

# Estimación y Control Dinámico para Cultivos de Microalgas con un Esquema EKF-NMPC

F.A. Gorrini, S. Biagiola, J.L. Figueroa

Instituto de Inv. en Ing. Eléctrica “Alfredo Desages” (IIIE),  
Universidad Nacional del Sur (UNS)-CONICET,  
8000 Bahía Blanca, Argentina  
federicogorrini01@gmail.com,  
{biagiola,figueroa}@uns.edu.ar

A. Vande Wouwer

Systems, Estimation, Control and Optimization (SECO)  
University of Mons  
7000 Mons, Belgium  
alain.vandewouwer@umons.ac.be

**Abstract**— En este artículo se considera el problema de estimación y control de cultivos de microalgas en biorreactores. Éstos son sistemas no lineales con escasas mediciones y un nivel de ruido en las mismas muy elevado, lo que constituye un problema para la optimización de la productividad. Los sensores basados en software constituyen una solución ya que permiten reconstruir los estados completos del sistema en base a un número reducido de mediciones. En este trabajo se propone abordar el problema de optimización de la producción mediante la combinación de un controlador predictivo basado en modelo no lineal (NMPC) y un filtro de Kalman extendido (EKF). Tanto el control como el estimador se basan en un modelo matemático cuyos parámetros fueron identificados para la cepa *Scenedesmus obliquus*. La manipulación simultánea de la luz incidente y la tasa de dilución como variables de control, además de la sintonía dedicada del EKF hacen que la estructura observador-controlador propuesta resulte muy eficiente. El desempeño se evalúa mediante simulación numérica.

**Keywords**— *microalgas; software sensor; filtro de Kalman extendido; control predictivo.*

## I. INTRODUCCIÓN

La biomasa de las microalgas constituye una materia prima prometedora en el ámbito de las energías renovables, además de otras aplicaciones para industrias emergentes de biotecnología y química [1]. Por ello, existe un fuerte interés en desarrollar esquemas de control que permitan el funcionamiento óptimo de estos procesos [2]-[3]. Sin embargo, los biorreactores de microalgas son sistemas complejos, principalmente debido a su comportamiento no lineal y variable en el tiempo.

En la literatura, contribuciones tempranas relacionadas con el control de la producción de cultivos de microalgas, utilizan controladores realimentados estándar para lograr un criterio de optimización estática ([4], [5]). En [6] se propuso una identificación entrada-salida adaptativa basada en redes para la optimización de la biomasa ajustando la intensidad de la luz con una estrategia de control predictivo basado en modelo (MPC). En [7] se aplicó una estrategia de búsqueda de extremos basada en mínimos cuadrados recursivos para la optimización en línea de la productividad de las microalgas, utilizando solo la tasa de dilución como variable manipulada. En [8] se proporcionan valores óptimos para la tasa de dilución y la intensidad de la luz incidente con el fin de maximizar la productividad de la superficie de microalgas en estado estacionario en un cultivo continuo. Una contribución reciente utiliza un MPC basado en un modelo de tres estados [9]. En este caso, la dilución se manipula para maximizar la productividad.

Actualmente, es bien sabido que el crecimiento del cultivo de microalgas depende de dos procesos: la captación de nutrientes y la foto-aclimatación. En este trabajo se utilizan ambos mecanismos de control biológico para optimizar la producción. La propuesta se basa en un esquema NMPC que maximiza la productividad mediante la manipulación de la tasa de dilución y la irradiación de la luz al reactor.

Por otro lado, las diferentes propuestas de control y optimización requieren un cierto conocimiento del estado interno del bioproceso. En este punto, surgen problemáticas inherentes a la adquisición de datos de estos sistemas: no todos los estados son medibles y, en aquellos casos en que la medición es factible, se suele presentar un considerable nivel de ruido. La propuesta natural para lidiar con estas dificultades es recurrir a un estimador de estados, comúnmente conocido como *software sensor*.

En [10] se aplicó con éxito un observador de Luenberger sobre el modelo dinámico de Droop clásico de tres estados, que no tiene en cuenta el efecto de la luz sobre el crecimiento. Otro observador de alta ganancia se presenta en [11]. En [12] se utiliza un filtro de Kalman extendido para estimar la concentración de biomasa en un fotobiorreactor industrial usando como variables de control la inyección de dióxido de carbono y oxígeno. En [13] se comparan los desempeños de un filtro de Kalman extendido, un filtro de Kalman “unscented” y un filtro de partículas. El objetivo de estos esquemas es estimar las cuotas de células internas de lípidos, a partir de mediciones de biomasa y/o sustrato. En el presente trabajo, proponemos el uso de un filtro de Kalman extendido (en inglés, EKF), dado que permite considerar el modelo de estados completo y también ajustar los parámetros del algoritmo en coherencia con la información disponible sobre las estadísticas de los parámetros del modelo identificado.

El trabajo se organiza de la siguiente manera: En la Sección II se presenta el modelo del cultivo en el biorreactor. Las Secciones III y IV desarrollan el observador y el esquema de control predictivo, respectivamente. En la Sección V se describe la combinación EKF-NMPC empleada en este trabajo, y se analizan los resultados de la simulación. Finalmente, en la Sección VI se incluyen las conclusiones.

## II. MODELO MATEMÁTICO

El proceso de cultivo de microalgas es descrito mediante el siguiente modelo de Droop extendido [14]-[16], desarrollado por Bernard, que tiene en cuenta los fenómenos de foto-aclimatación y foto-inhibición, con un acoplamiento entre la fenomenología biológica y fisicoquímica:

TABLA I. PARÁMETROS DEL MODELO PARA SCENEDESMUS OBLIQUUS

Parámetro	Valor	CV (%)	CI	Unidades
$\bar{\mu}$	1.69	7.0	0.23	d <sup>-1</sup>
$k_s$	17.69	10.0	3.5	g <sub>N</sub> g <sub>C</sub> <sup>-1</sup>
$Q_0$	0.0104	4.0	0.0008	g <sub>N</sub> g <sub>C</sub> <sup>-1</sup>
$Q_l$	0.1172	8.2	0.0189	μE/m <sup>2</sup> s
$\bar{\rho}$	0.0573	6.4	0.0072	μE/m <sup>2</sup> s
$k_{sl}^*$	1.36	17.3	0.46	g <sub>N</sub> g <sub>C</sub> <sup>-1</sup> d <sup>-1</sup>
$k_{il}$	94.3	14.6	27.0	g <sub>N</sub> m <sup>-3</sup>
$R_e$	0.0779	2.1	0.0032	d <sup>-1</sup>
$\gamma_{max}$	1.158	1.6	0.037	g <sub>chl</sub> g <sub>N</sub> <sup>-1</sup>
$k_{I^*}$	184	7.7	28	μE/m <sup>2</sup> s
$a$	12.6	37.0	9.1	m <sup>2</sup> g <sub>chl</sub> <sup>-1</sup>
$b$	0.72	23.8	0.34	m <sup>-1</sup>
$c$	15.1	45.9	13.6	m <sup>-1</sup>
$K_g$	10.6	24.5	5.1	[-]

$$\dot{X} = \mu(X, Q, I_0)X - DX - R_e X \quad (1)$$

$$\dot{Q} = \rho(Q, S) - \mu(X, Q, I_0)Q \quad (2)$$

$$\dot{S} = DS_{in} - \rho(Q, S)X - DS \quad (3)$$

$$\dot{I}^* = \mu(X, Q, I_0)[\bar{I}(I_0) - I^*] \quad (4)$$

donde  $X, Q, S, I^*$  representan respectivamente a la concentración de biomasa, la concentración de cuota interna, la concentración de sustrato, y la irradiación lumínica de foto-aclimatación a la que las microalgas se adaptan; mientras que  $D, I_0, S_{in}$ , son la tasa de dilución, la irradiación lumínica en la superficie del cultivo y la concentración de nutrientes en el flujo de entrada. Por último,  $R_e$  es la tasa de respiración.

*Velocidad Específica de Crecimiento*

$$\mu = \bar{\mu} \left(1 - \frac{Q_0}{Q}\right),$$

$$\bar{\mu} = \bar{\mu} \frac{\bar{I}}{k_{sl} + \bar{I} + \left(\frac{\bar{I}^2}{k_{il}}\right)},$$

$$I_{opt} = \sqrt{k_{sl} k_{il}}, \quad k_{sl} = \frac{k_{sl}^*}{\theta} \quad \lambda = \xi L,$$

$$\xi = aChl + bX + c, \quad \gamma(I^*) = \bar{\gamma} \frac{k_{I^*}}{k_{I^*} + I^*},$$

$$Chl = \gamma(I^*)XQ, \quad \theta = \frac{chl}{X}$$

*Consumo de Nitrógeno*

$$\rho = \bar{\rho} \frac{S}{k_s + S} \left(1 - \frac{Q}{Q_l}\right),$$

*Intensidad Lumínica Promedio*

$$\bar{I} = \frac{I_0}{\lambda} [1 - e^{-\lambda}] = \frac{I_0 - I(L)}{\ln(I_0/I(L))} \approx I_0 \frac{K_g}{K_g + \lambda}$$

Los valores de los parámetros del modelo, así como sus intervalos de confianza para la cepa *Scenedesmus obliquus*, tomados de [17], se exhiben en la Tabla I.

### III. OBSERVADOR: FILTRO DE KALMAN EXTENDIDO

Un observador de estados es un sistema dinámico cuyos estados  $\hat{x}$  tienden a los del sistema observado  $x$ . Las propiedades de convergencia del observador se asocian a la dinámica del error de estimación  $\hat{e}(t) = \hat{x}(t) - x(t)$  y, para algunos algo-

ritmos, es común estudiar esa convergencia (de  $\hat{e}(t)$  a cero) mediante un análisis de estabilidad, como el de Lyapunov. En este trabajo, se emplea una variante del filtro de Kalman extendido capaz de lidiar con un modelo en tiempo continuo, pero con medidas en tiempo discreto [18]. Para la mayoría de los sistemas físicos, una representación adecuada consiste en un modelo de tiempo continuo, mientras que las variables monitoreadas se toman como medidas de tiempo discreto. Por lo tanto, el modelo del sistema y el modelo de medición vienen dados por [18]:

$$\dot{x}(t) = f(x(t), u(t)) + w(t), \quad (5)$$

$$y_k = h(x_k) + v_k,$$

$$w(t) \sim \mathcal{N}(0, Q(t)),$$

$$v_k \sim \mathcal{N}(0, R_k),$$

siendo  $x_k = x(t_k)$ .

El EKF utilizado se basa en las siguientes ecuaciones:

*Inicialización*

$$\hat{x}_{0|0} = E[x(t_0)], \quad (6)$$

$$P_{0|0} = E[(x(t_0) - \hat{x}(t_0))(x(t_0) - \hat{x}(t_0))^T],$$

*Predicción*

$$\hat{x}(t) = f(\hat{x}(t), u(t)) + w(t) \quad (7)$$

$$\dot{P}(t) = F(t) P(t) + P(t) F^T(t) + Q(t),$$

con

$$\hat{x}(t_{k-1}) = \hat{x}_{k-1|k-1},$$

$$P(t_{k-1}) = P_{k-1|k-1}.$$

$$\hat{x}_{k|k-1} = \hat{x}(t_k)$$

$$P_{k|k-1} = P(t_k)$$

$$F(t) = \left. \frac{\partial f}{\partial x} \right|_{\hat{x}(t), u(t)}$$

*Corrección*

$$K_k = P_{k|k-1} H_k^T (H_k P_{k|k-1} H_k^T + R_k)^{-1} \quad (8)$$

$$\hat{x}_{k|k} = \hat{x}_{k|k-1} + K_k [z_k - h(\hat{x}_{k|k-1})]$$

$$P_{k|k} = (\mathbb{I} - K_k H_k) P_{k|k-1}$$

donde  $H_k = \left. \frac{\partial h}{\partial x} \right|_{\hat{x}_{k|k-1}}$ .

El filtro de Kalman posee tres parámetros de diseño que se deben seleccionar adecuadamente de acuerdo con el problema de estimación que se enfrente, y son: la covarianza del ruido de medición,  $R$ ; la covarianza del ruido del proceso,  $Q$ ; y la covarianza estimada del estado inicial,  $P_0$ . Además, la estimación del estado inicial en sí,  $\hat{x}(t_0^+)$ , es un parámetro a determinar. Cada uno afecta al filtro de forma diferente y una selección inadecuada de alguno de ellos puede conducir a un desempeño deficiente o inviabilidad del observador.

Para hacer frente a esta situación, en [19] se presentan aspectos prácticos sobre la selección de estos parámetros, en base a características del propio sistema.

*Covarianza del Ruido de Medición*

$$R = k_R \text{diag}(\sigma_i^2) \quad (9)$$

donde  $\sigma_i$  es la desviación estándar de la medida  $i$  y la constante  $k_R = 1$  (a menos que se suponga que la incertidumbre en la medición será mayor que  $\sigma_i$ ).

*Covarianza en la Estimación de los Estados Iniciales*

$$P_0 = \text{diag}((\hat{x}_0 - x_0)^T (\hat{x}_0 - x_0)) \quad (10)$$

donde el estado inicial real ( $x_0$ ) se conoce en forma aproximada, pero dentro de ciertas cotas superior ( $x_u$ ) e inferior ( $x_l$ ). De esta forma, podemos establecer el estimado inicial  $\hat{x}_0 = 0.50 (x_u + x_l)$ , siendo entonces  $\hat{x}_0 - x_0 = 0.50 (x_u - x_l)$ .

*Covarianza del Ruido del Proceso*

$$Q(t) = k_Q J_{\hat{p}}(t) C_{\hat{p}} J_{\hat{p}}(t)^T \quad (11)$$

donde  $k_Q = 1$ ,  $C_{\hat{p}}$  es la covarianza de los parámetros del modelo (obtenida durante la identificación del mismo) y  $J_{\hat{p}}(t)$  es el jacobiano del modelo respecto de los parámetros, evaluado a lo largo de la trayectoria que va siguiendo el proceso. En base a la información experimental previamente obtenida del cultivo considerado en este trabajo, los parámetros de diseño se establecen de la siguiente manera:

$$\begin{aligned} P_0 &= \text{diag} [10^2 \quad 0.005^2 \quad 4^2 \quad 20^2] \\ R &= 1.5 J_{\hat{p}}(t) C_{\hat{p}} J_{\hat{p}}(t)^T \\ R &= 4 \text{diag} [25^2 \quad 2^2] \end{aligned}$$

#### IV. CONTROL PREDICTIVO BASADO EN MODELO

Con el objetivo de maximizar la producción de biomasa se implementa un control predictivo no lineal (NMPC) que manipula la dilución ( $D$ ) y la irradiancia de la luz en la superficie ( $I_0$ ). El modelo discreto se obtiene integrando las ecuaciones diferenciales (1)-(4) con un tiempo de muestreo  $T_s$  durante el cual las variables manipuladas permanecen constantes. En cada instante se supone que se conoce el conjunto completo de condiciones iniciales, provisto por el observador. El algoritmo NMPC considera un horizonte de predicción de  $P$  muestras, haciendo que la función objetivo (productividad) se defina como [20]:

$$J = \sum_{k=1}^P D(k) X(k) \quad (12)$$

y el horizonte de control es  $M$  ( $M < P$ ), donde las variables de control se calculan resolviendo el siguiente problema:

$$\arg \max_{\{D(k), I_0(k), k=1, \dots, M\}} J \quad (13)$$

sujeto a

$$\dot{x} = F(x, u) \quad (14)$$

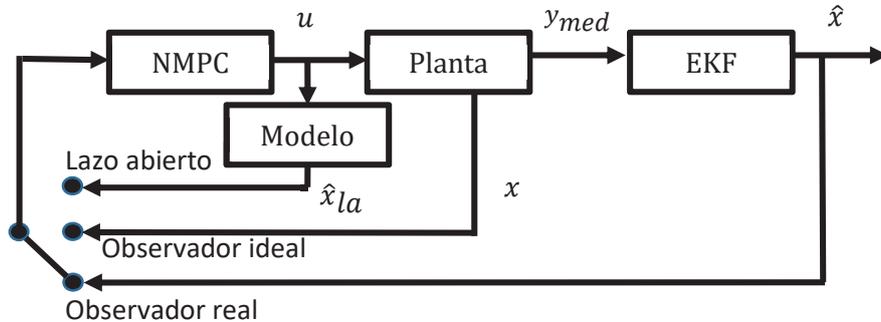


Fig. 1. Diagrama del esquema EKF-NMPC bajo tres escenarios diferentes: observador a lazo abierto, observador ideal y observador real.

$$0 = D^{lower} \leq D(k) \leq D^{upper} = 1.5 \quad (15)$$

$$0 = I_0^{lower} \leq I_0(k) \leq I_0^{upper} = 2000 \quad (16)$$

donde (14) representa el modelo de estados detallado en (1)-(5).

#### V. PERFORMANCE DE LA ESTRUCTURA EKF-NMPC

El sistema se encuentra representado por un modelo dinámico continuo, mientras que los muestreos se realizan en tiempos definidos. Para optimizar la producción de biomasa, un enfoque natural es utilizar NMPC. Desafortunadamente, algunos de los estados del modelo son difíciles o imposibles de medir, por lo que se recurre a la implementación de estimación de estados para obtener un valor aproximado de esas variables. Dadas las características del bioproceso en estudio, se considera conveniente optar por un Filtro de Kalman Extendido (EKF).

La Fig. 1 muestra la estructura del esquema de monitoreo y control propuesto. El controlador establece la entrada al sistema; y el observador reconstruye el vector de estados. En este caso, las variables medidas son  $[X \ S]^T$ , y los estados no medidos son  $[Q \ I^*]^T$ . Es importante destacar que el EKF contribuye, además, al filtrado de las medidas que incluyen un nivel de ruido considerable.

El sistema presenta tres variables de entrada ( $I_0, D, S_{in}$ ), pero solo las dos primeras son manipuladas por el controlador, luego  $u = [I_0 \ D]^T$ .

En un primer paso se analizó independientemente el desempeño del observador, tanto en el entorno de simulación con ruido de medición como también en el contexto más realista de estimación a partir de mediciones experimentales. En las simulaciones, se consideraron mediciones de biomasa con ruido aditivo con media cero y varianza  $(0.04 X)^2$ . Con respecto a  $S$ , se supuso ruido aditivo con media nula y varianza  $(0.10 S)^2$ . Estos valores están en consonancia con el nivel de ruido de medición observado en estos procesos.

En lo que respecta a los parámetros de diseño del EKF, la raíz cuadrada de cada uno de los elementos diagonales de la matriz  $P$  representa la desviación estándar del estado asociado a la posición de dicho elemento mientras que su determinante ( $\det(P)$ ) se utiliza para evaluar la calidad de convergencia del estimador y su evolución en el tiempo. Si  $\det(P)$  desciende monótonamente, entonces hay una buena convergencia. La Fig. 2 muestra la convergencia del observador para uno de los ensayos en términos de la reducción de  $\det(P)$  conforme el sistema evoluciona. Las condiciones iniciales de los estados se muestran en la Tabla II

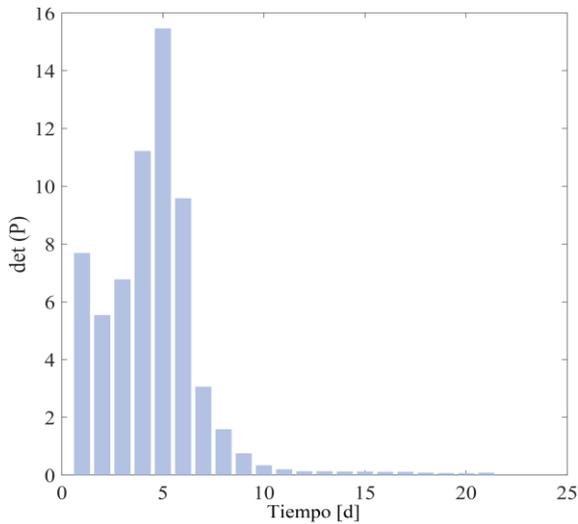


Fig. 2. Evolución de la covarianza en la estimación de estados.

TABLA II. CONDICIONES INICIALES.

$X_0$	$250 \text{ g}_X/\text{m}^3$
$Q_0$	$0.050 \text{ g}_N/\text{g}_X$
$S_0$	$50.00 \text{ g}_N/\text{m}^3$
$I_0^*$	$250 \text{ }\mu\text{E}/\text{m}^2 \text{ s}$
$S_{in}$	$75 \text{ g}/\text{m}^3$

Se realizaron varias pruebas considerando errores en las condiciones iniciales, en todos los casos el observador convergió a las cercanías de los perfiles reales en pocas muestras. También mostró un buen desempeño frente al ruido de medición.

El desempeño de la estructura EKF- NMPC es evaluado tomando como base de comparación dos escenarios límite con respecto a la información disponible del sistema: el uso de un observador a lazo abierto (OL); y la hipótesis de medición perfecta del vector de estado, denominada observador ideal (IO). En el caso OL, el controlador (NMPC) funciona solo con las predicciones obtenidas usando el modelo con los parámetros nominales (que llamaremos *modelo nominal*). Existe una discrepancia entre el modelo y el sistema que el controlador no podrá abordar, porque carece de información sobre cuál es el estado real del sistema. Este es el peor escenario posible para la estructura y establece una línea de base para las comparaciones. En el segundo caso (IO), se asume un conocimiento completo de los estados del sistema, proporcionando al NMPC la mejor información posible; por lo que representa el límite superior del desempeño alcanzable con MPC.

La propuesta de este trabajo consiste en el uso de un EKF, que denominaremos observador real (RO), el cual representa una situación intermedia. La Fig. 1 resume estos tres escenarios poniendo de manifiesto el flujo de información. Las variables involucradas son la entrada  $u$ ; la salida medida  $y_{med}$ ; el estado real  $x$ ; la estimación del estado,  $\hat{x}$ ; y la salida del modelo (estimación a lazo abierto),  $\hat{x}_{la}$ .

Según se determinó en [17], el modelo tiene una incertidumbre significativa en los parámetros (ver Tabla I), por lo que es importante evaluar el impacto de esta incertidumbre en el desempeño del esquema propuesto. Para este propósito, se con-

sideran variaciones paramétricas dentro de los intervalos de confianza, determinados por el desvío estándar, y se genera un total de  $10^3$  combinaciones a través del muestreo de hipercubo latino (*Latin Hypercube Sampling*, LHS). La metodología es la siguiente:

- Se realiza la optimización del cultivo con NMPC y parámetros nominales, obteniendo una trayectoria de control óptima,  $u|_{opt}$ .
- El cultivo se simula con la entrada  $u|_{opt}$  para cada una de las  $10^3$  combinaciones de parámetros creadas con el LHS. El conjunto de parámetros se determina con el comando *lhsdesign* de MATLAB®.
- Una vez obtenidos los resultados, para cada instante de tiempo, se selecciona el conjunto de parámetros que genera los valores máximo y mínimo de las variables de estado ( $X$ ,  $Q$ ,  $S$ ,  $I^*$ ), y de producción  $P$  y de la producción acumulada,  $P_c$ .

A través de ese procedimiento se identificó un total de 23 conjuntos de parámetros con los que se obtienen las curvas envolventes sobre la biomasa. Éstos son los mismos que generan las envolventes alrededor de las curvas de la producción de cultivo,  $P = DX$ . El controlador (NMPC) fue ajustado con  $T_s = 1$ ,  $P = 6$  and  $M = 3$  logrando un buen compromiso entre productividad y tiempo de computación. La optimización se resuelve con la función *fmincon* de MATLAB®. En cada iteración, la función objetivo se calcula integrando el modelo sobre el horizonte de predicción. La solución de tiempo anterior se utiliza como suposición inicial para las variables manipuladas, que deben respetar las restricciones impuestas en (15)-(16).

Para analizar la respuesta del esquema EKF-NMPC se realizaron simulaciones para cada una de las combinaciones extremas de parámetros. La Fig. 3 muestra la productividad alcanzada, que es comparada con las obtenidas con el mismo controlador en los esquemas OL-NMPC e IO-NMPC. La Fig. 4 muestra las variables manipuladas obtenidas, para el uso del EKF y el observador ideal. La irradiación lumínica óptima se establece en un nivel que favorece el crecimiento de la biomasa evitando efectos inhibidores. Por otro lado, la tasa de dilución es relativamente baja, lo que permite una entrada de nutrientes suficiente para mantener la tasa de crecimiento, pero reduce el riesgo de lavado. Los perfiles de las variables de optimización no presentan cambios bruscos o permanentes, lo que es deseable. Un estado estable se alcanza tras pocos días de cultivo. Como se muestra en la Fig. 3, la mejor estrategia para lograr la máxima productividad es maximizar el crecimiento de biomasa durante los primeros días. Es por eso que la tasa de dilución se mantiene inicialmente igual a su límite inferior (ver Fig. 4).

Para cuantificar los diferentes desempeños alcanzados se definen índices numéricos simples. Dado que el objetivo del proceso es lograr la máxima producción de biomasa, se establece una medida de rendimiento y productividad como el promedio entre los peores y mejores casos:

$$P_{pro} = \text{media}(P|_{mejor\ caso} + P|_{peor\ caso}) \quad (16)$$

y, a efectos de referencia, se establece un índice de robustez como la diferencia entre los casos extremos

$$P_{rob} = (P|_{mejor\ caso} - P|_{peor\ caso}) \quad (17)$$

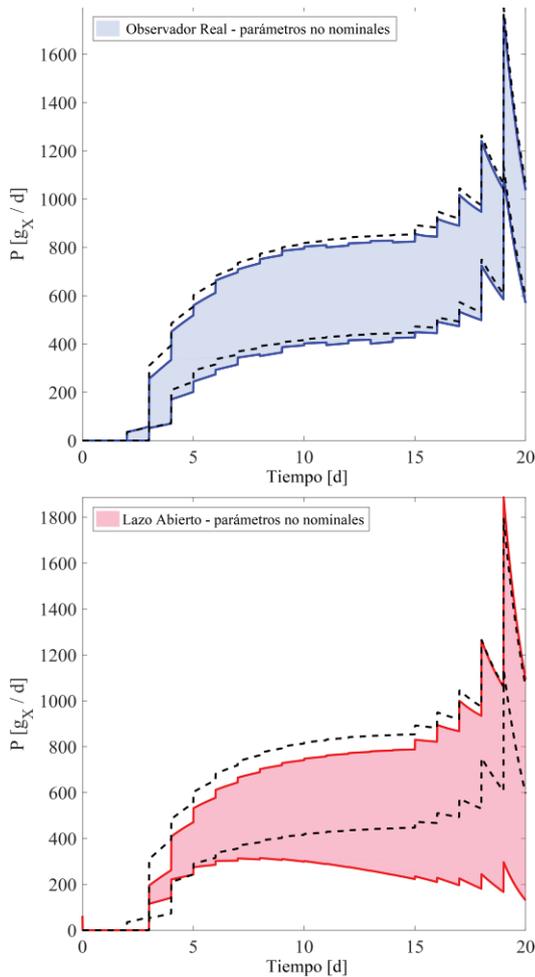


Fig. 3. Producción obtenida con la combinación EKF-NMPC para las combinaciones de parámetros más desventajosas (azul). Comparación contra el IO-NMPC (líneas discontinuas negras) y OL-NMPC (rojo).

TABLA III: ÍNDICES DE DESEMPEÑO PARA LOS CASOS EN ESTUDIO.

Estrategia de Control	$P_{pro}[g_X/d]$	$P_{rob}[g_X/d]$
IO +NMPC	10769.0	6782.4
OL+NMPC	8669.5	8847.6
RO+NMPC	10284.0	6752.5

La Tabla III proporciona esta información para un análisis comparativo y para cuantificar la mejora lograda. El comportamiento general, así como el desempeño de la estructura EKF-NMPC, es sobresaliente. En términos de productividad, el observador ideal obtuvo un rendimiento un 24,2% más alto que su contraparte de lazo abierto, mientras que el observador real casi alcanzó ese rendimiento, con una mejora del 18,6% sobre el caso de lazo abierto.

Otro aspecto que analizamos es la robustez del esquema EKF-NMPC ante un error en el estado inicial del estimador. Para ello, se ejecutaron 10 simulaciones con condiciones iniciales aleatorias dentro de límites de error de  $\pm 20\%$  de los estados iniciales. Los resultados de la simulación se muestran en las Figs. 5-6, donde las trayectorias están contenidas entre las envolventes de cada área. Como se puede ver, el perfil de producción sigue el mismo patrón sin importar la condición inicial. La intensidad lumínica y la tasa de dilución determinadas por el contro-

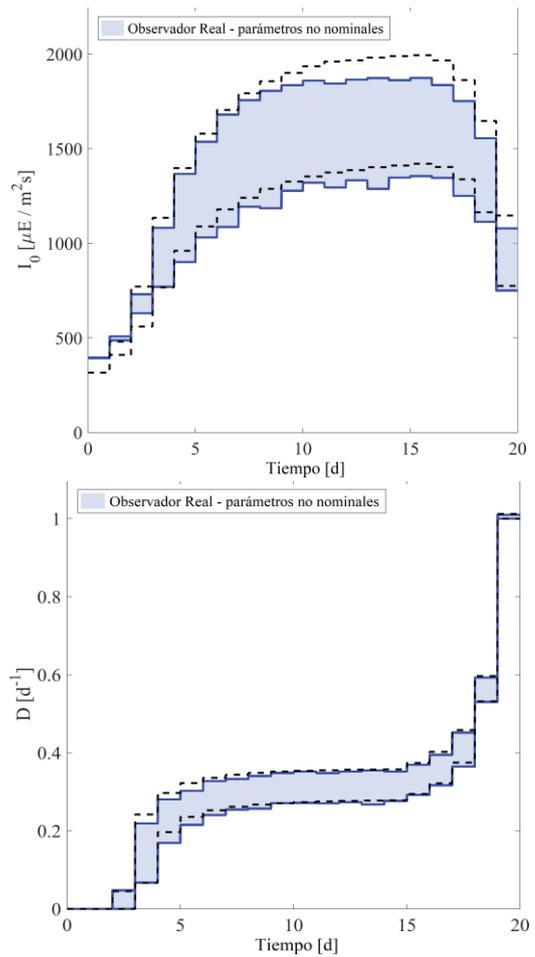


Fig. 4. Variables manipuladas para los peores conjuntos de parámetros: para el esquema EKF-NMPC (azul) y para el IO-NMPC (trazo negro discontinuo).

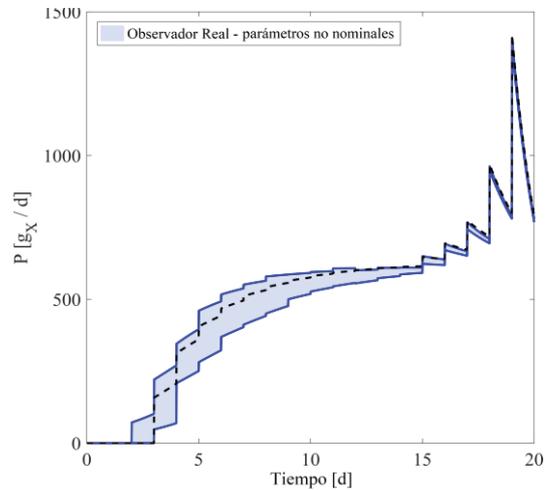


Fig. 5. Producción bajo análisis de sensibilidad por error de estado inicial ( $\pm 20\%$ ) (la línea discontinua negra corresponde a un observador ideal con parámetros nominales).

lador se ajustan adecuadamente a cada situación específica, pero los perfiles principales no se alteran. Lo mismo se observa en cuanto al patrón de evolución temporal de las variables de estado.

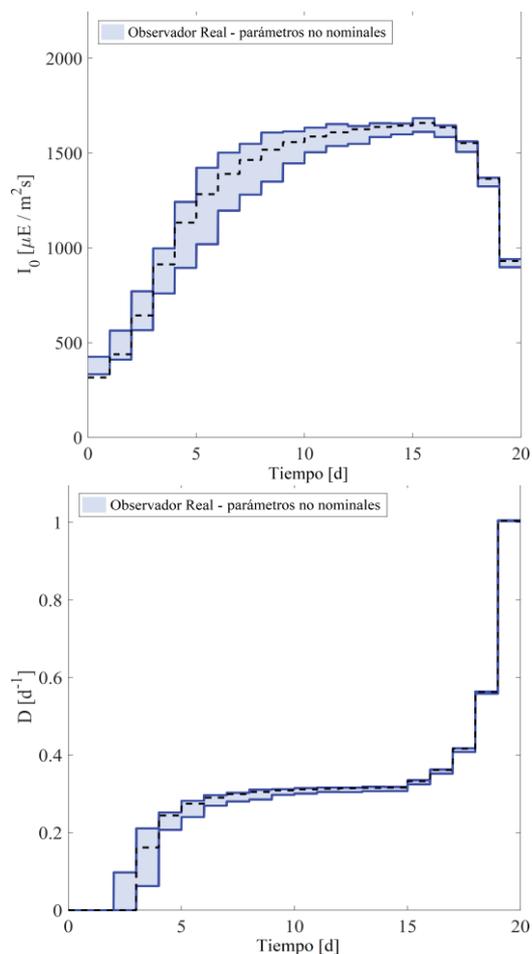


Fig. 6. Intensidad lumínica y tasa de dilución bajo análisis de sensibilidad para error de estado inicial ( $\pm 20\%$ ) (la línea discontinua negra corresponde a un observador ideal con parámetros nominales).

## VI. CONCLUSIONES

La propuesta desarrollada para la estimación de estados y control de cultivos de microalgas muestra resultados promisorios. Se utilizó un modelo altamente no lineal que hace frente a los fenómenos de foto-inhibición y foto-aclimatación, obteniendo resultados que evidencian que el esquema observador/controlador predictivo propuesto conduce a una mejora significativa en los criterios de desempeño a los fines de optimización del cultivo. La implementación de un controlador NMPC permite maximizar la productividad de las microalgas, mientras que el observador EKF reconstruye los estados de manera efectiva, lo cual queda reflejado en los estudios obtenidos en un ambiente de simulación.

En la actualidad, está en curso la verificación experimental de este esquema EKF-NMPC.

## ACKNOWLEDGMENT

Los autores agradecen el apoyo financiero del Programa de Cooperación Bilateral CONICET-FNRS y la Universidad Nacional del Sur (PGI 24/089).

## REFERENCIAS

[1] Y. Chisti, "Biodiesel from microalgae beats bioethanol," *Trends Biotechnol.*, vol. 26, pp. 126-131, 2008.

[2] G. Olivieri, P. Salatino, and A. Marzocchella, "Advances in photobioreactors for intensive microalgal production: configurations, operating strategies and applications," *J. Chem. Technol. Biotechnol.*, vol. 89, pp. 178-195, 2014.

[3] C. Martínez, O. Bernard, and F. Mairet, "Maximizing microalgae productivity by shading outdoor cultures," 20<sup>th</sup> IFAC World Congress Proceedings, pp. 8734-8739, Toulouse, France. July 2017.

[4] S. Ben-Yaakov, H. Guterman, A. Vonshak, and A. Richmond, "An automatic method for on-line estimation of the photosynthetic rate in open algal ponds," *Biotechnol. Bioeng.*, vol. 27 (8), 1136-1145, 1985.

[5] H. Guterman, S. Ben-Yaakov, A. Vonshak, Automatic on-line growth estimation method for outdoor algal biomass production, *Biotechnol. Bioeng.*, vol. 34 (2), 143-152, 1989.

[6] D. Hu, H. Liu, C. Yang, and E. Hu, "The design and optimization for light-algae bioreactor controller based on Artificial Neural Network-Model Predictive Control", *Acta Astronautica*, vol. 63, 1067-1075, 2008.

[7] C.G. Feudjio Letchindjio, L. Dewasme, J.-S. Deschênes, and A. Vande Wouwer, "An Extremum Seeking Strategy Based on Block-Oriented Models: Application to Biomass Productivity Maximization in Microalgae Cultures." *Industrial & Engineering Chemistry Research*, vol. 58, 13481-13494, 2019.

[8] C. Martínez, O. Bernard, and F. Mairet, "Maximizing microalgae productivity in a light-limited chemostat." *IFAC-PapersOnLine*, vol. 51, 735-740, 2018.

[9] A. Juneja, and G. Murthy, "Model predictive control coupled with economic and environmental constraints for optimum algal production." *Bioresource Technology*, vol. 250, 556-563, 2018.

[10] M. Benavides, Daniel Coutinho, A.L. Hantson, J. Van Impe, A. Vande Wouwer. "Robust Luenberger Observers for Microalgal Cultures." *Journal of Process Control*, vol. 36, 55-63, 2015.

[11] S.I. Biagiola, J.L. José Luis Figueroa, and A. Vande Wouwer. 2019. "A High-Gain Observer Approach for Monitoring Microalgae Cultures." XVIII RPIC, Bahía Blanca. Argentina. 2019.

[12] F. García-Mañas, J.L. Guzmán, M. Berenguel, G. Acien. "Biomass estimation of an industrial raceway photobioreactor using an extended Kalman filter and a dynamic model for microalgae production." *Algal Research*, vol. 37, 103-114, 2019.

[13] S.J. Yoo, J.H. Kim, and J.M. Lee. "Soft Sensor Design with State Estimator for Lipid Estimation of Microalgal Photobioreactor System." In 2014 14th International Conference on Control, Automation and Systems (ICCAS 2014), 1299-1304, 2014.

[14] O. Bernard, "Hurdles and challenges for modelling and control of microalgae for CO2 mitigation and biofuel production," *Journal of Process Control*, vol. 21, 1378-1389, 2011.

[15] O. Bernard, P. Masci, and A. Sciandra, "A photobioreactor model in nitrogen limited conditions," 6<sup>th</sup> Vienna International Conference on Mathematical Modelling, 2009.

[16] P. Hartmann, A. Nikolaou, B. Chachuat, and O. Bernard, "A dynamic model coupling photoacclimation and photoinhibition in microalgae," *European Control Conference (ECC13)*, Zurich, Switzerland. July 2013.

[17] F.A. Gorrini, J.M. Zamudio Lara, S.I. Biagiola, J.L. Figueroa, H. Hernández Escoto, A.-L. Hantson, and A. Vande Wouwer. "Experimental Study of Substrate Limitation and Light Acclimation in Cultures of the Microalgae *Scenedesmus Obliquus*—Parameter Identification and Model Predictive Control." *Processes* 8 (12) 1551, 2020.

[18] D. Simon, *Optimal State Estimation. Kalman, H<sub>∞</sub>, and Nonlinear Approaches*. Wiley-Interscience. USA. 2006.

[19] R. Schneider, and C. Georgakis. "How To NOT Make the Extended Kalman Filter Fail." *Industrial & Engineering Chemistry Research*, 52, 3354-3362, 2013.

[20] E. Fernández Camacho, and C. Bordons Alba, "Model Predictive Control in the Process Industry (Advances in Industrial Control)", Springer, 2013.