




# XVII Simposio CEA de Control Inteligente

27-29 de junio de 2022, León



## Estimación del gradiente para optimización del control de enfriadoras

Arahal, M.R.<sup>a,\*</sup>, Satué, M.G.<sup>a</sup>, Ortega, M.G.<sup>a</sup>

<sup>a</sup>Departamento de Ingeniería de Sistemas y Automática, Universidad de Sevilla, Camino de los Descubrimientos, s/n, 41092, Sevilla, España.

**To cite this article:** Arahal, M.R., Satué, M.G., Ortega, M.G. 2022. Gradient estimation for optimized control of chillers. XVII Simposio CEA de Control Inteligente.

### Resumen

El control predictivo basado en modelo se ha usado en plantas de refrigeración como medio para obtener un reparto de carga entre enfriadoras que minimiza el consumo garantizando que la producción de frío se ajusta a la demanda prevista. El principal problema de este método es que se requiere un modelo preciso de la planta. Los modelos usados habitualmente contienen parámetros que pueden ser difíciles de medir. Por este motivo el modelo usado para control puede diferir substancialmente de los datos observados. En este contexto la técnica de control sin sesgo permite corregir el efecto de diversos factores como perturbaciones y errores de modelado. Para usar esta técnica se precisa una estimación del gradiente de la función objetivo con respecto a las acciones de control. En este trabajo en curso se pretende aprovechar las técnicas de control inteligente para obtener mejores estimaciones del gradiente.

*Palabras clave:* Control inteligente, Control predictivo, Enfriadora, Estimación, Planta de refrigeración

### Gradient estimation for optimized control of chillers

#### Abstract

Model based predictive control has been used in cooling plants as a means of solving the chiller loading problem in an optimal manner while satisfying a given cooling demand. The main drawback of this method is the need for an accurate plant model. Most models include adjustable parameters that are difficult to identify. As a result, there are mismatches between plant and plant model. In this context, the offset-free techniques have been proposed to counter the effect of disturbances and modelling errors. A gradient estimation is needed. This paper presents some work in progress aiming at using techniques from intelligent control to attain better gradient estimations.

*Keywords:* Intelligent control, Predictive control, Chiller, Estimation, Cooling plant

### 1. Introducción

Las plantas industriales de producción de frío usan más de una enfriadora conectada en paralelo. Esto es así por diversas razones. La principal suele ser la capacidad de seguir operando si una enfriadora se avería (Dossat, 1961). Otra, menos evidente, es que el rendimiento de un conjunto de máquinas es mejor que el de una sola (de mayor tamaño) (Deng et al., 2014). Por este motivo han surgido estudios acerca de cómo dividir la demanda de frío entre las distintas enfriadoras que constituyen la planta. Este problema recibe el nombre de OCL (Optimal Chi-

ller Loading) (Chang, 2004). Los autores han avanzado en esta línea incluyendo el efecto de los transitorios en el reparto de carga (Arahal et al., 2021b).

Por otro lado, el control predictivo basado en modelo (CPBM) permite considerar el coste de producción de frío directamente y usarlo como función objetivo de manera que el reparto de carga entre enfriadoras se obtiene en línea, considerando en cada momento el estado real de la planta (Satué et al., 2022). Téngase en cuenta que en el OCL, se usan predicciones tanto de la demanda de frío como de las condiciones ambientales (temperatura, humedad, radiación) y de otro tipo (por

\*Autor para correspondencia: arahal@us.es

ejemplo la ocupación de un edificio o la producción prevista en una planta industrial). Estas predicciones no son perfectas y por tanto pueden influir en un reparto de carga mejorable. En el caso de usar CPBM las predicciones pueden afinarse cada cierto tiempo, disminuyendo el impacto de los errores (Arahal et al., 2021a).

Sin embargo, el CPBM requiere un modelo preciso de la planta. Los modelos usados habitualmente contienen parámetros que pueden ser difíciles de medir. Por este motivo el modelo usado para control puede diferir substancialmente de los datos observados. En este contexto la técnica de control sin sesgo permite corregir el efecto de diversos factores como perturbaciones y errores de modelado. Para usar esta técnica se precisa una estimación del gradiente de la función objetivo con respecto a las acciones de control. En este trabajo en curso se pretende aprovechar las técnicas de control inteligente para obtener mejores estimaciones del gradiente.

## 2. El problema del reparto

En la figura 1 se muestra el diagrama de una planta de producción de frío en la que se usan varias enfriadoras en paralelo. El reparto de la carga entre las enfriadoras (OCL) es especialmente relevante en el caso de que las enfriadoras tienen distintas curvas características pues en ese caso el problema no es convexo (Salari and Askarzadeh, 2015). Se han propuesto diversos métodos para resolver el OCL, considerando la carga parcial (PLR) de cada máquina enfriadora como variable de decisión. Por ejemplo en (Chang, 2005) se usan algoritmos genéticos.

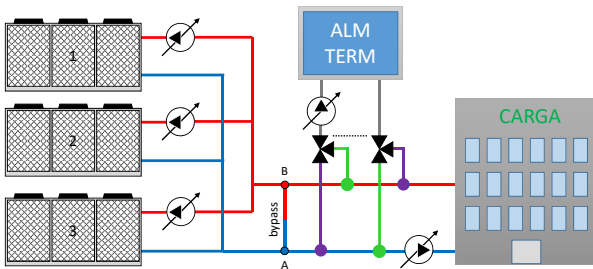


Figura 1: Diagrama de una instalación de producción de frío con 3 enfriadoras y almacenamiento térmico.

El reparto puede obtenerse también mediante el uso de un sistema de control. El objetivo primario de dicho sistema es servir la demanda actual manteniendo las variables intermedias (caudales, temperaturas, etc.) dentro de límites (Bejarano et al., 2018). Como resultado se obtiene un reparto aunque de forma indirecta y no optimizada.

Un caso especial lo constituye el CPBM, donde el modelo de la planta se usa para obtener las acciones de control que permiten combinar los objetivos de bajo nivel (demanda y variables intermedias) con consideraciones de nivel superior como es el caso de la optimización económica. El CPBM se ha aplicado a diferentes tipos de sistemas relacionados con enfriadoras como por ejemplo (Castilla et al., 2011; Candanedo et al., 2013; Álvarez et al., 2013).

El aspecto económico es tenido en cuenta por el CPBM calculando el consumo eléctrico asociado a la producción de una cierta demanda de frío  $\dot{Q}_L$ . Este consumo depende de la temperatura de salida de cada enfriadora  $T^o$  y del flujo másico  $\dot{m}$ . Para una planta con  $N$  enfriadoras el consumo viene dado por

$$E = \left( \sum_{i=1}^N P_i + P_s + P_e \right) \cdot T_H \quad (1)$$

siendo  $P_i$  el consumo eléctrico para la enfriadora  $i$ ,  $P_s$  el consumo de la bomba del circuito secundario y  $P_e$  el consumo extra debido a transitorios. El tiempo  $T_H$  define un cierto horizonte temporal para el problema de optimización, el cual se define mediante

$$\begin{aligned} \min_{\mathbf{x}} \quad & \sum_{t=1}^T E(\mathbf{x}) \\ \text{s.t.} \quad & \dot{Q}(\mathbf{x}) = \dot{Q}_L \\ & x_l \leq \mathbf{x} \leq x_u \\ & g_l \leq G(\mathbf{x}) \leq g_u, \end{aligned} \quad (2)$$

siendo  $\mathbf{x}$  el vector de variables de decisión que definen el estado de cada enfriadora ( $i = 1, \dots, N$ ) para cada periodo temporal  $t = 1$  to  $t = T$ . De este modo

$$\mathbf{x} = \left( \dot{m}_s|_1^T, \dot{m}_1|_1^T, T_1^o|_1^T, \dots, \dot{m}_N|_1^T, T_N^o|_1^T \right)^T \quad (3)$$

siendo  $\dot{m}_s$  el flujo másico en el circuito secundario. Las restricciones consideradas son las siguientes:

- $\dot{Q}(\mathbf{x}) = \dot{Q}_L$  implica que la demanda es satisfecha en cada periodo.
- $x_l \leq \mathbf{x} \leq x_u$  asegura los límites de variables intermedias.
- $g_l \leq G(\mathbf{x}) \leq g_u$  permite imponer restricciones más complejas como por ejemplo el salto de temperatura en cada enfriadora y el consumo máximo.

El problema reflejado en (2) es un problema de optimización multivariable en el que  $\dim \mathbf{x} = T \cdot (2N + 1)$  siendo  $T$  el número de periodos considerados. En la mayoría de los casos se toma entre 8 y 24 horas.

### 2.1. Control predictivo

La técnica de CPBM se aplica con facilidad al problema planteado. Esto permite lidiar con varios aspectos del problema como altas inercias, perturbaciones y la necesidad de optimizar Killian and Kozek (2016). La acción de control  $u$  es un vector que contiene las variables manipulables. El vector  $y$  se forma con medidas tomadas de la planta, como temperaturas. La técnica CPBM considera una ventana deslizante en tiempo discreto que va desde el instante actual  $k$  hasta  $k + H$ , siendo  $H$  el horizonte. Las acciones de control a aplicar se agrupan en el vector  $U = (u(k), \dots, u(k + H))$  y se seleccionan mediante optimización de una cierta función de coste  $J$ . En la función de coste se agrupan términos que penalizan desviaciones de las salidas predichas por el modelo  $\hat{Y}(U) = (\hat{y}(k + 1), \dots, \hat{y}(k + H + 1))$  respecto a las referencias  $Y^*$  y el esfuerzo o coste asociado a las acciones de control. De este modo se construye:

$$J = \|Y^* - \hat{Y}(U)\|^2 + \lambda \|\Delta U\|^2 \quad (4)$$

donde  $\lambda$  es un parámetro ajustable que permite dar mayor peso relativo al coste asociado a las acciones de control. La minimización de  $J$  produce una secuencia  $U^*$  de la cual se usa solamente el primer elemento. En los instantes de muestreo sucesivos se repite todo el procedimiento siguiendo la idea de horizonte deslizante.

### 3. Estimación del gradiente y control inteligente

El llamado control predictivo económico (CPE) une la idea de CPBM con la idea de optimización en tiempo real (OTR) de manera que se consigue un objetivo económico (normalmente reducción de costes). Para evitar los problemas asociados a las imprecisiones del modelo de la planta y a la existencia de perturbaciones, se ha propuesto el concepto de CPE sin sesgo (Vaccari and Pannocchia, 2016). Esta idea se ha aplicado a diversos problemas de control con el propósito de obtener optimalidad en presencia de errores de modelado. Sin embargo, el CPE sin sesgo supone conocimiento de los gradientes estáticos de la planta con respecto a las entradas. Este requisito no es fácil de obtener en el caso de plantas de producción de frío debido a los problemas ya mencionados. Por tanto se suele acudir a estimar dichos gradientes.

Las técnicas de estimación de gradiente se dividen en dos clases: técnicas que usan datos de estado estacionario y las que usan datos dinámicos. En cada grupo se han presentado diferentes variantes para lidiar con algunos de los problemas que se presentan. Entre ellos cabe mencionar los siguientes

#### 3.1. Método de Broyden

El método de Broyden es un cálculo recurrente para estimar gradientes usando valores actuales y pasados obtenidos de mediciones en línea en la planta (Broyden, 1993). El método no precisa la adición de señales de excitación. Matemáticamente equivale a la técnica de la secante usada para estimar una derivada parcial de primer orden.

El método ha sido aplicado al cálculo de gradientes para control óptimo (Roberts, 2000) y en otros contextos, en particular en CPE sin sesgo (Rodríguez-Blanco et al., 2018).

Uno de los principales problemas del método es el asociado al número de condición de las matrices usadas para la adaptación del gradiente cuando los cambios en las entradas son pequeños. Para evitar estos problemas frecuentemente se añade una capa de monitorización que evita la actualización para cambios pequeños en las entradas. Esto elimina el problema numérico, pero puede llevar a situaciones en las que la planta opera en estados no óptimos.

Como parte del trabajo en curso los autores están estudiando el desarrollo de otros mecanismos de supervisión que mejoren la actualización del gradiente en situaciones de estado estacionario evitando el problema de la falta de optimalidad. Los autores estiman que estas ideas tienen una gran proyección y son en la actualidad investigadas en otros ámbitos de aplicación por investigadores de prestigio (Berenguel, 2022).

### 4. Conclusiones

Las técnicas de control inteligente en el contexto de la optimización del control de plantas de producción de frío pueden

ofrecer mejores estimaciones del gradiente. Ha de tenerse en cuenta que los problemas que aparecen en este contexto son similares a los problemas que habitualmente se tratan en el control inteligente: no linealidades, excitación no persistente, tratamiento de datos con incertidumbre y alta dimensión. El trabajo en curso aquí propuesto no está cerrado ni agotado, al contrario existen muchas técnicas que merecen atención. El estudio de las ventajas e inconvenientes puede dar como resultado nuevos esquemas con prestaciones elevadas.

### Agradecimientos

Este trabajo ha sido realizado en el seno del Proyecto RTI2018-101897-B-I00 by FEDER/Ministerio de Ciencia e Innovación, Agencia Estatal de Investigación.

### Referencias

- Álvarez, J., Redondo, J., Camponogara, E., Normey-Rico, J., Berenguel, M., Ortigosa, P., 2013. Optimizing building comfort temperature regulation via model predictive control. *Energy and Buildings* 57, 361–372.
- Arahal, M. R., Ortega, M. G., Satué, M. G., 2021a. Chiller load forecasting using hyper-gaussian nets. *Energies* 14 (12).  
URL: <https://www.mdpi.com/1996-1073/14/12/3479>  
DOI: 10.3390/en14123479
- Arahal, M. R., Satué, M. G., Ortega, M. G., 2021b. Optimal chiller loading including transients. *Energy and Buildings* 253, 111527.
- Bejarano, G., Alfaya, J. A., Rodríguez, D., Morilla, F., Ortega, M. G., 2018. Benchmark for pid control of refrigeration systems based on vapour compression. *IFAC-PapersOnLine* 51 (4), 497–502.
- Berenguel, P. O., 2022. Modelado y control del proceso de producción de microalgas mediante estrategias de aprendizaje automático. V Jornadas de Doctorado en Informática 131, 131.
- Broyden, C., 1993. Block conjugate gradient methods. *Optimization methods and Software* 2 (1), 1–17.
- Candanedo, J., Dehkordi, V., Stylianou, M., 2013. Model-based predictive control of an ice storage device in a building cooling system. *Applied Energy* 111, 1032–1045.
- Castilla, M., Álvarez, J., Berenguel, M., Rodríguez, F., Guzmán, J., Pérez, M., 2011. A comparison of thermal comfort predictive control strategies. *Energy and buildings* 43 (10), 2737–2746.
- Chang, Y.-C., 2004. A novel energy conservation method optimal chiller loading. *Electric Power Systems Research* 69 (2-3), 221–226.
- Chang, Y.-C., 2005. Genetic algorithm based optimal chiller loading for energy conservation. *Applied Thermal Engineering* 25 (17-18), 2800–2815.
- Deng, K., Sun, Y., Li, S., Lu, Y., Brouwer, J., Mehta, P. G., Zhou, M., Chakraborty, A., 2014. Model predictive control of central chiller plant with thermal energy storage via dynamic programming and mixed-integer linear programming. *IEEE Transactions on Automation Science and Engineering* 12 (2), 565–579.
- Dossat, R. J., 1961. Principles of refrigeration. John Wiley & Son.
- Killian, M., Kozek, M., 2016. Ten questions concerning model predictive control for energy efficient buildings. *Building and Environment* 105, 403–412.
- Lo, C.-C., Tsai, S.-H., Lin, B.-S., 2016. Economic dispatch of chiller plant by improved ripple bee swarm optimization algorithm for saving energy. *Applied Thermal Engineering* 100, 1140–1148.
- Roberts, P., 2000. Broyden derivative approximation in ISOPE optimising and optimal control algorithms. *IFAC Proceedings Volumes* 33 (16), 293–298.
- Rodríguez-Blanco, T., Sarabia, D., de Prada, C., 2018. Optimización en tiempo real utilizando la metodología de adaptación de modificadores. *Revista Iberoamericana de Automática e Informática industrial* 15 (2), 133–144.
- Salari, E., Askarzadeh, A., 2015. A new solution for loading optimization of multi-chiller systems by general algebraic modeling system. *Applied Thermal Engineering* 84, 429–436.
- Satué, M. G., Arahal, M. R., Acedo, L. F., Ortega, M. G., 2022. Economic versus energetic model predictive control of a cold production plant with thermal energy storage. *Applied Thermal Engineering* 210, 118309.
- Vaccari, M., Pannocchia, G., 2016. A modifier-adaptation strategy towards offset-free economic mpc. *Processes* 5 (1), 2.