

## Modelado y control del pH en la producción de microalgas en reactores *raceway* usando técnicas de adaptación de parámetros

Malena Caparroz<sup>a</sup>, Pablo Otálora<sup>a</sup>, José Luis Guzmán<sup>a,\*</sup>, Manuel Berenguel<sup>a</sup>, Francisco Gabriel Acién<sup>b</sup>

<sup>a</sup>Departamento de Informática, ceiA3, CIESOL, Universidad de Almería, Ctra. Sacramento s/n, La Cañada de San Urbano, Almería, España.

<sup>b</sup>Departamento de Ingeniería Química, ceiA3, CIESOL, Universidad de Almería, 04120, Almería, España.

**To cite this article:** Caparroz, M., Otálora, P., Guzmán, J.L., Berenguel, M., Acién, F.G., 2023. Modelado y control adaptativo del pH en reactores *raceway* para la producción de microalgas. Revista Iberoamericana de Automática e Informática Industrial 20, 379-388. <https://doi.org/10.4995/riai.2023.19103>

### Resumen

Este trabajo propone la obtención y el uso de modelos de árboles de regresión para la predicción de pH y su control en fotobiorreactores *raceway* de aguas limpias, teniendo en cuenta las distintas condiciones de operación a las que se encuentra sometido el cultivo. Dichas condiciones de operación vienen dictadas, entre otras variables medibles, por la radiación solar, la temperatura y nivel del medio en que crece el cultivo. El objetivo es evaluar la validez de esta aproximación, en la que se obtienen modelos sencillos y de ejecución rápida, en el modelado de procesos biológicos complejos como el tratado en este trabajo. Se ha validado su desempeño en simulación, usando como planta virtual un modelo no lineal basado en redes neuronales artificiales y un algoritmo de control PI del pH cuyos parámetros se adaptan en función del modelo escogido en el árbol de regresión.

**Palabras clave:** Microalgas, modelado, reactores abiertos, control con adaptación de parámetros.

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

#### Abstract

This work proposes the obtaining and use of regression tree models for the prediction of pH and its control in clean water *raceway* photobioreactors, taking into account the different operating conditions to which the culture is subjected. These operating conditions are dictated, among other measurable variables, by solar radiation, the temperature and level of the medium in which the culture grows. The aim is to evaluate the validity of this approach, which produces simple and fast-running models, in the modelling of complex biological processes such as the one discussed in this paper. Its performance has been validated in simulation, using a non-linear model based on artificial neural networks as a virtual plant and a pH PI control algorithm whose parameters are adapted according to the model chosen in the regression tree.

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

### 1. Introducción

Durante los últimos años se están desarrollando líneas de investigación que faciliten la implantación industrial de sistemas de producción de microalgas, que son microorganismos fotosintéticos que pueden crecer y reproducirse en entornos diversos. Constituyen una vía para combatir el calentamiento global del planeta, pues a través de la captura de radiación solar, pueden convertir fuentes carbónicas como el CO<sub>2</sub> en biomasa y

producir grandes cantidades de oxígeno (Guzmán et al., 2021).

Para que estos microorganismos puedan crecer, se requiere un aporte de nutrientes tales como nitrógeno, fósforo y carbono. El carbono se aporta a través de la inyección de CO<sub>2</sub>, permitiendo además regular el pH del sistema (Hoyo Sánchez et al., 2022). El resto de nutrientes se suele aportar de forma directa al medio acuoso, o ser absorbidos del propio medio en el caso en que se utilicen las microalgas para el tratamiento

\*Autor para correspondencia: joguzman@ual.es (Guzmán, J.L.);

de aguas residuales. Las microalgas también pueden utilizarse en la elaboración de productos de alto valor en alimentación animal, cosmética e incluso nutrición humana (Guzmán et al., 2021).

Un aspecto clave para el desarrollo industrial de esta biotecnología es el fotobiorreactor en el que crecen las microalgas, cuyo diseño impacta en la forma de operación y la complejidad de su control automático. En aplicaciones de alto valor se suelen utilizar fotobiorreactores cerrados, que evitan que el cultivo esté expuesto al ambiente que lo rodea y por tanto su posible contaminación. Los más utilizados de esta clase son los 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 (Guzmán et al., 2021).

La tasa de crecimiento de las microalgas la determina principalmente la disponibilidad de luz. No todas las microalgas reciben los mismos niveles de radiación, aunque por diseño de los reactores se establecen estrategias para que los niveles medios de radiación recibida por todas las microalgas sean similares. Por ejemplo, se suelen incorporar elementos mecánicos que produzcan flujos rotatorios. En general, se considera que la disponibilidad de luz depende en gran medida del nivel del medio (a mayor nivel menor radiación llegará en las capas bajas) y de la concentración del cultivo (a mayor concentración, menor penetración de los rayos solares). Además, se utilizan tres factores de ponderación de este término, normalizados entre 0 y 1, para incluir la influencia del pH, el oxígeno disuelto y la temperatura en la tasa de crecimiento (Barceló-Villalobos et al., 2019).

La forma en que afectan el pH y la temperatura es similar, presentando un valor óptimo que proporciona una tasa de crecimiento máxima, pero a medida que tanto el pH como la temperatura se alejan de esos valores óptimos, la tasa de crecimiento disminuye de forma drástica. En el caso del oxígeno disuelto, existe un valor a partir del cual la tasa de crecimiento disminuye. De todos estos factores el más crítico es el pH, que a su vez es el más complicado de controlar, debido a que la fotosíntesis produce variaciones continuas en esta variable (Pawloski et al., 2019). Además, se da la circunstancia de que el pH se suele regular en este tipo de plantas con controladores todo/nada, sin tener en cuenta la dinámica del proceso (afectada por la inyección de CO<sub>2</sub> y por diversas perturbaciones) ni el impacto que pueda tener en la producción. Esto es debido en parte a que en este tipo de sistemas biológicos es muy complicado obtener modelos sencillos que permitan caracterizar su dinámica, mientras que los modelos complejos desarrollados dificultan la sintonización de algoritmos de control (Barceló-Villalobos et al., 2019; Pawloski et al., 2019).

En la literatura se han publicado diversos modelos cuya complejidad varía en función al uso que se les vaya a dar (Bereguet et al., 2004; Fernández et al., 2016, 2017; Rodríguez-Miranda et al., 2021). Recientemente también se están desarrollando modelos basados en datos (debido precisamente a la dificultad y los conocimientos necesarios para la obtención de modelos basados en primeros principios), entre los que destacan las redes neuronales artificiales (Otálora et al., 2021, 2022).

Se trata de lograr una solución de compromiso entre la complejidad del modelo de pH y la dificultad para desarrollar algoritmos de control basados en dichos modelos. Los modelos basados en primeros principios reflejan el comportamiento espacio-temporal de una forma más completa, pero requieren algoritmos de control sofisticados y difícilmente entendibles por el personal de operación o simplificaciones a la hora de llevar a cabo una estrategia de control. Por otro lado, modelos simples como los que se usan tradicionalmente en control de procesos permiten de forma natural la implementación de algoritmos de control, pero incluyen una alta incertidumbre de modelado que se manifiesta cuando se somete al sistema a condiciones ambientales distintas a las utilizadas para la obtención del modelo y por tanto en el diseño del controlador. Este tipo de modelos sencillos requiere una calibración frecuente para ajustarse a la gran variedad de condiciones ambientales en las que se operan los fotobiorreactores abiertos, que tienen una influencia determinante en la dinámica del sistema.

Las razones expuestas en los párrafos anteriores justifican la aproximación planteada en este trabajo, en el que se han desarrollado modelos de árboles de regresión que permiten escoger los parámetros de modelos simples que mejor se adecúan a las condiciones a las que está sometida la planta. El trabajo incluye la etapa de modelado y también ejemplos de uso de dichos modelos en la implementación de un esquema de control en el que se modifican los parámetros del controlador en función del modelo seleccionado. Se ha seguido aquí la denominación propuesta por K. J. Åström y T. Hägglund en su conocido libro sobre control PID (Åström and Hägglund, 2006), en el que se usa la denominación de "técnicas de adaptación o adaptativas" para referirse a la auto-sintonía de controladores, la programación de ganancias (*gain scheduling*) y la adaptación (por ejemplo controladores auto-ajustables). La estrategia desarrollada en este trabajo tiene elementos comunes con *gain scheduling*, en el sentido que utiliza variables medibles que se correlacionan bien con los cambios en la dinámica del proceso para estimar todos los parámetros del modelo (no únicamente la ganancia), si bien mejora uno de los principales inconvenientes de la técnica como es el esfuerzo necesario para aplicarla, puesto que el uso de árboles de regresión e identificación por mínimos cuadrados facilita el ajuste de los modelos.

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 (Otálora et al., 2021).

Una versión preliminar de este trabajo se presentó en las XLIII Jornadas de Automática (Caparroz et al., 2022), obteniendo la distinción al mejor trabajo en el grupo temático de Ingeniería de Control.

## 2. Descripción del proceso

Para el desarrollo de este trabajo se ha tomado como planta de referencia el fotobiorreactor *Raceway* ubicado en el centro IFAPA de la Junta de Andalucía anexo a la UAL (Figura 1). Se dispone de dos fotobiorreactores, uno utiliza agua limpia y un aporte externo de nutrientes y el otro usa aguas residuales provenientes de la UAL. En este trabajo se usa 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°. Cada reactor cuenta con una superficie total de 80 m<sup>2</sup>, proporcionando una relación entre el volumen y el nivel del medio de 800 L/cm. La profundidad es de 30 cm, si bien la altura de cultivo óptima se encuentra alrededor de los 15 cm (González Hernández et al., 2022), usándose el control de nivel para regular la temperatura.



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

Para impulsar el medio y facilitar la mezcla se usa una rueda de diámetro 1.2 m con 8 palas de aluminio. Esta rueda se acciona usando un grupo motorreductor con variador de frecuencia, si bien se suele operar a una velocidad constante de 0.2 m/s.

La instalación cuenta con un foso de forma cilíndrica (con un diámetro de 65 cm y 1 m de profundidad) ubicado detrás de las palas (a 1.8 metros de distancia) en el que se realiza la inyección de aire y CO<sub>2</sub> a través de tres discos difusores.

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 esta planta. En la Figura 2 se puede observar un esquema de la instalación descrita anteriormente.

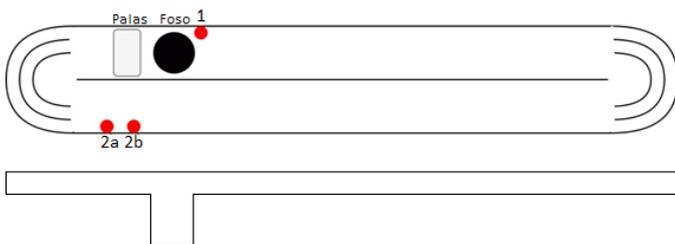


Figura 2: Esquema del fotobiorreactor utilizado

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. Ha demostrado también ser una excelente cepa para el tratamiento de aguas residuales por su alta resistencia a los contaminantes. 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 (Barceló-Villalobos et al., 2019).

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> (Berenguel et al., 2004). Las siguientes ecuaciones muestran un modelo simple lineal en forma de funciones de transferencia que captura la dinámica principal del pH:

$$\begin{aligned}
 pH(s) &= TF_1(s)TF_2(s)CO_2(s) + TF_3(s)I_{sat}(s) \\
 &= \frac{K_1}{(\tau s + 1)} \frac{K_2 w_n^2}{(s^2 + 2\delta w_n s + w_n^2)} e^{-\tau_r s} CO_2(s) \quad (1) \\
 &+ \frac{K_r}{(\tau_r s + 1)} I_{sat}(s)
 \end{aligned}$$

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 modificado y saturado de radiación global que explica la radiación que realmente utilizan las microalgas para hacer la fotosíntesis (hay que hacer notar que también se podría haber utilizado un sensor de radiación PAR) (Berenguel et al., 2004).

En la ecuación (1) se puede observar que la dinámica del pH con respecto al CO<sub>2</sub> se puede modelar de forma muy simplificada por un término de primer orden con retardo ( $TF_1(s) = \frac{K_1 e^{-\tau_r s}}{1 + \tau s}$ ) que marca la dinámica dominante del proceso, junto a una función de transferencia de segundo orden ( $TF_2(s)$ ) que modela 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 frecuencia natural amortiguada está relacionada con la velocidad de circulación del fluido). La función  $TF_3(s)$  representa el efecto sobrearmortiguado de la radiación solar sobre el pH como un efecto de la fotosíntesis. Los parámetros de las funciones toman valores particulares dependiendo del tipo de reactor, de la cepa y de las condiciones meteorológicas (Guzmán et al., 2021).

Este modelo presenta la ventaja de facilitar el diseño de los algoritmos de control. Sin embargo, la sencillez del mismo hace que sea incapaz de adaptarse a la enorme variedad de condiciones a las que puede verse sometido el sistema, las cuales tienen una gran influencia sobre su dinámica, sobre todo en reactores industriales de gran dimensión. Esto implica que los modelos deban ser constantemente recalibrados. A pesar de que estos modelos han sido ampliamente utilizados, en el presente problema se pretende obtener un modelo sencillo que sea automáticamente recalibrado gracias al uso de árboles de regresión que estimen los parámetros según las condiciones presentes en cada instante.

### 3. Modelos desarrollados

Para la obtención de modelos de árboles de regresión se han realizado ensayos en el sistema real descrito con un algoritmo

de control todo/nada con una banda de histéresis de  $\pm 0,5$ , siendo la referencia un pH de 8. Así, cuando el pH llega a 8.5 comienza la inyección de  $CO_2$ , que provoca su descenso. Cuando el pH alcanza un valor de 7.5 cesa la inyección del gas y, pasado el tiempo de retardo característico del sistema, la fotosíntesis realizada por las microalgas provoca un aumento del pH. Estos ensayos se han realizado durante aproximadamente tres meses, distribuidos a lo largo de distintas épocas del año, obteniendo datos para condiciones ambientales muy diversas. Así, el comportamiento del sistema con dicho algoritmo de control, para un único día, es el mostrado en la Figura 3.

Al observar el comportamiento del sistema con el algoritmo de control implementado, se ha decidido separar la dinámica del sistema en dos modelos. Como se observa en la Figura 4, al realizarse inyección de  $CO_2$ , una vez que transcurre el tiempo de retardo del sistema, el pH disminuye. Esta parte de la respuesta será la llamada “respuesta forzada” del sistema, dado que el caudal de  $CO_2$  será la señal de control utilizada para controlar el pH. Por otro lado, al cesar la inyección, pasado el tiempo de retardo el pH vuelve a aumentar. Esta, dado que se debe a la fotosíntesis que realizan los microorganismos en ausencia de inyección de  $CO_2$ , será la “respuesta libre”.

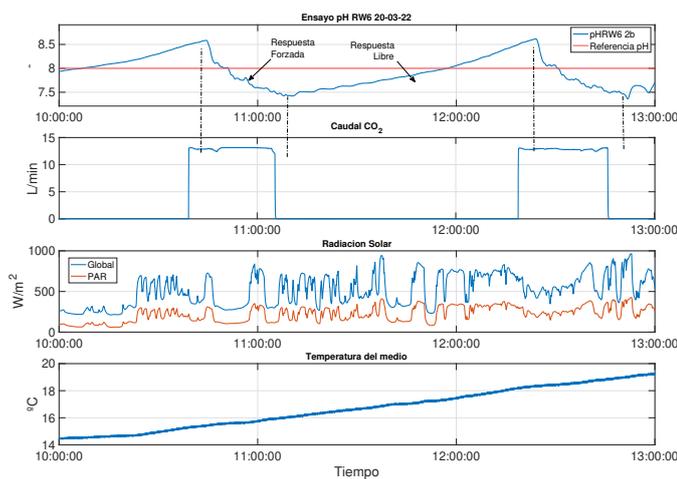


Figura 4: Ensayo con control todo/nada con histéresis

Por lo tanto, una vez realizada una campaña extensa de los ensayos descritos anteriormente, se han obtenido modelos distintos para cada tipo de respuesta.

3.1. Modelos de respuesta forzada

La respuesta forzada se ha modelado utilizando una función de transferencia de primer orden con retardo. El retardo es el mismo en todos los casos, puesto que es un parámetro que depende de las características físicas del sistema y en concreto del tiempo de residencia del cultivo entre el foso y el sensor de medida. Como la velocidad del fluido viene determinada por la velocidad de las palas, que es constante, el retardo será fijo. 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: radiación, temperatura y nivel. Por lo tanto, la forma de los modelos obtenidos es la mostrada en la ecuación (2).

$$pH(s) = \frac{K}{\tau s + 1} e^{-t_r s} CO_2(s) \tag{2}$$

donde  $K$  (ganancia estática) y  $\tau$  (constante de tiempo en segundos) son función de los parámetros ambientales anteriormente mencionados,  $t_r$  es el tiempo de 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  $CO_2$  inyectado en el foso, en L/min.

Así, se ha obtenido una gran cantidad de estos modelos y se ha almacenado, para los 207 modelos calculados, el valor de la radiación global media, la temperatura media del medio y el nivel medio en cada uno. 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 5 y 6).

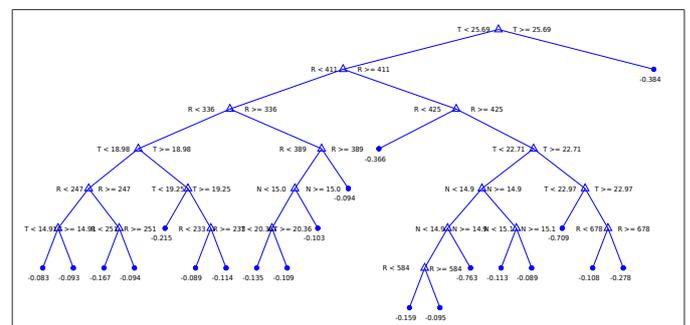


Figura 5: Árbol de regresión para la estimación de la ganancia estática  $K$

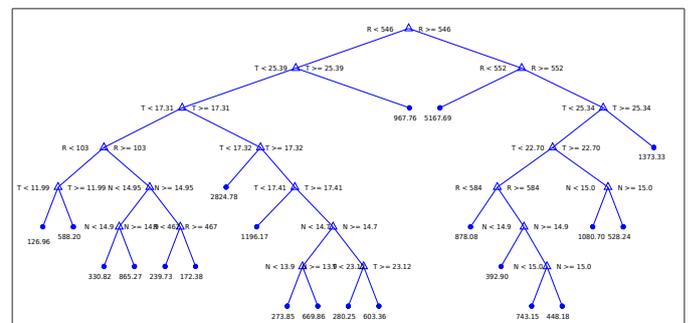


Figura 6: Árbol de regresión para la estimación de la constante de tiempo  $\tau$

En la Figura 7 se puede observar la importancia de cada predictor (radiación global, temperatura del medio y nivel del cultivo) en la estimación de los parámetros del modelo de la respuesta forzada,  $\tau$  (Figura izquierda) y  $K$  (Figura derecha). En el eje de las abscisas se encuentran los predictores utilizados, cuya importancia se puede deducir del valor que toma cada uno en el eje de las ordenadas, siendo más importante cuando toma valores mayores. Se puede observar que la velocidad de respuesta del sistema depende en mayor medida de la radiación y la temperatura del medio, mientras que el nivel del cultivo presenta menor importancia. Por otro lado, la variación de pH, representada por la ganancia estática del sistema  $K$ , se ve más influenciada por la temperatura del medio y el nivel del cultivo, siendo la radiación global el predictor de menor importancia.

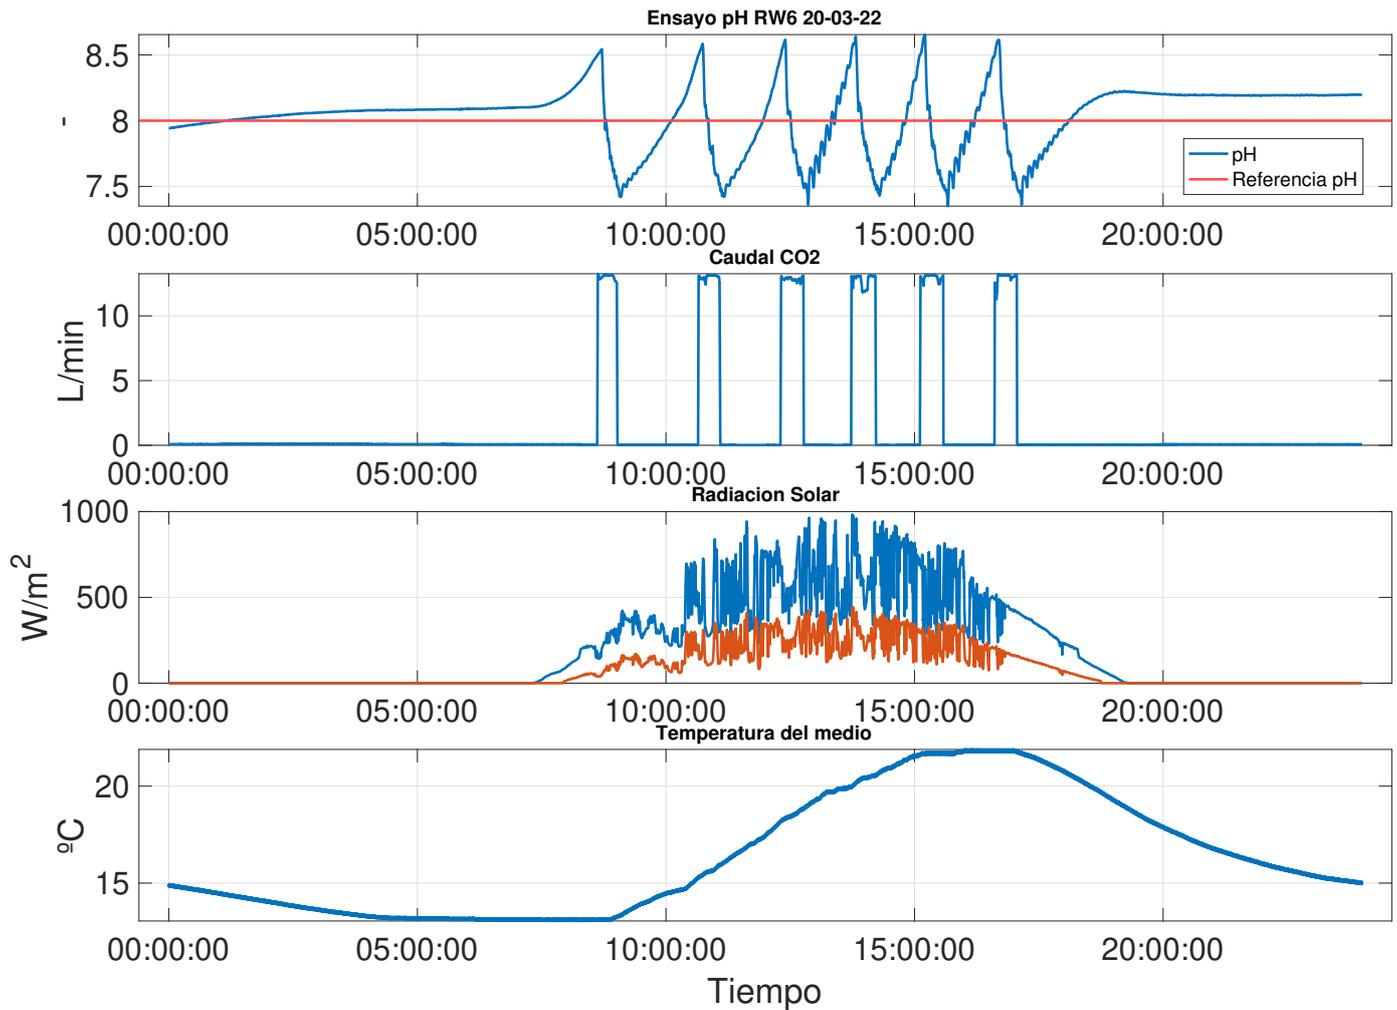


Figura 3: Ensayo con control todo/nada con histéresis

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, tal como se comprobará en la sección 3.3.

### 3.2. Modelos de respuesta libre

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. La decisión de usar en este caso espacio de estados es debida al carácter dinámico de la respuesta libre, que viene dado por un sistema autónomo sin señal de entrada. Así, el modelo tendría la forma mostrada en la ecuación (3).

$$pH(k) = \theta_1 pH(k - 1) + \theta_2 \quad (3)$$

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 ( $k - 1$ ).

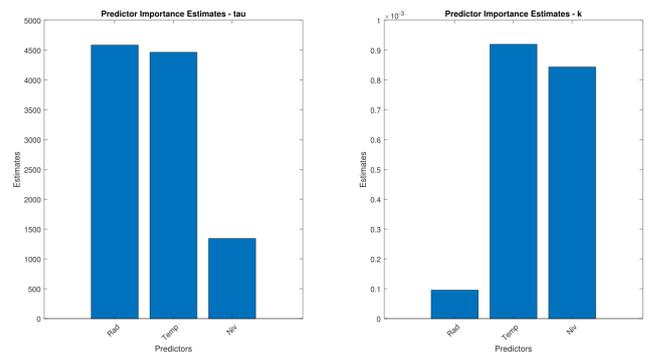


Figura 7: Importancia de cada predictor en la estimación de los parámetros de la respuesta forzada.

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 difiere considerablemente de la del pH real, tal como se verá en la sección 3.3. 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. Los resultados arrojados al estimar la respuesta libre dejan abierta una línea de trabajo futura en la que se tratará de mejorar el término de respuesta libre del sistema.

### 3.3. Validación de los árboles de regresión

Una vez entrenados los árboles, se debe realizar una validación de los resultados obtenidos mediante los mismos. En la Figura 9 se muestran los resultados de la implementación de un estimador de pH. En dicho desarrollo, cada árbol de regresión recibe como entrada el valor instantáneo de radiación global, temperatura y nivel del medio y estima, según corresponda, los parámetros de la respuesta libre o forzada del sistema. La estimación de los parámetros de la respuesta forzada se realiza en el instante en el que comienza la inyección, mientras que los parámetros de la respuesta libre son estimados en cada instante de muestreo.

En la Figura 10 se puede observar la actualización de los parámetros de cada uno de los modelos, gracias a los árboles de regresión entrenados. Se puede comprobar que en cada intervalo de respuesta forzada se realiza una única estimación de la ganancia y la constante de tiempo, una vez transcurrido el tiempo de retardo a partir del instante en que comienza la inyección de CO<sub>2</sub>. Por otro lado, la estimación de los parámetros de la respuesta libre se realiza en cada muestreo, comenzando una vez transcurrido el tiempo de retardo luego de cesar la inyección del gas.

A pesar de que hay intervalos de respuesta libre que se estiman correctamente, se puede observar en la Figura 9 que en algunos tramos la estimación de pH difiere mucho de la respuesta real del sistema. Por otro lado, se observa una buena estimación de pH en la totalidad de intervalos correspondientes a la respuesta forzada del sistema, habiendo muy poco error entre el pH estimado y el pH real.

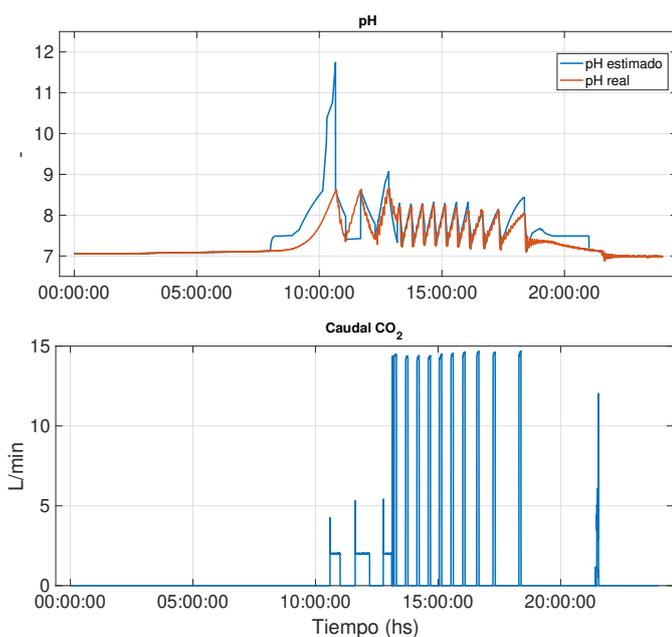


Figura 9: Resultados de validación de los árboles de regresión.

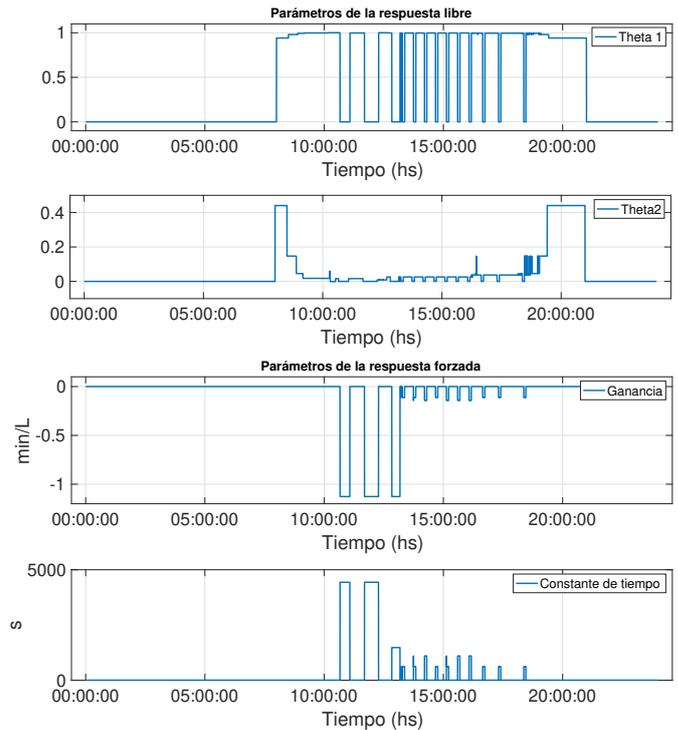


Figura 10: Parámetros de los modelos de la validación de los árboles de regresión.

## 4. Control con técnicas adaptativas y control con parámetros fijos en simulación

Una vez validados los resultados arrojados por los árboles de regresión, se han implementado dos algoritmos de control en un simulador que utiliza como planta virtual un modelo de red neuronal (Otálora et al., 2021). Por un lado, se ha desarrollado un control PI 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, la temperatura y el nivel del medio. Por otro lado, se ha implementado también un control PI de parámetros fijos cuyos parámetros han sido calculados a partir de la media de los parámetros de todos los modelos obtenidos. Este último controlador se ha implementado con el fin de comparar los resultados obtenidos con ambos algoritmos. Se trata de dos controladores PI sintonizados mediante método  $\lambda$  Åström and Hägglund (2006), puesto que el sistema presenta retardo no dominante.

Por lo tanto, los controladores son de la forma mostrada en la ecuación (4), donde  $K_p$  y  $T_i$  se calculan a partir de las expresiones (5) y (6) respectivamente.

$$C(s) = K_p \left( \frac{T_i s + 1}{T_i s} \right) \quad (4)$$

$$K_p = \frac{\tau}{K(\tau_{bc} + t_r)} \quad (5)$$

$$T_i = \tau \quad (6)$$

La constante de tiempo de bucle cerrado,  $\tau_{bc}$ , ha sido calculada como 0.8 veces la constante de tiempo de bucle abierto, de modo que se obtenga un control conservador. Además, para el caso del control con ajuste de parámetros se ha implementado transferencia sin saltos de modo que cuando se presente

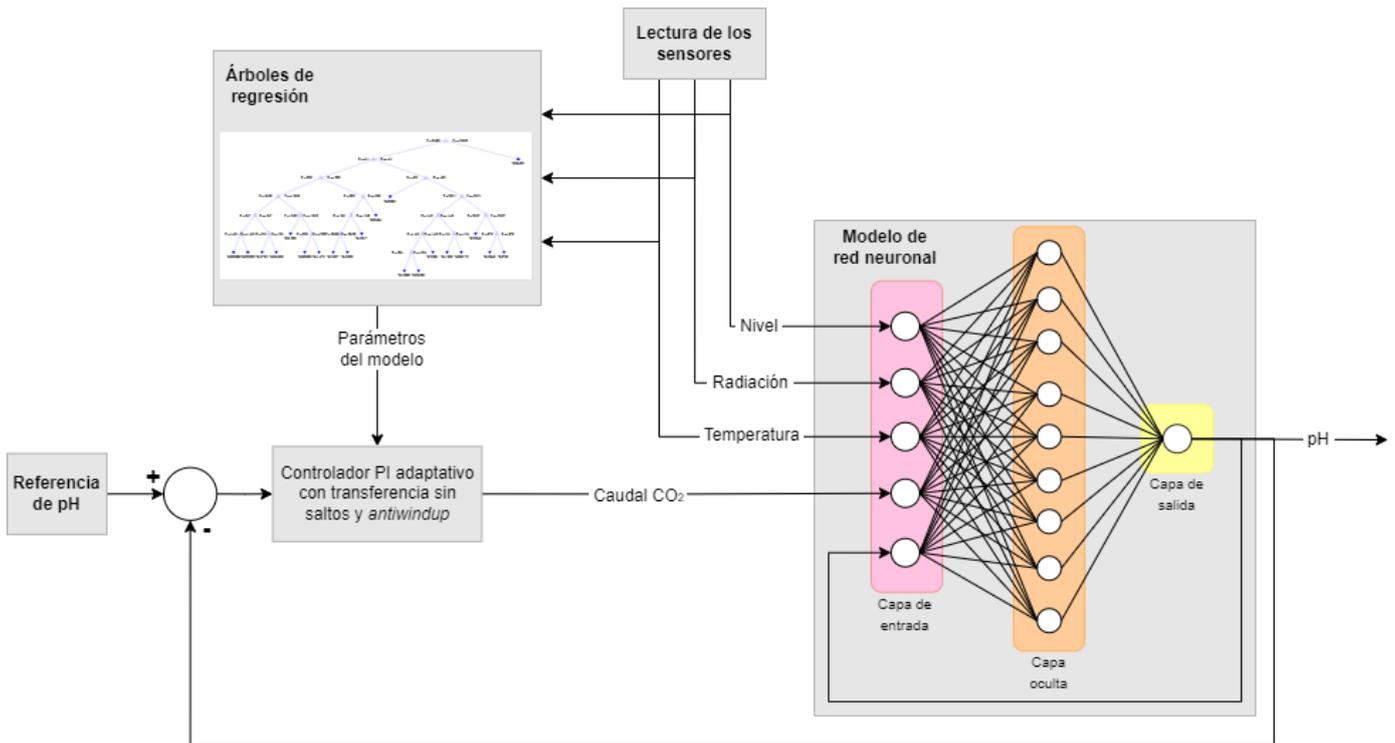


Figura 8: Esquema de control en las simulaciones incluidas en este trabajo.

un cambio en los valores de  $K_p$  y  $T_i$  no se produzca un cambio brusco en la señal de control. Por último, ambos controladores presentan estructura *antiwindup*, puesto que el controlador presenta acción integral. La constante de *tracking* utilizada es  $T_t = \sqrt{T_i}$ .

Por lo tanto, el esquema de control utilizado para la implementación del controlador es el que se observa en la Figura 8.

En las Figuras 11, 12 y 13 se muestran los resultados obtenidos al implementar ambos controladores en tres días con distintas condiciones ambientales, junto con el valor de los parámetros de ambos controladores instante a instante. Se puede observar que los perfiles de radiación difieren de un día a otro y, por lo tanto, también difieren los parámetros del modelo. En la Figura 11 se observa un perfil con nubes en las primeras horas del día, pero estas cesan a partir de las 13 h, aproximadamente. En la Figura 12 se observa una ligera cantidad de nubes distribuida a lo largo de todas las horas de sol, mientras que en la Figura 13 se observa un día particularmente nublado, obteniendo radiaciones menores la mayoría de las horas del día. Esta variedad de condiciones permite comprobar la validez del controlador diseñado para distintas condiciones ambientales. Hay que hacer notar que el controlador sólo funciona cuando hay radiación solar, por ese motivo se observa en las gráficas que los parámetros del controlador van a cero al finalizar la operación a la vez que se desactiva el controlador PI.

Se puede verificar que ambos controladores son capaces de mantener el pH en torno al valor de la referencia y los resultados arrojados por los mismos son visualmente similares.

En la Tabla 1 se pueden observar los índices de desempeño obtenidos, en tanto por uno, para cada tipo de control. Estos han sido calculados considerando únicamente el intervalo en que el lazo de control se encuentra en acción, desde que el pH

supera la referencia hasta que se apaga el control a las 20 h. Se puede observar que el control PI de parámetros adaptativos desarrollado en este trabajo presenta, en general, índices mejores. Se ha conseguido que la integral absoluta del error (IAE) y la integral absoluta del error por el tiempo (ITAE) mejoren aproximadamente un 15 % respecto a los obtenidos con el control fijo. Por otro lado, la integral del error cuadrático (ISE) y la integral del error cuadrático por el tiempo (ITSE) pueden mejorar hasta un 22 % al usar el algoritmo de control con adaptación de parámetros diseñado en este trabajo. Por último, se observa que el esfuerzo de control obtenido con el algoritmo de control con adaptación de parámetros aumenta un 14.7 % respecto al control fijo, como por otra parte cabe esperar. Este último parámetro se calcula realizando la integral de la señal de control mediante el método trapezoidal.

| Control    | Índices de desempeño |      |       |      |       |
|------------|----------------------|------|-------|------|-------|
|            | IAE                  | ISE  | ITAE  | ITSE | EC    |
| Fijo       | 1                    | 1    | 1     | 1    | 1     |
| Adaptativo | 0.856                | 0.78 | 0.855 | 0.78 | 1.147 |

Tabla 1: Índices de comportamiento del control fijo y con adaptación de parámetros

### 5. Conclusiones y trabajos futuros

El objetivo fundamental de este trabajo, que es evaluar la idoneidad del uso de modelos de árboles de regresión para conseguir la adaptación de los parámetros de modelos simples a las condiciones ambientales, ha sido cumplido, como se pone de manifiesto en los resultados incluidos. Además, cuando estos modelos se combinan con controladores PI, se pueden adaptar

los parámetros del controlador al modelo actual proporcionado por los árboles de regresión. Los resultados obtenidos muestran el correcto funcionamiento del estimador de pH durante la inyección de  $\text{CO}_2$  y del controlador PI con adaptación de parámetros, que evita la necesidad de recalibración del modelo en función de las condiciones de operación.

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. El inconveniente de la técnica propuesta es que es necesario disponer de una gran cantidad de datos para que todas las condiciones que se puedan presentar estén contempladas en los nodos de decisión de dicho árbol. El trabajo presentado se puede mejorar a medida que se realicen más ensayos en las cuatro estaciones del año, siguiendo la metodología planteada.

Por otro lado, se tiene que investigar más en el modelado de la respuesta libre (parte de la respuesta en la que no hay inyección de  $\text{CO}_2$ ), pues no se han llegado a resultados satisfactorios a pesar de haber propuesto un modelo muy sencillo pero que es acorde con la respuesta observada. Previsiblemente el motivo sea precisamente la simplicidad que presenta la estructura de los modelos escogidos y a la falta de un mayor volumen de

datos en el entrenamiento de los árboles. En cualquier caso, el modelo de respuesta libre tiene utilidad para fines de modelado, no de control.

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, queda abierta una línea de trabajo futura cuyo objetivo será conseguir un modelo para estimar la respuesta libre del sistema, en ausencia de inyección de  $\text{CO}_2$  y la búsqueda e implantación de sensores de concentración de biomasa que proporcionen medidas que ayuden a explicar la dinámica del sistema, si bien no se dispone hasta el momento de sensores en línea fiables.

### Agradecimientos

Este trabajo ha sido financiado con el proyecto del Plan Nacional PID2020-112709RB-C21 del Ministerio de Ciencia, Innovación y Universidades, y por el proyecto REALM 101060991 de la Unión Europea.

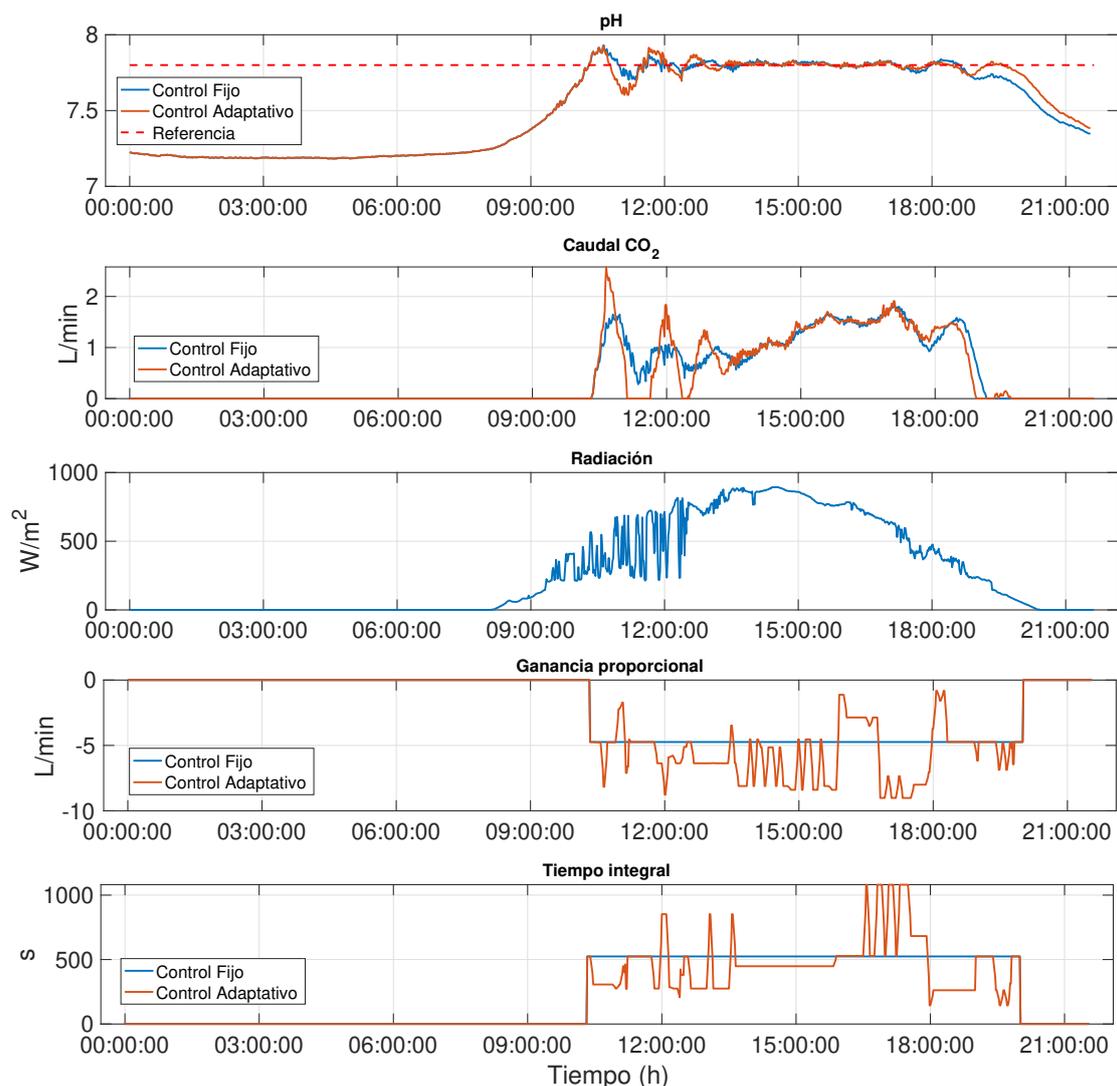


Figura 11: Resultados de control con parámetros fijos y control con adaptación de parámetros - 1

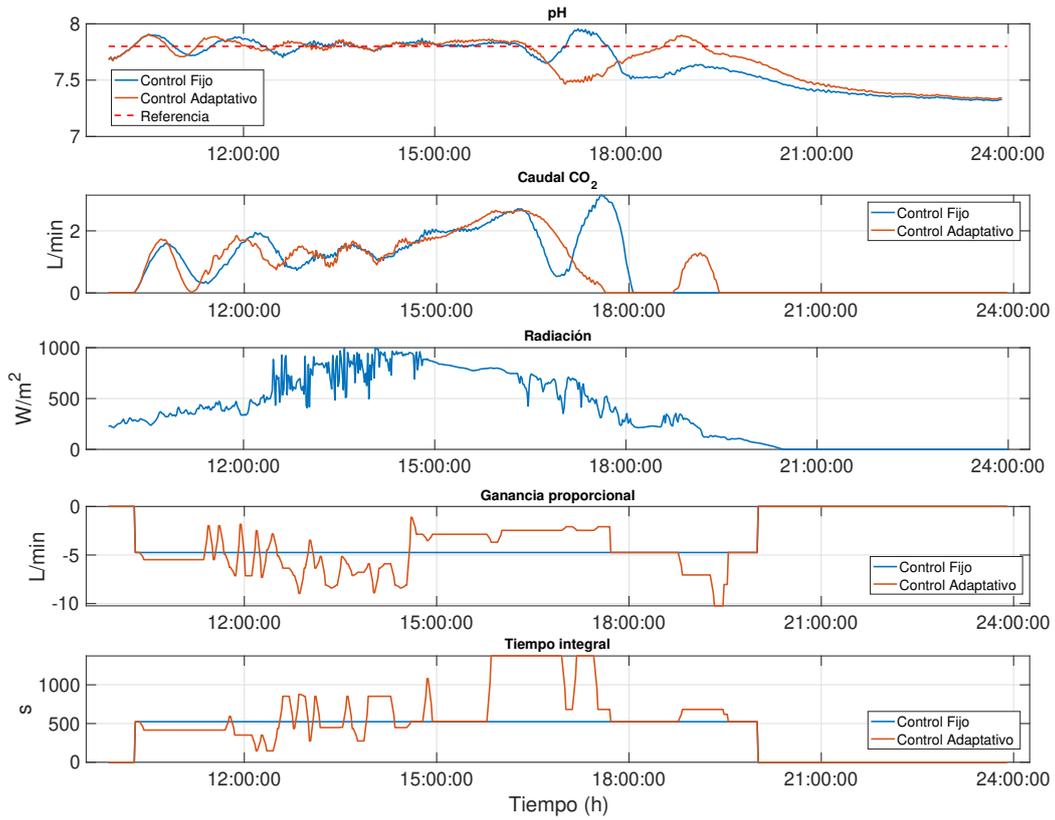


Figura 12: Resultados de control con parámetros fijos y control con adaptación de parámetros - 2

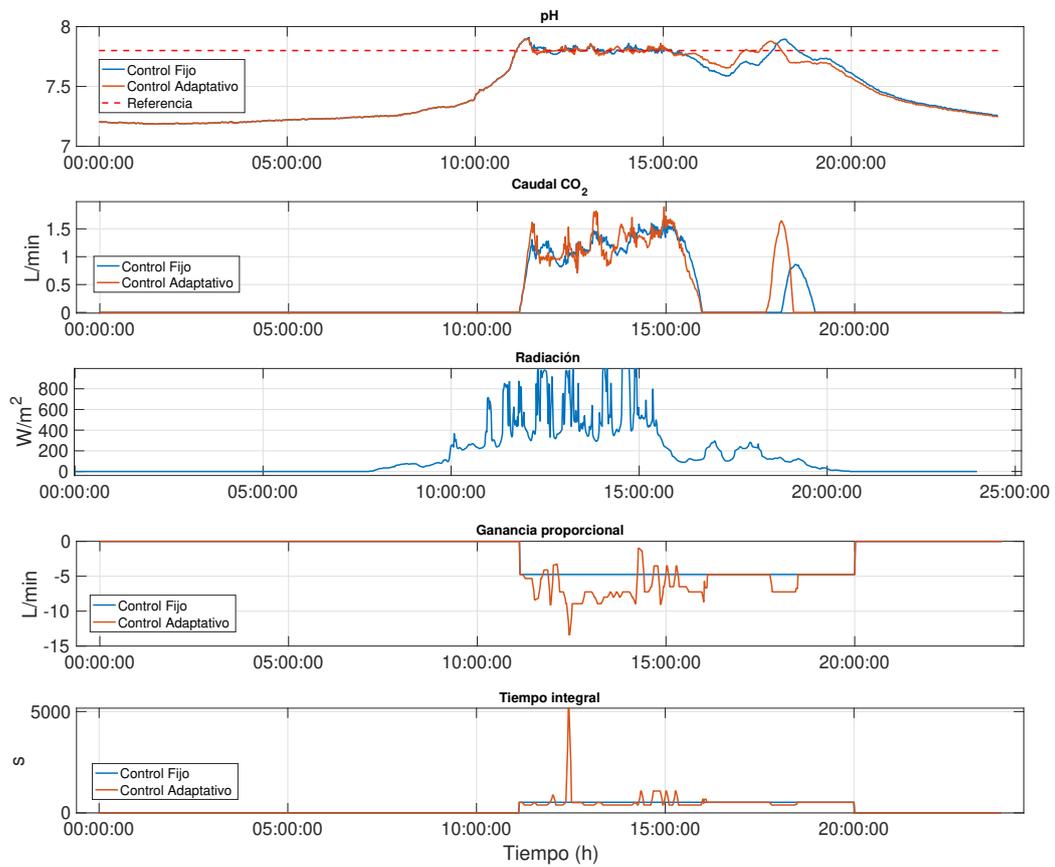


Figura 13: Resultados de control con parámetros fijos y control con adaptación de parámetros - 3

## Referencias

- Åström, K. J., Hägglund, T., 2006. Advanced PID control. ISA - The Instrumentation, Systems and Automation Society.
- 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>.
- Berenguel, M., Rodríguez, F., Ación, F. G., García, J., 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>.
- Caparroz, M., Otálora, P., Guzmán, J. L., Berenguel, M., 09 2022. Modelado y control adaptativo del pH en reactores raceway para la producción de microalgas. In: Libro de Actas de las XLIII Jornadas de Automática. Servicio de Publicaciones. Universidade da Coruña, A Coruña; Comité Español de Automática, Barcelona; Universidad de La Rioja, Logroño, pp. 333–340, <https://doi.org/10.17979/spudc.9788497498418.0333>.
- 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>.
- Fernández, I., Guzmán, J. L., Ación, F. G., Berenguel, M., 2017. Dynamic modeling of microalgal production in photobioreactors. In: Prospects and Challenges in Algal Biotechnology. Springer, Ch. 7, p. 49–87, [https://doi.org/10.1007/978-981-10-1950-0\\_2](https://doi.org/10.1007/978-981-10-1950-0_2).
- González Hernández, J., Rodríguez Miranda, E., Guzmán Sánchez, J. L., Ación Fernández, F. G., Visioli, A., 2022. Optimización de temperatura en reactores raceway para la producción de microalgas mediante regulación de nivel. *Revista Iberoamericana de Automática e Informática Industrial* 19(2), 164–173, <https://doi.org/10.4995/riai.2022.16586>.
- Guzmán, J. L., Ación, F. G., Berenguel, M., 2021. Modelado y control de la producción de microalgas en fotobiorreactores industriales. *Revista Iberoamericana de Automática e Informática Industrial* 18, 1–18, <https://doi.org/10.4995/riai.2020.13604>.
- Hoyo Sánchez, A., Guzmán Sánchez, J. L., Moreno Úbeda, J. C., Baños Torrico, A., 2022. Control robusto del pH en un fotobiorreactor raceway. *Revista Iberoamericana de Automática e Informática Industrial* 19(3), 274–283, <https://doi.org/10.4995/riai.2022.16731>.
- Otálora, P., Guzmán, J. L., Berenguel, M., Ación, F., 09 2021. Dynamic model for the pH in a raceway reactor using deep learning techniques. In: Gonçalves, J. A., Braz-César, M., Coelho, J. P. (Eds.), *CONTROL 2020*. Springer International Publishing, Cham, pp. 190–199, [https://doi.org/10.1007/978-3-030-58653-9\\_18](https://doi.org/10.1007/978-3-030-58653-9_18).
- Otálora, P., Guzmán, J. L., Gil, J. D., Berenguel, M., Ación, F., 09 2022. Modelado dinámico del pH en reactores raceway con redes neuronales. In: Libro de Actas de las XLIII Jornadas de Automática. Servicio de Publicaciones. Universidade da Coruña, A Coruña; Comité Español de Automática, Barcelona; Universidad de La Rioja, Logroño, pp. 575–582, <https://doi.org/10.17979/spudc.9788497498418.00575>.
- Pawloski, A., Guzmán, J. L., Berenguel, M., Ación, F. G., 2019. Control system for pH in raceway photobioreactors based on Wiener models. *12th IFAC Symposium on Dynamics and Control of Process Systems, including Biosystems DYCOPS* 52, 928–933, <https://doi.org/10.1016/j.ifacol.2019.06.181>.
- 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* 118(2), 877–889, <https://doi.org/10.1002/bit.27617>.