

Apoyo a la Toma de Decisión en una Red de Evaporadores Industriales

Marc Kalliski^a, José Luis Pitarch^{b,*}, Christian Jasch^c, César de Prada^b

^a Fakultät Bio- und Chemieingenieurwesen, Technische Universität Dortmund, Emil-Figge-Str. 70, 44227, Dortmund, Germany.

^b Departamento de Ingeniería de Sistemas y Automática, EII, Universidad de Valladolid, C/Real de Burgos s/n, 47011, Valladolid, España.

^c Lenzing Aktiengesellschaft, Werkstraße 2, 4860, Lenzing, Austria

Resumen

La planificación de la producción y tareas de mantenimiento en una red de equipos es una tarea cuya complejidad aumenta exponencialmente con el número de productos, equipos y tareas. Encontrar soluciones óptimas (económicas o de eficiencia de recursos) se hace especialmente difícil para un planificador humano, más aún cuando se requiere tomar decisiones en breves periodos de tiempo. Este trabajo aborda el problema de distribución de carga en tiempo real y programación de limpiezas en una red de evaporadores industriales mediante herramientas de ayuda a la decisión basadas en optimización mixta entera con modelos. Las herramientas propuestas tienen en cuenta las preferencias de visualización de los operarios y están integradas con el sistema de supervisión de la planta. Además de proporcionar recomendaciones para la operación óptima de la red, se incluye un sistema semiautomático de actualización de modelos basado en datos históricos de operación.

Palabras Clave:

Ayuda a la operación, Asignación de recursos, Modelos subrogados, Programación de limpiezas, Industria del papel y textil.

Support to Decision-Making in a Network of Industrial Evaporators

Abstract

Production and maintenance scheduling within an equipment network is a task whose complexity increases exponentially with the number of products, equipment and tasks. Finding optimal solutions (economic or resource efficient) becomes especially difficult for a human scheduler, even more when taking decisions in short time periods is required. This work addresses the problem of load allocation in real time and cleaning scheduling in a network of industrial evaporators via decision-support tools based on mixed-integer optimization with plant models. The proposed tools take into account the operators' visualization preferences and they are integrated with the plant supervision system. Apart from providing recommendations for the optimal operation of the network, a semi-automatic model updating system based on historical operation data is included.

Keywords:

Decision support systems, Resource allocation, Surrogate models, Cleaning schedule, Fiber and paper industry.

1. Introducción

Las actuales condiciones variables de los mercados así como la cada vez más restrictiva regulación en materia medioambiental hacen que la industria de procesos se vea forzada a adaptar su operación de forma continua para cumplir las restricciones y a su vez mantenerse competitiva en un marco global. Por lo tanto, se hace necesaria una optimización de planta completa ágil y que tenga en cuenta tanto variables continuas (cantidades a procesar, variables de control, etc.) como decisiones discretas (asignación de equipos, modos de operación o tareas de mantenimiento) (Engell y Harjunkoski, 2012).

Para abordar estos nuevos retos, se necesita proveer de herramientas asistidas por ordenador a los gerentes de planta y operarios, de forma que sean una guía para mejorar la eficiencia, optimizar la producción y el consumo de recursos (Melouk *et al.*, 2013; Krämer y Engell, 2017).

Se debe poner especial atención al desarrollo eficiente de modelos de planta, ya que son la base para las tareas de reconciliación de datos, control avanzado, optimización y coordinación con la planificación. Además, existen una amplia variedad de alternativas en lenguajes de programación y algoritmos de optimización, lo que puede llegar a ser un rompecabezas para el ingeniero a la hora de implementar un Sistema de Ayuda a la Decisión (SAD) e integrarlo con la infra-

*Autor para la correspondencia: jose.pitarch@autom.uva.es

estructura de sistemas de información en planta, e.g., mediante una plataforma neutra que sea capaz de conectar con diferentes tecnologías de gestión de la información (LeiKon, 2014). En este trabajo se aborda dicha problemática en la red de evaporación de Lenzing AG, una de las mayores plantas de fabricación de fibra viscosa del mundo, y se proponen prototipos de herramientas de apoyo a las decisiones que los operarios deben tomar para la operación óptima de los equipos.

La principal tarea que debe realizar el encargado de gestión de la red de evaporación (alrededor del 60% del consumo energético total de la fábrica) es distribuir la carga entre los equipos disponibles con el objetivo de cumplir la tasa de evaporación requerida por el proceso principal de fabricación. Cada planta de evaporación tiene una eficiencia nominal y una capacidad. Además, existen diversos productos que no pueden ser mezclados, lo que complica la tarea. Por tanto aparece un primer problema de optimización en tiempo real (OTR) para distribuir la carga de forma que se minimice el consumo de energético (vapor de calderas) general.

A esta tarea hay que añadir el problema de la disminución de eficiencia con el tiempo en los equipos, debido al fenómeno de ensuciamiento por materia orgánica en los intercambiadores de calor. Esto requiere programar tareas de mantenimiento (limpieza) periódicas en los evaporadores para recuperar la eficiencia nominal, lo que incurre en un coste adicional de productos, personal dedicado y una disminución de la capacidad de evaporación total. Consecuentemente, aparece un problema adicional de optimización económica con decisiones continuas y discretas, en el que se deben balancear los costes de operación y mantenimiento. De hecho el fenómeno de pérdida de eficiencia en equipos y su problemática asociada son bastante comunes en la industria de procesos: ensuciamiento en intercambiadores de calor (Heluane *et al.*, 2012), coquización en hornos de cracking térmico (Schulz *et al.*, 2006), desactivación de catalizadores en reactores químicos (Bizet, *et al.*, 2005), etc.

Nuestra propuesta en este trabajo es, por un lado, diseñar una optimización en tiempo real (entendiendo tiempo real por una adecuada ejecución periódica) que resuelva el problema de asignación de productos a equipos y distribución de cargas. Por otro lado, el problema de planificación de limpiezas se plantea como una segunda optimización económica para cada línea, en la que se busca encontrar una solución periódica con ciclo de trabajo (operación + limpieza) óptimo.

Para representar el comportamiento de las plantas de evaporación se utilizarán modelos de caja negra basados en datos, facilitando así la tarea de actualización de los mismos por los ingenieros de planta. Los problemas de optimización anteriormente mencionados se han programado como módulos en MATLAB® y MS Excel® que utilizan algoritmos eficientes de programación mixta-entera (MIP) para la resolución. A su vez, estos módulos enlazan con el sistema de información de la planta OSIssoft PI.

Las siguientes secciones del trabajo detallan: primero, en la Sección 2, la descripción del caso de estudio industrial, sus limitaciones y las asunciones tenidas en cuenta. Después, la Sección 3 presenta los modelos utilizados y resume los detalles de la rutina semiautomática para la actualización de los mismos. La Sección 4 expone la formulación de los dos problemas de optimización mencionados, asignación de cargas y programación de limpiezas. Posteriormente la Sección 5 está

enfocada al diseño de las interfaces con el usuario y a la integración de las herramientas propuestas. Éstas han sido evaluadas en planta, cuyos resultados se presentan en la Sección 6. Para concluir, en la Sección 6 se discuten los resultados preliminares y, basándose en ellos, se comentan los siguientes pasos a dar para continuar mejorando.

2. Caso de Estudio

La fabricación de fibra viscosa se basa en un recurso renovable: la madera. Una vez triturada, la pulpa de celulosa que contiene la madera se trata químicamente y se convierte en una solución viscosa. La etapa clave de la producción, el hilado (destacado en la Figura 1), es la reconversión de dicha solución en nuevas fibras con las propiedades deseadas. Para ello, se introduce la pasta de celulosa en un baño ácido, y se hace pasar a presión por unos tamices de fino diámetro.

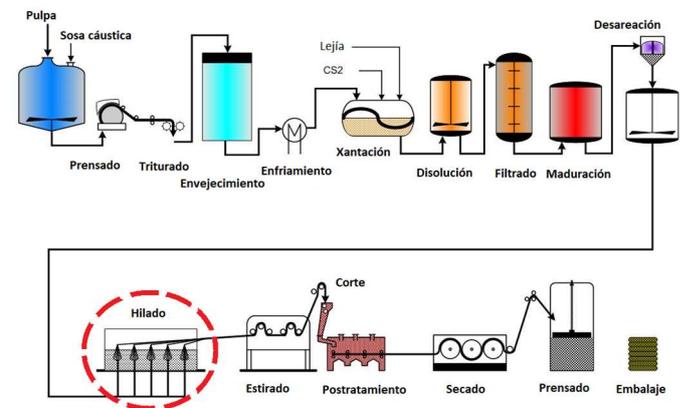


Figura 1: De la pulpa a las fibras.

Aparte de las nuevas fibras sólidas, como parte del mencionado tratamiento se produce sulfato de sodio (Na_2SO_4) y agua como subproductos, degradando así la acidez del baño y, en consecuencia, la calidad del producto obtenido. Por lo tanto, se hace necesario regenerar dicho baño en las máquinas de hilado mediante la extracción continua de agua y Na_2SO_4 . A tal efecto se utiliza una red de plantas de evaporación y una sección de cristalización, anexas al proceso de producción principal (Figura 2).

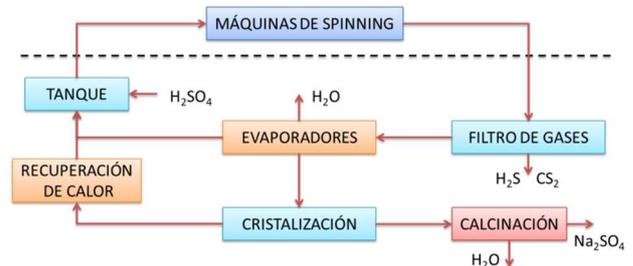


Figura 2: Ciclo de regeneración del baño ácido.

Seguidamente, la Figura 3 muestra un esquema simplificado de una planta de evaporación, donde se pueden observar las principales entradas de producto y consumo energético (vapor vivo de calderas) y salidas de producto concentrado y correspondientes condensados de agua. Además se muestran las principales variables que gobiernan la eficiencia de la operación: el caudal de recirculación de producto F y la temperatura del producto a la entrada de las cámaras de eva-

poración T (variables manipuladas), y la temperatura del agua del sistema de condensación T_{MK} (variable dependiente de los factores climatológicos).

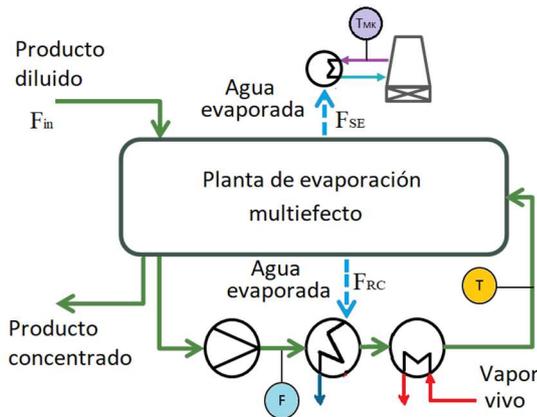


Figura 3: Esquema simplificado de una planta de evaporación.

Para una explicación más detallada de la planta de evaporación y su sistema de control se emplaza al lector a consultar la referencia (Pitarch *et al.*, 2017).

2.1. Descripción de la Red de Evaporadores

La red de evaporación está formada por 25 plantas con capacidades nominales dispares. Esta red debe ser capaz de regenerar los baños ácidos provenientes del hilado, existiendo varios tipos de fibras a fabricar. Algunas plantas de evaporación pueden prestar servicio en más de un ciclo de regeneración, pero solo pueden estar trabajando en uno a la vez. El cambio de un tipo de baño a otro requiere tiempo e incurre en un coste (desconexión y limpieza del evaporador).

Diversos factores afectan a la eficiencia de las plantas:

- **Tipo de planta:** Hay plantas compactas de pequeña capacidad, de tres etapas con capacidades medias y otras de gran capacidad equipadas con torre de refrigeración (el resto condensan utilizando agua de río).
- **Perturbaciones externas:** La temperatura y humedad del aire ambiente afectan al rendimiento de las torres de refrigeración, y la temperatura del agua de río a los condensadores.
- **Ensuciamiento en los intercambiadores:** Los restos de materia orgánica contenidos en el baño ácido se adhieren a las paredes del intercambiador, reduciendo así la transferencia de calor.
- **Punto de operación:** Existen varias combinaciones de caudal F y temperatura T que consiguen la consigna deseada de evaporación. Sin embargo, el consumo energético (vapor vivo) es distinto.

El objetivo primario de la operación óptima en la red es reducir el consumo específico de vapor (CEV) global, definido en un periodo de tiempo como:

$$CEV := CAV / FE \quad (1)$$

Donde CAV denota el consumo absoluto de vapor y FE el flujo de agua evaporada (extraída del baño) en idénticas unidades físicas.

La tarea del personal de planta es encontrar una asignación óptima de plantas a productos y una operación óptima de las

plantas que asegure el menor CEV global. Sin embargo, esta forma óptima de operar solo puede conseguirse si se tienen en cuenta todas las anteriores influencias sobre la eficiencia, lo que no resulta tarea fácil debido el gran tamaño del problema combinatorio asociado.

En consecuencia, se necesitan herramientas de ayuda a la decisión basadas en optimización que guíen a los operarios a tomar decisiones. Para ello, se deben desarrollar modelos de plantas adecuados para optimización, teniendo en cuenta que las recomendaciones proporcionadas deben estar disponibles en un breve periodo de tiempo para asegurar la aceptación del personal.

2.2. Modelado de las plantas

Aunque los evaporadores varían en el número de etapas y capacidades, el montaje y control de la Figura 3 es similar para todas las plantas. El flujo de agua evaporada depende del caudal de recirculación F , la temperatura del producto T y de la temperatura del agua de refrigeración T_{MK} , la cual está limitada de alguna manera por la temperatura ambiente exterior (condensado por torre de enfriamiento o agua de río).

Para evaluar la eficiencia de las plantas respecto al punto de operación, se han realizado pruebas experimentales con diferentes valores de las variables controladas (F, T), asumiendo una temperatura ambiente y un nivel de ensuciamiento aproximadamente constantes (por ejemplo, tras una limpieza). De estos experimentos se obtiene un mapeado del CEV con las variables de control, tipo el que se muestra en el esquema representativo de la Figura 4. Se puede observar que el consumo específico de vapor se comporta de forma aproximadamente lineal con las variaciones en la temperatura y caudal de recirculación. Además, nótese como un mismo flujo de evaporación deseado (eje de abscisas) se puede obtener con múltiples combinaciones de T y F , las cuales llevan asociados distintos consumos energéticos (eje de ordenadas). Por ejemplo, el punto de operación $[T_2, F_1]$ consigue la misma evaporación que el punto $[T_1, F_2]$, pero con menor consumo específico de vapor. El análisis de dicho comportamiento nos lleva a descubrir un patrón de operación óptima: la máxima eficiencia se obtiene con temperatura T alta y caudal de recirculación F mínimo, que cumpla la consigna de evaporación. Este patrón define una zona de operación energética óptima, representada por la frontera verde en la Figura 4.

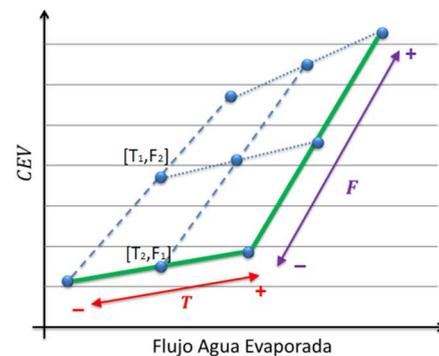


Figura 4: CEV versus flujo de agua evaporada.

La temperatura en el sistema de refrigeración T_{MK} se va a tratar como una entrada de perturbación conocida, ya que depende del ambiente y es medible. Se asume también que el efecto del ensuciamiento en los intercambiadores provoca un

progresivo aumento del consumo específico para el mismo punto de operación, i.e., el mapeado de la Figura 4 se desplaza verticalmente con el grado de ensuciamiento. Por tanto, el ensuciamiento se asimilará como una entrada de perturbación K_f desconocida, que deberá ser estimada a partir de datos medidos en planta. Finalmente, se proponen dos modelos afines con las entradas para representar el comportamiento de una planta de evaporación:

$$FE = [a_1 \ a_2 \ a_3 \ b_0] \cdot [T \ F \ T_{MK} \ 1]^T + K_{f1} \quad (2)$$

$$CEV = [c_1 \ c_2 \ c_3 \ d_0] \cdot [T \ F \ T_{MK} \ 1]^T + K_{f2} \quad (3)$$

Donde $\theta := \{a_1, a_2, a_3, b_0, c_1, c_2, c_3, d_0\}$ son parámetros constantes a identificar mediante regresión fuera de línea con datos históricos, mientras que K_{f1} y K_{f2} representan el estado de ensuciamiento (serán estimados en línea). El consumo absoluto de vapor (CAV) se calcula como el producto de (2) y (3). De esta manera, dado un estimado del estado de ensuciamiento K_{f1} y una temperatura del agua de refrigeración T_{MK} medida, la máxima y mínima capacidad de evaporación, denotadas por \overline{EC} y \underline{EC} respectivamente, para cada planta pueden ser calculadas por (2) y los límites de operación de caudal ($\overline{F} \leq F \leq \underline{F}$) y temperatura ($\overline{T} \leq T \leq \underline{T}$):

$$\overline{EC} = FE(\overline{T}, \overline{F}, T_{MK}, K_{f1}), \quad \underline{EC} = FE(\underline{T}, \underline{F}, T_{MK}, K_{f1}) \quad (4)$$

El criterio para seleccionar el punto de operación en cada planta es: mínimo CEV cumpliendo una consigna de agua evaporada, i.e., el punto de operación debe pertenecer a la frontera verde marcada en la Figura 4. Esto se asegura mediante una estrategia de control sencilla, consistente en un PID de rango partido que actúa primero llevando la temperatura T a su límite superior para después ajustar la consigna de evaporación deseada con el caudal de recirculación F . Dicho control ha sido ya implementado en el sistema de control distribuido (DCS) para cada planta. Gracias a ello, dado ahora un flujo FE deseado y un estimado del estado de ensuciamiento K_f , es posible predecir con (2) los valores de control (F, T) necesarios para operar en la zona de eficiencia óptima: nótese que si T se fija en su máximo (o F en su mínimo para cargas bajas) y T_{MK} viene dada por el sistema de refrigeración, el caudal F (o T en cargas bajas) se despeja directamente de (2) y, por tanto, el CEV se calcula con (3).

3. Actualización Semiautomática de Modelos

Como se ha planteado en la sección anterior, los modelos de planta necesitan una estimación del ensuciamiento en línea. Además, es conveniente actualizar el resto de parámetros fijos de forma periódica para corregir posibles derivas con el tiempo y que sigan reflejando la realidad.

Para el conveniente mantenimiento de los modelos se ha implementado en MATLAB una rutina de identificación que realiza una fase de tratamiento de datos para eliminar medidas inconsistentes, identifica transitorios ante cambios de punto de operación (escalón) y ajusta los parámetros del modelo de forma iterativa. Los datos de planta requeridos se obtienen del sistema PI de OSIsoft vía conexión OPC (“OLE for Process Control,” estándar de comunicaciones entre software industrial), mientras que información adicional como la ventana de tiempo para identificación, etiquetas de las variables recogidas en el histórico, mínimo cambio en el FE , ban-

da de ruido aceptable en estado estacionario, máximo tiempo en transitorio ante cambio escalón o la ventana de tiempo para validación, son proporcionados por el operario de planta mediante formularios MS Excel estandarizados. Finalmente, la calidad del modelo se evalúa mediante comparación de las predicciones de FE y CEV con sus medidas.

3.1. Detección de Cambios de Carga

Los modelos (2) y (3) son estacionarios, se deben identificar los subconjuntos de datos en los que la planta se encuentre en estado transitorio entre un punto de operación y otro. Además, la contribución del ensuciamiento (desconocida a priori) debería ser eliminada del conjunto para la correcta identificación de θ mediante datos históricos. Una manera práctica de superar este inconveniente es utilizar datos de cambios en la operación que estén sujetos al mismo grado de ensuciamiento. Para ello, la rutina de modelado busca cambios en el FE para recoger datos en estacionario previos y posteriores al cambio, asumiendo que el punto de operación varía suficientemente como para identificar θ y que el ensuciamiento no varía significativamente en una ventana de tiempo inferior a un día.

El procedimiento es escanear los datos históricos en búsqueda de cambios significativos en la carga como se muestra en la Figura 5, habiendo previamente proporcionando los intervalos de tiempo denotados como a y b . Los escalones son identificados en los siguientes casos: [1] los datos en la zona acotada como a sean estacionarios (asumible en una banda de variabilidad predefinida), [2] el cambio sea mayor que un mínimo c y [3] la transición entre los dos estacionarios se realice dentro del intervalo b . Para cada cambio identificado se hace la media de los valores en los estacionarios antes y después del cambio, y se traduce en una entrada de datos que se almacena para regresión. Por supuesto, para una correcta identificación de θ , se necesitan suficientes cambios de carga provocados por las entradas al sistema (T, F y T_{MK}) para que en el conjunto de datos para regresión haya excitación suficiente en todos los canales.

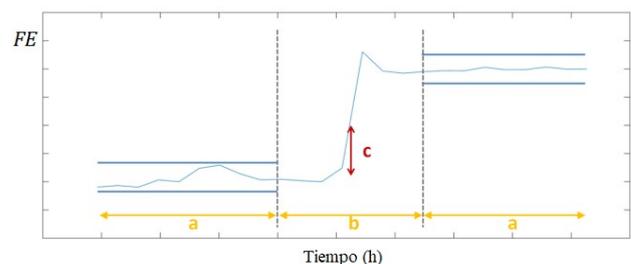


Figura 5: Estado estacionario antes y después del cambio (entre cotas azules), mínimo cambio aceptado (flecha roja c) y máximo tiempo en transitorio b .

3.2. Estimación de Parámetros

Asumiendo que el grado de ensuciamiento es diferente de un experimento a otro pero permanece constante durante cambios de carga, los parámetros K_f pueden ser estimados mediante comparación de las predicciones del modelo ($\overline{CEV}, \underline{FE}$) con los valores medidos CEV y FE . El estimado resultante del parámetro se asigna después a ambos puntos de operación (antes y después del cambio analizado).

De esta forma se puede realizar una identificación iterativa por mínimos cuadrados sobre todo el conjunto de datos alma-

cenados, la cual primero proporciona un primer estimado de los parámetros θ , para utilizarlos en un segundo paso estimando valores de K_f y así encontrar una nueva generación del modelo. Dichas iteraciones continúan hasta que el residuo

$$R(\theta, u) := \sum_{i=1}^n \left(\frac{(FE_i - \widehat{FE}_i)^2}{\sigma_{1i}} + \frac{(CEV_i - \widehat{CEV}_i)^2}{\sigma_{2i}} \right) \quad (5)$$

se reduzca significativamente. Aquí $u := [T, F, T_{MK}]$ representa el vector de entradas del modelo (2)-(3), n es el número de cambios de carga identificados y $(\sigma_{1i}, \sigma_{2i})$ son factores de normalización, calculados por ejemplo como los valores absolutos del cambio en las variables o las varianzas de las medidas utilizadas en cada punto de operación. El anterior procedimiento se resume en el siguiente algoritmo.

Algoritmo 1. Estimación de parámetros iterativa.

1. Proporcionar un estimado inicial para θ y hacer $k=0$.
2. Hacer la media de las medidas de CEV y FE en cada estado estacionario recogido en el conjunto de datos.
3. Estimar los factores K_f para cada experimento almacenado por comparación de la predicción del modelo con los valores del paso anterior.
4. Minimizar (5) con θ como variables de decisión para encontrar el mejor ajuste común a todos los datos.
5. Si $R_k < R_{k-1}$ hacer $k=k+1$ e ir al Paso 3. En otro caso, el algoritmo termina y proporciona los óptimos θ^* .

En la práctica, para un estimado inicial razonable de θ , el valor de los parámetros converge en pocas iteraciones.

3.3. Validación de modelos

La etapa de validación en la rutina de modelado se requiere para evaluar la calidad de los modelos en un conjunto de datos independiente de los utilizados para identificación. Estos datos se seleccionan del histórico de acuerdo al procedimiento de la Sección 3.1. Primero, el factor de ensuciamiento K_f se calcula para ajustar la desviación de los modelos respecto a la media de los valores en estacionario antes del cambio de carga para el experimento seleccionado. Después, el modelo con K_f actualizado se utiliza para simular la planta aplicando los cambios medidos en las entradas en el experimento. Finalmente se compara la predicción del modelo con el punto de operación real antes y después del cambio (Figura 6). El error absoluto se normaliza respecto al tamaño del cambio en el CAV. De esta forma se tiene una indicación del error relativo para evaluar el modelo.

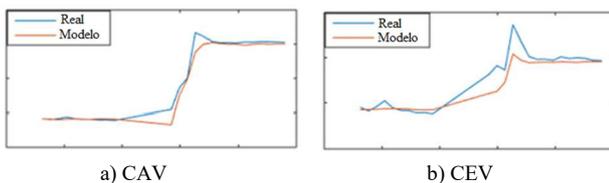


Figura 6: Validación ante cambio no incluido en los datos de identificación.

Los errores relativos observados en las pruebas realizadas están en su mayoría por debajo del 10%, lo que es aceptable debido a que la optimización se ejecutará de forma periódica y el error de predicción no se acumula con el tiempo gracias a la estimación en línea de los parámetros de ensuciamiento K_f . En algunos casos se han observado errores relativos de hasta

30%. Analizando las causas se llegó a la conclusión de que es debido a una pobre selección de experimentos en los datos de identificación, e.g. transitorios identificados erróneamente como estacionarios, falta de excitación suficiente en alguno de los canales de entrada, etc. En estos casos, una intervención manual para seleccionar los experimentos (cambiando el horizonte temporal o las bandas de ruido) fue suficiente para mejorar el ajuste.

4. Operación Óptima de la Red

Para monitorizar y evaluar en tiempo real como de óptima está siendo la operación de la red (respecto al mejor caso dadas las condiciones actuales) y, si se requiere, tomar medidas correctivas, se han definido los siguientes indicadores de eficiencia (Kalliski et al., 2015; Kujanpää et al., 2017).

Definición 1. Se denotará por *Consumo Específico de Vapor Relativo* (REI_1) a la relación entre el CEV medido en planta y el óptimo alcanzable, predicho mediante optimización basada en modelos \widehat{CEV}^* .

$$REI_1 := 100 \cdot \frac{\widehat{CEV}^*}{CEV} \quad (6)$$

Definición 2. Dado un caudal de evaporación FE , el *Coste Medio Normalizado* por hora (REI_2) indica el coste unitario (€/h) de una planta de evaporación durante un ciclo de operación t_f , i.e., entre dos tareas de limpieza consecutivas.

$$REI_2 := (\text{Coste Operacion} + \text{Coste Limpieza}) / t_f \quad (7)$$

Donde el coste de operación depende del caudal de evaporación FE (supuesto igual al valor consigna en el caso de control perfecto), del consumo de vapor vivo, y de los días en operación t_f . Mientras que el coste de limpieza depende de los productos de limpieza y del personal asociado a dicha tarea. Detalles en la Sección 4.2.

4.1. Asignación Óptima de Cargas

El problema puede plantearse de forma general como, dado un conjunto de $p \in P$ productos a procesar en $e \in E$ plantas de evaporación, asignar plantas a líneas de producto y distribuir la carga de agua evaporada por producto SP_p entre dichas plantas de manera que se minimice el CAV global de la red. Se han definido dos conjuntos de variables de decisión para la optimización:

- X_{ep} : Variable binaria que enlaza el producto p con la planta de evaporación e .
- FE_{ep} : Variable real que fija el flujo de evaporación a obtener en una planta e procesando el producto p .

Recuérdese que T_{MK} es una entrada conocida y acotada y que el estado de ensuciamiento K_f viene proporcionado por el estimador. Entonces, el conjunto de capacidades máximas y mínimas de cada planta viene dado por (4). Siguiendo el patrón de control óptimo para cada planta (llevar T a su límite superior \bar{T}) expuesto en la Sección 2.2, despejando F de (2) y sustituyendo en (1) y (3), obtenemos:

$$F_{ep} = \frac{FE_{ep} - a_1 \bar{T} - a_3 T_{MKe} - b_0 - K_{fle}}{a_2} \quad (8)$$

$$CAV_{ep} = \frac{c_2}{a_2} FE_{ep}^2 + \left[\left(c_1 - \frac{c_2 a_1}{a_2} \right) \bar{T} + \left(c_3 - \frac{c_2 a_3}{a_2} \right) T_{MK} - \frac{c_2 b_0}{a_2} + d_0 - \frac{c_2 K_{fle}}{a_2} + K_{fle} \right] FE_{ep} \quad (9)$$

Finalmente, aportando dicha información, la asignación óptima de plantas a productos se plantea como el siguiente problema de programación mixta-entera cuadrática (MIQP):

$$\text{minimizar } \sum_{e \in E} \sum_{p \in P} CAV_{ep} \quad (10)$$

$$\text{sujeto a: } \sum_{p \in P} X_{ep} \leq 1 \quad \forall e \in E \quad (11)$$

$$\sum_{e \in E} FE_{ep} \geq SP_p \quad \forall p \in P \quad (12)$$

$$FE_{ep} \leq \overline{EC}_e \cdot X_{ep} \quad \forall e \in E, \forall p \in P \quad (13)$$

$$FE_{ep} \geq \underline{EC}_e \cdot X_{ep} \quad \forall e \in E, \forall p \in P \quad (14)$$

$$X_{ep} = 0 \quad (e,p) \notin N \quad (15)$$

$$X_{ep} \in \{0,1\}, FE_{ep} \in R^+ \quad (16)$$

En (11) se asegura que cada planta sólo trabaja con un producto a la vez, donde además X_{ep} se restringe en (15) a encontrar soluciones factibles dentro del conjunto N de conexiones físicamente posibles entre plantas y productos. Con (12) se asegura cumplir la demanda total de evaporación por producto SP_p . A su vez (13)-(14) fuerzan que, si la planta e está asignada a procesar el producto p , el flujo de evaporación FE_{ep} toma valores dentro de los límites preestablecidos, o es cero en cualquier otra situación.

4.2. Programación de Limpiezas

La optimización anterior está diseñada para que se ejecute en tiempo real y solo tiene en cuenta el estado actual de las plantas. Una vez que la operación óptima está asegurada por (10)-(16), la idea es diseñar una rutina complementaria que sugiera el ciclo de trabajo óptimo (día a realizar la siguiente tarea y tipo de limpieza) que minimice el REI_2 . Sin embargo, para planificar las tareas de limpieza se necesitan modelos de evolución temporal del ensuciamiento (predicción).

Se han realizado extensos ensayos experimentales midiendo el CEV en cada planta operando en un nivel referencia (punto de operación predefinido) durante ciclos de limpieza consecutivos. Esto permite aislar el efecto que tiene el ensuciamiento sobre el CEV, haciendo así más comparables las medidas en diferentes días. Mediante este procedimiento se han podido identificar evoluciones temporales del ensuciamiento que pueden ser asimiladas a un comportamiento lineal mediante regresión, véase Figura 7.

Así, la contribución del ensuciamiento K_f en (2)-(3) queda

$$K_f(t) = K_{f0} + \alpha \cdot t \quad (17)$$

donde t representa el tiempo de operación (en días) desde la última limpieza, K_{f0} es la estimación del valor inicial del parámetro cuando la planta está limpia y α es la pendiente del modelo lineal. De esta forma, dado un SP de evaporación deseado, se puede calcular (predecir) el progresivo aumento del CAV con el tiempo y, por tanto, sus costes.

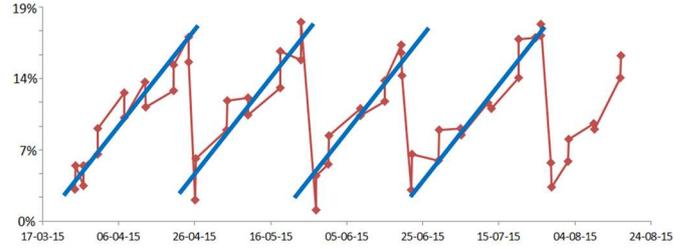


Figura 7: Evolución del CEV medido (puntos en rojo) y superposición con salida del modelo de regresión (azul).

Para abordar el problema de comparar recursos de diferente naturaleza (vapor, mano de obra, productos de limpieza, etc.) y poder presentar resultados con un único indicador de eficiencia (el previamente definido REI_2), no queda más remedio que incluir precios y costes (unidad común a todos los recursos). Así, los costes de acumulados en una planta durante un ciclo de trabajo t_f se calculan como:

$$\text{Coste Operación} = \sum_{t=0}^{t_f} CAV(t) \cdot P_{Th} \quad (18)$$

$$\text{Coste Limpieza} = \Delta t_{cl} \cdot P_{Manh} + W_{H_2O} \cdot P_{m^3} + \Delta t_{cl} \cdot CAV(t_f) \cdot 1.1 \cdot P_{Th} \quad (19)$$

Donde Δt_{cl} es el tiempo requerido para completar una tarea de limpieza determinada, W_{H_2O} es la cantidad de agua con agentes de limpieza utilizada, (P_{Th} , P_{Manh} , P_{m^3}) son los costes de vapor vivo, mano de obra y agua residual respectivamente y t_f es el futuro día donde se sugiere realizar la limpieza. Una vez que el valor de FE se ha fijado para cada planta por (10)-(16)¹, el $CAV(t)$ se calcula con (9) y (17). Nótese también que los costes de limpieza incluyen un término adicional para tener en cuenta que, cuando un evaporador se desconecta para limpiarse, otros deben asumir su carga, aumentando así su consumo energético. Este efecto se ha contemplado en (19) mediante un incremento del 10% sobre el coste del vapor consumido por la planta en el momento de la parada para mantenimiento.

El objetivo en este caso es minimizar el REI_2 respecto a t_f para cada planta de evaporación de forma que se asegure una política de limpieza periódica *óptima individualmente*, asumiendo que será *cuasi óptima* para la red completa. No obstante, hay que lidiar con un pequeño inconveniente a la hora de usar (7) como función objetivo: el coste de operación (18) es una suma discreta de t_f términos, siendo el valor de t_f desconocido a priori (es precisamente el resultado que se busca obtener de la optimización). Para resolver el problema de una manera elegante (no iterativa), se ha hecho uso de la serie aritmética descubierta por Gauss a finales del siglo XVIII para sumar los t_f primeros números (Burton, 1976):

$$\kappa \cdot (1+2+3+\dots+t_f) = \kappa \cdot \frac{(1+t_f) \cdot t_f}{2}, \quad \kappa \in R \quad (20)$$

Adicionalmente se deben considerar dos tipos de tareas de limpieza, denotadas por S (leve) y B (profunda), con diferentes niveles de eficacia alcanzada K_{f0} , tiempos de limpieza Δt_{cl} , y cantidad de productos empleados W_{H_2O} . Así, cada tipo

¹ Por simplicidad se asumen valores constantes para FE y T_{MK} , ya que se podrán actualizar con medidas y corregir las decisiones futuras (Sección 4.3). No obstante, no existe inconveniente en utilizar pronósticos en (18).

de limpieza se caracteriza por unos *costes fijos* distintos. Por tanto, la herramienta de optimización debe elegir que opción es la más apropiada para minimizar el REI_2 .

Finalmente, el problema de optimización propuesto para encontrar la política de limpiezas óptima individual es:

$$\underset{t_f, c}{\text{minimizar}} \quad c \cdot REI_2|_B + (1-c) \cdot REI_2|_S \quad (21)$$

$$\text{sujeto a:} \quad 0 \leq c \leq 1, \quad t_f > 0 \quad (22)$$

La notación $REI_2|_B$ significa que (7) se considera los costes fijos de una limpieza tipo **B** y de manera análoga para $REI_2|_S$. En este problema de optimización, además de t_f , se ha añadido la variable de decisión c , que será encargada de seleccionar el tipo de limpieza más adecuado. Nótese que el tipo de limpieza es una decisión discreta, mientras que $c \in \mathbb{R}$. Por tanto, estrictamente hablando, la restricción (22) debería ser $c \in \{0,1\}$. No obstante, en este caso particular (21) es una función monótona con respecto a c , por tanto su mínimo debe estar situado en uno de los extremos, bien $c=1$ o $c=0$. Con esta consideración, la restricción relajada (22) permite resolver el problema mediante programación no lineal (NLP) sin necesidad de usar MIP, más costosa computacionalmente.

4.3. Manejo de Incertidumbres

La formulación de la sección anterior es determinista. Sin embargo, los procesos reales conllevan la existencia de incertidumbres, tanto de naturaleza exógena (climatología, demandas de producción, precios, etc.) como endógena (errores de modelado). Para que un sistema de ayuda a la decisión sea de utilidad en la práctica, debe tener en cuenta dichas incertidumbres y proporcionar soluciones robustas y/o flexibles.

En el caso de estudio que nos ocupa, las principales fuentes de incertidumbre vienen dadas por la climatología (afecta a las predicciones futuras de T_{Mk}), la demanda de producción futura (afecta a distribución de cargas FE_{ep}) y las desviaciones del modelo de ensuciamiento (aproximación lineal) respecto al real (se traduce en parámetros α inciertos).

En la literatura existen diversos métodos para abordar problemas de optimización con incertidumbre, que van desde encontrar soluciones robustas ante el peor caso, como optimización minimax (Bandler y Charalambous, 1974), H_∞ (Başar y Bernhard, 2008), conjuntos invariantes (Sala y Pitarch, 2016), etc., al uso de métodos probabilísticos (Charnes y Cooper, 1959), basados en escenarios (Rockafellar y Wets, 1991) y optimización estocástica multietapa (Pereira y Pinto, 1991).

Para el caso que nos ocupa, los métodos robustos darían soluciones demasiado conservadoras, ya que no tienen en cuenta que la incertidumbre es medible en el futuro: tanto la temperatura exterior como la demanda de producción diaria se conocen con precisión, y los parámetros de ensuciamiento son estimados en línea mediante regresión.

Se podría utilizar optimización estocástica multietapa. Sin embargo, ésta solo incrementaría sensiblemente el coste computacional sin aportar mucha ventaja práctica, ya que todas las decisiones en el problema (21)-(22) se programan para el final del horizonte de predicción t_f , i.e., no hay ninguna *decisión robusta* en la primera etapa que influya sobre las variables de recurso en las subsiguientes etapas.

Desechadas las anteriores opciones, se ha optado por tratar el problema de incertidumbre con una estrategia de reali-

mentación basada en eventos, similar al horizonte descendente en control predictivo. La idea es resolver la optimización determinista con los valores esperados de las variables inciertas y proponer una primera solución. Después, en el momento en que las medidas detecten una desviación sustancial de los valores esperados en alguna de las fuentes de incertidumbre, se actualizan las predicciones y se relanza la optimización para corregir las decisiones. Por ejemplo, en el caso más sencillo de mantener valores constantes a futuro, basta con expresar (18) como una función a tramos:

$$P_{Th} \left(\sum_{t=0}^{t_1} CAV(t) + \sum_{t_1}^{t_2} CAV(t) + \dots + \sum_{t_{n-1}}^{t_n} CAV(t) \right) \quad (23)$$

Donde t_1, t_2, \dots, t_n son los instantes temporales en los que se producen cambios en la incertidumbre respecto a sus previsiones y cada sumatorio representa el coste acumulado de operación entre dichos instantes.

Nótese que esta estrategia no compromete la optimalidad de la solución, por el motivo anteriormente mencionado de que todas las decisiones se van a tomar el último día del ciclo.

5. Integración del Sistema

La actualización de modelos y la asignación óptima de cargas han sido programadas como módulos de MATLAB, mientras que la optimización del ciclo de limpieza para cada planta se ha implementado directamente en MS Excel. Esta elección se justifica por la disponibilidad de licencias y la experiencia acreditada del personal de ingeniería en Lenzing AG en dicho software, ya que son los encargados del mantenimiento futuro de la solución desarrollada.

La Figura 8 muestra un diagrama con los pasos que implementa el SAD diseñado para la asignación de plantas a productos y distribución óptima de cargas. La parte de OTR se ejecuta automáticamente cada 30 minutos.

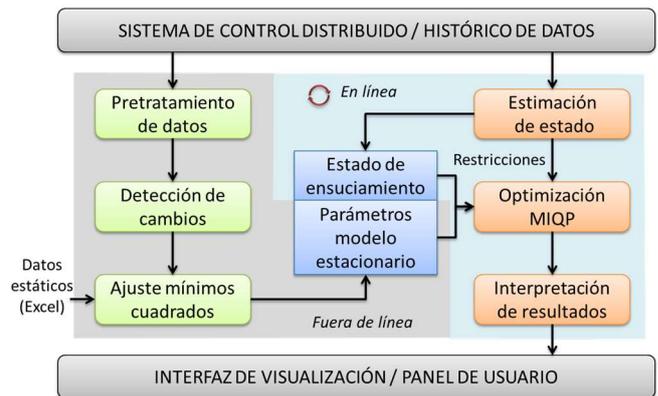


Figura 8: Concepto SAD diseñado para la red de evaporadores.

El panel de usuario diseñado para la herramienta se ha incluido como "Process Book" en el sistema PI de OSIsoft. En él se muestran los resultados de la optimización y también permite lanzar manualmente una ejecución en caso de que el operario deba afrontar cambios inesperados en las demandas de evaporación SP_p . En el momento de su activación se lee la información estática (estado de la red, parámetros de modelos, etc.) mediante interfaz MS Excel. Las restricciones de producción cambian de forma dinámica con el tiempo, por

tanto éstas son directamente suministradas por el histórico o estimadas de medidas. Después se actualizan los parámetros de ensuciamiento² K_f siguiendo la propuesta de las secciones 3.2 y 3.3 (i.e., paso 3 del Algoritmo 1).

La ejecución de la optimización devuelve la asignación de plantas a productos, la distribución de cargas y los CEV y CAV previstos en cada planta. Esta información se devuelve al sistema PI escribiendo en registros especiales que son posteriormente monitorizados en el panel de usuario. De esta manera los operarios de planta reciben las indicaciones óptimas en tiempo real y están en condición de ajustar la operación de las plantas de evaporación en consecuencia.

No obstante, la optimización de la distribución de cargas puede resultar no factible eventualmente, debido a que los modelos (2) son aproximaciones lineales y, en ocasiones, subestiman la capacidad de evaporación real de las plantas. Esta situación basada en la predicción de modelos podría conducir a no factibilidades en la distribución total, aunque la capacidad real de las plantas sea suficiente para cumplir con las demandas de evaporación requeridas.

5.1. Manejo de No Factibilidades

Para que una herramienta de ayuda a la decisión sea confiable para los operarios de planta, se deben diseñar un mecanismo de protección contra las no factibilidades. En caso contrario se pueden dar situaciones donde ciertas restricciones estrictas pueden ser violadas, comprometiendo así no solo la optimalidad de la operación, sino la seguridad de la misma. Para evitar situaciones de falsos negativos, el sistema primero hace una comprobación de factibilidad que evalúa si el flujo de evaporación actual (medido) en cada planta puede conseguirse con el modelo sujeto a las mismas restricciones externas (temperatura de refrigeración, disponibilidad de la red, etc.). Posteriormente, la restricción (13) del problema MIQP se relaciona con las variables de holgura $S_e \in \mathbb{R}^+$:

$$FE_{ep} - S_e \leq \overline{EC}_e \cdot X_{ep} \quad \forall e \in S, \forall p \in P \tag{24}$$

Donde $S \subseteq E$ representa el subconjunto de plantas identificadas como no factibles por el modelo según el test anterior de factibilidad. Finalmente, un término adicional de suma sobre todas las variables de holgura se incluye como penalización en la función objetivo, reemplazando (10) por:

$$\min_{X_{ep}, FE_{ep}, S_e} \sum_{e \in E} \sum_{p \in P} CAV_{ep} + M \cdot \sum_{e \in S} S_e \tag{25}$$

El parámetro de ponderación M se puede elegir de forma aproximada para ser mayor que el valor máximo posible de (10), i.e., sin la contribución de las variables de holgura. De esta manera el algoritmo de optimización encontrará soluciones factibles que violen restricciones lo mínimo posible. Nótese que esto no se traducirá en violaciones reales en la operación de la red³, ya que la no factibilidad es únicamente fruto de errores de modelado. En caso de haber detectado una situación de no factibilidad mediante el anterior test, el sistema envía una alarma al ingeniero de planta (supervisor) el cual, dependiendo de su evaluación sobre la magnitud del error de modelado, puede decidir acciones correctivas como,

² Los parámetros de plantas inactivas (en parada o limpieza) no se actualizan.

³ Se asume que la red tiene capacidad real suficiente para satisfacer la demanda global de evaporación, i.e., no hay falsos positivos.

por ejemplo, lanzar una actualización de modelos de acuerdo al procedimiento presentado en la Sección 3.

La implementación final se ha programado en MATLAB y se puede resolver utilizando la OPTI Toolbox vía aproximaciones sucesivas con un algoritmo MIP lineal (Bliek *et al.*, 2014), o bien directamente con un algoritmo MIP no lineal como BONMIN (Bonami *et al.*, 2008).

5.2. Diseño de Interfaces

La interfaz de visualización para el usuario se ha adaptado al concepto ya existente en planta, diseñado para presentar una vista general del estado de la red. Por una parte, se proporciona a los operadores de planta con un panel de usuario como el de la Figura 9, el cual muestra la solución óptima calculada para el instante actual. Las columnas representan a las plantas de evaporación (23 en este prototipo) y las filas a los productos (5 tipos distintos). Los recuadros en gris claro indican las posibles conexiones físicas entre planta y producto. Si una planta está asignada a un producto, la celda correspondiente pasa a color verde. Las plantas que no están en operación debido a tareas de mantenimiento o limpieza se muestran con una celda roja en las filas inferiores.

La asignación de acuerdo con los resultados de la optimización se indica con círculos amarillos (carga parcial) o verdes (carga completa) en las posiciones de la matriz que correspondan. La distribución de cargas óptima se muestra directamente al lado del valor actual en las filas superiores de la matriz. Además, se han añadido unos pictogramas en forma de flecha para indicar la dirección del cambio necesario a realizar en las consignas de evaporación por cada planta. En la parte derecha se muestran los flujos de evaporación total por producto (tanto actuales como los utilizados para la optimización) y sus correspondientes valores de CAV. Finalmente, en la parte de abajo a la derecha se muestra al operario la estimación de ahorro (€/h) que presuntamente se conseguirá aplicando la distribución optimizada. De esta forma se pretende incentivar a los operarios para que sigan las recomendaciones propuestas por la herramienta.

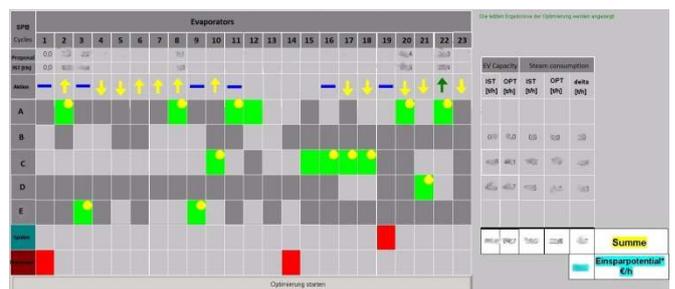


Figura 9: Interfaz de usuario en el prototipo para la OTR de la red.

Por otra parte, se ha implementado el módulo para la predicción óptima de limpiezas (Sección 4.2) en MS Excel, parcialmente basándose en macros de Visual Basic y haciendo uso del complemento OpenSolver (Mason, 2012), cuya versión actual incluye BONMIN como motor de optimización. Esta herramienta complementa a la anterior, ya que recibe como dato de entrada la distribución de cargas óptima prevista para cada planta de evaporación.

La interfaz está compuesta de diversas hojas Excel: una para cada planta más una dedicada a una visión general de la red. En las de planta el operario tiene que especificar una

serie de datos: duración de cada tarea de limpieza, coste de los productos de limpieza, costes energéticos (vapor, electricidad), parámetros de los modelos de planta y consignas de control (véase Figura 10).

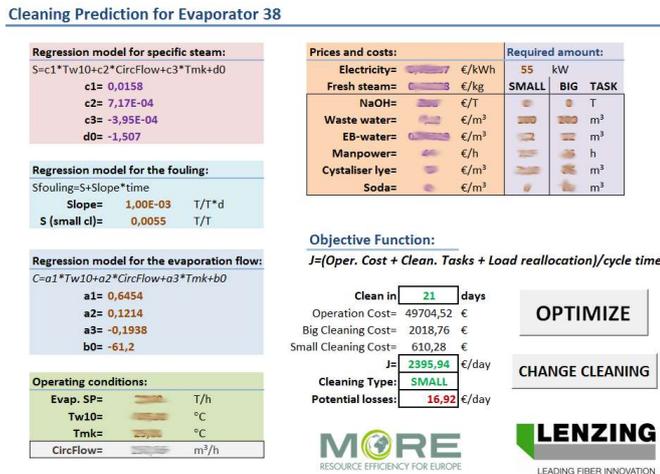


Figura 10: Interfaz del prototipo para la programación de limpiezas.

La herramienta proporciona un botón en cada hoja individual para lanzar la optimización (21)-(22), mostrando posteriormente el día y tipo de operación óptimos para realizar la próxima tarea de limpieza. Además, se muestran los costes desglosados en sus componentes (operación y limpieza) y el valor del REI_2 calculado según la política de limpieza sugerida. Es más, la herramienta sirve también como simulador para analizar situaciones hipotéticas (conocido como análisis “what-if” en la literatura inglesa), ya que el usuario puede manualmente fijar el día/tipo de limpieza y la herramienta le informa de las pérdidas potenciales (€/día) incurridas con respecto a la política óptima. De esta forma se incentiva al encargado de planificación a programar las limpiezas siguiendo las recomendaciones en la medida de lo posible.

6. Pruebas en Planta y Resultados

El prototipo para optimizar la asignación y distribución de cargas ya está implantado en Lenzing AG para dar soporte a toda la red plantas de evaporación y está actualmente en periodo de pruebas. Se dispone de modelos para casi todas las plantas, aunque falta modelar las más antiguas y de menor capacidad (menos instrumentadas y con poco peso específico en el consumo energético global). De todas maneras, éstas también están consideradas en la actual versión prototípica mediante la inclusión de reglas heurísticas simples (restricciones) en la optimización, e.g. se asignan en primer lugar las de menor capacidad, o las que se limpiaron más recientemente. La herramienta ha sido evaluada primeramente en simulación con datos de 580 situaciones extraídas del histórico de la red. La Tabla 1 muestra el beneficio potencial en ahorro energético y los tiempos de resolución obtenidos con una CPU estándar, para dar idea del coste computacional.

Tabla 1: Datos obtenidos de la optimización MIQP de la red.

	Ahorro energético	Tiempo CPU
Media	8.9%	4.8627 s
Máximo	11.9%	69.4127 s
Mínimo	1.2%	0.0552 s

Posteriormente se realizaron 5 pruebas de asignación de carga en tiempo real con todas las plantas, de entre 1 a 5 horas de duración. Comprobando que las decisiones recomendadas por el SAD eran coherentes y con el objetivo de evaluar las ganancias potenciales, se programó un test de 4 días de duración donde la optimización se lanzaba automáticamente cada 90 segundos. En este test se compararon las acciones propuestas por el SAD con la distribución real implementada por los operarios⁴. El análisis preliminar de los datos proporcionados por dicha comparación arroja un ahorro en el consumo de vapor de unas 40 toneladas/día, que se traduce en una reducción de 250 k€/año en costes.

Sin embargo, hay que destacar que evaluar cuantitativamente los beneficios de utilizar el nuevo sistema de ayuda a la decisión en la práctica es una tarea difícil, ya que habría que computar la media de los beneficios reales sobre un largo periodo de operación (e.g. meses), reduciendo así la influencia puntual de factores externos como la climatología, y compararla con datos históricos en un periodo de tiempo similar antes de la implantación del SAD.

Para el prototipo de herramienta para la predicción de limpiezas se dispone de modelos de ensuciamiento para 9 evaporadores equipados con torre de refrigeración (los más modernos). Los resultados arrojados por la optimización (21)-(22) en este subconjunto de plantas recomiendan:

- **limpiar más frecuentemente** que la política existente y,
- **reemplazar limpiezas grandes por pequeñas** en las plantas de menor capacidad (menos eficientes por edad).

Por ejemplo, para una determinada planta, la política anterior en Lenzing AG era limpiar cada 30 días aproximadamente. Sin embargo la optimización recomienda limpiar antes y, en particular para esta planta, se ha calculado que la limpieza pequeña cada 17 días es menos costosa que hacer limpieza grande cada 26 días (ver Figura 11).

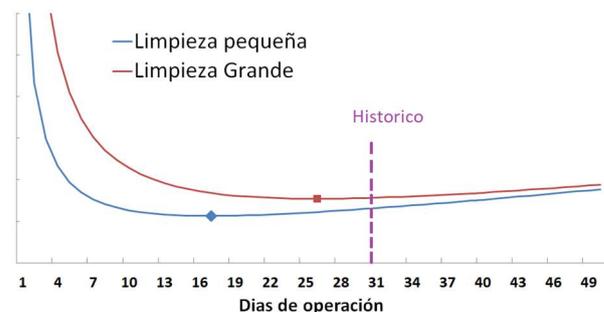


Figura 11: Evolución del REI_2 con el tiempo predicha por optimización para ambos tipos de limpieza en una misma planta de evaporación.

En este caso, el ahorro potencial previsto al adelantar la limpieza grande del día 30 al 26 es de 48 € por ciclo, y de 509 € por ciclo el de adelantar la pequeña del día 30 al 17. La diferencia entre reemplazar una limpieza grande por pequeña supone un ahorro de 789 € en esta planta lo que, con la política actual, supone reemplazar 4 limpiezas grandes con un ahorro de 3200 €/año.

No obstante existen algunas dificultades prácticas que han impedido, por el momento, evaluar las ganancias reales de aplicar las anteriores recomendaciones. La primera es que sólo los modelos de ensuciamiento identificados para 5 plan-

⁴ Nótese que solo un conjunto de decisiones es implementables a la vez: bien las recomendadas por la herramienta o las proporcionadas por el operario.

tas tienen una desviación típica aceptable (variabilidad de α con las medidas de CEV en un ciclo de operación y entre ciclos consecutivos). Si la variabilidad en la predicción del ensuciamiento es muy elevada es imposible obtener resultados concluyentes, incluso corrigiendo por realimentación con medidas (Sección 4.3), ya que las propias medidas son inciertas. Para minimizar esta variabilidad se han corregido (i.e. normalizado a un punto de referencia (Tremblay, Berriah y Veillette, 2009)) las medidas de CEV con la diferencia de temperaturas ΔT_{RC} del producto entre extremos de los intercambiadores de calor situados entre la bomba y la entrada de vapor vivo⁵ de la Figura 3, y con la temperatura de entrada del producto a la planta T_{in} :

$$CEV = \frac{CAV}{F_{SE} + F_{RC} + F_T} \quad (26)$$

$$F_{RC} = \eta_1 \cdot \frac{\Delta T_{RC} \cdot C_p}{\Delta H_{vap}} \cdot F, \quad F_T = \eta_2 \cdot \frac{(\bar{T} - T_{in}) \cdot C_p}{\Delta H_{vap}} \cdot F_{in} \quad (27)$$

Donde el consumo absoluto de vapor vivo CAV y el flujo de condensado en el sistema de refrigeración F_{SE} son medidos, mientras que el flujo de condensado en la sección interna de recuperación de calor F_{RC} se calcula con el balance de energía en (27) corregido con el factor experimental η_1 . F_T representa una corrección adicional con el flujo de entrada de producto (baño ácido) a la planta F_{in} , para tener en cuenta la diferencia de temperaturas entre la real del producto que entra a la planta T_{in} respecto a una temperatura de referencia \bar{T} . Esta relación también se pondera con un factor η_2 .

Nótese, que los calores específicos del producto C_p y las entalpías de vaporización ΔH_{vap} toman valores distintos para el cálculo de cada flujo en (27), ya que dependen de la concentración de ácido y la presión de vapor (i.e., temperatura) en los intercambiadores y cámara de entrada de producto respectivamente.

La segunda y principal limitación es debida a que el personal de mantenimiento sólo alcanza a realizar la limpieza de una planta al día. Por tanto, dado el número de plantas existentes, la frecuencia de limpiezas real no puede alcanzar la recomendada por el SAD. La acción que sí se ha tomado es eliminar los tipos de limpieza que la herramienta de ayuda a la decisión identifica como claramente subóptimos para cada una de las 5 plantas de las que se dispone de modelos relativamente fiables. El beneficio potencial derivado de aumentar la frecuencia de limpiezas y utilizar únicamente las operaciones óptimas en estas 5 plantas es de unos 25000 €/año aproximadamente.

Identificados los anteriores inconvenientes, el trabajo futuro se va a centrar en dos líneas principales de actuación: [1] *modelado* para mejorar la identificación de la dinámica de ensuciamiento, bien eliminando la influencia de factores exógenos en las mediciones o identificando modelos para aquellos factores que realmente modifiquen dicha dinámica y [2] *planificación integrada* de producción y tareas de mantenimiento, de forma que se tengan en cuenta explícitamente las limitaciones de personal y equipos, y se coordinen conjuntamente con la demanda global de evaporación.

Agradecimientos

Este trabajo ha sido financiado por el programa Horizonte 2020 de la UE (contrato nº 723575) y por el Gobierno de España con fondos MINECO/FEDER (DPI2015-70975-P).

Referencias

- Başar, T., Bernhard, P., 2008. H^∞ -optimal control and related minimax design problems: A dynamic game approach. Springer, Boston.
- Bandler, J.W., Charalambous, C., 1974. Nonlinear programming using minimax techniques. *Journal of Optimization Theory and Applications*, 13 (6), 607-619. DOI: 10.1007/BF00933620
- Bizet, V.M., Grossmann, I.E., Juhasz, N.M., 2005. Optimal production and scheduling of a process with decaying catalyst. *AIChE Journal*, 51 (3), 909-921. DOI: 10.1002/aic.10342
- Blick, C., Bonami, P., Lodi, A., 2014. Solving mixed integer quadratic programming problems with IBM-CPLEX: a progress report. *Proceedings of the 26th RAMP Symposium*, 171-180.
- Bonami, P., Biegler, L.T., Conn, A.R., Cornuéjols, G., Grossmann, I.E., Laird, C.D., Lee, J., Lodi, A., Margot, F., Sawaya, N., Wächter, A., 2008. An algorithmic framework for convex mixed integer nonlinear programs. *Discrete Optimization*, 5(2), 186-204. DOI: 10.1016/j.disopt.2006.10.011
- Burton, D.M., 1976. *Elementary Number Theory*. Allyn & Bacon, Boston.
- Charnes, A., Cooper, W.W., 1959. Chance-constrained programming. *Management Science*, 6 (1), 73-79. DOI: 10.1287/mnsc.6.1.73
- Engell, S., Harjunkoski, I., 2012. Optimal operation: Scheduling, advanced control and their integration. *Computers & Chemical Engineering*, 47, 121-133. DOI: 10.1016/j.compchemeng.2012.06.039
- Heluane, H., Blanco, A.M., Hernández, M.R., Bandoni, J.A., 2012. Simultaneous re-design and scheduling of multiple effect evaporator systems. *Computers & Operations Research*, 39 (5), 1173-1186. DOI: 10.1016/j.cor.2011.06.015
- Kalliski, M., Krahé, D., Beisheim, B., Krämer, S., Engell, S., 2015. Resource efficiency indicators for real-time monitoring and optimization of integrated chemical production plants. *Computer Aided Chemical Engineering*, 37, 1949-1954. DOI: 10.1016/B978-0-444-63576-1.50019-4
- Krämer, S., Engell, S. (Eds.), 2017. *Resource Efficiency of Processing Plants: Monitoring and Improvement*. Wiley-VCH Verlag.
- Kujanpää, M., Hakala, J., Pajula, T., Beisheim, B., Krämer, S., Ackerschott, D., Kalliski, M., Engell, S., Enste, U., Pitarch, J.L., 2017. Successful Resource Efficiency Indicators for process industries. *VTT Technology*, 290, Helsinki.
- LeiKon, 2014. D4.1 Requirement specification for the integrated deployment platform, Outcomes of the MORE Project. <http://www.more-nmp.eu/outcomes/deliverables/>
- Mason, A.J., 2012. OpenSolver – An open source add-in to solve linear and integer programmes in Excel. En: Klatte, D., Lathi, H., Schmedders, K. (Eds.), *Operations Research Proceedings 2011*. Springer-Verlag, Berlin Heidelberg, 401-406. DOI: 10.1007/978-3-642-29210-1_64
- Melouk, S.H., Freeman, N.K., Miller, D., Dunning, M., 2013. Simulation optimization-based decision support tool for steel manufacturing. *International Journal of Production Economics*, 141 (1), 269-276. DOI: 10.1016/j.ijpe.2012.08.001
- Pereira, M.V.F., Pinto, L.M.V.G., 1991. Multi-stage stochastic optimization applied to energy planning. *Mathematical Programming*, 52, 359-375. DOI: 10.1007/BF01582895
- Pitarch, J.L., Palacín, C.G., Merino, A., de Prada, C., 2017. Optimal operation of an evaporation process. En: Bock, H.G., Phu, H.X., Rannacher, R., Schlöder, J. (Eds.), *Modeling, Simulation and Optimization of Complex Processes HPSC 2015*. Springer, Cham. DOI: 10.1007/978-3-319-67168-0_16
- Rockafellar, R.T., Wets, R. J.-B., 1991. Scenarios and policy aggregation in optimization under uncertainty. *Mathematics of Operations Research*, 16 (1), 119-147. DOI: 10.1287/moor.16.1.119
- Sala, A., Pitarch, J.L., 2016. Optimisation of transient and ultimate inescapable sets with polynomial boundaries for nonlinear systems. *Automatica*, 73, 82-87. DOI: 10.1016/j.automatica.2016.06.017
- Schulz, E.P., Bandoni, J.A., Diaz, M.S., 2006. Optimal shutdown policy for maintenance of cracking furnaces in ethylene plants. *Industrial & Engineering Chemistry Research*, 45 (8), 2748-2757. DOI: 10.1021/ie050341r
- Tremblay, G., Berriah, S., Veillette, M., 2009. Method and system for electrolyzer diagnosis based on curve fitting analysis and efficiency optimization. U.S. Patent No. 7,616,006, Washington DC.

⁵ Detalles del esquema interno de una planta en (Pitarch et al., 2017).