

Real-time optimization with modifier adaptation based on dynamic gradient estimation

Daniel Navia* Ixbalank Torres** Fernando López-Caamal***
Héctor Hernández-Escoto***

* *Universidad Técnica Federico Santa María, Vicuña Mackenna 3939,
San Joaquín, Santiago, Chile. email: daniel.navia@usm.cl*

** *Departamento de Ingeniería Electrónica, Universidad de
Guanajuato, Carr. Salamanca-Valle de Santiago, Km. 3.5+1.8, C.P.
36885, Salamanca, México. email: ixbalank@ugto.mx*

*** *Departamento de Ingeniería Química, Universidad de Guanajuato,
Noria Alta, C.P. 36050, Guanajuato, México. email: fernando.lopez,
hhee@ugto.mx*

Abstract: In this paper, an optimization strategy with modifier adaptation based on a mechanistic model and the estimation of the input-output map gradient is presented to solve optimization problems in real-time. The strategy consists of defining an optimization problem based on the process model with first order modifiers in the objective function that include the information of the input-output map gradient to correct the uncertainties of the process model. The gradient of the input-output map is estimated by means of a differentiator based on a multivariable Super-Twisting algorithm. The proposed real-time optimization with modifier adaptation strategy is implemented in a bioethanol production process and validated through closed-loop simulations.

Keywords: Real-time optimization, modifier adaptation, differentiator, Super-Twisting algorithm, bioethanol.

1. INTRODUCTION

El diseño tradicional de sistemas de control se ocupa del problema de estabilización del sistema sobre una trayectoria de referencia conocida, mientras se alcanzan ciertos criterios de diseño. Este problema genérico de estabilización incluye problemas de "seguimiento" y problemas de "regulación", en los cuales la referencia a menudo se determina fácilmente o es generada. Sin embargo, en algunas ocasiones, puede ser bastante difícil encontrar un valor de referencia adecuado. Por ejemplo, para mantener un funcionamiento óptimo en procesos industriales, lo que requiere calcular la entrada de control óptima para alcanzar un valor máximo o mínimo (también conocido como un extremo) de una función de rendimiento (Zhang and Ordóñez, 2012). Tal problema de control implica resolver un problema de optimización en tiempo real.

La optimización en tiempo real (RTO, por sus siglas en inglés) de plantas en estado estacionario tiene como objetivo mejorar el rendimiento de un proceso a través de la optimización de un criterio medible o función objetivo bajo condiciones económicas, de restricciones de seguridad o de calidad. Una de las limitaciones más

críticas de los métodos RTO radica en la precisión del modelo, y esto ha llevado a desarrollar técnicas de RTO adaptables que toman en cuenta modelos inciertos de los procesos de interés (Dewasme and Vande Wouwer, 2020). La incertidumbre del modelo puede tener tres fuentes principales, (i) incertidumbres paramétricas debido a la diferencia entre los valores de los parámetros del modelo y la realidad del proceso, (ii) desajuste estructural del modelo del proceso debido a que la estructura del modelo no es perfecta, por ejemplo, en el caso de fenómenos o dinámicas desconocidos, y (iii) perturbaciones exógenas del proceso (Marchetti et al., 2016).

Así, la RTO incorpora mediciones del proceso en el marco de la optimización matemática para combatir el efecto perjudicial de las incertidumbres. De hecho, los métodos de RTO se pueden clasificar según cómo se utilicen las mediciones disponibles. En este contexto, la metodología de RTO con Adaptación de Modificadores (MA, por sus siglas en inglés) utiliza las mediciones y la estimación del gradiente del mapa entrada-salida del proceso para modificar las funciones de costo y de restricciones en un problema de optimización basado en el modelo del proceso (Marchetti et al., 2016).

Durante la última década la metodología de optimización en tiempo real con adaptación de modificadores (RTO-MA) ha recibido mucha atención, por ejemplo, Navia et al. (2015) reformulan la metodología Adaptación de Modificadores para resolver problemas de optimización en tiempo real como un problema de optimización anidado; Oliveira-Silva et al. (2021) proponen una estrategia de optimización dinámica con elementos tomados de la metodología Adaptación de Modificadores para optimización en tiempo real; Oliveira-Silva et al. (2023) proponen un método para estimar el gradiente del mapa entrada-salida de forma dinámica que combinado con la metodología Adaptación de Modificadores mejoran la solución de problemas de optimización en tiempo real. Una visión general de los desarrollos recientes de la metodología Adaptación de Modificadores para resolver problemas de optimización en tiempo real de procesos con incertidumbres se puede encontrar en (Marchetti et al., 2016).

En este artículo se presenta una estrategia RTO-MA basado en el modelo del proceso y la estimación del gradiente del mapa entrada-salida utilizando datos transientes mediante el algoritmo Súper-Twisting, con el objetivo de llevar un proceso a sus condiciones óptimas de operación en tiempo real. La estrategia de optimización en tiempo real propuesta es validada por medio de simulaciones. El caso de estudio considerado es un proceso de fermentación para la producción de bioetanol.

El artículo está organizado como sigue: en la sección 2 se presenta la estrategia RTO-MA basada en la estimación del gradiente del mapa entrada-salida. Dicho gradiente es estimado por medio de un diferenciador basado en el algoritmo Súper-Twisting. En la sección 3 se presenta el caso de estudio, un reactor de fermentación para la producción de bioetanol. Primero se presenta el modelo del proceso de fermentación y posteriormente se aplica la estrategia RTO-MA propuesta al proceso de fermentación considerando un modelo con incertidumbres paramétricas. En la sección 4 se presentan y se discuten los resultados de simulaciones en lazo cerrado. Finalmente, en la sección 5 se presentan algunas conclusiones sobre los resultados obtenidos de la estrategia RTO-MA propuesta.

2. OPTIMIZACIÓN EN TIEMPO REAL

La optimización en tiempo real (RTO, por sus siglas en inglés) abarca una familia de métodos de optimización que incorporan mediciones de los procesos en el marco de la optimización matemática para llevar un proceso real a sus condiciones óptimas de operación, al mismo tiempo que se garantiza la satisfacción de las restricciones del proceso. La secuencia típica de pasos para la optimización de procesos incluye (i) modelado del proceso, (ii) optimización numérica utilizando el modelo de proceso, y (iii) aplicación de las entradas óptimas al proceso. En la práctica, este último paso es bastante peligroso en ausencia de restricciones adicionales, ya que las entradas basadas en el modelo son óptimas para el modelo, pero no

para el proceso real, a menos que el modelo sea una representación perfecta de la planta. Esto a menudo trae como resultado condiciones de suboptimalidad durante la operación del proceso y una violación de las restricciones de operación del proceso, por ejemplo, cuando la operación óptima implica operar cerca de alguna restricción y el modelo subestima o sobreestima el valor de esa restricción en particular (Marchetti et al., 2009).

2.1 Optimización en tiempo real con adaptación de modificadores

La RTO incluye una serie de algoritmos que permiten actualizar las condiciones de operación de un determinado proceso con el objetivo de optimizar su desempeño.

La ecuación (1) presenta el problema de optimización de un proceso determinado, cuya condición óptima se define como \mathbf{u}^* .

$$\begin{aligned} \min_{\mathbf{u} \in \mathcal{U}} J(\mathbf{u}) \\ \mathbf{g}(\mathbf{u}) \leq \mathbf{0} \end{aligned} \quad (1)$$

Asumiendo que no se conoce el mapeo entrada-salida del proceso no es posible resolver (1). Sin embargo, si se dispone de un modelo aproximado del proceso real, una estimación de \mathbf{u}^* se puede obtener al resolver el problema de optimización (2), donde el subíndice "M" denota que se ha utilizado el modelo aproximado del proceso real, el cual depende de los parámetros α .

$$\begin{aligned} \min_{\mathbf{u} \in \mathcal{U}} J_M(\mathbf{u}, \alpha) \\ \mathbf{g}_M(\mathbf{u}, \alpha) \leq \mathbf{0} \end{aligned} \quad (2)$$

Debido a la incerteza asociada al modelo aproximado del proceso, la solución de (2), \mathbf{u}_M^* , no corresponde con \mathbf{u}^* . Para encontrar el valor del óptimo real del proceso, la RTO resuelve de manera periódica un problema optimización basado en modelos similar al de (2), el cual ha sido actualizado con los datos disponibles del proceso. De esta forma, cada ejecución del algoritmo de RTO implica una etapa de aprendizaje, seguida de una etapa de toma de decisiones. En la etapa de aprendizaje se extrae la información relevante desde los datos del proceso y se actualiza el problema de optimización basado en modelos, el cual se resuelve en la etapa de toma de decisiones para estimar la siguiente condición de operación a implementar en el proceso, según se muestra en la figura 1.

La etapa de aprendizaje define la capacidad que tiene el algoritmo de RTO para identificar \mathbf{u}^* . En este sentido, se ha demostrado que si se modifican las condiciones necesarias de optimalidad (NCO) de (2) utilizando información del proceso, de tal forma que converjan a las NCO de (1), es posible estimar \mathbf{u}^* mediante el esquema de la figura 1. Para modificar las NCO (2), en la etapa de toma de decisiones se resuelve el problema de optimización modificado definido en (3).

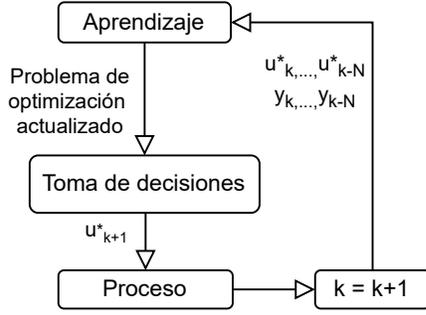


Fig. 1. Diagrama de la capa de RTO, \mathbf{y} representa las variables de salida del proceso

$$\begin{aligned} \min_{\mathbf{u} \in \mathcal{U}} J_M(\mathbf{u}, \boldsymbol{\alpha}) + \boldsymbol{\lambda}_k^\top (\mathbf{u} - \mathbf{u}_k) \\ \mathbf{g}_M(\mathbf{u}, \boldsymbol{\alpha}) + \boldsymbol{\gamma}_k^\top (\mathbf{u} - \mathbf{u}_k) + \boldsymbol{\varepsilon}_k \leq \mathbf{0}, \end{aligned} \quad (3)$$

donde $\boldsymbol{\lambda}_k$ y $\boldsymbol{\gamma}_k$ corresponden a los modificadores de primer orden, y $\boldsymbol{\varepsilon}_k$ se define como el modificador de orden cero de las NCO de la optimización basada en modelos (Marchetti et al., 2009). Si los modificadores se estiman de acuerdo a (4), entonces las NCO de (3) convergen a las NCO de (1), lo que implica que es posible estimar \mathbf{u}^* (Marchetti et al., 2009).

Considerando el esquema de la figura 1, se puede indicar que la etapa de aprendizaje consiste en estimar los modificadores como:

$$\begin{aligned} \boldsymbol{\lambda}_k^\top &= \frac{\partial J}{\partial \mathbf{u}} \Big|_k - \frac{\partial J_M}{\partial \mathbf{u}} \Big|_k, \\ \boldsymbol{\gamma}_k^\top &= \frac{\partial \mathbf{g}}{\partial \mathbf{u}} \Big|_k - \frac{\partial \mathbf{g}_M}{\partial \mathbf{u}} \Big|_k, \\ \boldsymbol{\varepsilon}_k &= \mathbf{g} \Big|_k - \mathbf{g}_M \Big|_k, \end{aligned} \quad (4)$$

mientras que la etapa de toma de decisiones consiste en resolver el problema (3) con los modificadores actualizados, este algoritmo se denomina RTO con Adaptación de Modificadores (RTO-MA).

El cálculo de los modificadores $\boldsymbol{\lambda}_k$ y $\boldsymbol{\gamma}_k$ requiere de la correcta estimación de los gradientes del proceso. Para esto, existen distintos acercamientos los cuales se pueden clasificar en aquellos que solo utilizan información de los estados estacionarios pasados del proceso, y los que estiman gradientes experimentales a partir de información dinámica del sistema (Marchetti et al., 2016). Los datos de estados estacionarios anteriores contienen información que permitiría estimar el gradiente requerido en (4). Sin embargo, su aplicabilidad es muy limitada en procesos con dinámicas lentas o sujetos a constantes perturbaciones. Para este tipo de procesos, se ha sugerido la utilización de datos transientes. La estimación de derivadas utilizando datos entrada-salida en régimen dinámico, permitiría calcular las sensibilidades del sistema experimental, definidas como $s(t) = \partial y / \partial u$, las cuales no son directamente los gradientes requeridos en (4). Sin embargo, si se asume que el sistema es estable, el valor de las

sensibilidades coincide con el gradiente estático cuando el sistema llega al estado estacionario (Oliveira-Silva et al., 2021, 2023).

2.2 Estimación del gradiente entrada-salida

Como se mencionó en la sección previa, el cálculo de los modificadores en la ecuación (4) requiere del gradiente del mapa entrada-salida del proceso $\partial J / \partial \mathbf{u}$. En este trabajo, el gradiente $\partial J / \partial \mathbf{u}$ se estima en tiempo finito por medio de un diferenciador basado en una versión multivariable del algoritmo Súper-Twisting (López-Caamal and Moreno, 2019).

El diferenciador se define como:

$$\begin{aligned} \dot{\hat{\boldsymbol{\theta}}}(t) &= -k_1 \boldsymbol{\phi}_1(\hat{\boldsymbol{\theta}} - \boldsymbol{\theta}) + \hat{\boldsymbol{\omega}}(t) \\ \dot{\hat{\boldsymbol{\omega}}}(t) &= -k_2 \boldsymbol{\phi}_2(\hat{\boldsymbol{\theta}} - \boldsymbol{\theta}), \end{aligned} \quad (5)$$

donde

$$\boldsymbol{\theta} := \begin{pmatrix} J \\ \mathbf{u} \end{pmatrix} \quad (6)$$

y

$$\boldsymbol{\omega} := \begin{pmatrix} \dot{J} \\ \dot{\mathbf{u}} \end{pmatrix}. \quad (7)$$

Además, $\hat{\boldsymbol{\theta}}$ ($\hat{\boldsymbol{\omega}}$, resp.) denota la estimación de $\boldsymbol{\theta}$ ($\boldsymbol{\omega}$, resp.) y

$$\begin{aligned} \boldsymbol{\phi}_1(\mathbf{x}) &:= \left(\eta \|\mathbf{x}\|_2^{-p} + \beta + \gamma \|\mathbf{x}\|_2^q \right) \mathbf{x}, \quad \boldsymbol{\phi}_1(\mathbf{0}) := \mathbf{0}, \\ \boldsymbol{\phi}_2(\mathbf{x}) &:= \left(\eta(1-p) \|\mathbf{x}\|_2^{-p} + \beta + \gamma(1+q) \|\mathbf{x}\|_2^q \right) \boldsymbol{\phi}_1(\mathbf{x}), \end{aligned} \quad (8)$$

donde $\mathbf{x} = \hat{\boldsymbol{\theta}} - \boldsymbol{\theta}$ y $\|\mathbf{x}\|_2 := \sqrt{\mathbf{x}^\top \mathbf{x}}$. Adicionalmente, $\eta, \beta, \gamma > 0$, $\frac{1}{2} \geq p > 0$, y $q > 0$. Para que el diferenciador tenga convergencia, k_1 y k_2 son seleccionados de manera que

$$\mathbf{A} = \begin{pmatrix} -\kappa_1 & 1 \\ -\kappa_2 & 0 \end{pmatrix} \quad (9)$$

tenga sus eigenvalores con parte real negativa. Así, nuestro estimado de gradiente del mapa entrada-salida es

$$\frac{\partial J}{\partial \mathbf{u}} := \frac{\hat{\omega}_1}{\hat{\omega}_2}; \hat{\omega}_2 \neq 0. \quad (10)$$

3. CASO DE ESTUDIO: PROCESO DE PRODUCCIÓN DE BIOETANOL

En esta sección aplicamos la estrategia RTO-MA acoplada al algoritmo Súper-Twisting descrita en la sección previa, a un proceso de fermentación para la producción de bioetanol. El problema de optimización en tiempo real consiste en maximizar la producción de etanol a pesar de los cambios en la concentración de sustrato en la alimentación y a la incerteza paramétrica en el modelo que describe el proceso. Para resolver el problema de optimización, la tasa de dilución es considerada como la variable de decisión.

3.1 Modelo del proceso de producción de bioetanol

Considérese un proceso de fermentación para producción de bioetanol descrito por el siguiente modelo (López-Caamal et al., 2022):

$$\frac{d}{dt} \begin{pmatrix} c_1(t) \\ c_2(t) \\ c_3(t) \end{pmatrix} = \begin{pmatrix} -m \\ 1 \\ n \end{pmatrix} k_1 \frac{c_1 c_2}{c_1^2 + k_2 c_1 + k_3} \left(1 - \frac{c_2}{k_4}\right)^{k_5} + u(t) (\mathbf{c}_{in} - \mathbf{c}) \quad (11a)$$

$$y(t) = u(t) c_3(t), \quad (11b)$$

que describe en continuo un proceso de fermentación en el cual m unidades de sustrato, c_1 , son consumidas por una unidad de biomasa, c_2 , para generar una unidad de biomasa adicional y n unidades de etanol, c_3 . La variable $u(t)$ es la tasa de dilución y \mathbf{c}_{in} es la concentración de las especies en el flujo de entrada. Se selecciona la productividad del reactor como la salida del mismo. El proceso simulado mediante el modelo (11) utiliza los parámetros mostrados en la tabla 1.

Table 1. Tabla de parámetros

Parámetro	Valor	Unidad
k_1	922.8228	$gL^{-1}h^{-1}$
k_2	1.8947×10^3	gL^{-1}
k_3	114.4452	g^2L^{-2}
k_4	100	gL^{-1}
k_5	0.9	
m	30.3	
n	7	

Además consideramos que

$$\mathbf{c}_{in} = \begin{pmatrix} s_{in} \\ 0.4785 \\ 0 \end{pmatrix},$$

con s_{in} una función escalón de tres niveles [5, 20, 10] [g/L]. El Modelo (11) puede ser escrito en manera compacta como

$$\frac{d}{dt} \mathbf{c}(t) = \mathbf{N} \mathbf{v}(\mathbf{c}) + \mathbf{u}(t) (\mathbf{c}_{in} - \mathbf{c}), \quad (12a)$$

donde

$$\mathbf{N} = (-m \ 1 \ n)^\top \quad (12b)$$

$$\mathbf{v}(\mathbf{c}) = k_1 \frac{c_1 c_2}{c_1^2 + k_2 c_1 + k_3} \left(1 - \frac{c_2}{k_4}\right)^{k_5}. \quad (12c)$$

Con estos parámetros, el mapeo productividad vs. tasa de dilución es convexo para las tres condiciones de s_{in} estudiadas (López-Caamal et al., 2022). Por tanto, es posible utilizar la tasa de dilución para maximizar producción de etanol.

3.2 RTO-MA aplicada al caso de estudio

La aplicación del algoritmo RTO-MA requiere de un modelo aproximado del proceso, para la capa de toma de decisiones. El modelo utilizado considera una estructura similar a la de (12), pero con los parámetros modificados de la tabla 2, donde el superíndice "i" denota el valor de los parámetros utilizados en el modelo incierto del proceso.

Table 2. Tabla de parámetros modificados

Parámetro	Valor
k_1^i	500
k_2^i	4×10^3
k_3^i	114.4452
k_4^i	120
k_5^i	1.05

En adelante, "proceso" se referirá al modelo (12) simulado con los parámetros de la tabla 1, mientras que "modelo" se referirá a la simulación de (12) con parámetros de la tabla 2.

La diferencia en el valor de los parámetros, implica que el óptimo del proceso y el modelo, no coinciden. A continuación se presenta el valor de la tasa de dilución óptima del proceso y modelo, para los tres valores de s_{in} a estudiar. Además se muestra el valor de la productividad esperada en el proceso utilizando ambas tasas de dilución, notando que la pérdida de optimalidad por efectos de la incerteza del modelo es del orden del 70% en los tres escenarios de $s_{in} = c_{1,in}$ a estudiar.

Identificador	$s_{in} = 5$		$s_{in} = 20$		$s_{in} = 10$	
	D^*	J	D^*	J	D^*	J
Proceso	2.1	1.93	0.82	3.51	1.2	2.46
Modelo	0.51	0.60	0.97	14	0.31	0.71

Considerando la pérdida de optimalidad producto de la incerteza del modelo, se propone aplicar la metodología de RTO-MA a la optimización del proceso. El problema de optimización a resolver en cada iteración de la capa de supervisión se define de acuerdo a la ecuación (13).

$$\min_{u \in (0, 2.5]} -u * c_3 + \lambda_k(u - u_k)$$

tal que :

$$\begin{pmatrix} -m \\ 1 \\ n \end{pmatrix} k_1^i \frac{c_1 c_2}{c_1^2 + k_2^i c_1 + k_3^i} \left(1 - \frac{c_2}{k_4^i}\right)^{k_5^i} + u(c_{in} - c) = 0 \quad (13)$$

4. RESULTADOS

La estrategia RTO-MA propuesta se implementó para maximizar la productividad del proceso de producción de bioetanol modelado por (12). La estrategia RTO-MA consiste en resolver el problema de optimización (13) en cada periodo de optimización para actualizar la tasa de dilución, de manera que la producción de bioetanol se maximice en tiempo real.

El sistema de optimización en lazo cerrado se simuló en Matlab durante 1200 horas. Las ecuaciones diferenciales del modelo del proceso de producción de bioetanol se resolvieron usando la función *ode15s*, mientras que el problema de optimización modificado se resolvió usando la función *fmincon*.

El proceso de producción de bioetanol está sujeto a una entrada desconocida, la concentración del sustrato de alimentación (ver la figura 2), la cual toma valores para concentraciones de azúcares en vinazas tequileras, tal como se consideró en (López-Caamal et al., 2022).

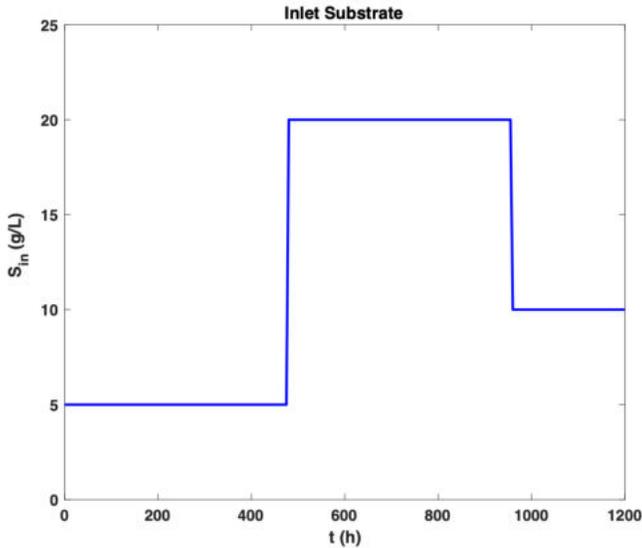


Fig. 2. Evolución temporal de la concentración del sustrato en la alimentación s_{in} .

La figura 3 muestra la evolución de la tasa de dilución y función objetivo para los tres escenarios estudiados. La línea roja discontinua representa el óptimo del proceso, mientras que la azul continua muestra la evolución del sistema, dirigida por la capa supervisora.

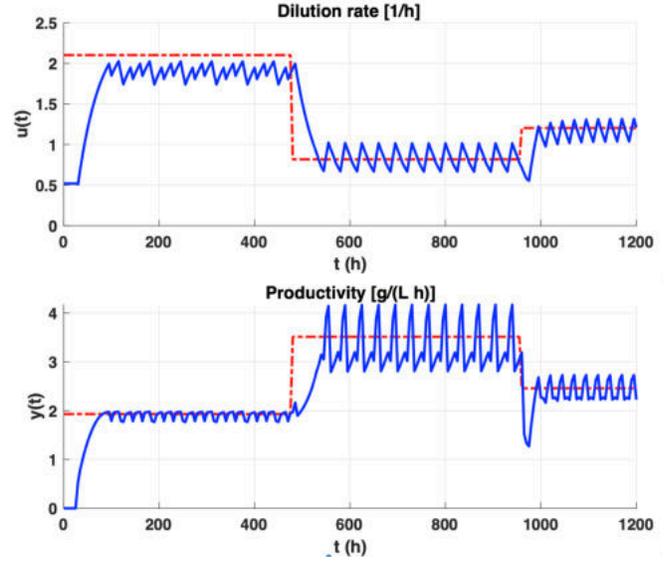


Fig. 3. Evolución temporal de la tasa de dilución (u) y productividad (y) obtenida al aplicar la estrategia RTO-MA propuesta.

La evolución de la variable de decisión para los tres escenarios de s_{in} muestra que el algoritmo de RTO-MA es capaz de identificar el óptimo del proceso, adaptándose a los cambios en las condiciones de entrada. Esto implica que el algoritmo Súper-Twisting permite estimar gradientes con datos transientes del sistema incierto, los cuales convergen al gradiente estacionario, permitiendo estimar la condición óptima del proceso de manera evolutiva.

Para cada escenario estudiado de s_{in} se puede identificar dos comportamientos asociados a la evolución de $u(t)$. El primero consiste en una trayectoria estable similar a una respuesta de primer orden, que lleva al proceso desde una condición inicial a una cercana al nuevo óptimo del proceso; mientras que el segundo consiste en una oscilación alrededor de la condición óptima actual. En relación a este segundo comportamiento, se puede indicar que, de acuerdo a estudios previos (López-Caamal et al., 2022; López-Caamal et al., 2022), el algoritmo de Súper-Twisting produce oscilaciones en condiciones cercanas al óptimo del proceso si este se utiliza en una capa supervisora libre de modelos (por ejemplo, basada en *Self Optimizing Control*), por lo que se puede inferir que los saltos observados en la figura 3 son consecuencia del método de estimación del gradiente del mapa entrada-salida.

5. CONCLUSIONES

En este artículo se presentó una estrategia de optimización en tiempo real con adaptación de modificadores basada en un modelo mecanístico y en la estimación del gradiente del mapa entrada-salida. La estrategia resuelve de un problema de optimización con modificadores de primer orden en la función objetivo para corregir las incertidumbres del modelo. Los modificadores se calculan a

partir de la diferencia entre el gradiente del mapa entrada-salida del proceso y el gradiente del mapa entrada-salida del modelo. Para estimar el gradiente del proceso, se utilizó un diferenciador basado en un algoritmo Súper-Twisting multivariable. Simulaciones en lazo cerrado validaron la estrategia de optimización en tiempo real aplicada al modelo con incertidumbres paramétricas de un proceso de fermentación para la producción de bioetanol.

Los resultados mostraron que la estrategia de optimización en tiempo real propuesta alcanza los valores de productividad máxima teóricos del proceso de producción de bioetanol, a pesar de las incertidumbres paramétricas del modelo utilizado para resolver el problema de optimización, y a cambios en las perturbaciones del sistema. Esa corrección se obtuvo considerando información transiente del proceso a través del gradiente del mapa entrada-salida del proceso 'real' (modelo con valores nominales de los parámetros). El desempeño del sistema supervisor presentó oscilaciones en la tasa de dilución sugerida cerca o alrededor del valor óptimo real (mientras más alta la concentración del sustrato, más alta la amplitud de las oscilaciones), lo que generó que la productividad del proceso también presentara oscilaciones.

Como conclusión general se puede indicar que la utilización del algoritmo de Súper-Twisting, para estimar gradientes utilizando datos transientes, representa una herramienta interesante para converger evolutivamente al óptimo estacionario de sistemas inciertos, utilizando RTO-MA. El hecho que el algoritmo de estimación de gradientes utilice datos dinámicos, evitaría la necesidad de esperar estados estacionarios entre cada ejecución de la capa supervisora, lo que reduciría el tiempo de convergencia al óptimo real. En contraparte, el uso de modelos aproximados, modificados con datos de planta, permitiría reducir el tiempo necesario para identificar el óptimo de un proceso incierto, respecto a sistemas libres de modelo. Por lo tanto, la utilización de RTO-MA en conjunto con el algoritmo de Súper-Twisting mejoraría sustancialmente el desempeño global de sistemas lentos, tales como los procesos biológicos.

Los resultados presentados en este trabajo representan una primera aproximación para diseñar estrategias de optimización en tiempo real robustas, ante incertidumbres del modelo y perturbaciones exógenas, que mejoren el tiempo de convergencia de las estrategias libres del modelo.

ACKNOWLEDGEMENTS

Este trabajo se realizó con el apoyo del programa SNII del CONAHCyT y de las universidades UG y UTFSM para la

realización de una estancia de investigación de Ixbalank Torres en la UTFSM en diciembre de 2022.

REFERENCES

- Dewasme, L. and Vande Wouwer, A. (2020). Model-free extremum seeking control of bioprocesses: A review with a worked example. *Processes*, 8(10), 1209–1239.
- López-Caamal, F., Hernández-Escoto, H., Cea-Barcia, G., and Torres, I. (2022). Gradient-based extremum seeking control applied to a dark fermentation process. In *Memorias del Congreso Nacional de Control Automático*, 318–323.
- López-Caamal, F. and Moreno, J.A. (2019). Generalised multivariable super-twisting algorithm. *International Journal of Robust and Nonlinear Control*, 29(3), 634–660.
- López-Caamal, F., Hernández-Escoto, H., and Torres, I. (2022). A gradient-based extremum seeking control of a substrate- and product-inhibited alcoholic fermentation process. *IFAC-PapersOnLine*, 55(7), 638–642. 13th IFAC Symposium on Dynamics and Control of Process Systems, including Biosystems DYCOPS 2022.
- Marchetti, A., Chachuat, B., and Bonvin, D. (2009). Modifier-adaptation methodology for real-time optimization. *Industrial & Engineering Chemistry Research*, 48, 6022–6033. doi:10.1021/ie801352x. URL <http://dx.doi.org/10.1021/ie801352x>. Doi: 10.1021/ie801352x.
- Marchetti, A., François, G., Faulwasser, T., and Bonvin, D. (2016). Modifier adaptation for real-time optimization - methods and applications. *Processes*, 4, 55. URL <http://www.mdpi.com/2227-9717/4/4/55>.
- Navia, D., Briceño, L., Gutierrez, G., and Prada, C.D. (2015). Modifier-adaptation methodology for real-time optimization reformulated as a nested optimization problem. *Industrial and Engineering Chemistry Research*, 54. doi:10.1021/acs.iecr.5b01946.
- Oliveira-Silva, E., de Prada, C., Montes, D., and Navia, D. (2023). Economic mpc with modifier adaptation using transient measurements. *Computers & Chemical Engineering*, 173, 108205. doi: <https://doi.org/10.1016/j.compchemeng.2023.108205>.
- Oliveira-Silva, E., de Prada, C., and Navia, D. (2021). Dynamic optimization integrating modifier adaptation using transient measurements. *Computers & Chemical Engineering*, 149, 107282. doi: <https://doi.org/10.1016/j.compchemeng.2021.107282>.
- Zhang, C. and Ordóñez, R. (2012). *Extremum-seeking control and applications: a numerical optimization-based approach*. Springer.