporte a la decisión.

Tabla 1: Unidades adicionales de cada fármaco para evitar el desabastecimiento durante 2 a 8 días, y coste total considerando precios unitarios.

		Número de días						
		2	3	4	5	6	7	8
Medicamentos	1	0	50	50	50	100	100	150
	2	0	4	8	8	12	16	16
	3	0	0	0	0	0	0	4
	4	0	0	0	0	0	0	0
	5	0	0	0	0	0	0	0
	6	0	10	160	240	250	270	350
	7	0	0	0	0	0	0	40
	8	0	0	0	0	20	20	120
	9	0	0	0	0	0	0	0
	10	0	0	0	0	0	0	0
	11	0	0	0	0	0	0	0
C_n		0	64	218	298	382	406	680

Tabla 2: Probabilidades individual y conjunta de desabastecimiento de 2 a 8 días sin pedidos.

		Número de días						
		2	3	4	5	6	7	8
Medicamentos	1	0	0.09	0.28	1.31	2.34	4.40	9.75
	2	0	0.09	0.65	1.59	4.12	7.77	12.93
	3	0	0	0	0	0	0	0.09
	4	0	0	0	0	0	0	0
	5	0	0	0	0	0	0	0
	6	0	0.09	0.47	0.84	1.31	2.53	7.59
	7	0	0	0	0	0	0	0.09
	8	0	0	0	0	0.09	0.28	0.75
	9	0	0	0	0	0	0	0
	10	0	0	0	0	0	0	0
	11	0	0	0	0	0	0	0
Prob. conj.		100	99,73	98,61	96,31	92,33	85,70	71,94

Las Tablas 1 y 2 muestran resultados experimentales presentados en (Fernández García et al., 2021). En particular, el experimento se realizó considerando un conjunto de 11 medicamentos suministrados por un mismo laboratorio. La farmacia hospitalaria proporcionó datos históricos sobre las cantidades demandas y pedidas de estos fármacos durante los dos años anteriores al experimento, y, durante el periodo de prueba, introdujo diariamente en el sistema los correspondientes niveles de stock. Teniendo esto en cuenta, el sistema de apoyo a la decisión calculó automáticamente los valores mencionados para períodos de 2 a 8 días, proporcionando la información de forma

tabulada como se muestra en las Tablas 1 y 2 para un cierto día. Se puede ver que las cantidades a pedir aumentan con el número de días sin realizar pedidos debido al aumento progresivo de la demanda acumulada de los pacientes. Como consecuencia, la probabilidad conjunta de prevenir cualquier desabastecimiento disminuye conforme pasa el tiempo. En base a estos datos, el personal decide qué pedidos deben realizarse, considerando a su vez todas las limitaciones del problema (máximo stock que se podía almacenar, pedido mínimo en proveedor, etc.). En comparación a los 4 meses anteriores al experimento, Fernández García et al. (2021) muestra que el sistema de apoyo a la decisión permitió disminuir las cantidades de medicamentos almacenados y el número de pedidos, lo cual se redujo en un 19%.

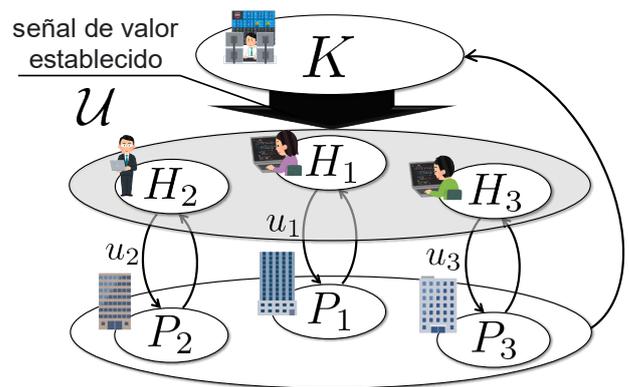


Figura 8: Estructura de realimentación para la gestión de energía en una comunidad de usuarios H_i . El controlador K proporciona al conjunto de H_i un rango admisible de consumo de energía en cada instante, facilitando así el análisis de estabilidad y rendimiento del sistema global.

2) *Gestión de energía en comunidades.* Otro ejemplo de esta estrategia de sinergia se puede encontrar en sistemas de gestión energética en los que existe una interacción entre decisiones humanas y otros elementos que aportan incertidumbre como los recursos energéticos renovables (Carrasco et al., 2006; Badal et al., 2019). La gran variabilidad de la generación renovable, que depende fuertemente de las condiciones meteorológicas, así como la aleatoriedad del comportamiento de los consumidores, suponen dificultades de primer orden en este contexto (Liang, 2016; Bordons et al., 2015). El llamado marco del control débil (Inoue and Gupta, 2019) permite que el conjunto de humanos con poder de actuación sobre el sistema tomen decisiones dentro de un rango establecido en base a sus preferencias y beneficios locales, permitiendo así cierto grado de autonomía. En este contexto, Shibasaki et al. (2020) presenta una estrategia de control basada en retroalimentación para la gestión de consumo energético a nivel de las comunidades de consumidores donde el consumo total se gestiona mediante el sistema multinivel de la Figura 8. En la capa superior se tiene un controlador K que actúa como gestor o supervisor del sistema y que proporciona una *solicitud de consumo de energía* a cada consumidor H_i . A su vez, éstos actúan como gestores locales en una capa inferior, de forma que cada H_i es responsable de abastecer a su propia planta P_i . En relación a esto, una de las principales dificultades es garantizar la estabilidad y el buen rendimiento del sistema ante la posibilidad que los consumidores actúen sin atender a la información enviada desde K .

3.3.3. Operador modelado como un controlador predictivo

Con el objetivo de aumentar la eficiencia y la fiabilidad de los sistemas de control con humanos en el bucle, se han desarrollado distintos métodos para modelar el comportamiento humano ante diferentes eventos. Un escenario típico del problema es aquel en el que un operador observa el estado del sistema bajo control y en base a éste determina sus acciones, haciendo evolucionar el sistema hacia un nuevo estado, repitiendo el proceso reiteradamente tal y como se hace en CP.

Autores como Priess et al. (2014); Ramadan et al. (2016, 2018); Hara et al. (2020) asumen que el operador humano determina sus acciones de control resolviendo *inconscientemente* un problema de optimización basado en modelo. Por ejemplo, si la dinámica de la planta está modelada por el siguiente modelo lineal

$$x(k+1) = Ax(k) + Bu(k), \quad (11)$$

donde x y u representan respectivamente los vectores de estado y entrada, Hara et al. (2020) propone que el comportamiento humano en un instante de tiempo dado está descrito por la solución $u^*(k : k + N_p - 1)$ del siguiente problema de CP:

$$u^*(k : k + N_p - 1) = \arg \min_{u(k:k+N_p-1)} J, \quad (12)$$

sujeto a (11), que predice la evolución del sistema a partir de una medida x_0 del estado inicial y la secuencia de acciones $u(k : k + N_p - 1)$. Por tanto, el modelado del comportamiento humano puede obtenerse mediante el cálculo de la función J a partir de secuencias de entradas $u(k : k + N_p - 1)$ y estados $x(k : k + N_p - 1)$ obtenidas experimentalmente, por ejemplo utilizando una plataforma como la de la Figura 9, de forma que la solución del problema (12) caracterice las acciones humanas para el estado dado. En este sentido, Hara et al. (2020) considera en el coste de etapa una penalización cuadrática en el estado y una norma uno en la señal de control con el fin de obtener secuencias largas de ceros en la acción de control (Nagahara et al., 2015). En la Figura 10, se ve la estimación de la secuencia de entradas frente a la que proporciona finalmente el usuario ante un cambio de referencia en la plataforma de la Figura 9. Por su parte, Priess et al. (2014) considera que J es una función cuadrática y aplica un regulador cuadrático inverso (iLQR) para ajustar las matrices de peso Q y R a partir de los datos experimentales. Esta idea es extendida por Ramadan et al. (2016, 2018), que considera el problema de CP inverso.

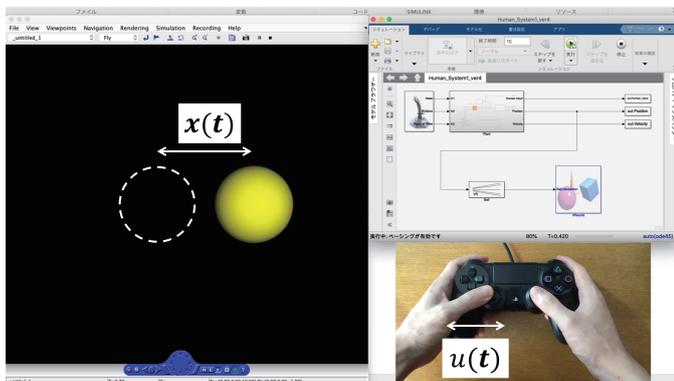


Figura 9: Plataforma para la identificación del usuario, quien debe utilizar el joystick para seguir una referencia dada (cortesía de Ryouu Naga).

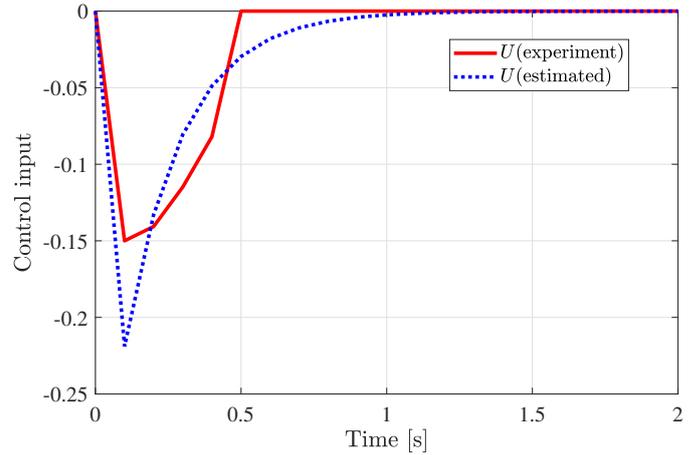


Figura 10: Estimación de la señal que generará el usuario frente al comportamiento realizado para una variación de la referencia empleando el método de (Hara et al., 2020) (cortesía de Keita Hara).

4. Conclusiones

A lo largo de este tutorial se han presentado resultados recientes que permiten trazar algunos rasgos relevantes de la adaptación del CP para el control de SCF, paradigma que requiere políticas de control flexibles, capaces de adaptarse dinámicamente a la presencia de un conjunto variable y heterogéneo de entidades con capacidad de decisión. En primer lugar, se ha presentado un método de agrupamiento o *clustering* de controladores predictivos que forman coaliciones basadas en su grado de acoplamiento para mejorar el rendimiento del sistema de forma escalable. Este tipo de mecanismos también están llamados a desempeñar un papel protagonista en aplicaciones en las que puedan entrar y salir sistemas sobre la marcha, ya sea de forma voluntaria (*plug & play*) o accidental (tolerancia a fallos). Asimismo, se ha visto la integración de robots dentro del bucle para construir un mapa de irradiancia que ayude a los controladores predictivos en la toma de decisiones. En este sentido, el propio robot es una integración de sistemas y el CP puede estar presente en uno o varios niveles de la jerarquía de control, por lo que esta metodología debe estar preparada para unos niveles de interacción cada vez mayores con otras tecnologías, subsistemas y agentes. Por último, se han revisado trabajos que presentan diferentes grados de relación entre operadores y el marco del CP, desde aplicaciones en las que los humanos funcionan como sensores y actuadores ambulantes a otras en las que los elementos que caracterizan al CP se reparten entre operador y controlador. Asimismo, se están desarrollando métodos para describir al operador como si se tratara de un controlador predictivo, lo que permite al resto de los elementos del sistema contar con un *gemelo* o *doble digital* que proporciona certidumbre respecto a su comportamiento.

A pesar de estos resultados, el campo de investigación que nos ocupa requiere muchísimo esfuerzo e investigación para ampliar las posibilidades que brinda el CP a los SCF. No existe todavía un método general para diseñar el sistema de control en sistemas donde interactúan elementos con diferentes tipos de dinámicas, por lo que la literatura ofrece fundamentalmente soluciones *ad-hoc*, esto es, diseñadas específicamente para cada tipo de problema particular. Es por ello que los SCF constituyen un reto de gran interés con capacidad para impulsar la

aplicación de estrategias de control avanzado en sistemas fuera del ámbito de la teoría de control actual.

Agradecimientos

Este trabajo ha sido financiado por el European Research Council (ERC) en el marco del programa de investigación e innovación Horizonte 2020 de la Unión Europea [OCONTSO-LAR, ref. 789051], por MCIN/AEI/ 10.13039/501100011033 mediante los proyectos C3PO [ref. DPI2017-86918-R] y C3PO-R2D2 [ref. PID2020-119476RB-I00], por el Ministerio de Ciencia, Innovación y Universidades en el marco del programa de Formación de Profesorado Universitario (FPU) [FPU17/02653 y FPU18/04476] y por la Consejería de Transformación Económica, Industria, Conocimiento y Universidades en el marco del programa de Ayudas a los agentes públicos del Sistema Andaluz del Conocimiento para la realización de proyectos de I+D+i (PAIDI 2020) a través del proyecto Ampliación Aquacollect H2020 [ref. P18-HO-4713].

Referencias

- Akyildiz, I. F., Su, W., Sankarasubramaniam, Y., Cayirci, E., 2002. Wireless Sensor Networks: A Survey. *Computer Networks* 38 (4), 393–422.
- Angulo, A., Nachtmann, H., Waller, M. A., 2004. Supply Chain Information Sharing in a Vendor Managed Inventory Partnership. *Journal of Business Logistics* 25 (1), 101–120.
- Badal, F. R., Das, P., Sarker, S. K., Das, S. K., 2019. A Survey on Control Issues in Renewable Energy Integration and Microgrid. *Protection and Control of Modern Power Systems* 4 (1), 1–27.
- Bordons, C., García Torres, F., Valverde, L., 2015. Gestión óptima de la energía en microrredes con generación renovable. *Revista Iberoamericana de Automática e Informática Industrial* 12 (2), 117–132.
- Camacho, E. F., Berenguel, M., 2012. Control of Solar Energy Systems. *IFAC Proceedings Volumes* 45 (15), 848–855.
- Camacho, E. F., Berenguel, M., Rubio, F. R., 1997. *Advanced Control of Solar Plants*. Springer Berlin.
- Camacho, E. F., Bordons, C., 1999. *Model Predictive Control*. Springer, Berlin Heidelberg.
- Carrasco, J. M., Franquelo, L. G., Bialasiewicz, J. T., Galván, E., PortilloGuisado, R. C., Prats, M. M., León, J. I., Moreno-Alfonso, N., 2006. Power-Electronic Systems for the Grid Integration of Renewable Energy Sources: A Survey. *IEEE Transactions on Industrial Electronics* 53 (4), 1002–1016.
- Castilla, M., Álvarez, J. D., Berenguel, M., Pérez, M., Rodríguez, F., Guzmán, J. L., 2010. Técnicas de control del confort en edificios. *Revista Iberoamericana de Automática e Informática Industrial RIAI* 7 (3), 5–24.
- Chanfreut, P., Maestre, J. M., Camacho, E. F., 2021. A Survey on Clustering Methods for Distributed and Networked Control Systems. *Annual Reviews in Control*. DOI: <https://doi.org/10.1016/j.arcontrol.2021.08.002>
- Conde, G., Quijano, N., Ocampo-Martínez, C., 2021. Modeling and Control in Open-Channel Irrigation Systems: A Review. *Annual Reviews in Control*. DOI: <https://doi.org/10.1016/j.arcontrol.2021.01.003>
- Dey, N., Ashour, A. S., Shi, F., Fong, S. J., Tavares, J. M., 2018. Medical Cyber-Physical Systems: A Survey. *Journal of medical systems* 42 (4), 1–13.
- Fele, F., Maestre, J. M., Camacho, E. F., 2017. Coalitional Control: Cooperative Game Theory and Control. *IEEE Control Systems Magazine* 37 (1), 53–69.
- Fele, F., Maestre, J. M., Hashemy, M., Muñoz de la Peña, D., Camacho, E. F., 2014. Coalitional Model Predictive Control of an Irrigation Canal. *Journal of Process Control* 24 (4), 314–325. DOI: <https://doi.org/10.1016/j.jprocont.2014.02.005>
- Fernández García, I., Chanfreut, P., Jurado, I., Maestre, J. M., 2021. A Data-Based Model Predictive Decision Support System for Inventory Management in Hospitals. *IEEE Journal of Biomedical and Health Informatics* 25 (6), 2227–2236. DOI: <https://doi.org/10.1109/JBHI.2020.3039692>
- Frejo, J. R. D., Camacho, E. F., 2020. Centralized and Distributed Model Predictive Control for the Maximization of the Thermal Power of Solar Parabolic-Trough Plants. *Solar Energy* 204, 190–199.
- Gil, J., Roca, L., Berenguel, M., 2020. Modelado y control automático en destilación por membranas solar: fundamentos y propuestas para su desarrollo tecnológico. *Revista Iberoamericana de Automática e Informática industrial* 17 (4), 329–343.
- Guzmán, J., Ación, F., Berenguel, M., 2020. Modelado y control de la producción de microalgas en fotobiorreactores industriales. *Revista Iberoamericana de Automática e Informática industrial* 18 (1), 1–18.
- Hara, K., Inoue, M., Maestre, J. M., 2020. Data-Driven Human Modeling: Quantifying Personal Tendency Toward Laziness. *IEEE Control Systems Letters* 5 (4), 1219–1224. DOI: <https://doi.org/10.1109/LCSYS.2020.3023337>
- Hatanaka, T., Chopra, N., Fujita, M., 2015. Passivity-Based Bilateral Human-Swarm-Interactions for Cooperative Robotic Networks and Human Passivity Analysis. In: 2015 54th IEEE Conference on Decision and Control (CDC). IEEE, pp. 1033–1039. DOI: <https://doi.org/10.1109/CDC.2015.7402008>
- Inoue, M., Gupta, V., 2019. “Weak” Control for Human-in-the-Loop Systems. *IEEE Control Systems Letters* 3 (2), 440–445.
- Jain, A., Chakraborty, A., Biyik, E., 2018. Distributed Wide-Area Control of Power System Oscillations under Communication and Actuation Constraints. *Control Engineering Practice* 74, 132–143.
- Jianjun, S., Xu, W., Jizhen, G., Yangzhou, C., 2013. The Analysis of Traffic Control Cyber-Physical Systems. *Procedia-Social and Behavioral Sciences* 96, 2487–2496.
- Jurado, I., Maestre, J. M., Velarde, P., Ocampo-Martínez, C., Fernández, I., Tejera, B. I., del Prado, J. R., 2016. Stock Management in Hospital Pharmacy Using Chance-Constrained Model Predictive Control. *Computers in Biology and Medicine* 72, 248–255.
- Khamis, A., Hussein, A., Elmogy, A., 2015. Multi-robot Task Allocation: A Review of the State-of-the-art. In: *Cooperative Robots and Sensor Networks*. Springer, pp. 31–51.
- Koubãa, A., Khelil, A., 2014. *Cooperative Robots and Sensor Networks*. Springer.
- La Bella, A., Klaus, P., Ferrari-Trecate, G., Scattolini, R., 2021. Supervised Model Predictive Control of Large-Scale Electricity Networks via Clustering Methods. *Optimal Control Applications and Methods*.
- Lee, J., Bagheri, B., Kao, H.-A., 2015. A Cyber-Physical Systems Architecture for Industry 4.0-Based Manufacturing Systems. *Manufacturing letters* 3, 18–23.
- Liang, X., 2016. Emerging Power Quality Challenges due to Integration of Renewable Energy Sources. *IEEE Transactions on Industry Applications* 53 (2), 855–866.
- Maestre, J. M., Fernández, M. I., Jurado, I., 2018. An application of economic model predictive control to inventory management in hospitals. *Control Engineering Practice* 71, 120–128.
- Maestre, J. M., Negenborn, R. R. (Eds.), 2014. *Distributed Model Predictive Control Made Easy*. Vol. 69 of *Intelligent Systems, Control and Automation: Science and Engineering*. Springer.
- Maestre, J. M., van Overloop, P. J., Hashemy, M., Sadowska, A., Camacho, E. F., 2014. Human in the Loop Model Predictive Control: An Irrigation Canal Case Study. In: 53rd IEEE Conference on Decision and Control. IEEE, pp. 4881–4886. DOI: <https://doi.org/10.1109/CDC.2014.7040151>
- Maestre, J. M., Zafra Cabeza, A., Fernández García, M. I., Isla Tejera, B., del Prado, J. R., Camacho, E. F., 2013. Control predictivo aplicado a la gestión de stocks en farmacia hospitalaria: un enfoque orientado a la minimización del riesgo. *Revista Iberoamericana de Automática e Informática industrial* 10 (2), 149–158. DOI: <https://doi.org/10.1016/j.riai.2013.03.005>
- Martín, J. G., Frejo, J. R. D., Garcáa, R. A., Camacho, E. F., 2021a. Multi-Robot Task Allocation Problem with Multiple Non-Linear Criteria Using Branch and Bound and Genetic Algorithms. *Intelligent Service Robotics*.
- Martín, J. G., García, R. A., Camacho, E. F., 2021b. Event-MILP-Based Task Allocation for Heterogeneous Robotic Sensor Network for Thermosolar Plants. *Journal of Intelligent & Robotic Systems* 102 (1), 1. DOI: <https://doi.org/10.1007/s10846-021-01346-w>
- Martín, J. G., Maestre, J. M., Camacho, E. F., 2021c. Spatial Irradiance Estimation in a Thermosolar Power Plant by a Mobile Robot Sensor Network. *Solar Energy* 220, 735–744. DOI: <https://doi.org/10.1016/j.solener.2021.03.038>
- Martínez, O. E. B., 2004. Evolución de una idea: de la cibernética a la ciberultura la filosofía griega y la cibernética. *Cuadernos de Filosofía Latinoamericana* 25 (91), 1.
- Masero, E., Frejo, J. R. D., Maestre, J. M., Camacho, E. F., 2020. A Light Clus-

- tering Model Predictive Control Approach to Maximize Thermal Power in Solar Parabolic-Trough Plants. *Solar Energy* 214, 531–541.
- Masero, E., Maestre, J. M., Camacho, E. F., 2022. Market-based clustering of model predictive controllers for maximizing collected energy by parabolic-trough solar collector fields. *Applied Energy* 306, 117936.
- Nagahara, M., Quevedo, D. E., Nešić, D., 2015. Maximum Hands-Off Control: A Paradigm of Control Effort Minimization. *IEEE Transactions on Automatic Control* 61 (3), 735–747.
DOI: <https://doi.org/10.1109/TAC.2015.2452831>
- Negenborn, R. R., Maestre, J. M., 2014. Distributed Model Predictive Control: An Overview and Roadmap of Future Research Opportunities. *IEEE Control Systems Magazine* 34 (4), 87–97.
- Negenborn, R. R., van Overloop, P. J., Keviczky, T., De Schutter, B., 2009. Distributed Model Predictive Control of Irrigation Canals. *Network and Heterogeneous Media* 4 (2), 359–380.
- Priess, M. C., Conway, R., Choi, J., Popovich, J. M., Radcliffe, C., 2014. Solutions to the Inverse LQR Problem with Application to Biological Systems Analysis. *IEEE Transactions on Control Systems Technology* 23 (2), 770–777.
- Protte, M., Fahr, R., Quevedo, D. E., 2020. Behavioral Economics for Human-in-the-Loop Control Systems Design: Overconfidence and the Hot Hand Fallacy. *IEEE Control Systems Magazine* 40 (6), 57–76.
DOI: <https://doi.org/10.1109/MCS.2020.3019723>
- Qin, S. J., Badgwell, T. A., 2003. A Survey of Industrial Model Predictive Control Technology. *Control Engineering Practice* 11 (7), 733–764.
DOI: [https://doi.org/10.1016/S0967-0661\(02\)00186-7](https://doi.org/10.1016/S0967-0661(02)00186-7)
- Ramadan, A., Choi, J., Radcliffe, C. J., 2016. Inferring Human Subject Motor Control Intent Using Inverse MPC. In: 2016 American Control Conference (ACC). IEEE, pp. 5791–5796.
- Ramadan, A., Choi, J., Radcliffe, C. J., Popovich, J. M., Reeves, N. P., 2018. Inferring Control Intent During Seated Balance Using Inverse Model Predictive Control. *IEEE Robotics and Automation Letters* 4 (2), 224–230.
- Ramírez-Arias, A., Rodríguez, F., Guzmán, J. L., Berenguel, M., 2012. Multiobjective Hierarchical Control Architecture for Greenhouse Crop Growth. *Automatica* 48 (3), 490–498.
- Sadowska, A., van Overloop, P. J., Maestre, J. M., De Schutter, B., 2015. Human-in-the-Loop Control of an Irrigation Canal Using Time Instant Optimization Model Predictive Control. In: Proceedings of the 2015 European Control Conference (ECC). IEEE, pp. 3274–3279.
DOI: <https://doi.org/10.1109/ECC.2015.7331039>
- 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* 165, 1–9.
- Schmidt, M., Åhlund, C., 2018. Smart Buildings as Cyber-Physical Systems: Data-Driven Predictive Control Strategies for Energy Efficiency. *Renewable and Sustainable Energy Reviews* 90, 742–756.
- Shibasaki, S., Inoue, M., Arahata, M., Gupta, V., 2020. Weak Control Approach to Consumer-Preferred Energy Management. *IFAC-PapersOnLine* 53 (2), 17083–17088.
- Sun, C., Puig, V., Cembrano, G., 2020. Real-Time Control of Urban Water Cycle under Cyber-Physical Systems Framework. *Water* 12 (2), 406.
- Van Overloop, P. J., Maestre, J. M., Sadowska, A. D., Camacho, E. F., De Schutter, B., 2015. Human-in-the-Loop Model Predictive Control of an Irrigation Canal [Applications of Control]. *IEEE Control Systems Magazine* 35 (4), 19–29.
DOI: <https://doi.org/10.1109/MCS.2015.2427040>
- Wang, G., Gunasekaran, A., Ngai, E. W., Papadopoulos, T., 2016. Big Data Analytics in Logistics and Supply Chain Management: Certain Investigations for Research and Applications. *International Journal of Production Economics* 176, 98–110.
- Wiener, N., 1948. *Cybernetics or Control and Communication in the Animal and the Machine*.
- Wolf, W., 2009. Cyber-physical systems. *IEEE Annals of the History of Computing* 42 (03), 88–89.
- Wu, F.-J., Kao, Y.-F., Tseng, Y.-C., 2011. From Wireless Sensor Networks Towards Cyber Physical Systems. *Pervasive and Mobile computing* 7 (4), 397–413.
- Zafra-Cabeza, A., Maestre, J. M., Ridao, M. A., Camacho, E. F., Sánchez, L., 2011. A Hierarchical Distributed Model Predictive Control Approach in Irrigation Canals: A Risk Mitigation Perspective. *Journal of Process Control* 21 (5), 787–799.
DOI: <https://doi.org/10.1016/j.jprocont.2010.12.012>
- Zhong, R. Y., Newman, S. T., Huang, G. Q., Lan, S., 2016. Big Data for Supply Chain Management in the Service and Manufacturing Sectors: Challenges, Opportunities, and Future Perspectives. *Computers & Industrial Engineering* 101, 572–591.