

Jornadas de Automática

Hacia la esterilización inteligente: desarrollo de una sombra digital para la industria conservera

José Luis Pitarch^{a,*}, Carlos Vilas^b

^aControl de Sistemas Complejos, Instituto de Automática e Informática Industrial (ai2), Universitat Politècnica de València, Valencia 46022, Spain

^bGrupo de Biosistemas e Ingeniería de Bioprocesos, IIM-CSIC, C/ Eduardo Cabello, 6, 36208, Vigo, España

To cite this article: Pitarch, J.L., Vilas, C. 2026. Towards smart sterilization: developing a digital shadow for the canning industry. *Jornadas de Automática*, 46. <https://doi.org/10.17979/ja-cea.2026.47.13820>

Resumen

La esterilización de alimentos envasados es una operación crítica en la industria conservera, ya que de su correcta ejecución dependen tanto la calidad del producto como la seguridad alimentaria. Además, constituye uno de los principales consumos energéticos de la planta. El modelado matemático y la optimización se han aplicado durante décadas a estos sistemas con el objetivo de mejorar su desempeño. Sin embargo, los enfoques existentes suelen abordar el problema de forma parcial, centrándose bien en la representación detallada de los fenómenos de transferencia de calor y las cinéticas de inactivación microbiana, o bien en la optimización fuera de línea de perfiles de temperatura y presión.

En este trabajo se propone una sombra digital para el proceso de esterilización de conservas de pescado en autoclaves de vapor. La solución integra un modelo matemático predictivo actualizado en tiempo real, basado en leyes físicas consolidadas de los procesos térmicos con equilibrio agua-vapor, capaz de describir y predecir los principales fenómenos dinámicos presentes durante la operación. Además, se realiza una implementación computacional eficiente que permite la simulación del modelo en tiempo real, facilitando tareas de supervisión y apoyo a la toma de decisiones. También se incorpora un estimador de perturbaciones basado en optimización dinámica en línea, que mantiene el modelo sincronizado con el proceso compensando perturbaciones, derivas, atascos de válvulas y otros fenómenos no modelados o no medibles con la instrumentación habitual.

Este desarrollo supone un paso hacia la implementación de un gemelo digital completo capaz de asistir la toma de decisiones en lazo cerrado durante la operación del proceso.

Palabras clave: Calibración, Simulación predictiva, Digitalización, Gemelo digital, Autoclave, Mantenimiento de modelos

Towards smart sterilization: developing a digital shadow for the canning industry

Abstract

Sterilization of packaged foods is a critical operation in the canning industry, as both product quality and food safety depend on its proper execution. Furthermore, it represents one of the plant's main energy consumptions. Mathematical modeling and optimization have been applied to these systems for decades with the aim of improving their performance. However, existing approaches often address the problem only partially, focusing either on the detailed representation of heat transfer phenomena and microbial inactivation kinetics, or on the offline optimization of temperature and pressure profiles.

This work proposes a digital shadow for the sterilization process of canned fish in steam autoclaves. The solution integrates a real-time, updated predictive mathematical model, based on established physical laws of thermal processes with water-steam equilibrium, capable of describing and predicting the main dynamic phenomena present during the operation. An efficient computational implementation allows for real-time simulation of the model, facilitating monitoring and supporting decision-making. Furthermore, a disturbance estimator based on online dynamic optimization is incorporated, which keeps the model synchronized with the process by compensating for disturbances, drift, valve blockings, and other phenomena not modeled or measurable with standard instrumentation.

This development represents a step toward the implementation of a complete digital twin capable of supporting closed-loop decision-making during process operation.

Keywords: Model calibration, Predictive simulation, Digitization, Digital twin, Autoclave, Model upkeep

*Autor para correspondencia: jlpitarch@isa.upv.es

1. Introducción

La aparición de tecnologías asociadas a la Industria 4.0 ha impulsado el desarrollo de representaciones virtuales capaces de acompañar la operación de los procesos industriales en tiempo real. En este contexto, suele distinguirse entre *digital model*, *digital shadow* y *digital twin*. Un modelo digital consiste en una representación matemática o computacional del proceso cuya evolución es independiente del sistema físico. Una sombra digital incorpora y registra información procedente de la planta para mantener actualizados sus estados y parámetros durante la operación, permitiendo una representación dinámica e histórica del proceso real. Finalmente, un gemelo digital establece una interacción bidireccional entre el sistema físico y su réplica virtual, de forma que esta última puede asistir o incluso tomar decisiones de control en tiempo real (Grievies and Vickers, 2016). Estas herramientas permiten combinar conocimiento físico, datos de planta y técnicas de optimización para mejorar la supervisión, el diagnóstico y la toma de decisiones. Su aplicación resulta especialmente atractiva en procesos complejos donde la experimentación directa es costosa, las variables relevantes no son completamente medibles o las decisiones operativas tienen un impacto significativo sobre la calidad del producto y el consumo de recursos.

La esterilización de alimentos envasados constituye un ejemplo representativo de este tipo de procesos. Además de garantizar la inocuidad microbiológica del producto mediante un tratamiento térmico, su operación debe equilibrar objetivos frecuentemente contrapuestos relacionados con la calidad final, la productividad y el consumo de recursos (energía, agua, etc.). Estas características han motivado numerosos trabajos centrados en el desarrollo de modelos matemáticos y herramientas de optimización para asistir su operación. Sin embargo, la mayoría de los trabajos desarrollados en este ámbito se han centrado en aspectos aislados, tales como la transferencia de calor en el producto, la estimación de la letalidad microbiana, el control de temperatura del proceso (Alonso et al., 1997) o la optimización fuera de línea de las condiciones de operación (Erdogdu and Balaban, 2003; Simpson and Abakarov, 2011; Pitarch et al., 2021). En comparación, la consideración holística de todas las dinámicas propias del autoclave para tomar decisiones en tiempo real ha recibido menor atención, a pesar de su relevancia para predecir comportamientos poco frecuentes o anómalos, reducir consumos energéticos y desarrollar estrategias avanzadas de supervisión y control.

La construcción de sombras digitales y gemelos digitales requiere mecanismos capaces de reducir la inevitable discrepancia entre la representación virtual y el proceso físico, debido a incertidumbres, perturbaciones y fenómenos no modelados. En este sentido, técnicas como la reconciliación dinámica de datos (Leibman et al., 1992) y los observadores de perturbaciones (Pina and Botto, 2006; Wallscheid and Ngountsa, 2020) proporcionan un marco sistemático para combinar medidas de planta con modelos dinámicos basados en leyes fundamentales. Esto permite obtener estimaciones consistentes de variables o inferir la acción de fenómenos desconocidos (o no medibles), entre los cuales se incluyen errores de

modelado, degradación de equipos, o cambios en ciertas condiciones de operación que pueden comprometer la capacidad predictiva del modelo.

Como punto de partida, este trabajo emplea y mejora el modelo dinámico de autoclave desarrollado previamente por los autores (Novoa et al., 2024), específicamente para aplicaciones de simulación y optimización dinámica en tiempo real. Dicho modelo describe los fenómenos térmicos y fluidodinámicos más relevantes del proceso mediante una formulación computacionalmente eficiente, capaz de representar situaciones fuera del equilibrio líquido-vapor y distintos comportamientos observados experimentalmente en la instalación.

Sobre esta base, se desarrolla una arquitectura de monitorización avanzada orientada a la *simulación predictiva en línea* del proceso de esterilización durante su operación (Galan et al., 2021; Deubert et al., 2024). La propuesta combina simulación dinámica en tiempo real con un mecanismo de estimación en línea de efectos no modelados, permitiendo incorporar de forma continua la información procedente de planta para mantener el modelo digital actualizado en todo momento. El resultado constituye un escalón intermedio entre un modelo dinámico convencional y el futuro sistema de apoyo a la operación basado en tecnologías de gemelo digital que representa la Figura 1.




Figura 1: Componentes del gemelo digital para una planta de esterilización.

Las contribuciones del trabajo pueden resumirse en:

1. La calibración de los parámetros inciertos del modelo (características no lineales de las válvulas) a partir de experimentos diseñados para lograr identificabilidad práctica.
2. La mejora de la representación del flujo a través del drenaje ante distintas condiciones de operación (presión, masa de condensado) para maximizar la capacidad de predicción.
3. La implementación de un mecanismo de compensación virtual de perturbaciones y fenómenos no modelados para mantener el modelo alineado con la planta real en todo momento.

En las siguientes secciones se presentan los detalles más relevantes relativos a las capacidades de predicción del mode-

lo digital y al mecanismo de estimación para mantener dicho modelo alineado con el proceso real.

2. Calibración y validación del modelo predictivo

El caso de estudio es la planta piloto de esterilización presente en las instalaciones del IIM-CSIC, cuyo equipo principal es un autoclave de vapor esquematizado en la Figura 2. La operación de la planta se lleva a cabo mediante la manipulación de 3 válvulas de regulación neumática (entrada de vapor saturado, aire comprimido, y purga de gases) y dos electroválvulas de apertura motorizada (drenaje de condensado y entrada de agua de enfriamiento).

El proceso de esterilización típicamente consta de tres etapas: A) **Venteo** para eliminar el aire que hay en el autoclave inicialmente, mejorando la transferencia de calor hacia las latas, y elevar la temperatura hasta la consigna; B) **Calentamiento** con objetivo de eliminar las bacterias presentes en el alimento envasado, sometiénolo a un cierto perfil tiempo-temperatura; y C) **Enfriamiento** para bajar rápidamente la temperatura, evitando que la calidad del producto se degrade en exceso.




Figura 2: Esquema general de la planta piloto de esterilización de alimentos del IIM-CSIC. Las líneas discontinuas de trazos cortos representan las señales de control enviadas a las válvulas, mientras que las de trazos largos representan las señales de los sensores.

La instalación actual cuenta con sensores que permiten registrar datos de las variables accesibles (presiones y temperaturas) cada 5 seg. Estas medidas se guardan automáticamente en InfluxDB, una base de datos en tiempo real (InfluxData, 2025). La descripción completa de la planta se puede consultar en Alonso et al. (2013).

2.1. Modelo digital

El modelo utilizado en este trabajo está basado en la física del proceso de esterilización en un autoclave de vapor:

- Ecuaciones diferenciales y algebraicas (EDA) que describen la evolución de temperaturas, presión y masas dentro del autoclave (agua, vapor y aire).
- Ecuaciones algebraicas que implementan el autómata híbrido que posibilita el cambio entre las 3 fases discretas: (i) equilibrio líquido-vapor, (ii) sólo vapor, (iii) sólo agua.

- Varias ecuaciones algebraicas explícitas que describen principalmente los flujos a través de las diferentes válvulas.

Este modelo evita resolver ecuaciones diferenciales parciales (EDP) para la evolución de la temperatura en el producto a esterilizar. En su lugar, todas las latas se modelan como una masa uniforme sujeta a una EDO con el fin de acelerar la simulación en tiempo real. No obstante, para predecir la letalidad microbacteriana con precisión, esta EDO puede reemplazarse fuera de línea por el modelo EDP estricto del producto.

La descripción de las ecuaciones dinámicas del modelo (balances de masa y energía) puede consultarse en Novoa et al. (2024). Esta formulación evita un sistema DAE de alto índice. Así, el modelo puede simularse rápidamente por integradores numéricos con sensibilidades (Hindmarsh et al., 2005).

En esta sección nos centramos en los caudales F_w^i , F_s^i , F_a^i y F_b^i , que representan los flujos de entrada a través de las válvulas de agua, de vapor, de aire y purga, respectivamente. Además, utilizamos la notación F_d^o y F_{sad}^o para los flujos de salida de agua condensada y gases (vapor y aire) a través de la válvula de drenaje, y F_b^o para el flujo saliente de gases a través de la purga. Este modelo permite la entrada de aire a través de la purga y el drenaje (si la diferencia de presiones es negativa) y la salida de gases mezclados con condensados a través del drenaje. Ambos fenómenos han sido observados y corroborados por los datos recogidos en la instalación real.

Los flujos a través de las válvulas de aire, vapor, y purga vienen descritos por ecuaciones de la forma:

$$F_x^k = 3.4 \times 10^{-8} C_{v,x} u_x^{(1/\alpha_x)} C_f P_{in} (\omega_x - 0.148 \omega_x^3) \quad (1)$$

$$\omega_x = \frac{1.63}{C_f} \sqrt{\frac{P_{in} - P_{out}}{P_{in}}}$$

Donde el superíndice k indica dirección de flujo (in para entrada en el autoclave, y out para salida) y x indica la válvula asociada al flujo (s para vapor, a para aire, y b para purga). P_k son las presiones a ambos lados de válvula según la dirección del flujo. La apertura de las válvulas se representa por $u_x \in [0, 1]$. Las características de estas válvulas son los parámetros a estimar a partir de datos de ensayos experimentales: $C_{v,x}$, α_x , C_f .

La mayor fuente de incertidumbre está en el drenaje (orificio en el centro del fondo del autoclave), donde la única instrumentación es una válvula motorizada en lazo abierto y, dependiendo del estado de operación en cada momento (presión total P_T , masas m de vapor, aire y agua), puede salir una mezcla variable de condensado y gases. Para describir la salida por el drenaje en función de las masas de condensado y gases, se ha empleado una función sigmoide con punto de inflexión κ y pendiente definida por:

$$\sigma := \frac{\log((10^{-4} - 1)^{-1})}{\kappa} \quad (2)$$

En ella, κ es el parámetro a identificar, que modela la "proporción" de condensado m_w , vapor m_s y aire m_a , que sale por el drenaje en función de la cantidad de masa en cada momento:

$$F_{sad}^{max} = 3.4 \times 10^{-8} C_{v,sad} u_d^{(1/\alpha_d)} P_T (\omega_{sad} - 0.148 \omega_{sad}^3)$$

$$F_{sad}^{out} = (1 - \text{sigmoide}(m_w \cdot (m_s + m_a), \kappa, \sigma)) F_{sad}^{max} \quad (3)$$

Nótese que (3) provoca menos salida de gases cuanto más condensado hay presente respecto a la masa de éstos. Así, considerando la presión interna en la válvula de drenaje como la

del gas en el autoclave mas el peso del agua condensada que pueda existir, se tiene:

$$F_d^{max} = A_d \sin\left(\frac{\pi u_d}{2}\right) \rho_w \sqrt{\frac{2(P_T - P_{atm})}{\rho_w}} + 2 \cdot 9.8 l_w$$

$$F_d^{out} = \text{sigmoide}(m_w \cdot (m_s + m_a), \kappa, \sigma) F_d^{max} \quad (4)$$

Siendo l_w la altura de la columna de agua en metros, la cual se calcula por trigonometría a partir de m_w , V_T , y las dimensiones de la sección del autoclave cilíndrico.

Si la presión interior cae por debajo de la atmosférica (por ejemplo por condensación masiva en enfriamiento brusco), se permite la entrada de aire por el drenaje:

$$F_{sad}^{in} = 3.4 \times 10^{-8} C_{v,sad} u_d^{(1/\alpha_d)} P_{atm} (\omega_{sad} - 0.148 \omega_{sad}^3) \quad (5)$$

El flujo de entrada de agua de refrigeración se describe mediante:

$$F_w = A_w u_w \rho_w \sqrt{\frac{2(P_{in} - P_{out})}{\rho_w}} \quad (6)$$

Consecuentemente, A_w , A_d , α_d y $C_{v,sad}$ se unen a la lista de parámetros a identificar.

2.2. Procedimiento de calibración

Además de las características de las válvulas descritas anteriormente, también vamos a estimar el coeficiente de convección h_r que ajusta la transferencia de calor al ambiente a través de la carcasa. En total, hay 12 parámetros cuyo valor hay que calibrar a partir de datos experimentales:

$$\theta = \{C_{v,s}, C_{v,b}, C_{v,sad}, C_{v,a}, \alpha_s, \alpha_b, \alpha_d, \alpha_a, C_f, h_r, A_d, A_w\}$$

El problema de estimación de parámetros consiste en encontrar los valores que minimicen el error entre las medidas experimentales y las predicciones del modelo ante una secuencia de entradas. En este caso, medimos temperatura y presión en el interior del autoclave, y se asume que sus errores de predicción e se ajustan a una distribución de probabilidad exponencial $p(e|\theta)$. Bajo esta hipótesis, el problema de estimación consiste en maximizar la verosimilitud, tomando logaritmos convenientemente:

$$\hat{\theta} = \arg \min_{\theta} -(\log p(e_T|\theta) + \log p(e_P|\theta)) \quad (7)$$

Como (7) tiene varios mínimos locales y hacer cientos de simulaciones con el modelo es relativamente costoso, se recurre a la *optimización Bayesiana* para resolver el problema. En particular, al algoritmo BADS, específicamente diseñado para la estimación de parámetros (Acerbi and Ma, 2017).

No obstante, ajustar simultáneamente 12 parámetros con datos de observaciones parciales del estado y pocos experimentos presenta problemas de identificabilidad práctica. Principalmente, porque la función objetivo es multimodal y existen distintas combinaciones de parámetros que reproducen bien la evolución de presión y temperatura para un experimento dado, ante la imposibilidad de medir las masas de condensado, vapor y aire en el interior del autoclave.

Con objeto de lograr identificabilidad práctica, se divide el conjunto θ en subconjuntos que se van a estimar de forma secuencial, ajustando a experimentos en los que se modifica la apertura de las válvulas cuyo efecto es más sensible a dichos parámetros. El procedimiento realizado es el siguiente:

1. A partir de un experimento sólo abriendo válvulas de vapor y purga, se estiman $\theta_1 = \{C_{v,s}, C_{v,b}, \alpha_s, \alpha_b, C_f, h_r\}$.
2. Con los anteriores ya fijados, se realizan otros experimentos con diferentes aperturas de la válvula de drenaje, y se estiman $\theta_2 = \{C_{v,sad}, \alpha_d, A_d\}$.
3. Finalmente, se realizan experimentos incluyendo la fase de enfriamiento, abriendo las válvulas de aire comprimido y entrada de agua para estimar $\theta_3 = \{C_{v,a}, \alpha_a, A_w\}$.

La Tabla 1 muestra los valores identificados y el rango de búsqueda impuesto para cada parámetro.

Tabla 1: Valores estimados de los parámetros θ .

Parámetro	Estimado	Rango	Unidades
$C_{v,s}$	1.68	0.5 -5	-
$C_{v,b}$	21.5	1 -30	-
$C_{v,sad}$	4.2	0.5 -15.00	-
$C_{v,a}$	11	1 -30	-
α_s	1	0.5 -1	-
α_b	0.65	0.5 -1	-
α_d	0.26	0.1 -1	-
α_a	1	0.5 -1	-
C_f	0.8	0.5 -1	-
h_r	15	1 -30	$\text{Wm}^{-2}\text{K}^{-1}$
A_d	12.33×10^{-4}	$(0.1-50) \times 10^{-4}$	m^2
A_w	4.6×10^{-5}	$(1-20) \times 10^{-5}$	m^2

2.3. Validación del modelo predictivo

Después del procedimiento anterior, hemos realizado una aproximación local de la distribución posterior de los parámetros, mediante un análisis variacional Bayesiano via técnicas de Monte Carlo (Acerbi, 2018). Para ello, hemos asumido una distribución a priori uniforme de los parámetros, con límites $\pm 20\%$ alrededor del valor estimado. Los resultados mostrados en la Figura 3 son aceptables, con bajas varianzas y distribuciones bastante regulares. No obstante, todavía se observan ciertas dificultades de identificabilidad práctica: correlación existente entre algunos parámetros y una mayor varianza en el coeficiente de transmisión de calor convectivo h_r .




Figura 3: Análisis variacional Bayesiano local de los parámetros. En la diagonal se muestra la distribución de probabilidad para cada parámetro. Fuera de la diagonal se ilustra la correlación entre cada par de parámetros.

La capacidad predictiva del modelo se ha validado realizando simulaciones en lazo abierto ante perfiles de apertura de válvulas aplicados a la planta real, comparando posteriormente la respuesta del modelo frente a las medidas experimentales en situaciones típicas del proceso de esterilización. La Figura 4 muestra el resultado para uno de dichos experimentos.




Figura 4: Predicción del modelo (línea continua azul) VS medida en el experimento real (línea discontinua negra).

3. Sincronización planta-modelo en tiempo real

La implementación de una sombra digital debe garantizar que el modelo digital está en todo momento alineado con el estado actual del proceso físico. Por tanto, no basta con implementar la simulación del modelo en tiempo real. También se necesita un mecanismo de estimación de estado/perturbaciones que minimice las discrepancias planta-modelo que no se han podido capturar en la fase de calibración.

De entre la variedad de opciones en la literatura, dada la naturaleza de este proceso, hemos optado por implementar un observador de horizonte móvil a un paso, basado en optimización con el propio modelo porque es la forma más natural de integrarlo utilizando toda la información ya capturada en las ecuaciones físicas. Sin embargo, en su versión más sencilla, no estimamos el estado completo del sistema. Nuestra hipótesis es: todas las discrepancias planta-modelo pueden representarse por *perturbaciones a la entrada*, i.e., las aperturas de válvulas reales no siempre corresponden fielmente a las consignas enviadas por el sistema de control. Considerar que tanto las salidas medidas como las entradas aplicadas tienen incertidumbre es habitual en la industria de procesos, y

la reconciliación de datos es la técnica a utilizar para realizar estimaciones coherentes (Leibman et al., 1992).

3.1. Diseño del estimador de perturbaciones

Consideremos que, en cada periodo de muestreo, las aperturas reales de las válvulas son $u = u^{SP} + \Delta u$, con $\Delta u \rightarrow 0$. Es decir, puede existir una perturbación no estacionaria entre la consigna enviada por el sistema de control a la válvula y la apertura real. Entonces, asumiendo que los errores de predicción a un paso y las perturbaciones Δu siguen una distribución Gaussiana truncada, el problema de estimación a resolver inmediatamente después de cada instante de muestreo es:

$$\begin{aligned} \min_{\Delta u} \quad & \frac{\|e_T\|_2}{2\sigma_T^2} + \frac{\|e_P\|_2}{2\sigma_P^2} + \frac{\|\Delta u\|_2}{2\sigma_U^2} + \frac{2\dim(e_T) + \dim(u)}{\log(2\pi\sigma_T^2\sigma_P^2\sigma_U^2)} \\ \text{s.a. :} \quad & f(x, \dot{x}, z, u) = 0 \quad \text{Modelo predictivo} \\ & x(0) = x_0^{[t-T_s]} \quad \text{Estado en instante anterior} \\ & -1 \leq \Delta u \leq 1 \end{aligned} \quad (8)$$

Donde se busca maximizar la verosimilitud a los datos, habiendo estimado previamente $\sigma_T = 2.32^\circ\text{C}$ y $\sigma_P = 0.155$ bar con datos del error entre predicción y medidas en lazo abierto. Elegimos $\sigma_U = 1/3$, dado que el máximo recorrido de $|\Delta u|$ es 1, debido al rango de operación de las válvulas.

3.2. Implementación

Hemos programado una clase MATLAB orientada a objetos que encapsula la definición del modelo del autoclave y los métodos de simulación dinámica y estimación de perturbaciones con CasADi-IDAS-IPOPT (Andersson et al., 2019), dentro de una única estructura reutilizable.

Algoritmo 1 Estructura simplificada de la clase autoclave

```

1: Clase autoclave( $N_{latas}, T_{sim}$ )
2:  $modelo \leftarrow \text{CREATE\_DAE}(\text{params}, N_{latas})$ 
3:  $integrador \leftarrow \text{INTEGRATOR}('idas', modelo, T_{sim})$ 
4:  $verosimilitud \leftarrow -\log N(e_T) - \log N(e_P) - N(\Delta u)$ 
5:  $nlp \leftarrow \text{struct}(\Delta u, [u, x_0], verosimilitud, integrador)$ 
6:  $optimizador \leftarrow \text{NLPSOL}('ipopt', nlp)$ 
7: Método simula( $u, p$ )
8:  $x(T_{sim}) \leftarrow \text{autoclave.integrador}(u, p)$ 
9:  $\text{autoclave}.x_0 \leftarrow x(T_{sim})$  Actualizar estado interno
10: return [ $T_{autoclave}, T_{latas}, P_{autoclave}, m_{vapor}, m_{aire}, m_{agua}$ ]
11: Método estima( $[u_{med}, T_{med}, P_{med}]$ )
12:  $\Delta u \leftarrow \text{autoclave.optimizador}([u_{med}, T_{med}, P_{med}])$ 
13:  $\text{autoclave.simula}(u_{med}, \Delta u)$ 
14: return  $\Delta u$ 
15: Método estático create_DAE( $\text{params}, N_{latas}$ )
16: Definir estados, entradas y variables algebraicas
17: Definir ecuaciones de transferencia de calor y flujo
18: Formular balances de masa y energía
19: Construir sistema DAE
20: return DAE
21: end
    
```

De esta forma podemos crear objetos de tipo autoclave que mantienen en todo momento su estado interno sincronizado con la planta real mediante el método *estima* y permiten

hacer predicciones mediante el método *simula* que pueden utilizarse en esquemas avanzados de supervisión y toma de decisión.

4. Resultados

La siguiente figura ilustra el funcionamiento de la sombra digital implementada, funcionando simultáneamente con la planta de esterilización durante un experimento hasta el instante de tiempo $t = 5000$ s.




Figura 5: Funcionamiento de la sombra digital en una prueba con la planta real. La sombra digital se ejecutó en tiempo real hasta $t = 5000$ s.

En la respuesta se observa cómo el modelo sincronizado en línea ajusta los datos experimentales medidos hasta el instante $t = 5000$ s. A partir de ese instante, la sombra digital se desconecta y deja de sincronizarse con la planta. La evolución que aparece en la figura para $t > 5000$ s es la predicción con el modelo en lazo abierto ante las consignas de u_x aplicadas posteriormente a la planta.

En la Figura 5 también se incluyen en línea punteada las desviaciones (Δu_x) sobre la consigna de apertura de válvulas, estimadas para obtener una respuesta coherente con los datos experimentales medidos.

5. Avances futuros

El actual desarrollo ya sirve de base para implementar un control predictivo no lineal como nuevo módulo del futuro gemelo digital del autoclave. Durante los próximos meses trabajaremos también en incorporar la descripción del producto (modelo EDP de las latas) de forma eficiente y en caracterizar la variabilidad e incertidumbre existentes para obtener predicciones probabilísticas más robustas.

Agradecimientos:

Este trabajo ha sido financiado por MCIN/AEI/10.13039/501100011033 con fondos FEDER, via el proyecto DSInVar (PID2024-157718OB-C32). También ha recibido el apoyo del Instituto de Investigación en Automática e Informática Industrial (ai2) de la Universitat Politècnica de València, en el marco del Programa de Financiación Interna de I+D+i.

Referencias

- Acerbi, L., 2018. Variational Bayesian Monte Carlo. *Advances in Neural Information Processing Systems* 31, 8222–8232.
- Acerbi, L., Ma, W. J., 2017. Practical Bayesian optimization for model fitting with Bayesian adaptive direct search. *Advances in Neural Information Processing Systems* 30, 1834–1844.
- Alonso, A. A., Arias-Méndez, A., Balsa-Canto, E., García, M. R., Molina, J. I., Vilas, C., Villafán, M., 2013. Real time optimization for quality control of batch thermal sterilization of prepackaged foods. *Food Control* 32 (2), 392–403.
DOI: <https://doi.org/10.1016/j.foodcont.2013.01.002>
- Alonso, A. A., Banga, J. R., Perez-Martin, R., 1997. A complete dynamic model for the thermal processing of bioproducts in batch units and its application to controller design. *Chemical Eng. Science* 52 (8), 1307–1322.
DOI: [https://doi.org/10.1016/S0009-2509\(96\)00484-8](https://doi.org/10.1016/S0009-2509(96)00484-8)
- Andersson, J. A. E., Gillis, J., Horn, G., Rawlings, J. B., Diehl, M., 2019. CasADi – A software framework for nonlinear optimization and optimal control. *Mathematical Programming Computation* 11 (1), 1–36.
DOI: <https://doi.org/10.1007/s12532-018-0139-4>
- Deubert, D., Klingel, L., Selig, A., 2024. Online simulation at machine level: a systematic review. *Int. Journal of Advanced Manufacturing Technology*.
DOI: <https://doi.org/10.1007/s00170-024-13065-1>
- Erdogdu, F., Balaban, M. O., 2003. Complex method for nonlinear constrained multi-criteria (multi-objective function) optimization of thermal processing. *Journal of Food Process Engineering* 26 (4), 357–375.
DOI: <https://doi.org/10.1111/j.1745-4530.2003.tb00607.x>
- Galan, A., De Prada, C., Gutierrez, G., Sarabia, D., Gonzalez, R., 2021. Real-time reconciled simulation as decision support tool for process operation. *Journal of Process Control* 100, 41–64.
DOI: <https://doi.org/10.1016/j.jprocont.2021.02.003>
- Grieves, M., Vickers, J., 2016. Digital twin: Mitigating unpredictable, undesirable emergent behavior in complex systems. In: *Transdisciplinary perspectives on complex systems*. Springer, pp. 85–113.
- Hindmarsh, A. C., Brown, P. N., Grant, K. E., Lee, S. L., Serban, R., Shumaker, D. E., Woodward, C. S., 2005. Sundials: Suite of nonlinear and differential/algebraic equation solvers. *ACM Transactions on Mathematical Software (TOMS)* 31 (3), 363–396.
DOI: <https://doi.org/10.1145/1089014.1089020>
- InfluxData, 2025. Why time series matters. Tech. rep.
URL: <https://www.influxdata.com>
- Leibman, M., Edgar, T., Lasdon, L., 1992. Efficient data reconciliation and estimation for dynamic processes using nonlinear programming techniques. *Computers & Chemical Engineering* 16 (10), 963–986.
DOI: [https://doi.org/10.1016/0098-1354\(92\)80030-D](https://doi.org/10.1016/0098-1354(92)80030-D)
- Novoa, M., Pitarch, J. L., Antelo, L. T., Vilas, C., 2024. Development and calibration of a mathematical model for the predictive control of the solid food sterilization process. *Jornadas de Automática*.
DOI: <https://doi.org/10.17979/ja-cea.2024.45.10915>
- Pina, L., Botto, M. A., 2006. Simultaneous state and input estimation of hybrid systems with unknown inputs. *Automatica* 42 (5), 755–762.
DOI: <https://doi.org/10.1016/j.automatica.2005.12.014>
- Pitarch, J. L., Vilas, C., de Prada, C., Palacín, C., Alonso, A. A., 2021. Optimal operation of thermal processing of canned tuna under product variability. *Journal of Food Engineering* 304, 110594.
DOI: <https://doi.org/10.1016/j.jfoodeng.2021.110594>
- Simpson, R., Abakarov, A., 2011. Optimization of food thermal processing: Sterilization stage and plant production scheduling. In: Aguilera, J. M., Simpson, R., Welte-Chanes, J., Bermudez-Aguirre, D., Barbosa-Canovas, G. (Eds.), *Food Engineering Interfaces*. Springer New York, pp. 261–284.
- Wallscheid, O., Ngoumtsa, E. F. B., 2020. Investigation of disturbance observers for model predictive current control in electric drives. *IEEE Transactions on Power Electronics* 35 (12), 13563–13572.
DOI: <https://doi.org/10.1109/TPEL.2020.2992784>