

# MODELADO DINÁMICO DEL PH EN REACTORES RACEWAY CON REDES NEURONALES

Pablo Otálora<sup>1</sup>, José Luis Guzmán<sup>1</sup>, Juan D. Gil<sup>1</sup>, Manuel Berenguel<sup>1</sup>, Francisco Gabriel Acién<sup>2</sup>

<sup>1</sup>Departamento de Informática, Universidad de Almería, ceiA3, CIESOL, Ctra. Sacramento s/n, 04120 Almería, España. Tel: +34 950 214133; {p.otalora, joseluis.guzman, juandiego.gil, beren}@ual.es

<sup>2</sup>Departamento de Ingeniería Química, Universidad de Almería; facien@ual.es

## Resumen

*Este trabajo se centra en el desarrollo de modelos de red neuronal para predicción de pH en fotobiorreactores raceway. Se han obtenido modelos capaces de predecir el valor del pH con un tiempo de muestreo de un minuto y un horizonte de predicción de hasta un día, para fotobiorreactores de aguas residuales o limpias. Los modelos emplean datos relativos a las condiciones climáticas y la operación del reactor. Los resultados obtenidos validan el uso de estas técnicas para el modelado de procesos biológicos, proporcionando modelos precisos, sencillos y de rápida ejecución.*

**Palabras clave:** Redes neuronales, microalgas, modelado, biotecnología.

## 1. Introducción

La producción industrial de microalgas resulta un proceso muy interesante por sus diferentes aplicaciones, además de ser notablemente sostenible [9]. Las microalgas son microorganismos fotosintéticos, capaces de desarrollarse en ausencia de agua limpia ni suelo fértil, con gran capacidad de producir biomasa y de crecer en una amplia variedad de entornos. En el campo del tratamiento de aguas residuales, su producción se presenta como una alternativa al proceso tradicional, siendo mucho más eficiente energéticamente. Del mismo modo, permite obtener productos derivados del proceso tales como biocombustibles, bioestimulantes, biofertilizantes o suplementos alimenticios, incrementando su atractivo.

Existen dos formas principales de llevar a cabo este proceso de producción. En primer lugar, la producción se puede realizar en fotobiorreactores cerrados o tubulares. En este tipo de sistemas, el cultivo circula por conductos cerrados, permitiendo el control total de sus condiciones e impidiendo la entrada de contaminantes externos, lo cual los convierte en la opción óptima para la obtención de productos de alto valor [1]. Por otro lado, la alternativa son los fotobiorreactores abiertos o *raceway*, que son grandes piscinas por las que se

desplaza el medio. En estos últimos el cultivo se encuentra expuesto a contaminantes externos, y el control de sus condiciones no es trivial, pero es la opción más implementada a nivel industrial, debido a sus menores costes y su sencilla escalabilidad [2].

Para su crecimiento, las microalgas requieren de tres elementos fundamentales: luz, agua y nutrientes. En los fotobiorreactores abiertos la fuente de luz es el sol, mientras que el agua es tomada directamente del medio en que se encuentra el cultivo. Los nutrientes pueden ser incorporados de varias formas. El nitrógeno y el fósforo que requieren las microalgas pueden ser proporcionados de manera externa, o se pueden emplear aguas residuales como medio, en las cuales estos elementos son los principales contaminantes, contribuyendo así al proceso de depuración. El carbono puede ser incorporado como dióxido de carbono, usándose a su vez para el control del pH.

La productividad del proceso durante su operación es dictada por tres variables fundamentales: el pH, el oxígeno disuelto y la temperatura del medio. De estas tres, el pH suele ser el objetivo principal del control del proceso, ya que la productividad alcanza su máximo cuando este se encuentra cercano a un valor óptimo. El control de pH se realiza mediante la inyección de CO<sub>2</sub>, pero no es un problema trivial, ya que el carácter biológico del proceso dificulta enormemente su caracterización, y con esta, el desarrollo de estrategias de control robustas u óptimas.

En la literatura se han realizado muchos trabajos con el fin de desarrollar modelos que describan las dinámicas del proceso de producción. Tradicionalmente, estos han sido modelos no lineales basados en primeros principios, los cuales, a pesar de contribuir a la comprensión del proceso, poseen un alto grado de complejidad y requieren de una recalibración constante debido a la variabilidad de las dinámicas, provocada por su carácter biológico [6, 5, 7, 8, 10, 15].

Ante esta casuística, las técnicas basadas en datos, y más concretamente, las redes neuronales artificiales, se presentan como una excelente alternati-

va para el modelado de estas dinámicas. En las últimas décadas, el incremento de la capacidad computacional unido a la existencia de un vasto volumen de datos, justifica el uso de este tipo de técnicas en una amplia variedad de ámbitos, especialmente en procesamiento y reconocimiento de imágenes, detección de patrones, gestión de recomendaciones... Los modelos obtenidos de esta forma destacan por su precisión y adaptabilidad, requiriendo siempre un conjunto de datos suficiente y de calidad.

Anteriormente se han empleado las técnicas de aprendizaje computacional principalmente para la caracterización de cultivos [3, 13, 16]. Otros trabajos han empleado este tipo de modelos para reactores *raceway*, obteniendo modelos concretos y precisos [14]. Por otro lado, algunos autores han planteado estrategias basadas en aprendizaje computacional para optimización de la producción [4, 12]. A pesar de esto, este tipo de modelos aún no ha sido muy explotado en el campo del modelado dinámico de procesos biológicos, pese a que a priori su capacidad de adaptarse a distintas circunstancias y su elevada precisión parecen adecuadas para modelar procesos tan cambiantes. Con esta motivación, en este trabajo se presentan dos modelos basados en redes neuronales para modelar la dinámica del pH en fotobiorreactores *raceway* de aguas limpias y residuales.

## 2. Materiales y métodos

### 2.1. Fotobiorreactores modelados

En este trabajo se han modelado dos fotobiorreactores *raceway* localizados en centro IFAPA de la Universidad de Almería, mostrados en la Figura 1. Los reactores están compuestos por dos canales de 40 m de longitud, 1 m de ancho y 0.3 de profundidad, unidos en sus extremos por curvas de 180°. El medio es impulsado mediante una rueda de palas accionada por un motor eléctrico, que hace circular el agua a una velocidad de aproximadamente 0.23 m/s. A 1.8 m de la rueda siguiendo el sentido de circulación del medio se dispone de un foso de 1 m de profundidad, desde el cual se realiza la inyección de CO<sub>2</sub> y aire empleados para el control de las condiciones del cultivo.

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, en el punto más alejado de este. 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.

### 2.2. Variables de interés

Los reactores descritos se encuentran completamente sensorizados, registrando de forma continua y en tiempo real los valores de múltiples variables relacionadas con su operación o ambientales, con un tiempo de muestreo de 10 s. Las variables medidas empleadas para el desarrollo de los modelos son las siguientes:

- pH en el punto más alejado del foso en ambos reactores.
- Caudal de CO<sub>2</sub> inyectado en ambos reactores [L/min].
- Nivel de ambos reactores [cm].
- Temperatura del medio de ambos reactores [°C].
- Radiación global incidente [W/m<sup>2</sup>].

### 2.3. Redes neuronales artificiales

Los algoritmos de aprendizaje automático tienen la singularidad de ser capaces de obtener modelos y extraer patrones de los datos, sin estar explícitamente programados para ello. Son especialmente efectivos cuando se dispone de un gran volumen de datos y buena capacidad computacional. Las redes neuronales artificiales forman parte de este conjunto de algoritmos.

Las redes neuronales artificiales, como su propio nombre indica, poseen un comportamiento similar a las biológicas. Se trata de una estructura formada por capas sucesivas. Cada capa está compuesta por nodos o neuronas, de manera que todos los nodos de una capa reciben como entrada la salida de cada nodo de la capa anterior, opera con estas, y calcula su propia salida, que servirá como entrada para las capas subsiguientes. La función típica que describe el funcionamiento de una neurona es la mostrada en la Ecuación (1), donde  $y$  es la salida de un nodo o neurona,  $x_k$  sus entradas (salidas de los nodos de la capa anterior),  $W_k$  y  $b$  son los pesos y la desviación del nodo respectivamente, y  $\phi$  es su función de activación no lineal.

$$y = \phi \left( \sum_k W_k x_k + b \right) \quad (1)$$

De este modo, la conexión sucesiva de capas permite desarrollar relaciones altamente no lineales entre los datos de entrada y salida, capaces de distinguir rasgos o patrones en estos y adaptarse a todo tipo de problemas. El proceso de entrenamiento de la red es el encargado de, dado un



Figura 1: Fotobiorreactores *raceway* modelados en este trabajo.

conjunto de datos, determinar el valor óptimo de los pesos y la desviación de cada neurona para minimizar la diferencia entre la salida del modelo y el valor real de dicha variable.

Existen multitud de tipos de redes neuronales artificiales, pero una de las que más llamativas resultan para el modelado de sistemas dinámicos son las redes NARX (*Nonlinear Autoregressive with eXogenous inputs*). Estas redes no poseen necesariamente ninguna capa característica, pero emplean como entradas los  $k$  valores anteriores de sus entradas, así como de la propia salida, para reflejar el carácter dinámico del sistema, de forma similar a un modelo en tiempo discreto (ver Figura 2). Del mismo modo, los valores predichos de salida pueden ser realimentados a la entrada para realizar predicciones infinitas siempre y cuando se conozcan el resto de entradas, y teniendo en cuenta las limitaciones del modelo. Este será el tipo de red empleado para el desarrollo de los modelos planteados en este trabajo.

### 3. Resultados

#### 3.1. Tratamiento de datos

El primer paso para la obtención de los modelos fue el tratamiento de datos. El conjunto de datos inicial estaba compuesto por registros de datos de 69 días entre los meses de abril y junio del año 2022. Estos registros contenían los valores de multitud de variables de ambos reactores con un muestreo de 10 s, de las cuales se emplearon para el desarrollo de los modelos aquellas mencionadas

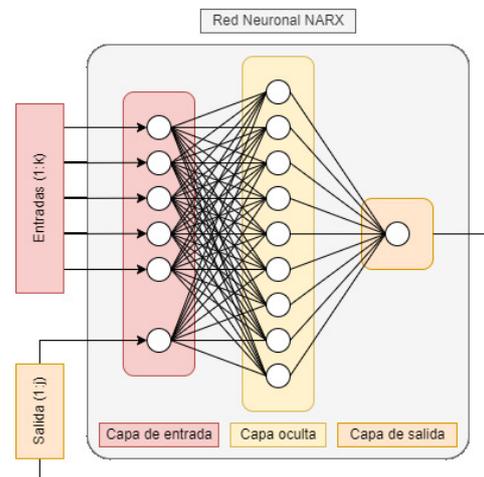


Figura 2: Esquema de red neuronal de tipo NARX, con  $k$  retardos a la entrada y  $j$  retardos a la salida

en la sección 2.2.

El tratamiento de datos comenzó con un cambio del tiempo de muestreo de los datos a un minuto, obteniendo un registro de 1440 muestras para cada día, ya que este muestreo es suficiente para posteriores aplicaciones y evitar *aliasing*, a la vez que facilita una predicción más precisa y reduce el número de retardos necesarios. De estos registros se eliminaron los días y tramos problemáticos por fallos en la adquisición. Esto eliminó por completo algunos registros, mientras que en otros su duración fue reducida de un día completo a un tramo de varias horas. De estos tramos resultantes se filtraron los *outliers* debidos a problemas puntuales en los sensores, y se eliminaron aquellos tramos

con dinámicas no representativas de la operación habitual del reactor, con el fin de que el modelo obtenido se adapte mejor a las condiciones usuales de operación. La Figura 3 muestra el perfil de las distintas variables para uno de los tramos empleados en el entrenamiento.

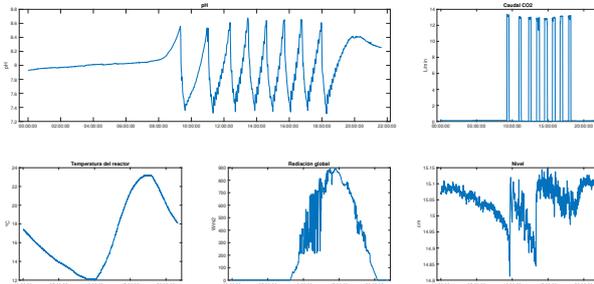


Figura 3: Perfiles de variables empleadas en el modelado para uno de los tramos empleados en el entrenamiento.

Una vez se dispuso de los tramos recortados y sin errores, cada variable del conjunto de datos fue normalizada mediante la substracción de su media y la división por su desviación típica, con el fin de facilitar el aprendizaje de la red. A partir de estos datos, se compuso el conjunto de datos completo, compuesto finalmente por 37 tramos para el reactor de aguas residuales, y 29 para el de agua limpia. Este conjunto tiene 4 variables de entrada y una de salida para cada reactor, siendo esta última realimentada como una quinta entrada.

### 3.2. Desarrollo de modelos

Tras asegurar la calidad de los datos, el siguiente paso para el desarrollo de los modelos es la selección de su proceso de entrenamiento y su estructura.

El proceso de entrenamiento viene dictado por la función de entrenamiento, la división de los datos y la condición de parada. La función empleada fue la regularización bayesiana, que se caracteriza por su capacidad de generalización [11]. Esta es importante, ya que el conjunto de entrenamiento es relativamente extenso en comparación al número de parámetros de la red, considerando que cada instante de muestreo es una muestra independiente para el entrenamiento de la red. El algoritmo de optimización usado es el *backpropagation*, y la función de activación de los nodos es la tangente hiperbólica.

La división de los datos en conjuntos de entrenamiento, validación y prueba será 70/15/15 %, respectivamente. La mayor parte de los datos se destinará al conjunto de entrenamiento para que la red neuronal aprenda de ellos. El conjunto de validación se considerará en la condición de pa-

rada, mientras que el de prueba únicamente será tenido en cuenta tras el entrenamiento. La condición de parada será atendiendo al desempeño del conjunto de validación. Este será medido según el error cuadrático medio de las predicciones, y dictará que el entrenamiento se detendrá cuando no aumente durante más de 200 iteraciones. Puesto que el modelo es entrenado en bucle abierto, esto es, sin realimentar predicciones, cada uno de los conjuntos estará compuesto por muestras individuales de días distintos.

Puesto que se desea obtener un modelo que refleje las dinámicas del sistema, se optó por una estructura de red neuronal de tipo NARX como las descritas en la sección 2.3. La estructura seleccionada está compuesta por dos capas: una capa profunda encargada de proporcionar complejidad a la red, y una capa de salida que compute el valor de la variable a predecir. La primera capa recibirá como entradas los  $k$ -valores anteriores de las entradas del modelo y los  $j$ -valores anteriores del pH, mientras que la última capa, con un único nodo, proporciona como salida el valor de pH en cada instante. Con esta estructura en mente, es preciso determinar dos parámetros fundamentales: el número de retardos que se emplearán para las entradas y la salida realimentada, y el número de nodos de la primera capa.

Como se mencionó anteriormente, el objetivo es predecir el pH del reactor en el punto más alejado de la inyección de  $\text{CO}_2$ , por ser el más desfavorable. Este distanciamiento espacial entre los puntos de inyección y de control se traduce en un tiempo de retardo continuo cuyo valor es dictado por la velocidad de desplazamiento del medio. Considerando que el medio circula con una velocidad de aproximadamente 0.23 m/s, y teniendo en cuenta la longitud total del reactor, el tiempo de retardo del sistema es de aproximadamente 5 minutos. Puesto que el modelo emplea un tiempo de muestreo de un minuto, este tiempo se traduce en 5 muestras de retardo, por lo cual el modelo deberá emplear como entrada los valores de inyección de  $\text{CO}_2$  correspondientes a 5 muestras en el pasado o más, o lo que es lo mismo, el número mínimo de retardos aplicados a la entrada de la red neuronal será 5.

Algunas de las variables de entrada, como la radiación o la temperatura, sí que tienen acción directa sobre el pH desde el instante anterior a la predicción, sin necesidad de atender al tiempo de residencia del fluido. La salida realimentada tampoco depende de este tiempo. Sin embargo, con el fin de unificar el formato de los datos, se seleccionó el mismo número de retardos en tiempo discreto para todas las entradas, así como para la salida re-

alimentada. Puesto que los 4 primeros valores de CO<sub>2</sub> son en teoría irrelevantes, el propio algoritmo de aprendizaje de la red debe dotar de pesos muy pequeños a estas entradas, con un efecto similar al de no considerarlas.

En cuanto al número de nodos de la capa intermedia, al no existir ninguna regla heurística para su selección, se siguió un proceso de prueba y error. En primer lugar se percibió que un número de nodos entre 10 y 20 es óptimo tanto para el tiempo de entrenamiento de la red como para su desempeño. Con esta premisa en mente, se realizaron entrenamientos con estructuras de red con 5 o 6 retardos en la entrada y en la realimentación, y con 10 o 20 nodos en la capa intermedia, y fueron evaluadas según su error cuadrático medio en todos los días del conjunto. La Tabla 1 muestra los resultados. Siguiendo estos, la estructura seleccionada fue de 6 con 10 nodos para ambos modelos, ya que el uso de 20 nodos duplica el número de parámetros de la red y el desempeño no mejora en tanta medida, y de este modo ambas redes emplean la misma estructura.

Tabla 1: Desempeño de distintas estructuras de modelo para cada reactor.

Retardos	Nodos	MSE	
		Residuales	Limpia
5	10	0.0495	0.0078
5	20	0.0615	0.0054
6	10	0.0473	0.0065
6	20	0.0435	0.0109

### 3.3. Validación de resultados

Al finalizar el tratamiento de datos, la selección de la estructura y el entrenamiento de los modelos, el último paso es la validación de resultados. Los dos modelos obtenidos se pusieron a prueba ante todos los días del conjunto de datos con el fin de comprobar su capacidad de predecir con precisión los perfiles de pH en circunstancias distintas. En esta validación, el objetivo es que el modelo sea capaz de predecir el perfil de pH durante tramos de mayor duración, realimentando sus predicciones como entradas para instantes futuros. Estos resultados son evaluados desde un punto de vista analítico en la Tabla 1, y también desde un punto de vista gráfico atendiendo a las diferencias visuales entre las señales. Las Figuras 4 y 5 muestran las predicciones de los modelos para ocho días distintos para el reactor de aguas limpias y residuales, respectivamente.

Como se observa en las figuras, ambos modelos predicen con gran precisión perfiles de pH muy distintos, correspondientes a días con condiciones

ambientales y modos de operación drásticamente diferentes. Tal y como indican los índices de desempeño de la Tabla 1, el modelo de pH para aguas limpias resulta más preciso, correspondiente con un error cuadrático medio inferior. Esto puede ser debido a que la presencia de bacterias en el reactor de aguas residuales tiene como efecto dinámicas más complejas y, por tanto, más difíciles de reflejar por el modelo.

## 4. Conclusiones y trabajos futuros

En este trabajo, se han desarrollado dos modelos dinámicos basados en redes neuronales para predicción de pH en reactores *raceway* de aguas residuales y agua limpia. Los modelos alcanzados permiten la predicción de forma precisa, con un muestreo de un minuto, y un horizonte de predicción de hasta un día, ante distintos perfiles climáticos, y diferentes estrategias de control. Los modelos realimentan las predicciones realizadas en cada periodo de muestreo, logrando así estos horizontes de predicción sin necesidad de datos reales de pH. Estos modelos pueden ser de gran utilidad para detección de fallos en tiempo real, simulación de nuevas estrategias de control, o como parte de un algoritmo de control predictivo no lineal. Es importante destacar que, debido a la naturaleza de este tipo de técnicas, el entrenamiento del modelo con datos de una única estación implica que no sea válido para otras con condiciones drásticamente distintas a las de los datos de entrenamiento. De cara a futuros trabajos relacionados con esta línea de investigación, será importante la implementación de este modelo en las aplicaciones ya mencionadas, así como su expansión a otras variables de interés del reactor, u otras épocas del año con condiciones drásticamente distintas.

### Agradecimientos

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

El autor Pablo Otálora Berenguel es beneficiario de una ayuda FPU del Ministerio de Ciencia, Innovación y Universidades.

Juan D. Gil agradece el apoyo económico del programa Personal Investigador Doctor de la Junta de Andalucía 2021, número de beca POST-DOC\_21\_00854.

### English summary

## DYNAMIC MODELING OF PH IN RACEWAY REACTORS USING NEURAL NETWORKS

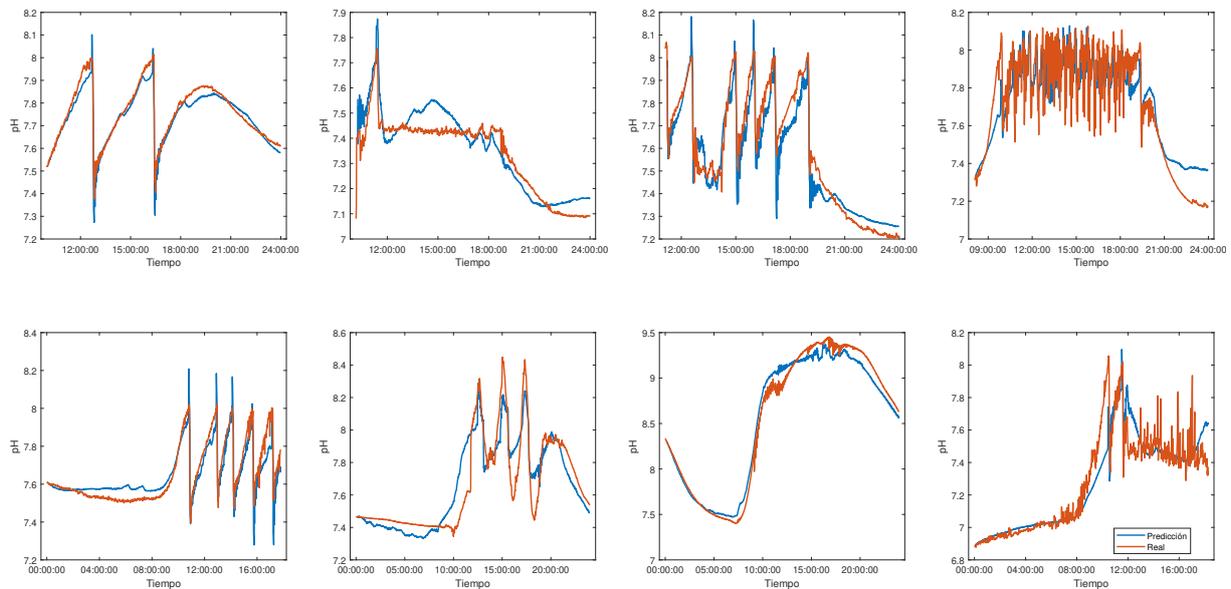


Figura 4: Resultados de validación del modelo de predicción de pH para reactor de aguas residuales. En rojo los datos reales, en azul los predichos.

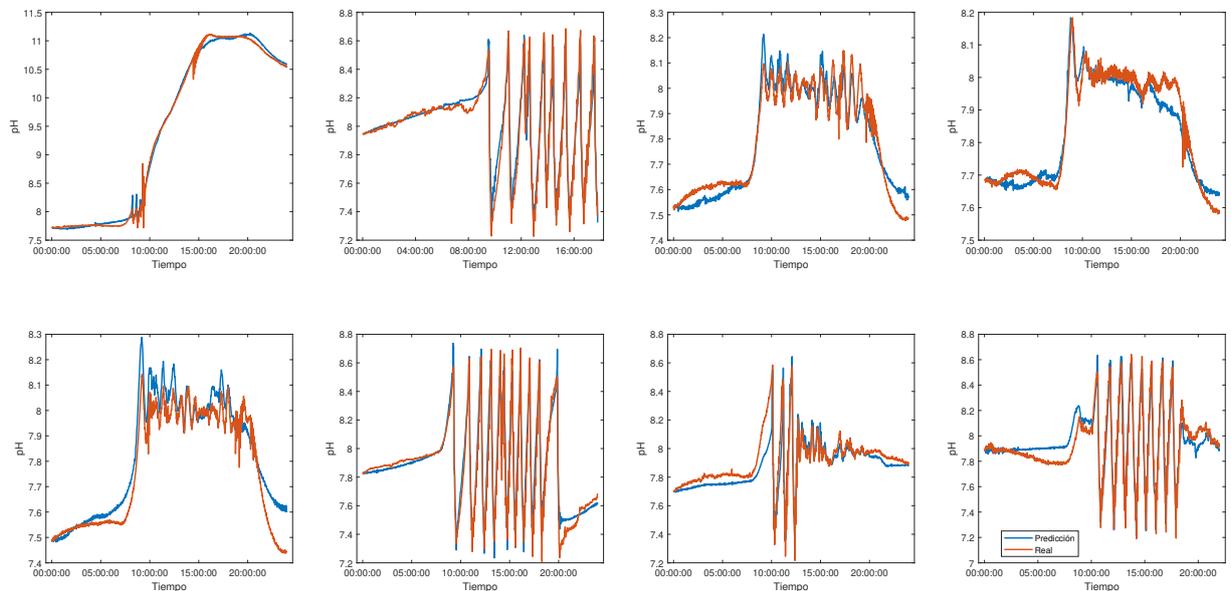


Figura 5: Resultados de validación del modelo de predicción de pH para reactor de agua limpia. En rojo los datos reales, en azul los predichos.

**Abstract**

*This work focuses on the development of neural network models for pH prediction in raceway photobioreactors. Models for predicting the pH value with a sampling time of one minute and a prediction horizon up to one day have been obtained for wastewater or clean water photobioreactors. The models use data related to climatic conditions and the reactor operation. The results*

*obtained validate the use of these techniques for biological process modeling, providing accurate, simple and fast execution models.*

**Keywords:** Neural networks, microalgae, modeling, biotechnology.

## Referencias

- [1] Andrade, G.A., Berenguel, M., Guzmán, J.L., Pagano, D.J., Ación, F.G. Optimization of biomass production in outdoor tubular photobioreactors. *Journal of Process Control*, 37, 58-69, 2016. <https://doi.org/10.1016/j.jprocont.2015.10.001>
- [2] Barceló Villalobos, M., Ación Fernández, F.G., Guzmán, J.L., Fernández Sevilla, J.M., Berenguel, M. New strategies for the design and control of raceway reactors to optimize microalgae production. *Handbook of Algal Technologies and Phytochemicals: Volume II: Phycoremediation, Biofuels and Global Biomass Production*. Edited by Gokare A. Ravishankar and Ambati Ranga Rao. CRC Press – Taylor & Francis Group. USA, ISBN: 9780429057892, 2019. <https://doi.org/10.1201/9780429057892>
- [3] Correa, I., Drews, P., Botelho, S., de Souza, M.S., Tavano, V. M. Deep Learning for microalgae classification. 2017 16th IEEE International Conference on Machine Learning and Applications (ICMLA), 20-25, 2017. 10.1109/ICMLA.2017.0-183.
- [4] del Rio-Chanona, E.A., Wagner, J.L., Ali, H., Fiorelli, F., Zhang, D. and Hellgardt, K. Deep learning-based surrogate modeling and optimization for microalgal biofuel production and photobioreactor design. *AICChE Journal*, 65, 915-923, 2019. <https://doi.org/10.1002/aic.16473>
- [5] Fernández, I., Ación, F.G., Berenguel, M., Guzmán, J.L. First principles model of a tubular photobioreactor for microalgal production. *Industrial & Engineering Chemistry Research*, 53, 11121-11136, 2014. <https://doi.org/10.1021/ie501438r>
- [6] Fernández, I., Ación, F.G., Berenguel, M., Guzmán, J.L., Andrade, G.A., Pagano, D.J. A lumped parameter chemical-physical model for tubular photobioreactors. *Chemical Engineering Science*, 112, 116-129, 2014. <https://doi.org/10.1016/J.CES.2014.03.020>
- [7] Fernández, I., Guzmán, J.L., Berenguel, M., Ación, F.G. Dynamic modelling of microalgal production in photobioreactors. In: *Prospects and Challenges in Algal Biotechnology*. Edited by Bhumi Nath Tripathi and Dhananjay Kumar, 49-87. Springer, 2017. ISBN ISBN 978-981-10-1949-4. [https://doi.org/10.1007/978-981-10-1950-0\\_2](https://doi.org/10.1007/978-981-10-1950-0_2)
- [8] García-Mañas, F., Guzmán, J.L., Berenguel, M., Ación, F.G. Biomass estimation of an industrial raceway photobioreactor using an extended Kalman filter and a dynamic model for microalgae production. *Algal Research-Biomass Biofuels and Bioproducts*, 37, 103-114, 2019. <https://doi.org/10.1016/j.algal.2018.11.009>
- [9] Guzmán, J.L., Ación, F.G., Berenguel, M. Modelling and control of microalgae production in industrial photobioreactors. *Revista Iberoamericana de Automática e Informática Industrial*, 18(1), 1-18, 2021. <https://doi.org/10.4995/riai.2020.13604>
- [10] Hoyo, Á., Rodríguez-Miranda, E., Guzmán, J.L., Ación, F.G., Berenguel, M., Moreno, J.C. A computer-based tool to simulate raceway photobioreactors for design, operation and control purposes. *Computers and Chemical Engineering*, 156, 107472, 2022. <https://doi.org/10.1016/j.compchemeng.2021.107572>
- [11] MacKay, D. J. C. Bayesian interpolation. *Neural computation*, 4, No. 3, 415–447, 1992. <https://doi.org/10.1162/neco.1992.4.3.415>
- [12] Milić, M., Petković, B., Selmi, A. et al. Computational evaluation of microalgae biomass conversion to biodiesel. *Biomass Conversion and Biorefinery*, 2021. <https://doi.org/10.1007/s13399-021-01314-2>
- [13] Otálora, P., Guzmán, J.L., Ación, F.G., Berenguel, M., Reul, A. Microalgae classification based on machine learning techniques. *Algal Research*, 55, 1022256, 2021. <https://doi.org/10.1016/j.algal.2021.102256>
- [14] Otálora, P., Guzmán, J.L., Berenguel, M., Ación, F.G. Dynamic model for the pH in a raceway reactor using deep learning techniques. In: Gonçalves, J.A., Braz-César, M., Coelho, J.P. (eds) *CONTROLO 2020. Lecture Notes in Electrical Engineering*, vol 695. Springer, Cham, 2021. [https://doi.org/10.1007/978-3-030-58653-9\\_18](https://doi.org/10.1007/978-3-030-58653-9_18)
- [15] Rodríguez-Miranda, E., Ación, F.G., Guzmán, J.L., Berenguel, M., Visioli, A. A new model to analyze the temperature effect on the microalgae performance at large scale raceway reactors. *Biotechnology and Bioengineering*, 118(2), 877-889, 2021. <https://doi.org/10.1002/bit.27617>
- [16] Sonmez, M. E., Eczacioglu, N., Gumuş, N.E., Aslan, M.F., Sabanci, K., Aşikkutlu,

B. Convolutional neural network - Support vector machine based approach for classification of cyanobacteria and chlorophyta microalgae groups. *Algal Research*, 61, 2022, 102568, ISSN 2211-9264, <https://doi.org/10.1016/j.algal.2021.102568>.



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