

Modelo computacional para la estimación de crecimiento del *Ambystoma mexicanum* empleando redes neuronales artificiales

Christian Axel Vera-Cortes, José Juan Carbajal-Hernández,
Luis Pastor Sánchez-Fernández

Instituto Politécnico Nacional,
Centro de Investigación en Computación,
México

cverac2021@cic.ipn.mx

Resumen. En México habitan 17 de las 38 especies reconocidas del género *Ambystoma*, 15 de ellas se encuentran en la lista de especies amenazadas. Esto se debe a la degradación del hábitat natural de estas especies que ha llevado a la disminución de sus poblaciones y a la amenaza de su supervivencia. Este trabajo propone la creación de un modelo computacional para obtener estimaciones de parámetros biométricos relacionados de la especie *Ambystoma mexicanum*. Este modelo correlaciona una red neuronal artificial con los parámetros fisicoquímicos con el incremento de peso. Asimismo, se utilizó un modelo autorregresivo para predecir valores medioambientales y alimentar con ellos a la red neuronal. Los resultados del modelo permiten establecer tendencias para determinar el adecuado manejo de la calidad del agua y del alimento, permitiendo obtener mejores tasas de crecimiento del organismo.

Palabras clave: Redes neuronales artificiales, *ambystoma mexicanum*, acuacultura.

Computational Model for Estimating Growth of *Ambystoma Mexicanum* Using Artificial Neural Networks

Abstract. Mexico is home to 17 of the 38 recognized species of the genus *Ambystoma*, 15 of which are on the list of threatened species. This is due to the degradation of the natural habitat of these species that has led to the decline of their populations and the threat to their survival. This study proposes the creation of a computational model to obtain estimates of biometric parameters of the species *Ambystoma mexicanum*. The model correlates an artificial neural network with physicochemical parameters with weight gain. Likewise, an autoregressive model was used to predict environmental values and feed them to the neural network. The result of the model establishes trends to determine the adequate management of water and food quality, allowing better growth rates of the organism.

Keywords: Artificial neural networks, *ambystoma mexicanum*, aquaculture.

1. Introducción

1.1. Antecedentes

En México habitan 17 de las 38 especies reconocidas del género de anfibios *Ambystoma* [1]. A las especies de este género se les conoce como ajolotes o achoques, según la región. Se encuentran distribuidas en la zona montañosa que abarca la Sierra Madre Occidental y se une con el Eje Volcánico Transversal [2]. Dentro las especies que habitan en México, 15 se encuentran en alguna categoría de riesgo según la norma NOM-059-SEMARNAT-2010 [3].

La disminución de las poblaciones de *Ambystoma* se debe a la degradación de su ambiente producto del dragado de lagos, la contaminación y la introducción de especies invasoras [2]. La especie más emblemática del género *Ambystoma* es el subgénero *mexicanum*, conocida comúnmente como ajolote de Xochimilco. Esta especie se encuentra en peligro de extinción según la norma NOM-059-SEMARNAT-2010.

El rescate de ésta y otras especies de ajolotes se realiza mediante la Secretaría de Medio Ambiente y Recursos Naturales (SEMARNAT) en conjunto con la Comisión Nacional de Áreas Naturales Protegidas (CONANP), quienes ha lanzado un plan de acción para su estudio y preservación [3]. Además, existen proyectos locales para preservar las especies de cada región [3].

Entre estos últimos se encuentra el proyecto Chinampa Refugio de la Universidad Nacional Autónoma de México (UNAM) para la preservación del *A. mexicanum* mediante la creación de áreas seguras al interior del lago de Xochimilco [4]. Por otra parte, para la preservación del *A. altamirani*, o ajolote de arroyo de montaña, la Secretaría de Educación, Ciencia, Tecnología e Innovación (SECTEI) ha impulsado un proyecto para la conservación *ex situ* de la especie trasladando ejemplares de su hábitat natural a una unidad de manejo para la conservación de la vida silvestre (UMA) en el Parque Nacional del Desierto de los Leones [5].

Otro esfuerzo de preservación se encuentra en el municipio de Tecámac, en el Estado de México, donde recientemente se descubrió la presencia del ajolote atigrado, especie que se creía extinta [6]. Finalmente, para la preservación del achoque de Pátzcuaro *A. dumerilii*, el Instituto Nacional de Pesca (INAPESCA) a través de Centro Regional de Investigación Acuícola y Pesquera (CRIAP) Pátzcuaro mantiene un programa para el estudio de la especie en condiciones de laboratorio [7].

Adicionalmente, existen manuales para el cuidado de ajolotes en cautiverio. No obstante, estos escasamente incorporan tecnologías de vanguardia para su estudio. Por lo anterior, es evidente que existe un área de oportunidad en la cual desde las ciencias de la computación se pueden hacer aportaciones para la preservación de la especie.

1.2. Estado del Arte

En el área de acuicultura, predecir el crecimiento de organismos acuáticos tiene gran importancia [8]. La forma más común de predecir el crecimiento de una especie es tomar los datos de un cultivo y ajustarlos a una curva como la función de crecimiento de Gompertz o el modelo de crecimiento de von Bertalanffy. No obstante, estos modelos no consideran la variabilidad de condiciones entre grupos que han crecido en

distintas condiciones de cultivo [8]. Por lo anterior, nuevos modelos han sido propuestos que tomen en consideración otras variables.

Entre los modelos propuestos se encuentra uno basado en redes neuronales artificiales que predicen el crecimiento de camarón a partir de datos de alimentación y temperatura [9]. Ampliando el modelo anterior, se desarrolló un modelo que, además de la alimentación y la temperatura, incorpora la edad del camarón, la temperatura del agua y la densidad larvaria como datos de entrenamiento [10]. De manera general, para cualquier especie acuática criada mediante acuicultura, se ha propuesto un modelo de crecimiento basado en redes neuronales que utilicen los parámetros fisicoquímicos de calidad del agua como entrada al sistema [11].

Otros trabajos similares son: el uso de un procedimiento empírico bayesiano para predecir el crecimiento de camarón [12]; el uso de un modelo jerárquico bayesiano para modelar la variabilidad en modelos de crecimiento de camarón [8]; redes neuronales para predicción del crecimiento de peces [13] y para correlacionar peso y longitud en langostas [14].

Finalmente, es importante señalar que al investigar sobre trabajos similares realizados para alguna especie del género *Ambystoma*, sólo se encontró el uso del modelo de von Bertalanffy para estimar la edad de los ajolotes cuando se hacían estudios en especímenes silvestres [15], pero no se encontró ninguna investigación enfocada en su totalidad en desarrollar un modelo de crecimiento.

1.3. Contribución

En este trabajo se presenta un modelo para la predicción de crecimiento del *A. mexicanum*, el cual se pretende sea utilizado por los criadores de la especie para tomar decisiones respecto a su cuidado y crianza. El modelo se hizo a partir de los parámetros fisicoquímicos de calidad del agua, así como datos sobre alimentación. Para generar el modelo anterior se utilizó una red neuronal artificial del tipo perceptrón multicapa entrada mediante el algoritmo de propagación hacia atrás. Por otra parte, para hacer predicciones a futuro se emplearon modelos autorregresivos para hacer una predicción de los parámetros fisicoquímicos.

2. Requerimientos

Para criar al *A. mexicanum* en cautiverio, es necesario contar con las instalaciones adecuadas que incluyan: un acuario o estanque donde habitará el ajolote y que debe contar un buen filtrado, proporcionar una buena iluminación y sustrato [16]. Además, al ser el ajolote una especie acuática, es de vital importancia mantener una calidad del agua adecuada para el correcto desarrollo de la especie [16].

La calidad del agua se mide a través de los parámetros fisicoquímicos de la misma. Los parámetros más importantes que se deben considerar son: potencial de hidrógeno (pH), dureza general (GH), dureza en cuanto a carbono (KH), concentración de nitritos y nitratos, concentración de amonio, concentración de CO₂, porcentaje de oxígeno disuelto, concentración de cloro y temperatura. En la literatura se reportan rangos dentro de los cuales se considera que el agua es segura para la especie en su etapa adulta. Dichos rangos pueden observarse en la Tabla 1.

Tabla 1. Rangos recomendados de valores de los parámetros fisicoquímicos de calidad del agua para la crianza del *Ambystoma mexicanum*.

Parámetro	Unidad	Rango
pH	---	6.5 – 8
Cloro	mg/l	0
Dureza General (GH)	dh	6 – 16°
Dureza en cuanto a carbono (KH)	dh	3 – 10°
Nitritos (NO ₂ -)	mg/l	< 1
Nitratos (NO ₃ -)	mg/l	< 20
Amonio	mg/l	< 0.1
Concentración de CO ₂	mg/l	< 0.5
Saturación de oxígeno disuelto (OD)	%	≥ 80
Densidad	---	1
Temperatura	Celsius	10° – 18°

La temperatura es considerada una de las variables de calidad del agua más importantes [16]. Se reporta que, en especímenes jóvenes, temperaturas de hasta 25°C aceleran el desarrollo, aunque a medida que alcanzan la edad adulta este efecto desaparece [16] y es necesario mantener la temperatura en los rangos mostrados en la Tabla 1. El pH afecta el metabolismo de todos los organismos acuáticos [17].

El amonio no ionizado es el principal compuesto excretado por los animales acuáticos como producto de su proceso metabólico [18]. Un exceso de amonio en el agua hace más difícil para los organismos su excreción, lo que puede llevar a la reducción o paralización de la actividad alimenticia [17]. También hace que los ajolotes sean más susceptibles a enfermedades e inhibe el crecimiento [18].

Los niveles de pH y amonio están, además, estrechamente relacionados entre sí y con los niveles de nitritos y nitratos, ya que estos últimos se forman como consecuencia de las reacciones químicas de los dos primeros. Finalmente, se sabe que el porcentaje de oxígeno disuelto también influye en el metabolismo de los animales acuáticos.

3. Preprocesamiento

3.1. Adquisición de datos

Para este estudio se tomaron los datos reportados en “Mantenimiento en cautiverio de *Ambystoma mexicanum* con dietas enriquecidas con selenio” [19]. Dicho reporte proporciona los datos de un experimento que se realizó durante tres meses. En éste se comparó el incremento de peso de tres grupos de ajolotes sometidos a tres regímenes de alimentación distintos. Todos los grupos tuvieron una dieta a base de tubifex, pero

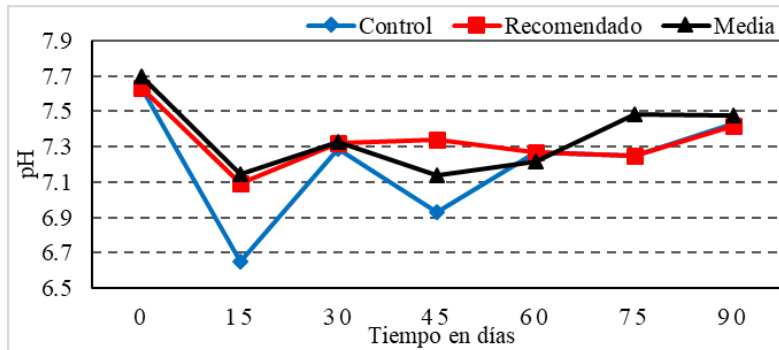


Fig.1. Datos reportados de pH durante un periodo de 90 días.




Fig. 2. Resultado de la interpolación para la variable pH durante un periodo de 90 días.

a dos de ellos se les añadió un suplemento de selenio. A uno de estos grupos se les proporcionó la dosis del suplemento recomendada y al otro la mitad de la dosis recomendada.

Los parámetros fisicoquímicos reportados fueron: pH, amonio, nitritos, nitratos y temperatura. Mientras que las variables biométricas reportadas son: peso, incremento de peso, biomasa y longitud total. No obstante, de esta última solo se reportaron los valores iniciales y finales. Para todas las variables se reportó el promedio quincenal por grupo, lo que da un total de 7 muestras por cada variable. Aunque el conjunto de parámetros es un poco grande, en la Fig. 1 se muestra la gráfica del pH para ejemplificar el tratamiento de los datos efectuados en este trabajo.

3.2. Interpolación

Debido a que la cantidad de datos reportados por parámetro es pequeña, se realizó un remuestreo para estimar los datos por día. Para este fin, se empleó una interpolación por trazadores cúbicos. Se eligió esta técnica después de probar otros métodos [20, 21] y encontrar que era la que arrojaba los mejores resultados para todas las variables.

La interpolación por trazadores cúbicos consiste en obtener un polinomio de tercer grado para cada intervalo entre dos nodos [20] como se muestra a continuación:

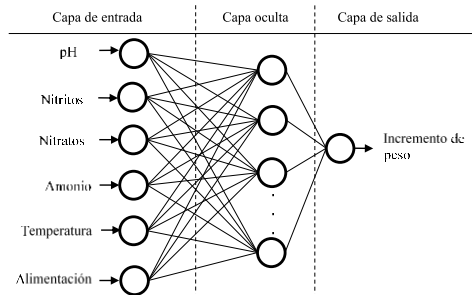


Fig. 3. Arquitectura de la red neuronal.

$$f(x) = ax^3 + bx^2 + cx + d. \quad (1)$$

La interpolación se hizo con el software MATLAB. Dicho software implementa el conjunto subrutinas PCHIP [21]. En la Fig. 2 se puede apreciar el resultado de la interpolación para la variable de pH.

3.3. Normalización

Las redes neuronales requieren de un conjunto de datos con la misma escala, debido a que los parámetros por su naturaleza presentan valores a diferentes escalas, se realizó un proceso de normalización de la siguiente forma:

$$I_i = (L_M - L_m) \times ((p_i - p_{\min}) / (p_{\max} - p_{\min})) - L_m, \quad (2)$$

donde I es el vector de parámetros normalizados, L_M y L_m son los límites superior e inferior del rango en el que se quiere normalizar, p_i es el i -ésimo parámetro a normalizar y p_{\max} y p_{\min} son los valores máximo y mínimo de los parámetros a normalizar.

Para este trabajo se optó por una normalización de $[-1, 1]$, debido a que es la comúnmente utilizada [24]. Sustituyendo en la ecuación (2) se obtiene:

$$I_i = (1 - (-1)) \times ((p_i - p_{\min}) / (p_{\max} - p_{\min})) - 1. \quad (3)$$

La ecuación (3) se aplicó a cada una de las variables empleadas en el estudio, tanto a los parámetros fisicoquímicos como a las variables biométricas.

4. Modelo

4.1. Diseño de la red neuronal artificial

En el presente trabajo, se utilizaron redes neuronales artificiales para correlacionar los parámetros fisicoquímicos de calidad del agua con el incremento de peso del *Ambystoma mexicanum*. Se seleccionaron las RNA debido a que son capaces de aproximar cualquier función continua [22]. Además, resultan útiles para resolver problemas en los que las relaciones entre variables no son evidentes [22].

Las RNA se componen de un conjunto de unidades interconectadas conocidas como neuronas artificiales [23]. Cada una de estas neuronas realiza una suma ponderada de

Tabla 2. Orden de los modelos AR obtenido con el criterio FPE para cada parámetro fisicoquímico.

Parámetro	Grupo	Orden
	Control	17
pHa	Recomendada	6
	Media	6
	Control	18
Nitritos	Recomendada	18
	Media	18
	Control	17
Nitratos	Recomendada	18
	Media	18
	Control	19
Amonio	Recomendada	18
	Media	21
	Control	23
Temperatura	Recomendada	6
	Media	6




Fig. 4. Modelo computacional para la predicción del incremento de peso.

los valores de entrada multiplicándolos por coeficientes conocidos como pesos w y sumando un valor adicional, conocido como sesgo b . El resultado de la suma es introducido a una función matemática conocida como función de activación.

Las RNA están organizadas en capas: en la primera, llamada capa de entrada, se reciben los valores de entrada. En este trabajo los valores de entrada son los parámetros fisicoquímicos y el tipo de régimen de alimentación.

Después, se encuentra una capa oculta. El número de neuronas de esta capa será seleccionado tras una serie de pruebas que se detallarán más adelante. Para esta red se ha escogido una tangente hiperbólica como función activación dada por la siguiente ecuación:

$$f(x) = 2 / (1 + e^{-2x}) - 1. \tag{4}$$

Tras la capa oculta se encuentra la capa de salida. Dicha capa entregará el valor de incremento de peso estimado. Debido a que se entrega un único valor a la salida sólo se necesita una neurona. Ésta tiene una función de activación lineal, comúnmente usada en la capa de salida para problemas de regresión [24], dada por la siguiente expresión:

Tabla 3. Error cuadrático medio para los conjuntos de entrenamiento, validación y prueba de las RNA para la estimación del incremento de peso.

Variable	Número de Neuronas	Entrenamiento	Validación	Prueba
Incremento de peso	2	0.002466276	0.005598149	0.007224309
	3	1.049401056	0.994811983	2.1967806
	4	0.004231471	0.111931298	0.0063346
	5	0.019030662	0.019389994	0.019100361
	6	0.001663586	0.002664131	0.007169914
	7	0.00200717	0.004276588	0.008812153
	8	0.009628086	0.015219814	0.01630441
	9	0.009355713	0.013654767	0.014383261
	10	0.000539841	0.001046942	0.00069038

$$f(x) = x. \tag{5}$$

La arquitectura utilizada se puede observar en la Fig. 3. A este tipo de arquitectura se le conoce como perceptrón multicapa.

4.2. Entrenamiento de la red neuronal artificial

Para determinar los pesos w y sesgos b de la RNA del perceptrón multicapa se utiliza el algoritmo de propagación hacia atrás [24]. El objetivo del algoritmo es minimizar el error cuadrático medio (MSE) entre el valor deseado t y la salida de la red a [25]. El MSE está dado por la ecuación (6):

$$E = (t - a)^2. \tag{6}$$

Para minimizar el MSE se modifican los pesos w y sesgos b de las neuronas. Existen distintos algoritmos para optimizar el entrenamiento. Debido a que el número de parámetros y datos a emplear es reducido, se utilizó la optimización por Levenberg Marquardt. Ésta es más rápida que otros algoritmos para una cantidad moderada de parámetros, aunque tiene como desventaja los requerimientos de almacenamiento [24].

Para el entrenamiento se separó el conjunto de entrada en tres: entrenamiento, prueba y validación. El primer subconjunto contiene el 70% de los datos, es decir, 63 muestras por cada variable, mientras que los dos últimos tienen 15% de los datos cada uno, es decir, entre 13 y 14 muestras por variable. La división se hace aleatoriamente.

Para determinar el número de neuronas de la capa oculta se realizaron una serie de pruebas que consistieron en entrenar una RNA con un número de neuronas de 2 a 10 y seleccionar la que mostrase un mejor desempeño, o bien aquella a partir de la cual el desempeño no mostrase mejorías.

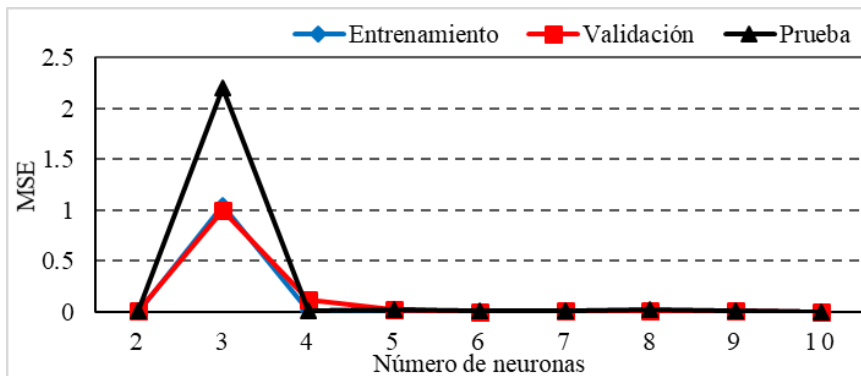


Fig. 5. Evolución del MSE según incrementa el número de neuronas de la RNA para la estimación del incremento de peso.

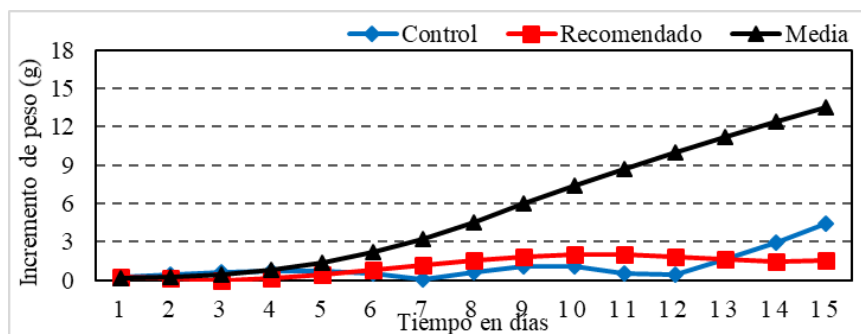


Fig. 6. Error absoluto de la predicción del incremento de peso.

4.3. Predicción

Para hacer predicciones a futuro de los parámetros fisicoquímicos se desarrollaron modelos autorregresivos para cada uno de los parámetros. Un modelo autorregresivo (AR) es una representación de una señal aleatoria en la cual los valores actuales dependen linealmente de los valores pasados. La función general de un modelo AR está dada por la ecuación (7):

$$p_t = \theta_1 p_{t-1} + \theta_2 p_{t-2} + \dots + \theta_i p_{t-i} + \dots + \theta_n p_{t-n} + \varepsilon_t, \tag{7}$$

donde p es el valor de la serie de tiempo de cada uno de los parámetros fisicoquímicos, θ_i es el i -ésimo coeficiente, ε_t es ruido blanco, t es el tiempo de la predicción y n es el orden del modelo.

El orden del modelo es el número de valores previos que se usarán para el cálculo de los coeficientes. Se obtuvo mediante el criterio del error final de predicción (FPE) dado por la ecuación (8):

$$FPE = V_n (1 + 2n/(L - n)), \tag{8}$$

donde L es el número de datos en la serie de tiempo, n es el orden del modelo y V_n es el error de predicción. Los coeficientes obtenidos se pueden observar en la Tabla 2.

El cálculo de los coeficientes AR se realizó mediante el método Yule-Walker implementado en LabVIEW. Una vez obtenidos los modelos AR, se hicieron predicciones de los parámetros que posteriormente fueron introducidos a la RNA. La Fig. 4 ilustra el proceso.

5. Resultados

Los resultados del entrenamiento de la red pueden observarse en la Tabla 3. Se puede apreciar que, para los tres conjuntos, el MSE es menor que 1 en la mayoría de los casos. Para apreciar más claramente la evolución del error, los resultados se muestran en la Fig. 5. En esta se observa que, a partir de 5 neuronas el error deja de disminuir significativamente.

En la Fig. 6 se puede observar el error absoluto de la salida de la RNA al introducir predicciones de los modelos AR y los valores reales para cada uno de los tres regímenes alimenticios. Como se puede observar el error incrementa a medida que aumentan el número de predicciones. Especialmente el grupo de dosis media muestra un aumento significativo después de 7 días de predicción. Por lo que el modelo puede hacer predicciones para este periodo de tiempo como máximo.

6. Conclusiones

En este trabajo se mostró que una red neuronal artificial es capaz de correlacionar los parámetros fisicoquímicos con el incremento de peso. Como se pudo observar, el error de la RNA decrece rápidamente aun cuando el número de neuronas en la capa oculta es pequeño. Esto se debe a que la muestra de datos es pequeña. Además, sólo fue necesaria una única capa oculta por la misma razón. No obstante, es importante mencionar que los datos utilizados fueron tomados durante un periodo corto de tiempo, además, hay parámetros fisicoquímicos importantes que no se tomaron en consideración debido a la carencia de datos disponibles.

Por lo anterior, es importante hacer estudios con datos tomados durante períodos más prolongados que abarquen todo el ciclo de vida del ajolote. Además, es necesario que se tomen medidas de variables importantes que no se consideraron en la realización de los modelos debido a la falta de información. Finalmente, es importante recordar que la mayoría de las especies del género *Ambystoma* que existen en México están amenazadas y que es posible adaptar este modelo a otras especies.

Referencias

1. Amphibian Species of the World: An online reference. Version 6.1, <https://amphibiansoftheworld.amnh.org/index.php>, último acceso 2023/03/06
2. Shaffer, H. B.: Natural history, ecology and evolution of the Mexican "axolotls.". Axolotl Newsletter, vol. 18, no. 5, pp. 5–11 (1989)

3. SEMARNAT: Programa de acción para la conservación de las especies ambystoma spp, SEMARNAT/CONANP (2018)
4. Olguín-Lacunza, M. A., Torres, R.: El ajolote de Xochimilco, a punto de la extinción, UNAM Global (2023)
5. Secretaría de Educación, Ciencia, Tecnología e Innovación, <https://ciencia.sectei.cdmx.gob.mx/2023/10/12/proyecto-8164/>, último acceso 2023/11/14
6. Periódico La Jornada: Buscan con IA contribuir al rescate del ajolote atigrado. La Jornada, (2023)
7. Secretaría de Agricultura y Desarrollo Rural, <https://www.gob.mx/agricultura/articulos/inapesca-al-cuidado-del-achoque?idiom=es>
8. Yu, R., Leung, P.: A Bayesian hierarchical model for modeling white shrimp (*Litopenaeus vannamei*) growth in a commercial shrimp farm. *Aquaculture*, vol. 306, no. 1–4, pp. 205–210 (2010) doi: 10.1016/j.aquaculture.2010.04.028.
9. Yu, R., Leung, P., Bienfang, P.: Predicting shrimp growth: Artificial neural network versus nonlinear regression models. *Aquacultural Engineering*, vol. 34, no. 1, pp. 26–32 (2006) doi: 10.1016/j.aquaeng.2005.03.003
10. Esmaeili, A., Tarazkar, M. H.: Prediction of shrimp growth using an artificial neural network and regression models. *Aquaculture International*, vol. 19, pp. 705–713 (2011) doi: 10.1007/s10499-010-9386-8
11. Deng, C., Gao, Y., Gu, J., Miao, X., Li, S.: Research on the growth model of aquaculture organisms based on neural network expert system. In: 2010 Sixth International Conference on Natural Computation, vol. 4, pp. 1812–1815 (2010) doi: 10.1109/ICNC.2010.5584492
12. Whiting, D. G., Tolley, H. D., Fellingham, G. W.: An empirical Bayes procedure for adaptive forecasting of shrimp yield. *Aquaculture*, vol. 182, no. 3–4, pp. 215–228 (2000) doi: 10.1016/S0044-8486(99)00263-X
13. Benzer, R.: Population dynamics forecasting using artificial neural networks. *Fresenius Environmental Bulletin*, vol. 24, no. 2, pp. 460–466 (2015)
14. Benzer, S., Benli, Ç. K., Benzer, R.: The comparison of growth with length-weight relation and artificial neural networks of crayfish, *Astacus leptodactylus*, in Mogan Lake. *Journal Black Sea/Mediterranean Environment*, vol. 21, no. 2, pp. 208–223 (2015)
15. Zambrano-González, L., Reynoso, V. H., Herrera, G.: Abundancia y estructura poblacional del axolotl (*Ambystoma mexicanum*) en los sistemas dulceacuícolas de Xochimilco y Chalco. Informe final SNIB-CONABIO proyecto No. AS004 (2004)
16. Servín-Zamora, E.: Manual de mantenimiento en cautiverio y medicina veterinaria aplicada al ajolote de Xochimilco (*Ambystoma mexicanum*) en el zoológico de Chapultepec. Tesis de Licenciatura, Universidad Nacional Autónoma de México (2011)
17. Vinatea-Arana, L.: Principios químicos de calidad del agua en acuicultura: una revisión para peces y camarones. UAM-Xochimilco (2006)
18. Corona-Salto, A.: Calidad del agua tratada por un humedal artificial para su uso en cultivo del ajolote *Ambystoma Mexicanum shaw* (*Amphibia urodela*) en Xochimilco D.F. Universidad Autónoma Metropolitana (2012)
19. Espinosa-Román, O.: Mantenimiento en cautiverio de *Ambystoma mexicanum* con dietas enriquecidas con selenio. UAM-Xochimilco (2019)
20. Chapra, S. C., Canale, R. P.: Métodos numéricos para ingenieros. 5ta edn. McGraw-Hill Interamericana, México (2007)
21. The MathWorks, Inc. <https://la.mathworks.com>
22. Zhang, G., Patuwo, B. E., Hu, M.: Forecasting with artificial neural networks: The state of the art. *International Journal of Forecasting*, vol. 14, no. 1, pp. 35–62 (1998)
23. Yáñez-Márquez, C., López-Leyva, L. O., Aldape-Pérez, M.: Neurona artificial de McCulloch & Pitts. Instituto Politécnico Nacional, Centro de Investigación en Computación (2007)

Christian Axel Vera-Cortes, José Juan Carbajal-Hernández, Luis Pastor Sánchez-Fernández

24. Hagan, M. T., Demuth, H. B., Beale, M. H., De-Jesús, O.: Neural network design. 2nd edn. Martin Hagan, Oklahoma (2014)
25. Christiansen, N. H., Voie, E. T., Winther, O., Høgsberg, J.: Comparison of Neural Network Error Measures for Simulation of Slender Marine Structures, *Journal of Applied Mathematics* vol. 4, pp. 1–11 (2014) doi: 10.1155/2014/759834