

Modelo basado en redes neuronales artificiales para la evaluación de la calidad del agua en sistemas de cultivo extensivo de camarón

• José Juan Carbajal-Hernández* • Luis P. Sánchez-Fernández •
Instituto Politécnico Nacional, México

*Autor para correspondencia

• Ignacio Hernández-Bautista •
Instituto Tecnológico de León, México

• Jorge Hernández-López •
Centro de Investigaciones Biológicas del Noreste, México

DOI: 10.24850/j-tyca-2017-05-05

Resumen

Carbajal-Hernández, J. J., Sánchez-Fernández, L. P., Hernández-Bautista, I., & Hernández-López, J. (septiembre-octubre, 2017). Modelo basado en redes neuronales artificiales para la evaluación de la calidad del agua en sistemas de cultivo extensivo de camarón. *Tecnología y Ciencias del Agua*, 8(5), 71-89.

El cultivo de especies acuícolas es una actividad comúnmente practicada alrededor del mundo. En México, el cultivo de camarón es una de las principales fuentes de ingresos en el área de la acuicultura. La calidad del agua es un factor relevante en el éxito del cultivo en granjas camaronícolas, por lo que su monitoreo resulta ser de vital importancia. Este estudio presenta un nuevo modelo computacional para la evaluación de la calidad del agua en granjas de cultivo extensivo para camarón *Litopenaeus vannamei*. Mediante el uso de las redes neuronales artificiales se creó un indicador de la calidad del agua, mismo que permite establecer una relación entre la dinámica de los parámetros del ecosistema y diferentes estados para el cultivo de la especie (excelente, bueno, regular y deficiente). Se seleccionaron cuatro parámetros medioambientales debido a su importancia en el hábitat: temperatura del agua, pH, oxígeno disuelto y salinidad. Los resultados obtenidos muestran un buen funcionamiento y eficiencia por parte del sistema propuesto, al compararlo con otros modelos de evaluación empleados para este fin. Las evaluaciones muestran a las RNA como una buena opción para la evaluación y detección de estados óptimos o no deseados para un buen manejo del agua en este tipo de cultivos.

Palabras clave: calidad del agua, redes neuronales, acuicultura, inteligencia artificial, camarón.

Abstract

Carbajal-Hernández, J. J., Sánchez-Fernández, L. P., Hernández-Bautista, I., & Hernández-López, J. (September-October, 2017). A model based on an artificial neural network for assessing water quality on large shrimp farms. *Water Technology and Sciences (in Spanish)*, 8(5), 71-89.

Aquaculture is a commonly practiced activity worldwide. In Mexico, shrimp represents a significant source of the income generated by aquaculture. Since the success of shrimp farming depends on good water quality, its monitoring is essential. This work presents a new computational model to assess the water quality of large shrimp ponds (*Litopenaeus vannamei*). An artificial neural network (ANN) was used to create a water quality index, with which a mathematical relationship can be established between the dynamics of environmental parameters and different water quality conditions (excellent, good, average, and poor). Four parameters that were important for the habitat were selected: temperature, dissolved oxygen, salinity, and pH. The results show that the proposed model performs well and efficiently, as compared to other evaluation models used for this purpose. The evaluations demonstrate that ANN is a good option for evaluating and detecting optimal and undesirable conditions, contributing to good water management for this type of farming.

Keywords: Water quality, artificial neural networks, aquaculture, shrimp.

Recibido: 18/09/2015
Aceptado: 25/04/2017

Introducción

El cultivo de camarón es una importante actividad económica que en la actualidad se practica en varios países del mundo. México es uno de los principales productores de camarón, localizándose la mayor parte de las granjas de cultivo en zonas costeras. Existen varias modalidades de cultivo de camarón: intensiva, semi-intensiva y extensiva; siendo esta última donde se enfoca este trabajo.

La producción de camarón se determina principalmente por la capacidad de maduración de organismo y por la capacidad de su hábitat, mismo que está sujeto a diferentes condiciones que permitan altas tasas de crecimiento y de reproducción (Casillas-Nolasco, García, Carrillo, & Páez, 2007). El análisis de la calidad del agua permite determinar la influencia que el medioambiente ejerce sobre la vida del camarón, permitiendo identificar situaciones desfavorables para el cultivo del organismo.

El adecuado manejo de la calidad del agua en sistemas de cultivo de camarón es una de las principales preocupaciones de los productores. Los parámetros medioambientales involucrados en el ecosistema son medidos y supervisados de forma constante para evitar situaciones de estrés en el organismo. Organizaciones

gubernamentales han dedicado grandes esfuerzos en el análisis acuícola, estableciendo normativas y criterios sobre límites permitidos de concentraciones para la práctica de la acuicultura, como la U.S. National Sanitation Foundation (NSF, 2017), Canadian Council of Environmental Ministers (CCME, 2004); la Agencia Catalana del Agua, España (ACA, 2017); la Secretaría de Medio Ambiente y Recursos Naturales, México (Semarnat, 2017), y el Instituto Nacional de Ecología, México (INECC, 2000).

La calidad del agua se puede evaluar con base en las diferentes concentraciones que presentan los parámetros medioambientales. Las relaciones entre ellos y su comportamiento establecen los criterios de un buen o mal manejo del agua en sistemas de cultivo. En sistemas de cultivo extensivo, el adecuado control de parámetros resulta un problema complejo, por lo que la creación de un indicador de la calidad del agua será de gran ayuda para poder entender el comportamiento a nivel global del estanque. Las redes neuronales artificiales (RNA) son capaces de aprender estos comportamientos (favorables o desfavorables) entre parámetros, si se plantea un adecuado análisis. La figura 1 muestra la metodología de funcionamiento del modelo propuesto, el cual permite realizar un análisis de la calidad del agua, obteniendo las mediciones

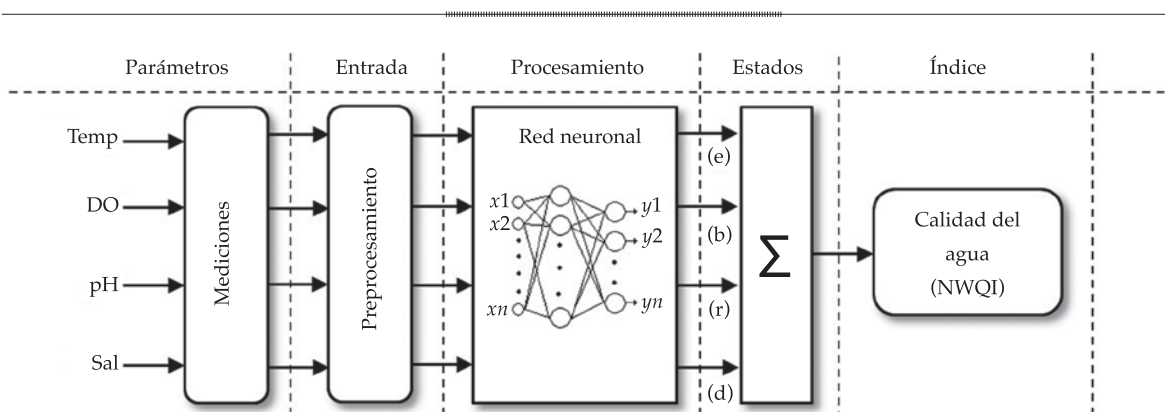


Figura 1. Metodología propuesta para la evaluación de la calidad del agua en camaronicultura empleando un modelo neuronal.

La RNA responde reconociendo los diferentes estados del estanque: (e) excelente, (b) bueno, (r) regular y (d) deficiente.

Posteriormente, mediante un proceso de agregación, se conjuntan los estados de la calidad del agua evaluados proporcionando un indicador global (NWQI).

de parámetros medioambientales, y teniendo como resultado un indicador en un rango de [0, 1] acerca del estado del sistema. Se eligieron cuatro parámetros como entrada del modelo: temperatura del agua, pH, oxígeno disuelto y salinidad. La justificación de su selección se describe más adelante.

Actualmente se han llevado a cabo varias investigaciones para analizar la calidad el agua en el área de la camaronicultura, desarrollando diferentes modelos e involucrando otros parámetros de la calidad del agua, como los propuestos por Beltrame, Bonetti y Bonetti (2006); Carbajal, Sánchez, Carrasco y Martínez (2012); Carbajal, Sánchez, Villa, Carrasco y Martínez (2013); Simões *et al.* (2008); Islam, Sarker, Yamamoto, Wahab y Tanaka (2004); Casé *et al.* (2008), y Riss, Ospina y Gutiérrez (2002). Asimismo, existen diferentes trabajos que sirven como complemento a esta investigación, que contienen información relevante sobre el comportamiento de los parámetros de la calidad del agua en diferentes sistemas acuícolas y que han sido propuestos por Ma, Song, Wan, Gao y Jiang (2014); Gharibi *et al.* (2012); Ramesh, Sukumaran, Murugesan y Rajan (2010); Lermontov, Yokoyama, Lermontov y Soares (2009); Ocampo, Ferré, Domingo y Schuhmacher (2006); Gutiérrez (2004), y Gutiérrez, Riss y Ospina (2006).

La aplicación de herramientas para el modelado del medioambiente como la inteligencia artificial ha sido cada vez más utilizada para la solución de este tipo de problemas, pues permite modelar con mayor precisión la dinámica del ecosistema. Alternativas como el uso lógica difusa (Gutiérrez *et al.*, 2006), procesos analíticos jerárquicos (Carbajal *et al.*, 2013), modelos autorregresivos (Carbajal, Sánchez, & Progrebnyak, 2011), redes neuronales (Shen, Chen, & Yu, 2009; Lek, Guiresse, & Giraudel, 1999) y máquinas de soporte vectorial (Liu, Xu, Li, & Zeng, 2014; Lin, Cheng, & Chau, 2006) entre otros, han sido ampliamente utilizados en análisis medioambientales, por lo que su empleo en el diagnóstico de la calidad del agua en el ecosistema del camarón permitirá desarrollar herramientas de evaluación de mayor precisión.

El análisis de la calidad del agua requiere del estudio de diversos parámetros medioambientales, mismos que pueden estar relacionados entre sí. El presente trabajo propone desarrollar un modelo de evaluación de la calidad del agua, empleando redes neuronales artificiales (RNA's) para sistemas de cultivo extensivo de camarón *Litopenaeus vanammei*. El conjunto de parámetros más significativos (temperatura, oxígeno disuelto, pH y salinidad) se estudia debido a que su comportamiento puede ser óptimo o negativo para el cultivo de la especie. El estudio de concentraciones dañinas, combinaciones no deseadas y efectos tóxicos para la especie son analizadas y clasificadas. Mediante una RNA se establece una respuesta a cada una de estas clasificaciones, permitiendo asociar un conjunto de concentraciones con un estado de la calidad del agua, generando un indicador global de excelente, bueno, regular y deficiente. Asimismo, las relaciones y dependencias intrínsecas entre parámetros son procesadas y aprendidas por la RNA, permitiendo una mayor exactitud en las evaluaciones hechas. Derivado de esto, se plantea la hipótesis basada en que es posible modelar y evaluar la calidad del agua mediante el uso de las redes neuronales artificiales, empleando el conjunto de parámetros más significativos en estanques de cultivo de camarón *Litopenaeus vanammei*. Como resultado, se hará una serie de comparaciones contra modelos reportados en la literatura para la medición de la calidad del agua, mostrando una mejora en las evaluaciones proporcionadas por el modelo neuronal.

El resto de este trabajo se ha organizado de la siguiente forma: en la sección "Acuicultura y calidad del agua" se presenta una introducción sobre los requerimientos de la acuicultura y la calidad del agua, en donde las características de los parámetros de mayor impacto se explican a detalle. En la sección "Materiales y métodos" se explican los materiales utilizados y la construcción del modelo neuronal para la clasificación de la calidad del agua. En la sección "Resultados experimentales y discusiones" se realizan las pruebas experimentales y discusiones del trabajo, mostrando un análisis de mediciones

durante un periodo de cultivo; asimismo, se efectúa una comparación del índice propuesto contra aquellos empleados comúnmente en el área de la camaronicultura. Por último se tienen las conclusiones del presente trabajo. El anexo A explica información sobre el cálculo de los índices de la calidad del agua empleados en las comparaciones mostradas en la sección de pruebas experimentales.

Acuicultura y calidad del agua

El ecosistema del camarón está compuesto por un conjunto de parámetros físico-químicos que deben ser monitoreados en todo momento y controlarse dentro de un intervalo permitido, generando una calidad del agua óptima para el cultivo de la especie. Con frecuencia existen situaciones con calidad del agua deficiente en sistemas de cultivo extensivos debido a que los parámetros suelen tener cambios bruscos o existen reacciones químicas que propician niveles de toxicidad poco aceptables en el ecosistema. Resulta de gran importancia conocer las características de los parámetros de la calidad del agua, así como la frecuencia en que se deben monitorear para obtener un mejor análisis sobre el comportamiento de la misma dentro de un estanque de cultivo (Casillas *et al.*, 2007; Páez, 2001; Cohen, Samocha, & Fox, 2005).

Dentro del ecosistema del camarón existen parámetros de mayor impacto, los cuales deben monitorearse con mayor frecuencia, pues desestabilizan el ecosistema más fácilmente que otros, siendo este conjunto el de mayor importancia en la evaluación de la calidad del agua (Semarnap, 1996). El cuadro 1 muestra la clasificación de parámetros involucrados en la calidad del agua debido a su frecuencia de monitoreo. En este trabajo, el grupo de monitoreo diario se seleccionó por su importancia principal en el ecosistema de cultivo.

Es importante remarcar que el amonio no ionizado es un parámetro altamente tóxico; sin embargo, puede controlarse mediante el manejo adecuado de la temperatura y en pH (Bower & Bidwell, 1978). Así, su frecuencia de medición es baja, analizándolo sólo cuando se requiere un análisis más detallado sobre la calidad del agua (Casillas *et al.*, 2007; Boyd, 2000; Martínez, 1994; Chien, 1992; Hirono, 1992; Belt, 1992). El monitoreo constante de los parámetros rutinarios (medición diaria) permitirá tener un mejor y más rápido control sobre el hábitat del camarón. La importancia del grupo de parámetros rutinarios en el cultivo de camarón se enuncia en el cuadro 2.

Los parámetros de la calidad del agua suelen tener comportamientos de constante cambio, y una combinación fuera de un límite permitido puede ser tóxico o desencadenar

Cuadro 1. Parámetros físico-químicos involucrados en el hábitat del camarón.

	Monitoreo		
	Diario	Semanal	Por requerimiento
Temperatura		Amonio total	Alcalinidad
Salinidad		Nitratos	Fósforo
Oxígeno disuelto		Amonio no ionizado	Sulfato de hidrógeno no ionizado
pH		Turbidez	Sulfato de hidrógeno
			Dióxido de carbono
			Silicatos
			Clorofila A
			Nitrógeno total inorgánico
			Sólidos suspendidos
			Potencial Redox
			Conteo <i>Vibrio</i>
			Coliformes fecales

Cuadro 2. Parámetros de calidad del agua monitoreados diariamente y su importancia en el cultivo de camarón.

	Parámetros	Importancia en camaronicultura
Monitoreo diario	Temperatura (Temp)	La temperatura tiene un efecto en los procesos químicos y biológicos en un estanque de cultivo; un aumento de 10 °C causa un aumento al doble o triple en las tasas de reacciones químicas y biológicas (Boyd, 1992; Fontenot, Bonvillain, Kilgen, & Boopathy, 2007). La temperatura controla la solubilidad de los gases en el agua, la velocidad de reacción química y la toxicidad del amonio. El rango ideal para la temperatura se considera entre 25 y 32 °C (Chien, 1992; Boyd, 1989)
	Oxígeno disuelto (DO)	La concentración mínima de oxígeno para mantener una tasa aceptable de sobrevivencia varía con el tiempo de exposición (Páez, 2001; Boyd, 1992). En concentraciones bajas de oxígeno disuelto, los camarones son más susceptibles a enfermedades. Cuando el porcentaje de saturación permanece por debajo de 5 ppm, los camarones presentan bajas tasas de alimentación y crecimiento. La fluctuación diaria de oxígeno disuelto en un estanque aparentemente tiene poco efecto sobre la alimentación y el crecimiento para algunas especies, siempre y cuando la concentración no caiga por debajo de 2 ppm en la mañana (Li, Li, & Wang, 2006). Los valores mínimos recomendados por expertos oscilan entre 4 y 5 ppm (Chien, 1992; Boyd, 1989)
	Salinidad (Sal)	Los organismos que viven en el agua deben mantener sus líquidos vitales a cierta concentración iónica (salinidad). Cuando la salinidad del medio es diferente, los organismos necesitan llevar a cabo ciertas estrategias para poder mantenerla en los niveles propicios, lo cual implica un gasto energético que puede verse reflejado en una menor tasa de crecimiento (Bower & Bidwell, 1978; Fontenot <i>et al.</i> , 2007). Altas concentraciones de salinidad reducen los niveles de oxígeno disuelto en el agua del estanque. Las concentraciones óptimas de salinidad se presentan en los rangos de 15 a 23 ppt (Páez, 2001; Boyd, 1992)
	pH	Cuando el pH tiene valores bajos o elevados causa estrés en los organismos bajo cultivo. Las aguas que presentan un intervalo de pH entre 6.5 y 9.0 son las más apropiadas para la producción acuícola. La reproducción disminuye en valores inferiores a 6.5 o mayores a 9.0. Por debajo de 4.0 hay muerte ácida y por encima de 11.0, muerte alcalina. Aunque los organismos pueden sobrevivir, el rendimiento es pobre en estanques que presentan valores de pH en la mañana de 4 a 6, o de 9 a 10. En muchos sistemas de cultivo, el pH puede aumentar hasta valores de 9 o 10 por periodos cortos sin ocasionar un efecto adverso a los organismos (Martínez, 1994; Arredondo & Ponce, 1998). Concentraciones extremadamente bajas y altas de pH pueden generar un caparazón duro y baja sobrevivencia (Chien, 1992; Boyd, 2001)

reacciones químicas que alteren el equilibrio del sistema. Es importante definir los niveles mínimos y máximos permitidos para cada uno de los parámetros a evaluar (Casillas *et al.*, 2007; Páez, 2001; Boyd, 2000; Chien, 1992; Casillas, Magallón, Portillo, & Osuna, 2006). Los parámetros medioambientales pueden clasificarse en diferentes intervalos de calidad; cada uno de ellos representa un impacto diferente en el ecosistema, los cuales son definidos según el daño al hábitat (cuadro 3).

Materiales y métodos

Área de estudio y adquisición de datos

Para análisis posteriores del modelo de evaluación se ha propuesto estudiar un estanque de

cultivo mediante el monitoreo del conjunto de parámetros rutinarios: pH, oxígeno disuelto, temperatura y salinidad. Como ya se mencionó, aunque el amonio no ionizado es un parámetro extremadamente tóxico para el organismo, no se realizaron mediciones debido a que éste puede controlarse mediante pH y temperatura (Chien, 1992; Boyd, 2001). La automatización de las mediciones permitió evitar algunos errores de monitoreo, como mediciones fuera de tiempo, mal posicionamiento de sensores o falta de mediciones. Durante el monitoreo de parámetros se presentaron fallas en algún dispositivo, por lo que tales mediciones fueron desechadas del conjunto de datos, generando así un registro más confiable. El proceso de monitoreo fue realizado por el Instituto Tecnológico de Sonora (Itson), en conjunto con el Centro de Investigaciones

Cuadro 3. Niveles de clasificación de los parámetros rutinarios.

Parámetros	Unidades	Niveles				
		Hipoxia ¹ ácido ²	Bajo	Normal	Alto	Alcalino ²
Temperatura	(°C)	N/A	0-23	23-30	> 30	N/A
Salinidad	(mg/l)	N/A	0-15	15-25	> 25	N/A
Oxígeno disuelto	(mg/l)	0-2	2-6	> 10	N/A	N/A
pH		0-4	4-7	6.5-9	9-10	10-14

Biológicas del Noreste (Cibnor), en la granja camaronera “Gez Acuícola”, dentro del ejido “Rancho Chapo”, ubicado en Huatabampo, Sonora, México (figura 2). Los estanques de cultivo son alimentados con agua marina proveniente del estero “El Riito”. Para la recolección de muestras se utilizó un estanque de 5 ha, con dimensiones de 100 m de ancho por 500 m de largo por estanque, con pendiente transversal de

0.1% y 0.1% en sentido longitudinal. El estanque requiere de un recambio de entre 5 y 15% diario de agua; no se contemplaron procedimientos de aeración en el mismo. La frecuencia de medición establecida fue de 15 minutos entre lecturas (4 mediciones/hora), debido a que esta frecuencia es suficiente para observar a detalle las fluctuaciones de cada parámetro. El tiempo de monitoreo en el proyecto se estableció dentro



Figura 2. Ubicación del sitio de muestreo de datos en Huatabampo, Sonora, México. Las mediciones de los parámetros de calidad del agua se realizaron en la granja camaronera Gez Acuícola, ubicada en la localidad de Rancho Chapo, en el municipio de Huatabampo, Sonora.

de un periodo de cultivo, correspondiendo a tres meses de almacenamiento de información (junio-agosto de 2007).

Modelo basado en redes neuronales artificiales

Un modelo neuronal se compone de dos fases: un proceso de aprendizaje y la respuesta durante la puesta en funcionamiento. El proceso de diseño de la RNA requiere de una serie de pasos para poder llevarse a cabo. Esta metodología de aprendizaje se puede observar en la figura 3, donde los valores de los parámetros de la calidad del agua se miden y preprocesan, para después ser clasificados y almacenados en una base de datos. Posteriormente son analizados y clasificados según el tipo de daño o condición de la calidad del agua, generando patrones. Por último, los patrones más representativos se utilizan para entrenar a la RNA, según la respuesta que el experto desea obtener.

a) Definición de estados de la calidad del agua

Como ya se mencionó, la calidad del agua puede categorizarse debido a las diferentes situaciones que generan los parámetros en el sistema de cultivo. Cada estado corresponde a una combinación de parámetros, que puede ser óptima o peligrosa para el organismo.

Estas combinaciones son clasificadas según su importancia para la acuicultura, mismas que se describen a continuación:

1. Excelente: todos los parámetros medioambientales están dentro de los niveles permitidos. La calidad del agua es la óptima para el cultivo del camarón.
2. Bueno: algún parámetro físico-químico presenta niveles fuera del rango óptimo; sin embargo, no representa ningún peligro para el cultivo.
3. Regular: algunos parámetros presentan concentraciones que pueden ser perjudiciales para el sistema acuícola. Cierta situación no deseada debe corregirse; por ejemplo, altos niveles de temperatura y pH desencadenan altos niveles de amonio no ionizado.
4. Deficiente: la calidad el agua no es aceptable para el cultivo de la especie. Los valores de los parámetros medioambientales son peligrosos para el organismo, como situación de hipoxia debido a muy bajas concentraciones de oxígeno disuelto.

b) Asociación

El grupo de mediciones se almacena en un vector de información (patrón), mismo que puede representarse de la siguiente manera:

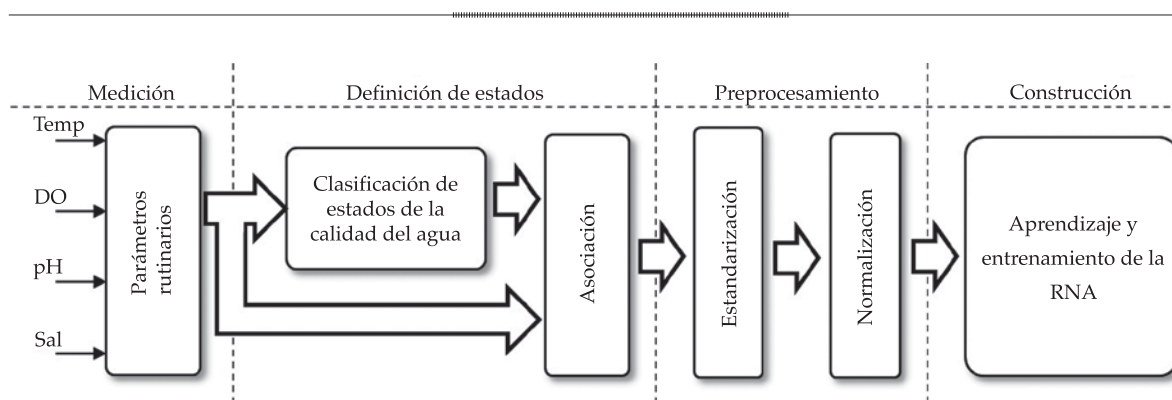


Figura 3. Metodología utilizada para el entrenamiento de aprendizaje en la RNA. La adquisición de muestras, generación de bases de datos y clasificación de situaciones no deseadas son de gran importancia para el buen desempeño de la RNA.

$$y = [x^{temp}, x^{sal}, x^{DO}, x^{pH}] \quad (1)$$

A cada vector se le asocia una clase, la cual se define por el estado de la calidad del agua en dependencia de los niveles permitidos, sus efectos en el estanque y su importancia para el cultivo de la especie (excelente, bueno regular y deficiente). Tal asociación se puede denotar como sigue:

$$\{(y_i, c_i) | i = 1, 2, \dots, n\} \quad (2)$$

donde c_i corresponde a la clase asignada. Cada vector clase se caracteriza por ser un vector orto-normal, el cual presenta un valor unitario en una localidad, dependiendo de la calidad del agua a detectar; es decir, la clasificación que se desea asignar se representará por un 1, mientras que el resto por un '0'.

$$c_i = [c_i^e \ c_i^b \ c_i^r \ c_i^d] \quad (3)$$

donde $c_i^k \in A$, tal que $A = \{0,1\}$.

c) Conjunto de entrenamiento

Un conjunto de entrenamiento se creó para el proceso de aprendizaje de la RNA. Dicho conjunto contiene un total de 28 335 mediciones, mismas que involucran a los cuatro parámetros de la calidad del agua estudiados en este trabajo. Esta base de datos se creó empleando patrones de mediciones reales y simulados debido a que en situaciones normales difícilmente se tiene una amplia variedad de mediciones que comprendan todas las situaciones posibles dentro del diagnóstico de la calidad del agua. Así, el conjunto de patrones de entrenamiento se basa en aquellas mediciones que representan diferentes situaciones en el estado de la calidad del agua.

d) Preprocesamiento

Las RNA son clasificadores muy eficientes y muy utilizados en el área de reconocimiento de patrones. Sin embargo, tal eficiencia puede verse

afectada por una mala selección de patrones en su etapa de entrenamiento. Por tanto, resulta de gran importancia realizar un preprocesamiento a la información generada para obtener una mejor tasa de clasificación (Principe, Luliano, & Lefebvre, 2000). El primer paso consiste en hacer un proceso de estandarización a los datos de entrenamiento, mismos que permitirán tener una media cero y unificar la desviación estándar con el uso de la siguiente ecuación:

$$x^k = \frac{x_i - \bar{x}}{\sigma}, \forall i = 1, 2, \dots, n; \quad (4)$$

donde k es el parámetro de la calidad del agua; \bar{x} , la media; σ , la desviación estándar; n , la cantidad de mediciones realizadas, y x^k es el vector de mediciones estandarizadas.

Debido a la naturaleza de los parámetros de calidad del agua, algunos de ellos presentan escalas mucho más grandes que otros; dentro de una RNA, este comportamiento genera una tendencia de decisión hacia los parámetros de mayor escala. Esto se puede minimizar o evitar normalizando el conjunto de datos de entrada estandarizados mediante la siguiente ecuación:

$$x^w = \frac{x_i^k - \min(x^k)}{\max(x^k) - \min(x^k)}, \forall i = 1, 2, \dots, n; \quad (5)$$

donde x^w es el conjunto de mediciones normalizados.

e) Estructura de una red neuronal artificial

Una red neuronal artificial establece una relación entre un patrón de entrada y uno de salida. Debido a esta característica puede ser empleada para relacionar patrones característicos entre parámetros y situaciones desfavorables para la calidad del agua. Dicho de otra manera, las RNA's proveen una relación no lineal entre parámetros medioambientales (conjunto de entrada) y el estado de la calidad del agua (respuesta deseada).

Una red neuronal está construida por elementos de procesamiento (PE's) conocidos como neuronas, los cuales están interconectados

por pesos y un sesgo (figura 4). Las neuronas están acomodadas en una estructura de capas. La primera capa de la red se conoce como de entrada y en ella se recibe toda la información de los parámetros medioambientales; la final se conoce como capa de salida y es donde las neuronas procesan la clasificación deseada, dando como resultado el estado de calidad del agua. A las capas utilizadas entre la capa de entrada y la de salida se les denomina capas ocultas y realizan todo el procesamiento de la información de la RNA. Gran parte del trabajo consiste en determinar la topología adecuada que permita el correcto funcionamiento de la RNA (Principe *et al.*, 2000; Romero & Shan, 2005; Charma *et al.*, 2003).

El comportamiento de una neurona puede ser expresada con la siguiente ecuación:

$$s_i = \sum_{j=1}^n y_j w_{ij} + b_i \quad (6)$$

Donde w_{ij} son los pesos que interconectan a las diferentes neuronas j de la capa anterior con la neurona actual i ; b_i el sesgo de cada neurona; y_j la salida de la neurona de la capa anterior, y s_i es la nueva salida de la RNA (Sharma, Negi, Rudra, & Yang, 2003; Muttill & Chau, 2006; Chow, 1997). El resultado de una neurona es procesado por una nueva función, llamada función de transferencia, la cual se define como:

$$z_i = \frac{1}{1 + e^{-s_i}} \quad (7)$$

donde z_i es la nueva salida de la i -ésima neurona actual y corresponde a una clase determinada.

f) Construcción del modelo de evaluación de la calidad del agua

El modelo para el diagnóstico de la calidad del agua se construye mediante una red neuronal por retropropagación (*backpropagation*). Debido a que se tienen cuatro parámetros de entrada contenidos en un patrón (y_i), se emplean para alimentar a la red neuronal, obteniéndose como salida las diferentes clases definidas como estados de la calidad del agua (c_i). La cantidad de neuronas en las capas intermedias realizan la parte del procesamiento de la información, pues garantizan el correcto funcionamiento de la RNA. En realidad no existe regla alguna que permita identificar la cantidad de capas y neuronas en cada una de capa; sin embargo, en este trabajo, una RNA con topología de 4, 20, 4 capas fue la que mejor resultados generó (figura 5). La topología de la red neuronal se determinó probando diferentes arquitecturas (capas y neuronas). No obstante, ésta fue la que resultó con el mejor tiempo de procesamiento y respuesta de clasificación. Asimismo, las arquitecturas con un número menor de capas o neuronas no clasificaron de forma adecuada. Dentro de las diferentes arquitecturas se determinó que no existían diferencias significantes con redes de número mayor de neuronas en las capas ocultas ni con mayor número de capas. El proceso de




Figura 4. Modelo de una neurona, en donde x_i es i -ésima entrada, w_i es el peso multiplicador, b es el sesgo y z es la salida.

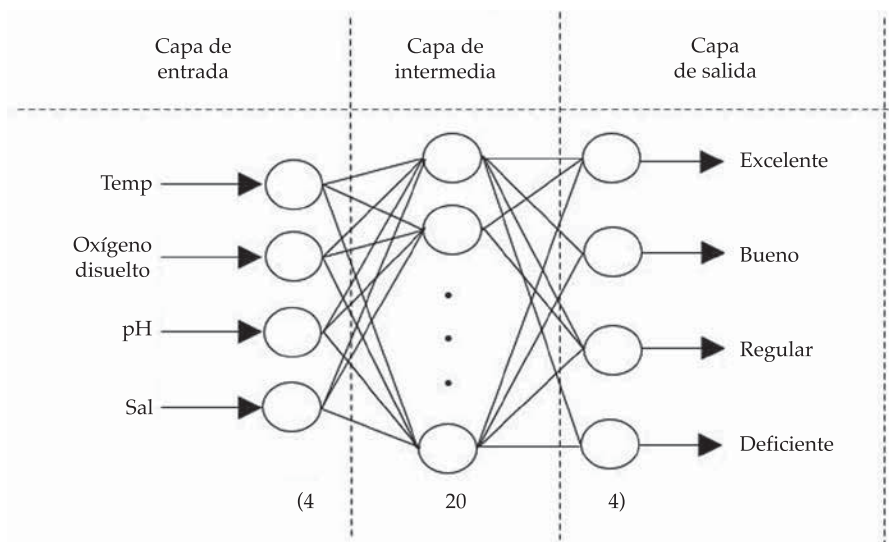


Figura 5. Arquitectura de la red neuronal para clasificar la calidad del agua.

entrenamiento se realizó empleando el *software* de *Matlab*, mediante el *Neural Network Toolbox*. El algoritmo de entrenamiento fue Levenberg–Marquardt debido a eficiencia en los procesos de aprendizaje en las RNA's. La capa de entrada recibe el conjunto de mediciones previamente clasificadas, normalizadas y estandarizadas (concentraciones de los parámetros físico-químicos). La capa de salida recibe el conjunto de vectores de clasificación del estado de deterioro del estanque (excelente, bueno, regular o deficiente). Durante el proceso de entrenamiento se necesitaron unas 500 iteraciones, con un error de entrenamiento MSE obtenido de 0.005%.

Una vez completado el entrenamiento de la RNA, se procede a integrar las salidas en un indicador que conformará el modelo de evaluación. En este caso, los conjuntos de mediciones deberán efectuar los mismos pasos de preprocesamiento del proceso de aprendizaje, tomando en cuenta los parámetros obtenidos de promedio, desviación, máximos y mínimos; después serán clasificados por la RNA. El modelo neuronal evalúa detectando los estados de la calidad del agua en el hábitat. Tales resultados pueden detectar diferentes estados, por lo que deben conjuntarse en un indicador

final, lo cual se hace mediante la integración de las salidas con un proceso de agregación. Dicho proceso conjunta todas las salidas de la RNA, convirtiéndolas en un solo indicador de la calidad del agua (NWQI). La figura 6 muestra esta metodología de evaluación.

g) Agregación

La salida de la red neuronal tiene cuatro variantes del estado de la calidad del agua; por consiguiente, las neuronas de salida se conectan a una etapa de agregación, misma que emplea un sistema difuso para la correcta integración de resultados. Esta etapa emplea un grupo de funciones difusas (μ), las cuales han sido diseñadas dentro de un rango de $[0, 1]$, como se muestra en la figura 7. No existe una regla definida para elegir un tipo de función difusa; sin embargo, las funciones lineales (trapezoidales en este trabajo) facilitan el proceso de agregación. Dichas funciones difusas pueden expresarse mediante la siguiente función:

$$\mu(x, a, b, c, d) = \max \left\{ \min \left\{ \frac{x-a}{b-a}, 1, \frac{d-x}{d-c} \right\}, 0 \right\} \quad (8)$$

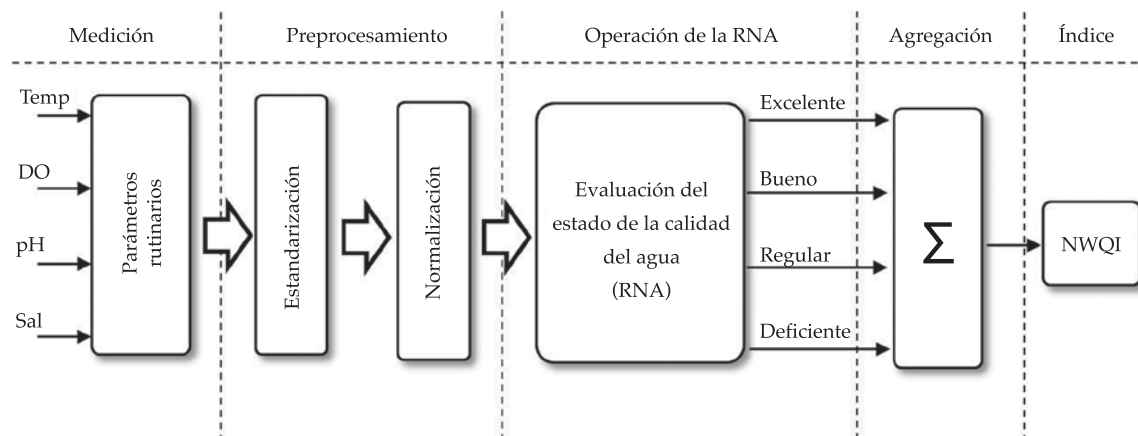


Figura 6. Metodología utilizada para la evaluación de la calidad del agua empleando a la RNA. El proceso de agregación integra las salidas de la RNA y las convierte en un indicador con rango [0, 1].




Figura 7. Funciones difusas empleadas para integrar los resultados de las neuronas de salida de la RNA.

Cada función de salida corresponde a la neurona designada a la misma clasificación y el valor de μ es determinado por el valor de la neurona. La figura 8 muestra este proceso.

El siguiente paso es la integración de las funciones de salida para el cálculo final del índice. Esto se realiza mediante el cálculo del centro de gravedad (centroide) de la función de agregación (figura 8). La función centroide (CF) ha demostrado físicamente ser la más eficiente

para transformar una función difusa a un valor real, al regresar el centro del área bajo la curva formada por la agregación de dichas funciones (Ocampo *et al.*, 2006; Chow, 1997). La función centroide se calcula mediante la siguiente expresión:

$$CF = \frac{\int x \mu_{out}(x) dx}{\int \mu_{out}(x) dx} \quad (9)$$




Figura 8. Proceso de agregación de las salidas de la red neuronal para obtener un el indicador de calidad del agua empleando el centro de gravedad.

Debido a que el método de centro de gravedad calcula el centro del área de una función, el resultado final para CF está restringido desde el centro de la función deficiente (0.078) hasta el centro de la función excelente (0.87), por lo que es necesario normalizar el valor final de CF para reajustarlo en un rango de $[0, 1]$; para hacer esta conversión, se emplea la siguiente expresión:

$$NWQI = \frac{CF - \text{mín}(CF)}{\text{máx}(CF) - \text{mín}(CF)} \quad (10)$$

donde NWQI (Neural Water Quality Index) es el índice normalizado.

Resultados experimentales y discusiones

Bases de datos experimentales

Este trabajo aborda la elaboración de un modelo para el análisis de la calidad del agua en sistemas de cultivo extensivo de camarón. El objetivo principal de dicho modelo es la evaluación precisa de los parámetros más significativos, tratando de analizar posibles niveles y relaciones entre parámetros que sean perjudiciales para la

especie cultivada. Debido a esto, es necesario utilizar un conjunto de datos extraídos de forma directa de un sistema de cultivo, con el afán de comparar los resultados con otros modelos propuestos en la literatura.

Como se mencionó en la sección “Área de estudio y adquisición de datos”, durante el periodo de medición, comprendido entre los meses de julio y agosto, se analizaron registros de parámetros de temperatura, oxígeno disuelto, salinidad y pH. Se creó una base de datos experimental para analizar y comparar el modelo propuesto contra aquellos reportados en la literatura en aplicaciones similares. La frecuencia de muestreo fue de cuatro mediciones por hora, eliminando aquellos días donde los sensores presentaron fallas, por lo que se obtuvo un total de 4 800 muestras para analizar. Para el proceso de evaluación, cada registro de cuatro muestras debe preprocesarse antes de ser introducido en la RNA, mediante los procedimientos de estandarización y normalización. Después, la RNA indicará el estado de la calidad del agua del estanque, según los valores de cada parámetro medido. Es importante remarcar que los valores empleados en el análisis servirán para

mostrar la eficiencia del modelo computacional, por lo que un análisis a otro sistema de cultivo requerirá de mediciones del propio hábitat, generando variaciones en los resultados entre estanques debido a las distintas condiciones en que se manejen de forma individual.

Análisis de parámetros medioambientales

Un análisis previo de cada parámetro de la calidad del agua registrado en la base de datos del estanque de prueba muestra un conjunto de características propias, que influirá de modo directo en el estado de la calidad del agua (figura 9).

En la figura 7a se puede apreciar el comportamiento de la temperatura, la cual oscila por los cambios de la intensidad solar durante el día. El rango óptimo se tiene con los límites superior e inferior, habiendo una ligera tendencia a sobrepasar el límite superior (30 °C), mismo que genera una ligera evaluación negativa en el NWQI. La figura 7b muestra el comportamiento de la salinidad, que en un principio indica concentraciones superiores al límite permitido (25 mg/l) y genera una corrección debido a cambios de agua para bajar los niveles de salinidad. Es de esperarse que las altas concentraciones al inicio del periodo de medición afecte el resultado del NWQI, provocando una evaluación negativa. En la figura 7c, el oxígeno disuelto muestra un comportamiento oscilatorio, debido principalmente a la actividad de microalgas, liberando altas concentraciones de oxígeno durante la mayor intensidad solar y reduciéndolo por las noches. No obstante, las concentraciones de oxígeno disuelto raramente presentan valores críticamente bajos (menores a 2 mg/l). El valor del NWQI se ve afectado con este parámetro, toda vez que se presentan valores bajos, pues en el proceso de entrenamiento se acentuó este comportamiento como no deseable. La figura 7d muestra el historial del pH, que está en niveles óptimos y estables, no generando ninguna complicación en el estanque y por consiguiente en el análisis de NWQI.

Análisis de la calidad del agua

Se propone un análisis comparativo entre índices de la calidad del agua para mostrar el funcionamiento del NWQI. En este trabajo se emplearon los índices propuestas por la CCME (2004) y el descrito en Beltrame, Bonetti y Bonetti (2006), y Ferreira, Bonetti y Seiffert (2011), empleados para realizar análisis similares de la calidad del agua y que pueden utilizarse en sistemas de cultivo de camarón.

La figura 10 muestra evaluaciones realizadas por los tres indicadores en el periodo de prueba. Los resultados obtenidos por la RNA contienen una mayor detección de estados desfavorables en el análisis de la calidad del agua, en comparación con los proporcionados por los índices CCME y (HI)c. Esto se explica por el proceso de entrenamiento de la RNA, donde aquellas concentraciones que representan una condición potencialmente dañina para la calidad del agua fueron clasificadas y aprendidas por la RNA. El resultado es una evaluación de mayor penalización cada vez que se mide una concentración problemática. El uso de la RNA permite generar asociaciones entre concentraciones adecuadas o desfavorables en el ecosistema con un estado de la calidad del agua. Debido a esto, una adecuada selección de patrones en el entrenamiento de la RNA permitirá tener un mejor funcionamiento de la misma en la evaluación. Esto se puede observar toda vez que los valores de oxígeno disuelto decrecen de forma considerable y el índice propuesto evalúa penalizando en mayor medida que los otros índices. De igual forma, al evaluar condiciones óptimas para el cultivo de la especie, se obtiene de haber clasificado concentraciones adecuadas en el ecosistema. Una gran ventaja en el empleo de las RNA es su poder de generalización, es decir, pueden clasificar patrones no incluidos dentro del conjunto de entrenamiento (Sharma et al., 2003; Chow, 1997). Por otra parte, el índice CCME propone un cálculo promediado entre mediciones dentro y fuera de rango. El resultado de la evaluación de parámetros fuera de rango es compensado con mediciones en rango óptimo, lo cual impide




Figura 9. Mediciones correspondientes a los parámetros de calidad del agua durante el mes de junio, julio y agosto (2007).




Figura 10. Comparación entre índices de la calidad del agua. Se puede observar cómo el comportamiento oscilante entre la temperatura y el oxígeno disuelto influye el resultado final.

la detección de situaciones potencialmente dañinas, como problemas de hipoxia. En el caso del índice (*HI*)*c*, se propone una multiplicación de subíndices, los cuales se obtienen mediante la asignación de un peso específico, según la concentración medida. En este caso, el resultado final puede caer a cero radicalmente si algún parámetro muestra un valor fuera de rango. Ambos índices (*CCME* y (*HI*)*c*) muestran evaluaciones con menor variabilidad, en donde rara vez se obtienen muy bajas calificaciones en calidad del agua.

Para efectos de este periodo de prueba, se puede observar una mala evaluación de la calidad del agua al inicio del proceso de medición, en donde se tienen valores del *NWQI* de 0.138, que tienden después a subir. Esto se puede explicar debido a las altas y bajas concentraciones de salinidad y oxígeno disuelto, respectivamente, al inicio del periodo. El comportamiento oscilatorio de temperatura y oxígeno disuelto fue un factor preponderante en el resultado final, pues en conjunto influenciaron de forma considerable la evaluación proporcionada por los indicadores; no obstante, el modelo propuesto permite identificar aquellas concentraciones de mayor peligro en el cultivo del camarón. El cuadro 4 muestra un conjunto de mediciones como ejemplo de evaluaciones elaboradas con

los indicadores propuestos. En este caso se pueden observar variaciones de oxígeno disuelto y temperatura, mismas que se encuentran cerca de los límites permitidos, condición que afecta la evaluación final en el *NWQI*.

Conclusiones

En este trabajo se ha diseñado un modelo computacional para evaluar la calidad del agua para el cultivo de camarón *Litopenaeus vannamei*. Dicho modelo se elaboró empleando técnicas de inteligencia artificial, como las redes neuronales artificiales. En la actualidad existe una gran variedad de modelos de diagnóstico de la calidad del agua; sin embargo, fueron diseñados y aplicados a diferentes tipos de ecosistemas, y no son compatibles con el hábitat del camarón. Como se pudo observar en la sección anterior, se llevó a cabo una serie de análisis de la calidad del agua en estanques de cultivo extensivos empleado dos índices que sirven para el mismo fin: el índice propuesto por la Canadian Council Ministers of Environment (*CCME*, 2004) y Ferreira *et al.* (2010). Los resultados obtenidos y mostrados en la figura 10 muestran una mayor penalización de los resultados empleando el *NWQI*, debido a que se identificaron aquellas situaciones problemáticas y la RNA fue

Cuadro 4. Concentraciones y evaluaciones de la calidad del agua correspondientes a un día de supervisión. Se sombreadon las mediciones que se encuentran fuera del límite permitido.

Día	Hora	Parámetros				Resultados		
		Temp.	DO	Sal	pH	NWQI	CCME	Hic
24-jun-13	00:00	27.5	5.85	23.47	8.4	0.58527044	0.799	0.855
24-jun-13	01:00	27.3	5.32	23.46	8.4	0.54061635	0.784	0.824
24-jun-13	02:00	27	4.99	23.48	8.4	0.46559748	0.774	0.803
24-jun-13	03:00	26.9	4.86	23.5	8.4	0.43612579	0.77	0.794
24-jun-13	04:00	26.7	5.18	23.55	8.4	0.50042767	0.78	0.816
24-jun-13	05:00	26.5	4.66	23.55	8.4	0.37986164	0.763	0.78
24-jun-13	06:00	26.4	4.43	23.55	8.4	0.33163522	0.755	0.763
24-jun-13	07:00	26.3	4.5	23.58	8.4	0.32895597	0.757	0.768
24-jun-13	08:00	26.4	4.94	23.58	8.4	0.44416352	0.772	0.8
24-jun-13	09:00	26.6	5.44	23.57	8.4	0.56205031	0.788	0.832
24-jun-13	10:00	27	6.22	23.59	8.4	0.5772327	0.809	0.876
24-jun-13	11:00	28.3	7.88	23.48	8.4	0.58437736	0.845	0.913
24-jun-13	12:00	29.2	8.43	23.38	8.4	0.56562264	0.855	0.913
24-jun-13	13:00	30.2	8.62	23.39	8.4	0.45577358	0.858	0.913
24-jun-13	14:00	31	8.45	23.46	8.4	0.34056604	0.852	0.913
24-jun-13	15:00	30.7	8.63	23.51	8.5	0.37986164	0.856	0.899
24-jun-13	16:00	30.9	8.33	23.54	8.5	0.34771069	0.85	0.899
24-jun-13	17:00	30.5	7.98	23.54	8.5	0.40754717	0.845	0.899
24-jun-13	18:00	29.9	7.58	23.56	8.5	0.47006289	0.839	0.899
24-jun-13	19:00	29.3	6.95	23.56	8.5	0.53972327	0.826	0.897
24-jun-13	20:00	29	6.39	23.63	8.5	0.57455346	0.813	0.871
24-jun-13	21:00	29	6.28	23.68	8.4	0.57008805	0.81	0.879
24-jun-13	22:00	28.6	5.81	23.73	8.4	0.56651572	0.797	0.855
24-jun-13	23:00	28.4	5.55	23.72	8.4	0.56740881	0.79	0.839

entrenada bajo estos criterios, mismos que se reflejaron al momento de la evaluación. Cabe mencionar que este trabajo propone un avance en el diagnóstico de la calidad del agua en tal tipo de sistemas acuícolas. La creación de un modelo neuronal genera un indicador sobre el comportamiento de los parámetros en el sistema de cultivo. Sin embargo, es necesario realizar mayores estudios para obtener un modelado más completo y preciso del ecosistema en cuestión. La correlación entre parámetros y comportamientos en el manejo del agua es un tema que se ha propuesto como trabajo futuro, pues las mismas redes neuronales permiten de-

tecar estas anomalías, permitiendo establecer una relación entre causa y efecto. Asimismo, se plantea el estudio-modelado de otros parámetros de importancia y su correlación con aspectos de contaminación y/o biológicos del organismo.

Agradecimientos

Los autores quisieran agradecer al Centro de Investigaciones Biológicas del Noreste S.C., unidad Hermosillo, Sonora; al Instituto Politécnico Nacional, y al Consejo Nacional de Ciencia y Tecnología, por el apoyo brindado en la realización del presente trabajo.

Apéndice A

Canadian Council Ministers of the Environment (CCME)

El índice propuesto por la CCME (2004) se calcula mediante una serie de pasos, los cuales se mencionan a continuación:

- a) Se calcula el porcentaje del número de parámetros que presentan valores fuera del rango óptimo:

$$F_1 = \frac{\text{Número de parámetros fallidos}}{\text{Número total de parámetros}} \times 100$$

- b) El porcentaje de mediciones por parámetro fuera de rango se calcula como:

$$F_2 = \frac{\text{Número total de pruebas fallidas}}{\text{Número total de parámetros}} \times 100$$

- c) Si el valor excede el límite superior del rango:

$$\text{excursión}_i = \frac{\text{Límite}_i}{\text{Valor fuera de rango}_i} - 1$$

- d) Si el valor excede el límite inferior del rango:

$$\text{excursión}_i = \frac{\text{Valor fuera de rango}}{\text{Límite}_i} - 1$$

- e) Suma normalizada de excursiones (*nse*):

$$nse = \frac{\sum_{i=1}^n \text{excursión}_i}{\text{number of test'}}$$

- f) Función asintótica de escalamiento [0, 100]:

$$F_3 = \frac{nse}{0.01nse + 0.01}$$

- g) Cálculo del índice CCME:

$$\text{CCME} = 100 - \left(\frac{\sqrt{F_1^2 + F_2^2 + F_3^2}}{1.732} \right)$$

Índice de la calidad hidrológico (HI)_c

El índice (HI)_c se desarrolló para diagnosticar la calidad del agua en un rango continuo mediante una asignación de pesos que varían de 0 a 5. Dichos pesos (VW) y el rango (WR) son asignados de forma particular para cada parámetro de la calidad del agua. VW y VR son multiplicados, para obtener un marcador de cada parámetro como sigue:

$$SVS_{\text{var}} = VW_{\text{var}} * WR_{\text{var}}$$

Después se calcula un indicador, involucrando los diferentes parámetros de la calidad del agua mediante la siguiente ecuación:

$$FSS = SVS_{\text{salinidad}} * SVS_{\text{pH}} * SVS_{\text{temperatura}} * SVS_{\text{oxígeno}}$$

Finalmente, se ajusta el índice a un intervalo de [0 – 10] mediante la siguiente expresión:

$$(HI)_c = 0.8546(FSS)^{0.25}$$

El detalle sobre los pesos empleados, rangos y su respectiva asignación puede consultarse con mayor precisión en Beltrame *et al.* (2006) y Ferreira *et al.* (2011).

Referencias

- ACA (2017). Agencia Catalana del Agua, España. Consultado en abril de 2017. Recuperado de <http://www.gencat.net>.
- Arredondo, J., & Ponce, J. (1998). *Calidad del agua en acuicultura: conceptos y aplicaciones*. México, DF: Ed. AGT, S. A.
- Beltrame, E., Bonetti, C., & Bonetti, J. (2006). Pre-selection of areas for shrimp culture in a subtropical Brazilian Lagoon based on multicriteria hydrological evaluation. *Journal of Coastal Research*, 3(39), 1838-1842.
- Belt, T. (1992). Principals of shrimp culture chemotherapy. *Proceedings of the Special Session on Shrimp Farming*. World Aquaculture Society, Orlando, Florida, USA.
- Boyd, C. (1992). Shrimp pond effluents: Observations of the nature of the problem on commercial farms. *Proceedings of the Special Session on Shrimp Farming*. World Aquaculture Society, Orlando, Florida, USA.
- Boyd, C. (1989). *Water quality management and aeration in shrimp farming*. Fisheries and allied aquaculture departmental

- (p. 70). Series No. 2. Alabama: Agricultural Experiments Stations, Auburn University.
- Boyd, C. (2000). Water composition and shrimp pond management. *Global Aquaculture Advocate*, 3(5), 40-41.
- Boyd, C. (2001). Water quality standards: pH. *Global Aquaculture Advocate*, 4(1), 42-44.
- Bower, C., & Bidwell, J. (1978). Ionization of ammonia in seawater: Effects of temperature, pH and salinity. *Journal of the Fisheries Research of Canada*, 35, 1012-1016.
- Carbajal, J., Sánchez, L., & Progrebnyak, O. (2011). Assessment and prediction of the water quality in shrimp culture using signal processing techniques. *Aquaculture International*, Springer, 19(6), 1083-1104.
- Carbajal, J., Sánchez, L., Carrasco, A., & Martínez, J. (2012). Immediate water quality assessment in shrimp culture using fuzzy inference systems. *Expert Systems with Applications*, Elsevier, 40, 5148-5159.
- Carbajal, J., Sánchez, L., Villa, L., Carrasco, A., & Martínez, F. (2013). Water quality assessment in shrimp culture using an analytical hierarchical process. *Ecological Indicators*, Elsevier, 29, 148-158.
- Casé, M., Eskinazi, E., Neumann, S., Eskinazi, E., Schwamborn, R., & Travassos, A. (2008). Plankton community as an indicator of water quality in tropical shrimp culture ponds. *Marine Pollution Bulletin*, Elsevier, 56(7), 1343-1352.
- Casillas, R., Nolasco, H., García, T., Carrillo, O., & Páez, F. (2007). Water quality, chemical fluxes and production in semi-intensive Pacific white shrimp (*Litopenaeus vannamei*) culture ponds utilizing two different feeding strategies. *Aquacultural Engineering*, 36(2), 105-114.
- Casillas, R., Magallón, F., Portillo, G., & Osuna, P. (2006). Nutrient mass balances in semi-intensive shrimp ponds from Sonora, Mexico using two feeding strategies: Trays and mechanical dispersal. *Aquaculture*, Elsevier, 258, 289-298.
- CCME (2004). *An assessment of the application and testing of the Water Quality Index of the Canadian Council of Ministers of the Environment for selected water bodies in Atlantic Canada. National indicators and reporting office*. Winnipeg: Canadian Council of Ministers of the Environment.
- Chien, Y. (1992). Water quality requirements and management for marine shrimp culture (pp. 144-156). *Proceedings of the Special Session on Shrimp Farming*. World Aquaculture Society, Orlando, Florida, USA.
- Chow, M. (1997). *Methodologies of using neural network and fuzzy logic technologies for motor incipient fault detection*. Singapore: World Scientific.
- Cohen, J., Samocha, T., & Fox, J. (2005). Characterization of water quality factors during intensive raceway production of juvenile *Litopenaeus Vannamei* using limited discharge and biosecure management tools. *Aquacultural Engineering*, Elsevier, 32, 425-442.
- Ferreira, N., Bonetti, C., & Seiffert, W. (2011). Hydrological and water quality indices as management tools in marine shrimp culture. *Aquaculture*, Elsevier, 318, 425-433.
- Fontenot, Q., Bonvillain, C., Kilgen, M., & Boopathy, R. (2007). Effects of temperature, salinity, and carbon: Nitrogen ratio on sequencing batch reactor treating shrimp aquaculture wastewater. *Bioresource Technology*, Elsevier, 98, 1690-1693.
- Gharibi, H., Sowlat, M., Mahvi, A., Mahmoudzadeh, H., Arabalibeik, H., Keshavarz, M., Karimzadeh, N., & Hassani, G. (2012). Development of a dairy cattle drinking Water Quality Index (DCWQI) based on fuzzy inference systems. *Ecological Indicators*, Elsevier, 20, 228-237.
- Gutiérrez, J. (2004). Lógica difusa como herramienta para la bioindicación de la calidad del agua con macroinvertebrados acuáticos en la sabana de Bogotá-Colombia. *Caldasia*, 26(1), 161-172.
- Gutiérrez, J., Riss, W., & Ospina, R. (2006). Bioindicación de la calidad del agua en la sabana de Bogotá-Colombia, mediante la utilización de la lógica difusa neuroadaptativa como herramienta. *Limnología, Caldasia*, 28(1), 45-46.
- Hirono, Y. (1992). Current practices of water quality management in shrimp farming and their limitations. *Proceedings of the Special Session on Shrimp Farming*. Orlando: World Aquaculture Society.
- INECC. (2000). *La calidad del agua en los ecosistemas costeros de México*. México, DF: Instituto Nacional de Ecología.
- Islam, S., Sarker, J., Yamamoto, T., Wahab, A., & Tanaka, M. (2004). Water and sediment quality, partial mass budget and effluent N loading in coastal brackish water shrimp farms in Bangladesh. *Marine Pollution Bulletin*, 48, 471-485.
- Lek, S., Guiresse, M., & Giraudel, J. (1999). Predicting stream nitrogen concentration from watershed features using neural networks. *Water Resources*, Pergamon, 3, 3469-3478.
- Lermontov, A., Yokoyama, L., Lermontov, M., & Soares, M. (2009). River quality analysis using fuzzy Water Quality Index: Ribeira do Iguape River watershed, Brazil. *Ecological Indicators*, Elsevier, 9(6), 1188-1197.
- Li, Y., Li, J., & Wang, O. (2006). The Effects of dissolved oxygen concentration and stocking density on growth and non-specific immunity factors in chinese shrimp, *Fenneropenaeus chinensis*. *Aquaculture*, Elsevier, 256, 608-616.
- Lin, J., Cheng, C., & Chau, K. (2006). Using support vector machines for long-term discharge prediction. *Hydrolog. Sci. J.*, 51(4), 599-612.
- Liu, S., Xu, L., Li, D., & Zeng, L. (2014). Online prediction for dissolved oxygen of water quality based on support vector machine with time series similar data. *Transactions of the Chinese Society of Agricultural Engineering*, 30(3), 155-162.
- Ma, Z., Song, X., Wan, R., Gao, L., & Jiang, D. (2014). Artificial neural network modeling of the water quality in intensive

- Litopenaeus vannamei* shrimp tanks. *Aquaculture*, Elsevier, 433, 307-312.
- Martínez, L. (1994). *Cultivo de camarones peneidos, principios y prácticas*. México, DF: Ed. AGT Editor, S.A.
- Muttill, N., & Chau, K. (2006). Neural network and genetic programming for modelling coastal algal blooms. *International Journal of Environment and Pollution*, 28(3), 223-238.
- NSF (2017). National Sanitation Foundation International. Consultado en abril, 2017. Recuperado de <http://www.nsf.org.es>.
- Ocampo, W., Ferré, N., Domingo, J., & Schuhmacher, M. (2006). Assessing water quality in rivers with fuzzy inference systems: A case of study. *Environment International*, Elsevier, 32, 733-742.
- Páez, F. (2001). *Camaronicultura y medio ambiente*. Instituto de Ciencias del Mar y Limnología (pp. 271-298). México, DF: UNAM.
- Principe, J., Luliano, N., & Lefebvre, W. (2000). *Neural and adaptative systems: Fundamentals through simulations*. New York: John Wiley & Sons.
- Ramesh, S., Sukumaran, N., Murugesan, A., & Rajan, M. (2010). An innovative approach of drinking water quality index: A case study from Southern Tamil Nadu, India. *Ecological Indicators*, Elsevier, 10(4), 857-868.
- Riss, W., Ospina, R., & Gutiérrez, J. (2002). Establecimiento de valores de bioindicación para macroinvertebrados acuáticos de la sabana de Bogotá. *Limnología*, Caldasia, 24(1), 135-156.
- Romero, C., & Shan, J. (2005). Development of an artificial neural network-based software for prediction of power plant canal water discharge temperature. *Expert Systems with Applications*, Elsevier, 29, 831-838.
- Semarnap (1996). *NOM-001-ECOL-1996*. México, DF: Secretaría de Medio Ambiente, Recursos Naturales y Pesca.
- Semarnat (2017). Secretaría de Medio Ambiente y Recursos Naturales. Consultado en abril, 2017. Recuperado de <http://www.semarnat.gob.mx>.
- Sharma, V., Negi, S., Rudra, R., & Yang, S. (2003). Neural network for predicting nitrate-nitrogen in drainage water. *Agricultural Water Management*, Elsevier, 63, 169-183.
- Shen, X., Chen, M., & Yu, J. (2009). *Water environment monitoring system based on neural networks for shrimp cultivation* (pp. 427-431). International Conference on Artificial Intelligence and Computational Intelligence, Shanghai, China.
- Simões, F., Moreira, A., Bisinoti, M., Nobre, S., & Santos, M. (2008). Water Quality Index as a simple indicator of aquaculture effects on aquatic bodies. *Ecological Indicators*, Elsevier, 8, 476-484.

Dirección institucional de los autores

Dr. José Juan Carbajal Hernández
Dr. Luis P. Sánchez Fernández

Instituto Politécnico Nacional
Centro de Investigación en Computación
Laboratorio de Sistemas Inteligentes para la Automatización
Av. Juan de Dios Bátiz s/n, Col. Nueva, Industrial Vallejo,
Gustavo A. Madero
07738 Ciudad de México, MÉXICO
Tel.: +52 (55) 5729 6000, ext. 56540
jcarbajalh@cic.ipn.mx
lsanchez@cic.ipn.mx

Dr. Ignacio Hernández Bautista

Instituto Tecnológico de León
Av. Tecnológico s/n, Industrial Julián de Obregón
37290 León, Guanajuato, MÉXICO
Tel.: +52 (477) 7105 200
ignaciohb@gmail.com

Dr. Jorge Hernández López

Centro de Investigaciones Biológicas del Noreste
Hermosa 101, Los Ángeles
83106 Hermosillo, Sonora, MÉXICO
Tel.: +52 (662) 2131 593
jhlopez04@cibnor.mx