

# Modelado y control adaptativo del pH en reactores *raceway* para la producción de microalgas

Malena Caparroz, Pablo Otálora, José Luis Guzmán, Manuel Berenguel

Departamento de Informática, Universidad de Almería, ceiA3, CIESOL, Ctra. Sacramento s/n, 04120 Almería, España. Tel: +34 950 214133; mc541@inlumine.ual.es, {p.otalora, joseluis.guzman, beren}@ual.es

## Resumen

*Este trabajo se centra el desarrollo de modelos de árboles de regresión para predicción de pH y su control en fotobiorreactores raceway. Se han obtenido árboles capaces de estimar los parámetros del modelo a partir de los cuales se puede predecir el valor del pH para fotobiorreactores de aguas limpias. Los modelos emplean datos relativos a las condiciones a las que se encuentra sometido el cultivo, tales como radiación global, temperatura del medio y nivel del cultivo. Los resultados obtenidos validan el uso de estas técnicas para el modelado de procesos biológicos, proporcionando modelos precisos, sencillos y de rápida ejecución. Dichos modelos se han utilizado para diseñar un control PI adaptativo del pH en este tipo de reactores, siendo evaluados en simulación.*

**Palabras clave:** Microalgas, modelado, reactores abiertos, control adaptativo.

## 1. Introducción

Una línea de investigación que ha cobrado mucha importancia en los últimos años es la referida a la producción de microalgas a escala industrial. Las microalgas son microorganismos fotosintéticos con la capacidad de crecer y reproducirse en entornos sin agua limpia o suelo fértil. Además, contribuyen enormemente en la lucha contra el calentamiento global del planeta, pues capturan energía solar y producen una gran cantidad de oxígeno, además de convertir fuentes carbónicas como el CO<sub>2</sub> en biomasa [5].

Para esto, necesitan un aporte adicional de nutrientes tales como carbono, nitrógeno y fósforo. El carbono se suministra mediante inyección de CO<sub>2</sub>, puesto que también sirve para regular el pH del sistema. Los nutrientes restantes pueden aportarse de forma directa, introduciéndolos en soluciones al medio acuoso, o ser absorbidos del propio medio, puesto que el nitrógeno y el fósforo son los principales contaminantes de las aguas residuales, por lo que este proceso se convierte también en una solución al tratamiento de estas. Además, las

microalgas pueden utilizarse en la elaboración de productos de alto valor en el campo de la cosmética, nutrición humana o alimentación animal [5].

El fotobiorreactor en el que se producen las microalgas es un factor clave, dado que la complejidad del control del sistema dependerá de su diseño y forma de operación. Se pueden utilizar fotobiorreactores cerrados, que presentan una barrera física que separa el cultivo con el ambiente que lo rodea, por lo que las microalgas no están expuestas a fuentes de contaminación externas. Entre ellos se encuentran los reactores tubulares. Por otro lado, se encuentran los fotobiorreactores abiertos, siendo los *raceway* los más extendidos. Requieren una inversión considerablemente menor, puesto que son estructuralmente más sencillos y precisan de materiales menos costosos, pero están sometidos a una continua contaminación al estar abiertos al ambiente. Estos últimos, además, presentan un fácil escalado y un bajo consumo energético [5].

La tasa de crecimiento de las microalgas viene determinada por un factor principal, que es la disponibilidad de luz y depende en gran medida de la concentración del cultivo y el nivel del medio. Además, este término viene ponderado por otros tres que representan la temperatura, el pH y el oxígeno disuelto y cuyos valores se encuentran normalizados entre 0 y 1 [1].

La influencia de la temperatura y el pH son muy similares, ambos presentan un valor óptimo en torno al cual la tasa de crecimiento es máxima, pero fuera de ese valor la tasa decrece drásticamente. En cuanto al oxígeno disuelto, hay un valor a partir del cual la tasa de crecimiento desciende. El pH es, entre todas las variables a controlar, la más crítica y complicada, pues la producción de la fotosíntesis provoca variaciones continuas [7].

El pH suele controlarse mediante algoritmos clásicos todo/nada durante el día, sin tener en cuenta la dinámica del sistema ni las perturbaciones del proceso. Esto se debe principalmente a que, al tratarse de un sistema biológico, es muy difícil obtener un modelo sencillo que refleje adecuadamente el comportamiento del mismo. Si se quiere

capturar correctamente la dinámica se debe trabajar con modelos muy complejos que dificultan el desarrollo de los algoritmos de control [1, 7].

En la literatura se pueden encontrar multitud de modelos, cuya complejidad varía enormemente de acuerdo a los objetivos de los mismos [2, 3, 4, 8].

Actualmente, es necesario llegar a un balance entre la complejidad del modelo de pH y la dificultad para desarrollar algoritmos de control. Por un lado, modelos muy complejos reflejan con mucha exactitud el comportamiento del sistema tanto espacial como temporalmente, pero dificultan el diseño de controladores. Por el otro, modelos muy simples facilitan el diseño de los algoritmos de control pero su excesiva sencillez provoca un modelado del sistema poco exacto y la pérdida de eficacia de los controladores cuando se presentan condiciones ambientales distintas a las que había a la hora de obtener el modelo, por lo que estos modelos tendrían que ser constantemente calibrados para ajustarse a la enorme variedad de condiciones ambientales que se presentan, que tienen una gran influencia sobre la dinámica del sistema.

Es por las razones expuestas anteriormente que se han desarrollado modelos de árboles de regresión que sean capaces de calcular los parámetros de un modelo simple. Se buscaba conseguir un modelo sencillo pero que, en cierto modo, sea capaz de autocalibrarse en función de las condiciones a las que se encuentre sometido el sistema. Este modelo ha sido utilizado tanto para fines de modelado como para fines de control para el diseño de un algoritmo de control adaptativo. El rendimiento de la estrategia desarrollada ha sido evaluado en simulación, utilizando como planta virtual un modelo no lineal del proceso basado en redes neuronales [6].

## 2. Descripción del proceso

Durante el desarrollo del presente trabajo, se ha utilizado el fotobiorreactor *Raceway* localizado en el centro IFAPA de la Junta de Andalucía que se encuentra anexo a la UAL (Figura 1). Se dispone de dos de ellos, uno utiliza agua limpia y un aporte externo de nutrientes, mientras que el segundo utiliza aguas residuales provenientes de la UAL. En el presente trabajo se utilizará el primero de ellos, aunque la única diferencia radica en el agua utilizada y el aporte de nutrientes.

Los reactores están compuestos por dos canales de 40 m de longitud, 1 m de ancho y 30 cm de profundidad, unidos en sus extremos por curvas de 180°. Por lo tanto, cada reactor cuenta con una superficie total de 80 m<sup>2</sup>, lo cual proporciona una relación entre el volumen y el nivel del medio de

800 L/cm. A pesar de contar con una profundidad de 30 cm, la altura de cultivo óptima se encuentra alrededor de los 15 cm.

El mezclado e impulsión del medio se realiza mediante una rueda de paletas de aluminio, con un diámetro de 1.2 m y formada por 8 palas. La misma es accionada por un grupo motorreductor controlado eléctricamente por medio de un variador de frecuencia, de modo que se pueda proporcionar al fluido una velocidad constante de 0.2 m/s.

En el foso que se encuentra justo detrás de las palas se realiza la inyección de aire y de CO<sub>2</sub>, a través de 3 discos difusores. El mismo se encuentra a 1.8 m de distancia de las palas impulsoras y presenta forma cilíndrica con un diámetro 65 cm y 1 m de profundidad.



Figura 1: Fotobiorreactores *raceway* disponibles en las instalaciones del Convenio UAL-IFAPA

El sistema dispone de sensores de nivel, temperatura, pH y oxígeno disuelto. El pH y el oxígeno disuelto son medidos en dos puntos distintos: el primero se encuentra justo después del foso, mientras que el segundo está al final del segundo canal, justo antes de las palas. Este último es el punto más desfavorable y difícil de controlar, y usualmente es el objetivo de las estrategias de control implementadas en este sistema.

Los reactores se encuentran inoculados con microalgas de la cepa *Scenedesmus*, la cual se caracteriza por su adaptabilidad y su buen crecimiento en reactores de exterior. Su resistencia a los contaminantes la convierte en una excelente cepa para el tratamiento de aguas residuales. Su pH óptimo se encuentra en el rango de 7.0 a 9.0 y la máxima actividad fotosintética a una temperatura en el rango comprendido entre 26 y 34 °C [1].

El control del pH es un problema no lineal que puede ser linealizado en ciertas circunstancias y su regulación se consigue con la inyección de CO<sub>2</sub> [2]. Un modelo simple que captura la dinámica del

pH es el mostrado en las siguientes ecuaciones:

$$pH(s) = \frac{K_1}{(1 + \tau s)} \frac{K_2 w_n^2}{(s^2 + 2\delta w_n s + w_n^2)} e^{-t_r s} CO_2(s) + \frac{K_r}{(1 + \tau_r s)} I_{sat}(s) \tag{1}$$

$$pH(s) = TF_1(s)TF_2(s)CO_2(s) + TF_3(s)I_{sat}(s) \tag{2}$$

donde pH es el pH del medio, CO<sub>2</sub> es el porcentaje de apertura de la válvula e I<sub>sat</sub> un valor saturado de radiación global [2].

Como se puede observar en la ecuación (1), la dinámica del pH con respecto al CO<sub>2</sub> viene dada por un término de primer orden con retardo ( $TF_1(s) = \frac{K_1 e^{-t_r s}}{1 + \tau s}$ ) que marca la dinámica dominante del proceso, junto a una función de transferencia de segundo orden ( $TF_2(s)$ ) que representa las oscilaciones existentes en el sistema debido a las inyecciones de CO<sub>2</sub> que se van atenuando por la recirculación del medio a lo largo del receptor solar. La función  $TF_3(s)$  representa el efecto sobre-amortiguado de la radiación solar sobre el pH como un efecto la fotosíntesis. Los parámetros de las funciones toman valores particulares dependiendo del tipo de reactor, de la cepa y de las condiciones meteorológicas [5].

### 3. Modelos desarrollados

Para la obtención de modelos de árboles de regresión se han realizado ensayos con un algoritmo de control todo/nada con histéresis, de modo que cuando el pH supere 8.5 se comience a inyectar CO<sub>2</sub> y cuando llegue a 7.5 cese la inyección (Figura 2).

Una vez realizada una campaña extensa de los ensayos descritos anteriormente, se han obtenido modelos de función de transferencia de primer orden con retardo para cada intervalo de inyección de CO<sub>2</sub>. El retardo era el mismo en todos los casos, puesto que es un parámetro fijo que depende de las características físicas del sistema. En este caso específico, representa el tiempo que tarda la masa de cultivo en desplazarse desde el foso al sensor de medida, por lo que depende de la velocidad del fluido, fijada por la velocidad de las palas. La ganancia y la constante de tiempo varían en cada modelo obtenido y se encuentran fuertemente vinculadas a las condiciones a las que se encuentra sometido el cultivo de radiación, temperatura y nivel. Por lo tanto, la forma de los modelos obtenidos es la mostrada en la ecuación (3).

$$pH(s) = \frac{K}{\tau s + 1} e^{-t_r s} CO_2(s) \tag{3}$$

donde  $k$  y  $\tau$  son función de los parámetros ambientales anteriormente mencionados,  $t_r$  es el retardo (en este caso de 270 s),  $pH(s)$  es el pH medido justo antes de las palas y  $CO_2(s)$  es el caudal de CO<sub>2</sub> inyectado en el foso, en L/min.

Así, se ha obtenido una gran cantidad de estos modelos y se ha almacenado, para cada uno, el valor de la radiación global media, la temperatura media del medio y el nivel medio en cada intervalo. Una vez analizados todos los datos obtenidos, se han entrenado árboles de regresión para estimar la ganancia estática y la constante de tiempo del modelo en función de los valores instantáneos de radiación global y temperatura y nivel del medio (Figuras 3 y 4).

Los parámetros estimados mediante estos árboles de regresión brindan una dinámica del pH durante la inyección de CO<sub>2</sub> que se acerca considerablemente bien a la del sistema real como se mostrará en el apartado de resultados.

Por otro lado, para la respuesta libre del sistema en ausencia de inyección de CO<sub>2</sub>, se ha intentado realizar la estimación mediante la obtención de modelos en espacio de estados por el método de mínimos cuadrados. Así, el modelo tendría la forma mostrada en la ecuación (4).

$$pH(k) = \theta_1 pH(k - 1) + \theta_2 \tag{4}$$

donde  $pH(k)$  es el pH del sistema en el instante de tiempo discreto actual ( $k$ ),  $\theta_1$  y  $\theta_2$  son parámetros del modelo que dependen de los valores de la radiación, la temperatura y el nivel, y  $pH(k - 1)$  es el pH del sistema en el instante de tiempo discreto anterior ( $k - 1$ ).

Para estos modelos se ha procedido de manera análoga a los modelos de función de transferencia, obteniendo un árbol de regresión para estimar cada parámetro.

Sin embargo, el modelo obtenido no conseguía resultados satisfactorios a la hora de realizar la estimación de los parámetros a partir de los valores instantáneos de los predictores. La dinámica del pH estimado mediante los árboles de regresión difería enormemente de la del pH real. En cualquier caso, este trabajo se ha centrado en la parte del modelo relacionada con la inyección de CO<sub>2</sub> con el objetivo de ser utilizado con fines de control. En futuros trabajos se tratará de mejorar el término de respuesta libre del sistema.

### 4. Estimación de pH en simulación

Una vez obtenidos los árboles de regresión que permiten estimar la ganancia y la constante de tiempo del sistema durante la inyección de CO<sub>2</sub> en fun-

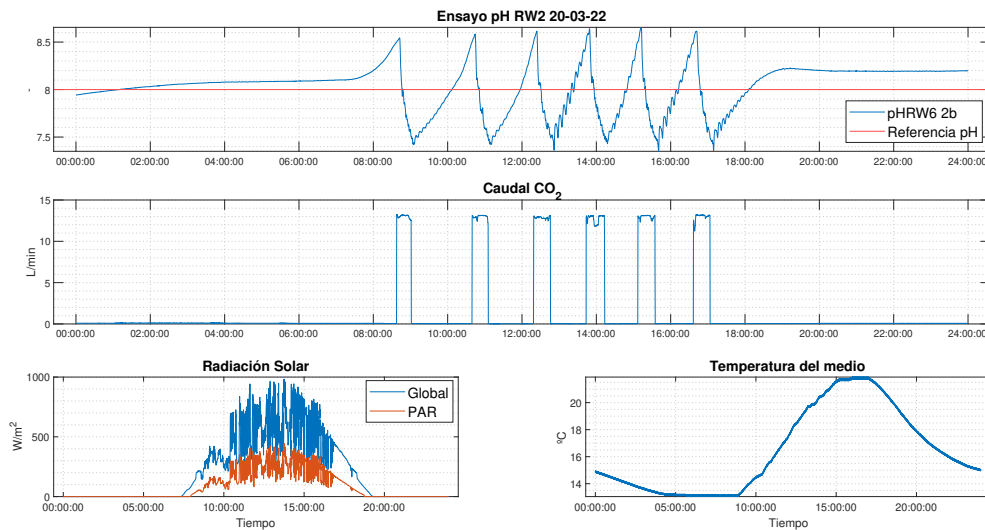


Figura 2: Ensayo con control todo/nada con histéresis

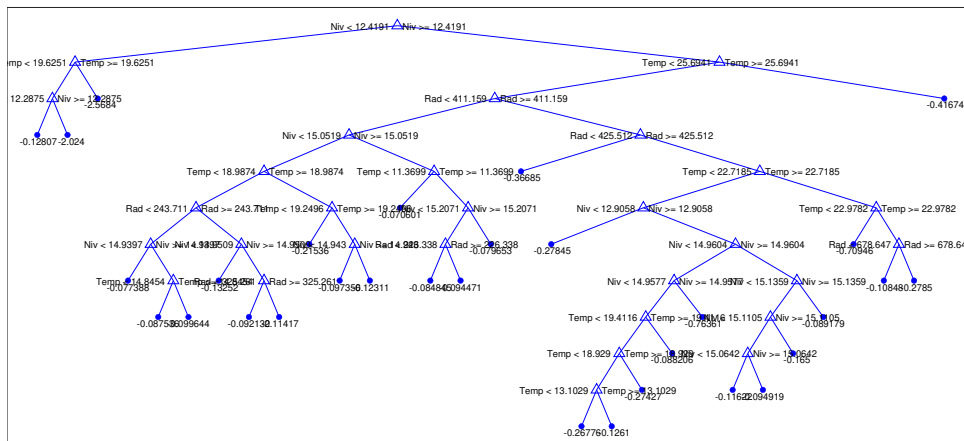


Figura 3: Árbol de regresión para la estimación de  $K$

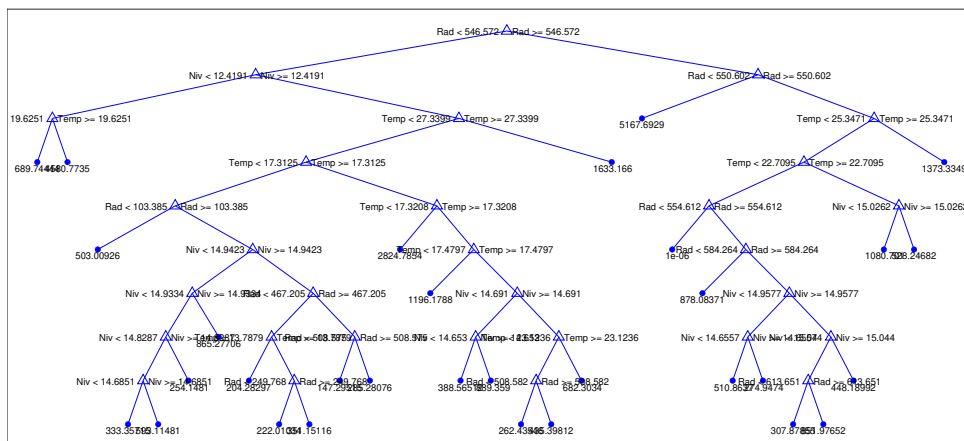


Figura 4: Árbol de regresión para la estimación de  $\tau$

ción del valor instantáneo de los predictores, se ha implementado el estimador de pH en un simulador que utiliza como planta virtual un modelo de red neuronal [6].

En las Figuras 5 y 6 se muestran los resultados de implementar el estimador de los parámetros del modelo ( $K$  y  $\tau$ ) para predecir la dinámica del pH al utilizar un control PI de parámetros fijos.

El controlador PI ha sido diseñado utilizando como modelo una función de transferencia de primer orden con retardo, cuya ganancia y constante de tiempo son el promedio de dichos parámetros de todos los modelos obtenidos para el entrenamiento de los árboles de regresión. Se ha diseñado mediante el método Lambda, puesto que presenta un retardo no dominante, imponiendo una constante de tiempo en bucle cerrado 0.8 veces la constante en bucle abierto. El modelo  $G(s)$  y el controlador obtenido  $C(s)$  son los mostrados en las ecuaciones (5) y (6) respectivamente.

$$G(s) = \frac{-0,16773}{524,2016s + 1} e^{-270s} \quad (5)$$

$$C(s) = -4,53 \left( \frac{524,2016s + 1}{524,2016s} \right) \quad (6)$$

En las Figuras 5 y 6 se puede observar que el pH estimado se acerca considerablemente bien a la dinámica del pH predicho por el simulador basado en red neuronal. En la Tabla 1 se puede observar el valor del RMSE obtenido para el pH estimado respecto al proporcionado por el simulador para el control PI de parámetros fijos implementado, así como los índices de comportamiento que se obtiene con dicho controlador (IAE, ISE, ITAE, ITSE y esfuerzo de control EC).

### 5. Control adaptativo en simulación

A continuación, se ha diseñado el mismo controlador que el comentado en la sección 4 pero cuyos parámetros  $K_p$  y  $T_i$  dependen en todo momento de los valores de  $K$  y  $\tau$  estimados por los árboles de regresión en función de los valores instantáneos de la radiación global y la temperatura y el nivel del medio.

Por lo tanto, el controlador es de la forma mostrada en la ecuación (7), donde  $K_p$  y  $T_i$  se calculan a partir de las expresiones (8) y (9) respectivamente.

Control	Fijo		Adaptativo		
	Día	1	2	1	2
<b>Comportamiento del controlador</b>					
IAE	18.40	11.18	17.34	14.05	
ISE	1.18	0.35	1.32	0.53	
ITAE	5364.6	3488	5054.8	4383.4	
ITSE	343.09	108.99	385.18	165.43	
EC	9.74	10.35	11.16	14.63	
<b>Comportamiento del estimador</b>					
RMSE	0.0208	0.018	0.0274	0.0226	

Tabla 1: Índices de comportamiento del control y del estimador de pH en simulación

$$C(s) = K_p \left( \frac{T_i s + 1}{T_i s} \right) \quad (7)$$

$$K_p = \frac{\tau}{K(\tau_{bc} + t_r)} \quad (8)$$

$$T_i = \tau \quad (9)$$

Además, se ha implementado transferencia sin saltos de modo que cuando se presente un cambio en los valores de  $K_p$  y  $T_i$  no se produzca un cambio brusco en la señal de control. La constante de *tracking* utilizada es  $T_t = \sqrt{T_i}$ . La constante de tiempo de bucle cerrado,  $\tau_{bc}$ , ha sido elegida como 0.8 veces la constante de tiempo de bucle abierto, de modo que se obtenga un control conservador. En las Figuras 7 y 8 se muestran los resultados de implementar dicho controlador en el simulador utilizado anteriormente, considerando las mismas condiciones ambientales que para los resultados del control fijo de las Figuras 5 y 6.

En la Tabla 1 se pueden observar los índices de desempeño obtenido tanto para la estimación como para el control de pH.

Se puede observar que el comportamiento de ambos controladores es similar, aunque el control PI de parámetros fijos presenta en general mejores índices, por lo que es un aspecto a analizar en detalle en futuros trabajos. Por otro lado, el comportamiento de estimador de pH es muy adecuado en todos los casos.

### 6. Conclusiones y trabajos futuros

Los resultados obtenidos durante el trabajo dejan de manifiesto el correcto funcionamiento del estimador de pH durante la inyección de CO<sub>2</sub> y de controlador PI de parámetros adaptativos. El controlador diseñado presenta la ventaja de que podría brindar un buen funcionamiento independientemente de las condiciones a las que se encuentre sometido el sistema, puesto que se adapta. Así,




Figura 5: Estimación de pH con control PI fijo - 1




Figura 6: Estimación de pH con control PI fijo - 2

el modelo no tendría que ser recalibrado para distintas épocas del año.

Por lo tanto, se puede concluir que la técnica utilizada para la estimación de los parámetros utilizando árboles de regresión funciona adecuadamente para este tipo de sistemas. Es necesario contar con una gran cantidad de datos para que todas las condiciones que se puedan presentar estén contempladas en los nodos de decisión de dicho árbol. Es por eso que, para un mejor comportamiento del controlador, sería conveniente realizar campañas de ensayo en las cuatro estaciones del año, para abarcar así todas las condiciones a las que se puede encontrar sometido el cultivo.

Por otro lado, se ha encontrado una limitación en lo que respecta al modelado de la respuesta libre, cuando el sistema no se encuentra sometido a inyecciones de CO<sub>2</sub>. A pesar del esfuerzo que se ha realizado en obtener un modelo que se ajuste a los datos y que sea capaz de realizar las estimaciones, no se ha llegado a resultados satisfactorios. Esto se debe, probablemente, a la simplicidad que presentaba la estructura de los modelos escogidos y a la falta de un mayor volumen de datos en el entrenamiento de los árboles.

Sin embargo, la respuesta libre representa el aumento de pH debido a la producción de la fotosíntesis en los intervalos donde el caudal de CO<sub>2</sub>




Figura 7: Implementación de control adaptativo en simulación - 1




Figura 8: Implementación de control adaptativo en simulación - 2

inyectado es nulo. Por lo tanto, el modelo que se busca obtener es únicamente con fines de modelado, pues no se puede utilizar para realizar un control. Es por eso que debería continuarse realizando el esfuerzo de obtener modelos para dicha dinámica, sin importar cuánto se tenga que aumentar la complejidad del mismo.

En base a las conclusiones, se pueden plantear como trabajos futuros la ampliación de datos para el entrenamiento de los árboles de regresión, en busca de la obtención de mejores índices de comportamiento. Además, sería conveniente conseguir un modelo para estimar la respuesta libre del sistema, en ausencia de inyección de CO<sub>2</sub>.

### Agradecimientos

Este trabajo ha sido financiado con el Proyecto del Plan Nacional PID2020-112709RB-C21 del Ministerio de Ciencia, Innovación y Universidades.

### English summary

### Modeling and adaptive control of pH in raceway reactors for microalgae production

## Abstract

*This work focuses on the development of regression tree models for pH prediction and control in raceway photobioreactors. Trees capable of estimating the model parameters from which the pH value can be predicted for clean water photobioreactors have been obtained. The models use data related to the conditions to which the culture is subjected, such as global radiation, media temperature and culture level. The results obtained validate the use of these techniques for modeling biological processes, providing accurate, simple and fast running models. These models are used to design a first attempt of an adaptive PI controller to control the pH in this type of reactors.*

**Keywords:** Microalgae, modeling, open reactors, adaptive control.

## Referencias

- [1] Barceló-Villalobos, M., Gómez Serrano, C., Sánchez Zurano, A., Alameda García, L., Esteve-Maldonado, S., Peña, J., Ación Fernández, F. G. (2019). "Variations of culture parameters in a pilot-scale thin-layer reactor and their influence on the performance of *scenedesmus almeriensis* culture". *Bioresource Technology Reports*, 6:190–197. <https://doi.org/10.1016/j.biteb.2019.03.007>.
- [2] Berenguel, M., Rodríguez, F., Ación, F.G., García, J.L. (2004). "Model predictive control of pH in tubular photobioreactors". *Journal of Process Control*, 14:377–387. <https://doi.org/10.1016/j.jprocont.2003.07.001>.
- [3] Fernández, I., Ación, F. G., Guzmán, J. L., Berenguel, M., Mendoza, J. L. (2016). "Dynamic model of an industrial raceway reactor for microalgae production". *Algal Research*, 17:67–78. <https://doi.org/10.1016/j.algal.2016.04.021>.
- [4] Fernández, I., Guzmán, J. L., Ación, F. G., and Berenguel, M. (2017). "Dynamic modeling of microalgal production in photobioreactors". *Prospects and Challenges in Algal Biotechnology*, chapter 7, page 49–87. Springer. [https://doi.org/10.1007/978-981-10-1950-0\\_2](https://doi.org/10.1007/978-981-10-1950-0_2).
- [5] Guzmán, J. L., Ación, F. G., Berenguel, M. (2021). "Modelling and control of microalgae production in industrial photobioreactors". *Revista Iberoamericana de Automática e Informática Industrial*, 18:1–18. <https://doi.org/10.4995/riai.2020.13604>.
- [6] Otálora, P., Guzmán, J. L., Berenguel, M., Ación, F.G. "Dynamic model for the pH in a raceway reactor using deep learning techniques". *Gonçalves J.A., Braz-César M., Coelho J.P. (eds) CONTROLLO 2020. Lecture Notes in Electrical Engineering, vol 695. Springer, Cham.* [https://doi.org/10.1007/978-3-030-58653-9\\_18](https://doi.org/10.1007/978-3-030-58653-9_18). 14th International Conference on Automatic Control and Soft Computing (CONTROLLO 2020). Bragança, Portugal, 2020.
- [7] Pawlowski, A., Guzmán, J. L., Berenguel, M., Ación, F.G. (2019). "Control system for pH in raceway photobioreactors based on Wiener models". *IFAC-PapersOnLine 52, 928–933, 12th IFAC Symposium on Dynamics and Control of Process Systems, including Biosystems DYCOPS.* <https://doi.org/10.1016/j.ifacol.2019.06.181>
- [8] Rodríguez-Miranda, E., Ación, F.G., Guzmán, J. L., Berenguel, M., Visioli, A. (2021). "A new model to analyze the temperature effect on the microalgae performance at large scale raceway reactors". *Biotechnology and Bioengineering*, 877-889, 118(2). <https://doi.org/doi.org/10.1002/bit.27617>



© 2022 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution CC-BY-NC-SA 4.0 license (<https://creativecommons.org/licenses/by-nc-sa/4.0/deed.es>).