



UNIVERSIDAD AUTÓNOMA CHAPINGO

DEPARTAMENTO DE INGENIERÍA MECÁNICA
AGRÍCOLA E IRRIGACIÓN

POSGRADO EN INGENIERÍA AGRÍCOLA Y USO
INTEGRAL DEL AGUA

ANÁLISIS DE CALIDAD DE AGUA EN UN SISTEMA ACUAPÓNICO MEDIANTE REDES NEURONALES Y CONGLOMERADOS

TESIS

QUE COMO REQUISITO PARCIAL PARA OBTENER EL GRADO DE:

MAESTRO EN INGENIERÍA AGRÍCOLA Y USO INTEGRAL DEL AGUA



APROBADA




Presenta:

JOSUE SANTILLAN ILLESCAS

Bajo la supervisión de:

DRA. RAQUEL SALAZAR MORENO

Chapingo, Estado de México, noviembre de 2023




ANÁLISIS DE CALIDAD DE AGUA EN UN SISTEMA ACUAPÓNICO
MEDIANTE REDES NEURONALES Y CONGLOMERADOS

Tesis realizada por **JOSUE SANTILLAN ILLESCAS** bajo la supervisión del
Comité Asesor indicado, aprobada por el mismo y aceptada como requisito
parcial para obtener el grado de:

MAESTRO EN INGENIERÍA AGRÍCOLA Y USO INTEGRAL DEL AGUA

DIRECTORA: 

DRA. RAQUEL SALAZAR MORENO

CODIRECTOR: 

DR. JOEL PINEDA PINEDA

ASESOR: 

Ph.D. EFRÉN FITZ RODRIGUEZ

ASESOR: 

Ph.D. IRINEO LORENZO LOPEZ CRUZ

CONTENIDO

1. INTRODUCCIÓN GENERAL.....	12
1.1 LITERATURA CITADA	16
2. REVISIÓN DE LITERATURA.....	18
2.1 Importancia de la acuaponía.....	18
2.2 ¿Qué es la acuaponía?.....	19
2.3 Calidad del agua en Acuaponía	20
2.3.1 Oxígeno disuelto	22
2.3.2 Temperatura	22
2.3.3 pH.....	23
2.3.4 Nitrógeno.....	24
2.4 Redes Neuronales Artificiales	26
2.5 Análisis de sensibilidad de Garson	30
2.6 Análisis de conglomerados	31
2.6.1 K-medias	32
2.7 Literatura citada	33
3. ANÁLISIS DE CALIDAD DE AGUA EN UN SISTEMA ACUAPÓNICO MEDIANTE ANALISIS DE SENSIBILIDAD Y CONGLOMERADOS	38
3.1 Resumen	38
3.2 Abstract.....	39
3.3 INTRODUCCIÓN	40
3.4 Materiales y métodos.....	42
3.4.1 Sensores	43
3.4.2 Sincronización de la información.....	44
3.4.3 Análisis de correlación	45
3.4.4 Redes neuronales	45
3.4.5 Análisis de sensibilidad de Garson.....	45
3.4.6 Método de conglomerados.....	46

3.5	RESULTADOS Y DISCUSIÓN	47
3.6	CONCLUSIONES	56
3.7	Literatura citada	57

LISTA DE CUADROS

Cuadro 1. Frecuencia de monitoreo de los parámetros de calidad de agua (Carbajal-Hernández et al., 2013).....	21
Cuadro 2. Tolerancias generales de calidad de agua para los organismos en acuaponía (Sallenave, 2016; Aleksic, 2020).	22
Cuadro 3. Porcentaje de Nitrógeno total de amoníaco en agua dulce que se encuentra en la forma tóxica de amoníaco no ionizado dependiendo de pH y temperatura (Sallenave, 2016).....	25
Cuadro 4. Análisis de correlación de variables ambientales y de calidad de agua (Testigo)(4-31 de mayo).....	49
Cuadro 5. Análisis de correlación de variables ambientales y de calidad de agua (Testigo)(4-31 de mayo).....	50
Cuadro 6. Rangos de los conglomerados del testigo, experimento 1 y 2.	53

LISTA DE FIGURAS

Figura 1. Partes de un sistema acuapónico (Wongkiev et al, 2020).	20
Figura 2. Diagrama esquemático de una red neuronal artificial alimentada hacia adelante. (Goethals et al., 2007).....	28
Figura 3.Sistema acuapónico de recirculación con cama de tezontle y ubicación de los sensores de calidad de agua.....	43
Figura 4.Variables ambientales y de calidad de agua durante el testigo y los 2 experimentos.	49
Figura 5. Grupos conformados para el testigo con el algoritmo k-means.	51
Figura 6. Grupos conformados para el experimento 1 con el algoritmo k-means.	53
Figura 7. Comportamiento de amonio, nitritos y nitratos durante el desarrollo del primer y segundo experimento.....	56

DEDICATORIAS

A mis padres: Alfredo Santillán y María Illescas

A mis hermanos: Eric y Yanet

A mis amigos: Alejandra, Kevin, Erandi, Natalia, Sebastián, Jessi y Mabel.

Por su incondicional apoyo e inspiración a lo largo de todo este camino.

Gracias por estar en los momentos más importantes de mi vida.

AGRADECIMIENTOS

Al Consejo Nacional de Humanidades, Ciencia y Tecnología (CONAHCyT) por el apoyo para desarrollar mis estudios de posgrado.

A la Universidad Autónoma Chapingo y al Posgrado de Ingeniería Agrícola y Uso integral del Agua por permitirme realizar mis estudios de maestría.

A mis directores Dra. Raquel Salazar Moreno y Dr. Joel Pineda Pineda por su apoyo durante todo el desarrollo de mi investigación y por brindarme su tiempo en los asuntos académicos y de asesorías.

A mis asesores Ph.D Efrén Fitz Rodríguez y Ph.D Irineo Lorenzo López Cruz por compartir su tiempo, conocimientos, experiencias y consejos en pro de mi investigación.

DATOS BIOGRÁFICOS



Datos personales

Nombre: Josue Santillan Illescas.

Fecha de nacimiento: 3 de Julio de 1998

Lugar de nacimiento: Texcoco, Estado de México.

No. Cartilla Militar: D - 4894341

CURP: SAIJ980703HMNCLS03

Profesión: Ingeniero Mecánico Agrícola.

Desarrollo académico

Bachillerato: Preparatoria Agrícola, Universidad Autónoma Chapingo.

Licenciatura: Universidad Autónoma Chapingo. Ingeniero Mecánico Agrícola (2020). Cedula profesional 12586779

RESUMEN GENERAL

ANÁLISIS DE CALIDAD DE AGUA EN UN SISTEMA ACUAPÓNICO MEDIANTE REDES NEURONALES Y CONGLOMERADOS

La acuaponía es una técnica sustentable de producción de alimentos debido a su alta eficiencia en el uso del agua, nutrientes y energía. Sin embargo, es crucial mantener una concentración adecuada de oxígeno disuelto en el estanque de peces para prevenir la mortalidad de estos. El objetivo de este estudio fue analizar el comportamiento de las variables ambientales y de calidad de agua y su relación con el oxígeno disuelto en un sistema acuapónico a pequeña escala. El estudio se realizó en un invernadero en la Universidad Autónoma Chapingo durante el periodo de mayo 2022 a enero 2023 donde se estableció un sistema acuícola de recirculación cerrada y posteriormente un sistema acuapónico con cultivo de Tilapia (*Oreochromis niloticus*) y lechuga (*Lactuca sativa*). Las variables ambientales (temperatura del aire, humedad relativa y radiación fotosintéticamente activa) y de calidad de agua (oxígeno disuelto, temperatura del agua, conductividad eléctrica y pH) fueron monitoreadas durante el experimento. Se implementó una red neuronal para predecir la concentración del oxígeno disuelto en el estanque de peces con un 99.3% de eficiencia. Se realizó un análisis de sensibilidad de Garson para determinar las variables más importantes en el comportamiento del oxígeno disuelto. El análisis anterior se complementó con el análisis de correlación de Pearson, y el análisis de conglomerados tanto en el sistema acuícola como en el sistema acuapónico. La temperatura del agua, el pH y la conductividad eléctrica fueron las variables más influyentes en el oxígeno disuelto. El análisis de conglomerados mostró una tendencia negativa entre la temperatura del agua y del aire con el oxígeno disuelto, además de una relación positiva entre la humedad relativa y el oxígeno disuelto. Este trabajo establece una base para comprender las relaciones entre las variables ambientales y de calidad de agua dentro de un sistema acuapónico.

Palabras clave: Tilapia, pH, predicción, oxígeno disuelto, temperatura.

Tesis de Maestría en Ingeniería Agrícola y Uso Integral del Agua, Universidad Autónoma Chapingo.

Autor: Josue Santillan Illescas

Director de Tesis: Dra. Raquel Salazar Moreno

ABSTRACT

WATER QUALITY ANALYSIS IN AN AQUAPONICS SYSTEM USING ARTIFICIAL NEURAL NETWORKS AND CLUSTERING

Aquaponics is a sustainable food production technique because of its high water, nutrients, and energy efficiency. However, it is crucial to maintain an adequate concentration of dissolved oxygen in the fish tank to prevent fish mortality. The objective of this study was to analyze the behavior of environmental and water variables and their relationship with dissolved oxygen in a small-scale aquaponic system. This study was carried out in a greenhouse at the Autonomous University of Chapingo from May 2022 to January 2023, where a recirculating aquaculture system was first developed, followed by an aquaponics system with Tilapia (*Oreochromis niloticus*) and lettuce (*Lactuca Sativa*). Environmental variables (air temperature, relative humidity, and photosynthetically active radiation) and water quality parameters (dissolved oxygen, water temperature, electrical conductivity, and pH) were monitored throughout the experiment. A neural network was implemented to predict the dissolved oxygen concentration in the fish tank with 99.3% efficiency. Garson's sensitivity analysis was conducted to determine the most influential variables on dissolved oxygen behavior. This analysis was complemented by Pearson correlation analysis and cluster analysis in both the aquaculture and aquaponic systems. Water temperature, pH, and electrical conductivity were the most influential variables on dissolved oxygen. The clustering analysis revealed a negative correlation between water and air temperature with dissolved oxygen, as well as a positive relationship between relative humidity and dissolved oxygen. This work establishes a foundation for understanding the relationships between environmental and water quality variables within an aquaponic system.

Keywords: Tilapia, pH, prediction, dissolved oxygen, temperature.

Tesis de Maestría en Ingeniería Agrícola y Uso Integral del Agua, Universidad Autónoma Chapingo.

Autor: Josue Santillan Illescas

Director de Tesis: Dra. Raquel Salazar Moreno

1. INTRODUCCIÓN GENERAL

El crecimiento de la población mundial representa un reto para la demanda global de alimentos. Para el año 2050 se estima una población de 9 mil millones de personas, esto sumado los efectos del cambio climático, a la sobreexplotación de los recursos, la competencia por tierras, agua y energía afecta directamente a nuestra capacidad de producción de alimentos. Adicional a esto, en la actualidad predominan prácticas como el uso de pesticidas y fertilizantes, que han devastado la biodiversidad y diversos hábitats. Dentro de este contexto, son necesarias estrategias e innovaciones creativas que puedan asegurar una seguridad alimentaria sostenible (Godfray et al., 2010; Tilman et al., 2011).

En los últimos años se han desarrollado diversas investigaciones sobre sistemas de producción novedosos como la acuaponía, ésta se caracteriza por ser un sistema sostenible y menos sensible a los efectos del cambio climático (David et al., 2022; Farrant et al., 2021). La acuaponía se puede definir como una tecnología emergente que combina la acuacultura y la hidroponía, se encarga de recircular el flujo de desechos de los peces hacia las plantas y que éstas puedan asimilar los nutrientes. La acuaponía es un sistema agrícola innovador sin suelo que tiene el potencial de producir cultivos, es considerada como una solución para la producción sustentable y hace frente al crecimiento de la población global y los impactos negativos del cambio climático en la seguridad alimentaria (Wongkiew et al., 2020; Goddek et al., 2015). Existen estudios que comprueban que el uso de agua y nutrientes es más eficiente en la acuaponía que en otros sistemas de producción como la hidroponía o la acuacultura (Cohen et al., 2018; Palm, 2018).

En un sistema acuapónico, el alimento de los peces es la fuente principal de nutrientes tanto para peces como para las plantas. Los subproductos metabólicos de los peces como el nitrógeno amoniacal y el fósforo son liberados en el agua. A medida que el flujo de la acuicultura fluye hacia el componente hidropónico, los nutrientes son absorbidos por las plantas, remediando así el agua antes de que regrese al tanque (Wongkiew et al., 2017; Cerozi et al., 2016). La acuaponía, al ser un sistema combinado, alberga 3 organismos vivos: peces, plantas y bacterias, es por ello que es crucial conocer los parámetros de calidad de agua, ya que ésta es el medio por el cual se transportan los nutrientes hacia las plantas y los peces obtienen oxígeno. Cada uno de estos organismos tiene un rango similar de tolerancias a dichos parámetros, sin embargo, algunos organismos no se desarrollan en óptimas condiciones cuando se acercan a los extremos de los rangos. Los parámetros más importantes en la evaluación de la calidad de agua son: temperatura, pH, concentración de amonio, nitritos, nitratos y el oxígeno disuelto. Es necesario un constante monitoreo de las variables de calidad de agua ya que la composición química de ésta puede afectar a los organismos del sistema (Aleksic et al., 2020; Somerville et al., 2014).

Una de las variables más importantes en la calidad de agua es el oxígeno disuelto ya que afecta directamente la ingesta de alimento de los peces, la tasa de conversión de nutrientes y la resistencia a enfermedades. Concentraciones bajas de oxígeno disuelto afectan negativamente el crecimiento de los productos acuícolas e incluso los pueden llevar a la muerte. Por lo que monitorear el oxígeno disuelto en el agua son factores clave para reducir los riesgos en el sistema acuícola (Culp et al., 2017; Cao et al., 2020).

Medir correctamente las variables de calidad de agua, en especial el oxígeno disuelto, representa un reto ya que un sistema acuícola es un espacio de datos y relaciones no lineales, lo que significa que contiene muchos tipos de ruidos complejos. Debido a esta complejidad y a los factores ambientales, las mediciones de oxígeno disuelto pueden tener un retraso ante las condiciones en tiempo real (Ren et al., 2020).

El oxígeno disuelto en sistemas acuícolas se ve afectado por numerosos factores ambientales y de calidad de agua, existen también variaciones diurnas en las que es más difícil poder predecir el comportamiento del oxígeno (Cao et al., 2020). Por estas razones, es importante conocer las variables que intervienen en la concentración de oxígeno disuelto. Factores como la temperatura, el pH y la concentración de nutrientes pueden afectar la disponibilidad de oxígeno disuelto, por ejemplo, temperaturas elevadas pueden reducir la solubilidad del oxígeno en el agua, lo que aumenta la importancia de un monitoreo constante (Somerville et al., 2014).

El presente estudio se centra en el análisis de la calidad de agua en un sistema acuapónico, enfocado al oxígeno disuelto como una de las variables más importantes, utilizando herramientas como redes neuronales, análisis de correlación, de sensibilidad y de conglomerados. Esto con el fin de comprender los factores que determinan la disponibilidad de oxígeno en un sistema acuapónico.

La hipótesis de este trabajo es que las redes neuronales artificiales y el análisis de sensibilidad de Garson revelen las variables que tienen un impacto significativo en la calidad de agua. Además de identificar grupos de datos que muestre patrones de influencia en la calidad del agua por medio de un análisis de conglomerados, lo que permitirá una comprensión más completa de las relaciones entre las variables ambientales y de calidad del agua.

El objetivo de este estudio fue analizar el comportamiento de las variables ambientales y de calidad de agua y el efecto que tienen en el oxígeno disuelto en un sistema acuapónico a pequeña escala. También predecir la concentración de oxígeno disuelto en un sistema acuícola para realizar un análisis de sensibilidad y destacar las variables que más influyen en la concentración de oxígeno disuelto. Por último, realizar un análisis de conglomerados para identificar patrones críticos que propicien una baja concentración de oxígeno disuelto en un sistema acuapónico.

La organización de este trabajo se basa en 3 capítulos. El primer capítulo presenta una introducción general del tema estudiado, la justificación, los objetivos y la hipótesis.

El segundo capítulo presenta una revisión de literatura donde se habla acerca de la acuaponía, los parámetros de calidad de agua en un sistema acuapónico, redes neuronales artificiales y el método de conglomerados, así como algunos trabajos similares sobre el tema.

El tercer capítulo muestra resultados del análisis de sensibilidad y de conglomerados que sientan base en el entendimiento de las relaciones entre las variables ambientales y de calidad de agua en un sistema acuapónico de pequeña escala.

1.1 LITERATURA CITADA

- Cao, X., Liu, Y., Wang, J., Liu, C., & Duan, Q. (2020). Prediction of dissolved oxygen in pond culture water based on K-means clustering and gated recurrent unit neural network. *Aquacultural Engineering*, 91, 102122. <https://doi.org/10.1016/j.aquaeng.2020.102122>
- Cerozi, S., Fitzsimmons, K. (2016). The effect of pH on phosphorus availability and speciation in an aquaponics nutrient solution. *Bioresour. Technol.* 219 778e781. <https://doi.org/10.1016/j.biortech.2016.08.079>
- Cohen, A., Malone, S., Morris, Z., Weissburg, M., & Bras, B. (2018). Combined Fish and Lettuce Cultivation: An Aquaponics Life Cycle Assessment. *Procedia CIRP*, 69, 551–556. doi:10.1016/j.procir.2017.11.029
- Culp, J.M., Luiker, E., Glozier, N.E., Meding, M., Halliwell, D., Wrona, F.J. (2017). Dissolved oxygen relationships of Under-Ice water column and pore water habitat: implications for environmental guidelines: dissolved oxygen levels under river-ice. *River Res. Appl.* 33 (3), 461–468. <https://doi.org/10.1002/rra.3096>
- David, L.H., Pinho, S.M., Agostinho, F., Costa, J.I., Portella, M.C., Keesman, K.J., Garcia, F. (2022). Sustainability of urban aquaponics farms: An emergy point of view. *J. Clean. Prod.*, 333, 129896 <https://doi.org/10.1016/j.jclepro.2021.129896>
- Farrant, D.N.; Frank, K.L.; Larsen, A.E. (2021). Reuse and recycle: Integrating aquaculture and agricultural systems to increase production and reduce nutrient pollution. *Sci. Total Environ.*, 785, 146859 <https://doi.org/10.1016/j.scitotenv.2021.146859>
- Godfray, H.C.J., Beddington, J.R., Crute, I.R., Haddad, L., Lawrence, D., Muir, J.F., Pretty, H., Robinson, S., Thomas, S.M. (2010). Food Security: The Challenge of Feeding 9 Billion People. *Science*, 327, 812–818. DOI:10.1126/science.11853
- Palm, H. W., Knaus, U., Appelbaum, S., Goddek, S., Strauch, S. M., Vermeulen, T. Kotzen, B. (2018). Towards commercial aquaponics: a review of systems, designs, scales and nomenclature. *Aquaculture International*, 26(3), 813–842. doi:10.1007/s10499-018-0249-z
- Somerville, C., Cohen, M., Pantonella, E., Stankus, A., Lovatelli, A., (2014). Small-scale aquaponic food production, Food and Agriculture Organization of the

United Nation, Rome, p. 261. <https://doi.org/10.1016/B978-0-444-64309-4.00020-9>

Tilman, D., Balzer, C., Hill, J., & Befort, B. L. (2011). Global food demand and the sustainable intensification of agriculture. *Proceedings of the National Academy of Sciences*, 108(50), 20260–20264. doi:10.1073/pnas.1116437108

Vasdravanidis, C., Alvanou, M. V., Lattos, A., Papadopoulos, D. K., Chatzigeorgiou, I., Ravani, M., Liantas, G., et al. (2022). Aquaponics as a Promising Strategy to Mitigate Impacts of Climate Change on Rainbow Trout Culture. *Animals*, 12(19), 2523. <http://dx.doi.org/10.3390/ani12192523>

Wongkiew S., Popp B.N., Kim H., Khanal S.K. (2017). Fate of nitrogen in floating raft aquaponic systems using natural abundance nitrogen isotopic compositions, *Int. Biodeterior. Biodegrad.* 125 24e32. <https://doi.org/10.1016/j.ibiod.2017.08.006>

Wongkiew, S., Hu, Z., Nhan, H. T., & Khanal, S. K. (2020). Aquaponics for resource recovery and organic food productions. In *Current Developments in Biotechnology and Bioengineering* (pp. 475-494). <https://doi.org/10.1016/B978-0-444-64309-4.00020-9>

2. REVISIÓN DE LITERATURA

2.1 Importancia de la acuaponía

La seguridad alimentaria es un tema que está cobrando mucha importancia en el contexto actual de cambio climático y la creciente población mundial. Con el aumento en la presión sobre los recursos naturales y los desafíos asociados al clima, el reto será alimentar a aproximadamente 9 mil millones de personas para el año 2050 (Godfray et al., 2010). Durante los últimos años, los métodos tradicionales de producción y su alto consumo en fertilizantes y pesticidas han causado un impacto negativo en diferentes hábitats, por esta razón es necesario encontrar diferentes alternativas creativas e innovadoras que sean capaces de garantizar la seguridad alimentaria con la mínima afectación al medio ambiente (Tilman et al., 2011).

Para lograr la seguridad alimentaria sostenible es necesario el desarrollo de sistemas de producción de alimentos que sean eficientes en el uso de recursos. Es decir, se necesitan nuevos métodos para reciclar nutrientes y agua, evitando la contaminación de los recursos, la acumulación de nutrientes en el suelo, la eutrofización y maximizando la eficiencia de los sistemas (Martinez et al., 2009). El concepto de “la cuarta revolución agrícola” propone la adopción de diversas tecnologías como la hidroponía la agricultura vertical para garantizar la seguridad alimentaria ante el crecimiento de la población mundial, el aumento de la urbanización, escasez de recursos y cambio climático (De Clerq et al., 2018).

De acuerdo con Verdegem et al. (2006) la acuaponía surge como otra tecnología de producción de alimentos, eficiente en el uso del agua, energía y nutrientes y con mejor gestión de residuos y reciclaje de nutrientes (Piedrahita, 2003). Además, la acuaponía no solo tiene méritos ecológicos, este sistema puede ser económicamente viable al ahorrar costos en tratamientos de agua, fertilizante y al beneficiarse en la obtención de dos productos: vegetales y peces (Liang y Chien, 2013).

2.2 ¿Qué es la acuaponía?

La acuaponía se definió, en un principio, como un sistema acuícola recirculante que incorpora la producción de plantas sin tierra (Rakocy et al., 2012). Otras definiciones de la acuaponía la describen como la fusión de la acuicultura y el cultivo de plantas hidropónicas en un ecosistema artificial conjunto. En este ecosistema, los nutrientes residuales provenientes de la alimentación y el metabolismo de los peces se utilizan, transforman y reciclan para ser usado por las plantas (Palm et al., 2018).

Otros autores definen la acuaponía como un sistema de producción de organismos acuáticos y plantas, en donde, la mayoría de los nutrientes que sustentan el desarrollo de las plantas provienen de los desechos generados al alimentar a los organismos acuáticos (Lennard et al., 2015). La producción de alimentos a través de la acuaponía resulta ser altamente eficiente ya que reutiliza los nutrientes del alimento de peces y el desecho metabólico para el desarrollo de las plantas en un ciclo ecológico (Love et al., 2015).

Los organismos que conviven en este sistema son peces, bacterias y plantas. Los peces son el organismo principal, que se encargan de consumir la fuente de nutrientes inicial (el alimento), posteriormente las bacterias, que realizan la conversión de amonio a nitritos y luego a nitratos que finalmente son aprovechados por las plantas. En este tipo de sistemas, los desechos de los peces se utilizan por completo para producir plantas con un uso eficiente de la fuente de nutrientes (el alimento de peces), lo que tiene un efecto positivo al reducir las descargas de nutrientes en comparación con la acuicultura convencional (Lennard et al., 2015).

El ciclo y transformación de nutrientes (principalmente Nitrógeno en sus formas de amonio, nitritos y nitratos) se lleva a cabo gracias a la acción de 2 grupos de diferentes bacterias, específicamente *Nitrosomonas spp.* para la oxidación del amonio y *Nitrobacter spp.* para la oxidación de nitritos (Palm et al., 2018; Wongkiew et al., 2018; Eck et al., 2019; Rurangwa et al., 2015). La acuaponía

depende de este tipo de consorcios microbianos para mantener la calidad del agua y promover la salud de los peces y las plantas, sin embargo, es muy difícil conocer los organismos que realmente se encuentran en los sistemas (Bartelme, 2019).

Generalmente los sistemas acuapónicos consisten en un tanque de peces, un biofiltro y una cama de crecimiento para las plantas (Figura 1). El biofiltro es el encargado del proceso de nitrificación por medio del consorcio microbiano, sin embargo, existen sistemas que no cuentan con este ya que la nitrificación se puede llevar a cabo en una cama de plantas con sustrato el cual provee de una superficie suficiente para el crecimiento de bacterias. En general, el agua se recircula a través del biofiltro a la cama de plantas y posteriormente al tanque de peces (Wonkiev et al., 2020; Maucieri et al., 2018).




Figura 1. Partes de un sistema acuapónico (Wongkiev et al, 2020).

2.3 Calidad del agua en Acuaponía

La gestión de un sistema acuícola depende totalmente de un buen monitoreo de la calidad del agua. Una baja calidad de agua puede afectar el crecimiento de los peces, retrasar la cosecha e incluso causar enfermedades de los peces que

afecte el rendimiento del sistema. Una producción óptima de peces depende completamente de las calidades físicas, químicas y biológicas del agua, sin importar el tipo de instalación o sistema. Es por ello que la calidad del agua juega un papel importante en la gestión acuícola. La calidad del agua está determinada por variables como: oxígeno disuelto, temperatura, turbidez, pH, amoníaco, nitritos, nitratos, dióxido de carbono, alcalinidad, etc. Sin embargo, las variables más críticas para el monitoreo de la calidad del agua es el pH, temperatura y oxígeno disuelto (Merino et al., 2012; Lafferty et al., 2015).

La calidad del agua en un sistema acuapónico debe ser monitoreada. Carbajal-Hernández et al. (2013) clasifica los parámetros de calidad de agua de acuerdo con la frecuencia de monitoreo (*Cuadro 1*).

Cuadro 1. Frecuencia de monitoreo de los parámetros de calidad de agua (Carbajal-Hernández et al., 2013).

Frecuencia de monitoreo	Parámetros de calidad de agua
Monitoreo diario	Temperatura, oxígeno disuelto, pH, salinidad.
Monitoreo semanal	Amonio, nitritos, nitratos, amoníaco, turbidez.
Monitoreo por petición	Alcalinidad, fósforo, sulfuro de hidrogeno, solidos en suspensión, silicato, clorofila, nitrógeno total, etc.

El agua es el medio en el cual conviven los tres organismos en los sistemas acuapónicos, por lo tanto, la composición del agua puede afectar a cada uno de ellos (Aleksic et al., 2020). Por ello es necesario el monitoreo continuo de la calidad del agua. En el *Cuadro 2* se muestran las tolerancias generales que se tienen que tomar en cuenta para un desarrollo óptimo del sistema.

Cuadro 2. Tolerancias generales de calidad de agua para los organismos en acuaponía (Sallenave, 2016; Aleksic, 2020).

Variable	Tilapia	Bacterias	Plantas
Oxígeno disuelto [mg L ⁻¹]	4 - 8	4 - 8	>3
pH	6 - 8.5	6 – 8.5	5.5 -7.5
Temperatura [°C]	22 – 32	14 – 34	18 – 30
NH ₄ ⁺ [mg L ⁻¹]	<3	<3	<30
NO ₂ ⁻ [mg L ⁻¹]	<1	<3	<1
NO ₃ ⁻ [mg L ⁻¹]	<400	-	150

2.3.1 Oxígeno disuelto

El oxígeno disuelto es considerado la variable más crítica en la evaluación de calidad de agua. Una baja concentración de oxígeno puede disminuir la tasa de crecimiento. La concentración mínima recomendable es de 4 a 5 ppm, de lo contrario, los peces permanecerán en la superficie para captar más oxígeno, tendrán un metabolismo lento y en última estancia, pueden morir por falta de oxígeno (Chien, 1992; Dupont et al., 2018; Palm 2018).

Una baja concentración de oxígeno disuelto suele ser un problema cuando se manejan altas poblaciones de peces. Si los niveles de oxígeno disuelto son bajos, se puede contrarrestar esto con una bomba de aire más grande o más piedras difusoras. No existe problema alguno por un exceso de oxígeno ya que cuando el agua se satura el oxígeno disuelto excedente se libera a la atmosfera. Los niveles de oxígeno disuelto están fuertemente relacionados con la temperatura, a mayor temperatura del agua, menor oxígeno disuelto (Sallenave, 2016).

2.3.2 Temperatura

La temperatura del agua es una variable importante dentro de la calidad del agua, ya que influye en todos los parámetros del sistema acuapónico, por ejemplo, afecta la solubilidad del oxígeno y la toxicidad del amonio. Esta variable también determina el tipo de peces que se pueden criar, el crecimiento de las plantas y el

rendimiento del biofiltro. A altas temperaturas existe poca solubilidad del oxígeno disuelto y más amonio no ionizado (tóxico). La absorción de algunos nutrientes como el calcio para las plantas se puede ver afectado por temperaturas fuera del rango óptimo. Los peces de agua cálida, como el caso de la tilapia (*Oreochromis niloticus*), prefieren un rango de temperatura entre 22 – 32 °C para un crecimiento máximo. Si la temperatura es menor a ese rango el crecimiento se ve ralentizado drásticamente y aumentan las enfermedades. La clave es encontrar una temperatura que se encuentre dentro del rango aceptable para los tres componentes del sistema acuapónico (Somerville et al., 2014; Sallenave, 2016).

2.3.3 pH

El pH es una variable importante en el monitoreo de calidad de agua la actividad de las bacterias nitrificantes. Un pH de aproximadamente 7.8 es óptimo para el crecimiento máximo de las bacterias nitrificantes, mientras que un pH por debajo de 6 hace que disminuya e incluso que se detenga la actividad de las bacterias nitrificantes (Brunty, 1995; Antoniou et al., 1990).

El pH es considerado una variable maestra dentro de la acuaponía, ya que influye en muchas otras variables como la proporción de amoníaco tóxico y no tóxico, así como la tasa de nitrificación. Los peces tienen un rango amplio de pH, mientras que las plantas crecen mejor cuando los niveles están por debajo de 6.5 y las bacterias funcionan óptimamente por arriba de 7.5. Teniendo estos parámetros y encontrando un rango óptimo para todos, los niveles de pH deberían estar entre 6.8 a 7. Sin embargo, es importante mantener un rango más amplio que no implique un control excesivo (Sallenave, 2016).

De acuerdo con Somerville (2014), existen procesos biológicos y químicos que afectan el pH en los sistemas acuapónicos como:

- Proceso de nitrificación: Las bacterias involucradas en este proceso tienden a reducir el pH del sistema acuapónico ya que, durante la conversión de amoníaco a nitrato, las bacterias liberan iones de hidrógeno produciendo concentraciones débiles de ácido nítrico.

- Densidad de población de peces: La respiración de los peces libera dióxido de carbono que se convierte naturalmente en ácido carbónico, lo que disminuye el pH al contacto con el agua. Este efecto se ve más pronunciado cuando los peces están más activos como sucede con temperaturas más altas.
- Fitoplancton: Mientras que la respiración de los peces baja el pH al liberar dióxido de carbono, la fotosíntesis del fitoplancton elimina ese dióxido y eleva el pH.

2.3.4 Nitrógeno

El nitrógeno entra al sistema principalmente por el alimento de los peces (Ru et al., 2017). Este elemento es importante ya que las plantas se encargan de absorberlo en forma de nitrato (Xu et al., 2012). El proceso de nitrificación se puede ver afectado por otras variables como pH y el oxígeno disuelto, así como la absorción de nitrógeno de las plantas que se ve afectada por la concentración ambiental de dióxido de carbono (Yildiz et al., 2017; Wongkiew et al. 2017). El nitrógeno, en sus diferentes formas, juega un papel importante en la calidad del agua.

Amoníaco y amonio

El amoníaco es la primera forma de nitrógeno que existe en el sistema acuapónico debido a que es el principal residuo nitrogenado excretado por los peces, principalmente por las branquias y mínimamente en la orina. El amoníaco puede existir en dos formas: no ionizado (NH_3) conocido como amoníaco e ionizado (NH_4^+) conocido como ion amonio (Sallenave, 2016).

La proporción de NH_3 y NH_4^+ en el agua depende completamente del pH y la temperatura del agua. Un pH menor a 7.0 propicia que la mayoría del nitrógeno está en forma de NH_4^+ (>95%) que es menos tóxico, sin embargo, a medida que el pH aumenta la toxicidad también ya que existirá más NH_3 . En el Cuadro 3 se muestra cómo varía el porcentaje de amoníaco tóxico (no ionizado) en función del pH y la temperatura del agua (Sallenave, 2016; Somerville et al., 2014).

Cuadro 3. Porcentaje de Nitrógeno total de amoníaco en agua dulce que se encuentra en la forma tóxica de amoníaco no ionizado dependiendo de pH y temperatura (Sallenave, 2016).

pH	Temperatura (°C)										
	10	16	18	20	21	22	24.5	26	28	30	32
7.0	0.18	0.294	0.342	0.396	0.425	0.457	0.546	0.607	0.697	0.799	0.95
7.2	0.29	0.466	0.540	0.625	0.673	0.723	0.863	0.958	1.10	1.25	1.25
7.4	0.46	0.736	0.854	0.988	1.06	1.14	1.36	1.50	1.73	1.98	2.36
7.6	0.73	1.16	1.35	1.56	1.67	1.80	2.14	2.36	2.72	3.11	3.11
7.8	0.16	1.82	2.12	2.44	2.63	2.80	3.35	3.68	4.24	4.84	4.84
8.0	1.82	2.86	3.31	3.82	4.10	4.39	5.21	5.75	6.56	7.46	8.77
8.2	2.86	4.45	5.16	5.92	6.34	6.79	8.01	8.75	10.0	11.3	13.2
8.4	4.45	6.88	7.93	9.07	9.69	10.3	12.1	13.0	15.0	16.8	19.5
8.6	6.88	10.5	12.0	13.7	14.5	15.5	17.9	19.4	21.8	24.3	27.7
8.8	10.5	15.7	17.8	20.0	21.2	22.5	25.7	27.8	30.7	33.7	37.8
9.0	15.6	22.7	25.6	28.4	29.9	31.5	35.5	37.7	41.2	44.6	49.0
9.2	22.7	31.8	35.2	38.6	40.4	42.1	46.5	49.2	63.8	56.1	70.8
9.4	31.8	42.5	46.3	49.9	51.8	53.5	58.0	60.5	63.8	66.9	70.7
9.6	42.5	53.9	57.7	61.3	63.0	64.6	68.5	70.8	73.6	76.2	85.9
9.8	53.9	65.0	68.4	71.6	72.9	74.3	77.6	79.4	81.6	83.6	85.9
10.0	65.0	74.6	77.4	79.9	81.0	82.1	84.5	85.9	87.5	89.0	90.6

El amoníaco puede causar envenenamiento a los peces desde 1 mg L⁻¹. Si los peces se exponen por un tiempo prolongado a niveles por encima de este nivel, pueden causar daños al sistema nervioso y branquias, lo que limita el correcto funcionamiento de procesos fisiológicos que pueden causar la muerte a los peces. Niveles cercanos a 1 mg L⁻¹ por periodos muy prolongados pueden causar estrés y la incidencia de enfermedades (Sallenave, 2016; Somerville et al., 2014). El proceso por el cual se elimina el amoníaco del agua se llama transformación del nitrógeno, comúnmente conocido como nitrificación (Tyson et al., 2004).

En un pH ácido (<7) el amoníaco se convierte en amonio que es menos tóxico, y un pH alto propicia una alta toxicidad del amoníaco. Sin embargo, los peces no son los únicos afectados por el amoníaco. Concentraciones mayores a 4 mg L⁻¹ pueden inhibir o reducir drásticamente la efectividad de las bacterias e incluso la

muerte lo cual incrementaría aún más los niveles de amoníaco (Somerville et al., 2014).

Nitritos

Los nitritos son la segunda forma de nitrógeno en el sistema ya que son producto de la oxidación del amonio por medio de las bacterias nitrificantes. Primero, el amonio y el amoníaco son convertidos a nitratos (NO_2) gracias a bacterias *Nitrosomonas*. Este proceso requiere de oxígeno y produce acidez lo que reduce el pH. Los nitritos también pueden causar envenenamiento a peces y plantas. Si los niveles de nitritos superan los límites establecidos es probable que se tenga un efecto tóxico en el agua del sistema. Los nitritos comienzan a ser tóxicos para los peces desde los 5 ppm, sin embargo, para Tilapia los niveles se deben mantener menores a 1 ppm (Deswati, 2018; Sallenave, 2016; Zou, 2016).

Nitratos

Los nitritos son convertidos a nitratos por el proceso de nitrificación encargado de las bacterias *Nitrobacter*. Este proceso, al igual que el anterior, requiere de suficiente oxígeno en el agua. Los nitratos no presentan un riesgo de toxicidad como las otras formas de nitrógeno, estos sirven como nutrientes para las plantas del componente hidropónico (Wongkiew et al., 2017; Vasdravanidis et al., 2022).

Los nitratos son la principal fuente de nitrógeno de las plantas, ya que la concentración de nitratos es mayor que las concentraciones de NH_4^+ y NO_2^- en sistemas acuapónicos (Hu et al., 2015). Los peces pueden soportar niveles de 400 mg L^{-1} , sin embargo, niveles muy altos de nitratos ($>250 \text{ mg L}^{-1}$) pueden tener impactos negativos en las plantas dependiendo la especie. Los niveles recomendados son entre 5 y 150 mg L^{-1} (Somerville et al., 2014).

2.4 Redes Neuronales Artificiales

Una red neuronal artificial (ANN por sus siglas en inglés) es un modelo de caja negra con una gran capacidad como modelo predictivo, ya que puede

proporcionar una predicción si es entrenada con todos los caracteres que describen una situación desconocida (Lek et al., 1999).

Las redes neuronales artificiales imitan el funcionamiento del cerebro humano procesando y transformando señales de entrada en salidas (Wesolowski et al., 2012). Una neurona humana recibe la señal por medio de la dendrita, posteriormente la señal se procesa en el cuerpo celular y se transmite a lo largo del axón hacia la terminal de salida, en donde, se puede conectar hacia otras neuronas o mandar una señal hacia órganos o músculos (Lantz, 2015). Una neurona artificial funciona de la misma manera. Las variables de entrada, covariables o también conocidas como predictores son señales de entrada que proveen de información para el reconocimiento de patrones. Cada una de estas variables se le asigna un número que pondera su importancia (Zhang, 2016). Estas señales ponderadas son sumadas y procesadas por una función de activación.

Este proceso anterior se puede expresar matemáticamente como se muestra en la Ecuación 1.

$$y(x) = \Phi \left(\sum_{i=1}^n W_i \cdot X_i \right) \quad (1)$$

En donde y es la señal de salida, Φ es la función de activación, X_i es la variable de entrada y W_i es el peso asignado a cada variable, en donde $i = 1, 2, \dots, n$ es el número de variables de entrada.

En las redes neuronales artificiales, los nodos de entrada reciben las variables de datos crudos, y el nodo de salida aplica la función de activación a la información combinada de los nodos de entrada. La topología de las redes se organiza en capas, es decir, todos los nodos de entrada constituyen una capa. Las redes que solo cuentan con nodos de entrada y salida se denomina una red de una sola capa. Este tipo de redes se utilizan para clasificaciones simples. Tareas más complejas necesitan de un mayor número de capas (Haykin, 2008; Zhang, 2016). La Figura 2 muestra una red neuronal alimentada hacia adelante

llamada perceptrón multicapa con: la capa de entrada, la capa oculta y la capa de salida.

Antes del proceso de entrenamiento, todos los valores de pesos y sesgos de la red se establecen de manera aleatoria. En el proceso de entrenamiento se presenta un conjunto de datos (vectores de entrada y de salida) y tiene como objetivo que la red neuronal aprenda de los datos dados. La red calcula los pesos de acuerdo con los vectores de entrada y se calcula el error entre la salida estimada por la red y la la salida real. Este error sirve para modificar los pesos de tal forma que la salida de la red se aproxime a la salida real. Este proceso se hace de manera iterada hasta reducir el error. Después de la etapa de entrenamiento, la red neuronal artificial puede ser validada utilizando datos independientes a este proceso (Goethals et al., 2007).

Existen diferentes tipos de redes neuronales artificiales que sirven para resolver varios tipos de problemas. Las ANN se pueden aplicar para modelado predictivo y para clasificación. Las ANN más populares son las redes neuronales multicapa alimentadas hacia adelante (Feed-Forward Multilayer Neural Network) con el algoritmo de entrenamiento de retropropagación (Hagan et al., 1996; Goethals et al., 2007).




Figura 2. Diagrama esquemático de una red neuronal artificial alimentada hacia adelante. (Goethals et al., 2007)

Las redes neuronales se pueden clasificar de acuerdo con dos grandes características: su topología y su tipo de aprendizaje.

Topología de las redes neuronales

Las redes neuronales se pueden clasificar en dos grupos de acuerdo con su topología:

- Alimentada hacia adelante: Una red neuronal con este tipo de topología solo tiene una condición, la información solo debe fluir desde la entrada hasta la salida en una sola dirección, sin retroalimentación. No existen limitantes para el número de capas, tipo de función de transferencias o el número de conexiones. Ejemplos de este tipo son: perceptrón, perceptrón multicapa y redes retropropagadas (Krenker et al., 2011).
- Redes recurrentes: Es similar a una red de alimentación directa con la diferencia que no existe límite con respecto a los bucles de retroalimentación. Es decir, la información ya no se transmite solo en una dirección, si no que se puede transmitir en sentido contrario. Ejemplos de esta red son: redes Hopfield, Elman y redes de memoria a corto y largo plazo (LSTM, por sus siglas en inglés: "Long Short Term Memory") (Krenker et al., 2011).

2.4.1.1 Tipos de aprendizaje

El aprendizaje es la característica más importante de las redes neuronales. Este proceso se basa en el ajuste de cada uno de los pesos de la red para obtener la salida deseada, de tal manera que la red pueda responder por sí sola a situaciones diferentes a las ya aprendidas. De acuerdo con Quesada et al. (1994) todos los métodos de aprendizaje pueden ser englobados en dos categorías:

- Aprendizaje supervisado: Se presentan dos vectores a la red, uno de entrada y otro de salida. La salida de la red se compara con los valores deseados y los pesos de la red se modifican hasta que el error sea aceptable.

- Aprendizaje no supervisado: En este caso solo se usa información local durante todo el proceso. No se utiliza un vector de salida, es decir, solo existen vectores de salida. Los algoritmos de entrenamiento se encargan de modificar los pesos para que la salida de la red sea consistente. Este proceso extrae características del conjunto de entrenamiento y agrupa por clases y similitudes.

2.5 Análisis de sensibilidad de Garson

Propuesto por Garson (1991), este análisis es una técnica utilizada en el contexto de redes neuronales, el cual, infiere la significancia (también referida como importancia relativa) de las variables de entrada de acuerdo con los pesos de una red neuronal artificial entrenada (Ghanizadeh, 2020).

El proceso general de este análisis se puede resumir en los siguientes pasos:

- Calcular las contribuciones de cada variable: Se analiza cómo cada variable de entrada contribuye a la salida del modelo, calculando el peso de cada conexión entre neuronas.
- Sumar las contribuciones por variable: Las contribuciones de las conexiones de cada variable se suman para determinar la importancia global de cada variable.
- Normalización: Los valores obtenidos se normalizan para expresar la importancia relativa en cada variable en términos de porcentaje.

Las ecuaciones del proceso anterior son las siguientes:

Primero, para cada neurona oculta i , se multiplica los valores absolutos del peso de la variable de entrada y el peso de la variable de salida. Esto se realiza para cada variable de entrada j (Ecuación 2).

$$P_{ij} = |W_{ij}| \times |W_{i1}| \quad (2)$$

En donde w_{ij} es el peso de la neurona de entrada j en la neurona oculta i , y $|W_{i1}|$ es el peso de la neurona de salida 1 en la neurona oculta i .

Para cada neurona oculta i , P_{ij} se divide entre la suma de todos los P_{ij} para las variables de entrada a fin de calcular Q_{ij} (Ecuación 3).

$$Q_{ij} = \frac{P_{ij}}{P_{i1} + P_{i2} + \dots + P_{im}} \quad (3)$$

El primer subíndice representa el número de neuronas ocultas, el segundo representa la variable de entrada y m representa el número total de entradas.

Posteriormente, para cada variable de entrada j se calcula S_j (Ecuación 4)

$$S_j = Q_{1j} + Q_{2j} + Q_{3j} + \dots + Q_{kj} \quad (4)$$

En donde k es el número de neuronas ocultas.

Por último, se calcula la importancia relativa (RI) con la Ecuación 5.

$$RI_j = S_j \times \frac{100}{S_1 + S_2 + S_3 + \dots + S_m} \quad (5)$$

Este análisis proporciona información valiosa sobre qué variables influyen en las predicciones de un modelo.

2.6 Análisis de conglomerados

El análisis de conglomerados (*clustering* en inglés) está diseñado para dividir un conjunto de datos en grupos o conglomerados (*clusters*) de tal manera que los datos dentro de un grupo son más similares entre ellos que los que se encuentran en otros grupos (Zhu et al., 2018). Cada grupo puede ser representado por un vector que tiene parámetros y atributos. Dentro de este análisis, es fundamental el cálculo de una media de distancia o similitud entre los patrones respectivos. Para patrones con propiedades métricas se pueden utilizar medidas de distancias, mientras que para patrones cualitativos es mejor utilizar medidas de coincidencia. Una medida de distancia comúnmente utilizada es la distancia euclidiana (Ecuación 6), sin embargo, esta medida no es invariante a la escala por lo que se recomienda estandarizar los valores antes de calcular la distancia (Moertini, 2002).

$$dist(d_i, c_k) = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2 + (z_2 - z_1)^2 + \dots} \quad (6)$$

En donde $dist(d_i, c_k)$ es la distancia euclidiana entre los datos d_i hacia el centroide c_k ; “x”, “y” y “z” son las coordenadas de los puntos de los centroides.

El método de k-medias (*k-means* en inglés) es uno de los más comunes dentro del análisis de conglomerados y se describe a continuación.

2.6.1 K-medias

K-medias es un algoritmo de agrupamiento que particiona una colección de datos en grupos, encontrando un centro de cluster para cada grupo de manera que una función de costo (o función objetivo) de similitud (o distancia) se minimice. En este método se utiliza la distancia euclidiana (Ecuación 6) como medida de distancia entre los datos. Lo que busca este método es minimizar la función objetivo (la suma de las distancias euclidianas entre cada dato y su respectivo centroide), esto se lleva a cabo con la actualización de centroides (Ecuación 7) (Moertini, 2002).

$$c_i = \frac{1}{|G_i|} \sum_{k, x_k \in G_i} x_k \quad (7)$$

En donde G_i es el tamaño de el grupo G_i , c_i son las coordenadas del centroide del grupo i , x es la posición del dato k . Esta ecuación calcula el centro de masas del centroide.

En resumen, los pasos del análisis de conglomerados con el algoritmo de k-medias son los siguientes (Khan et al., 2004):

1. Inicialización de centroides: Son elegidos aleatoriamente los centros iniciales de los k grupos.
2. Asignación de puntos: Se le asigna un grupo a cada valor de acuerdo con la distancia euclidiana (Ecuación 6) entre el valor y el centroide de cada grupo.

3. Cálculo de nuevos centroides. Se recalcula la posición de los centroides de acuerdo con el centro de masa de cada grupo (Ecuación 7).
4. Iteración: Se repite el paso 2 y 3 hasta que no exista cambio en las coordenadas del centroide.

2.7 Literatura citada

- Aleksić, N., & Šušteršič, V. (2020). Analysis of application of aquaponic system as a model of the circular economy: A review. *Recycling and Sustainable Development*, 13(1), 73-86.
- Antoniou, P., Hamilton, B., Koopman, R., Jain, B., Holloway, Lyberatos, G., and Svoronos S., A. (1990). Effect of temperature and pH on the effective maximum specific growth rate of nitrifying bacteria. *Water Res.* 24:97-101.
- Bartelme, R.P., Smith, M., C., Sepulveda-Villet, O. J., Newton, R.J. (2019). Component microenvironments and system biogeography structure microorganism distributions in recirculating aquaculture and aquaponic systems. *mSphere* 4, e00143-19.
- Brunty, J. L. (1995). Biological filtration for ornamental fish production and factors affecting total ammonia nitrogen and nitrite removal rates. M.S. Thesis, Univ. of Fla., Gainesville.
- Cao, X., Liu, Y., Wang, J., Liu, C., & Duan, Q. (2020). Prediction of dissolved oxygen in pond culture water based on K-means clustering and gated recurrent unit neural network. *Aquacultural Engineering*, 102122. doi:10.1016/j.aquaeng.2020.102122
- Chien, Y. (1992). Water quality requirements and management for marine shrimp culture. In: *Proceedings of the Special Session on Shrimp Farming*. World Aquaculture Society, USA, pp. 144–156
- De Clerq, M., Vats, A., Biel, A. (2018). Agriculture 4.0: The Future of Farming Technology; World Government Summit: Dubai, UAE.
- Dupont, C., Cousin, P., & Dupont, S. (2018). IoT for Aquaculture 4.0 Smart and easy-to-deploy real-time water monitoring with IoT. 2018 Global Internet of Things Summit (GloTS). doi:10.1109/giots.2018.8534581

- Eck, M., Sare, A., Massart, S., Schmutz, Z., Junge, R., Smits, T., Jijakli, M. (2019). Exploring Bacterial Communities in Aquaponic Systems. *Water* 11, 260.
- Fijani, E.; Barzegar, R.; Deo, R.; Tziritis, E.; Konstantinos, S. (2019). Design and implementation of a hybrid model based on two-layer decomposition method coupled with extreme learning machines to support real-time environmental monitoring of water quality parameters. *Sci. Total Environ.* 648, 839–853.
- Merino, G., Barange, M., Blanchard, J. L., Harle, J., Holmes, R., Allen, I., ... & Rodwell, L. D. (2012). Can marine fisheries and aquaculture meet fish demand from a growing human population in a changing climate?. *Global Environmental Change*, 22(4), 795-806.
- Garson G.,D. (1991). Interpreting neural-network connection weights. *AI Expert* 6:46–51
- Ghanizadeh, A. R., Heidarabadizadeh, N., & Jalali, F. (2020). Artificial neural network back-calculation of flexible pavements with sensitivity analysis using Garson's and connection weights algorithms. *Innovative Infrastructure Solutions*, 5(2). doi:10.1007/s41062-020-00312-z
- Goethals, P. L. M., Dedeker, A. P., Gabriels, W., Lek, S., & De Pauw, N. (2007). Applications of artificial neural networks predicting macroinvertebrates in freshwaters. *Aquatic Ecology*, 41(3), 491–508. doi:10.1007/s10452-007-9093-3
- Hagan, M. T., Demuth HB, Beale M. (1996). *Neural network design*. PWS Publishing Company, Boston
- Haykin S. O, editor. (2008). *Neural networks and learning machines*. 3rd ed. New Jersey: Prentice Hall.
- Lafferty, K. D., Harvell, C. D., Conrad, J. M., Friedman, C. S., Kent, M. L., Kuris, A. M., ... & Saksida, S. M. (2015). Infectious diseases affect marine fisheries and aquaculture economics. *Annual review of marine science*, 7, 471-496.
- Krenker, A., Bešter, J., & Kos, A. (2011). Introduction to the artificial neural networks. *Artificial Neural Networks: Methodological Advances and Biomedical Applications*. InTech, 1-18.
- Lantz B, editor. (2015). *Machine learning with R*. 2nd ed. Birmingham: Packt Publishing, 2015:1.

- Lek, S., & Guégan, J. F. (1999). Artificial neural networks as a tool in ecological modelling, an introduction. *Ecological modelling*, 120(2-3), 65-73.
- Lennard, W.A., Leonard, B.V. (2006). A comparison of three different hydroponic subsystems (gravel bed, floating and nutrient film technique) in an Aquaponic test system. *Aquacult. Int.* 14, 539e550
- Li, T., Lu, J., Wu, J., Zhang, Z., Chen, L. (2022). Predicting Aquaculture Water Quality Using Machine Learning Approaches. *Water*, 14, 2836. <https://doi.org/10.3390/w14182836>
- Liang, J.Y., Chien, Y. H. (2013). Effects of feeding frequency and photoperiod on water quality and crop production in a tilapia–water spinach raft aquaponic system. *Int. Biodeterior. Biodegradation* 85, 693–700 <https://doi.org/10.1016/j.ibiod.2013.03.029>.
- Love D., C., Jillian P., F., Ximin Li, Elizabeth S. H, Laura G., Ken S., and Richard E.T. (2015). Commercial Aquaponics Production and Profitability: Findings from an International Survey. *Aquaculture* 435 (January): 67–74. <http://dx.doi.org/10.1016/j.aquaculture.2014.09.023>
- Martinez, J., Dabert, P., Barrington, S., and Burton, C. (2009). Livestock waste treatment systems for environmental quality, food safety, and sustainability. *Bioresour. Technol.* 100 (22), 5527–5536 <https://doi.org/10.1016/j.biortech.2009.02.038>. PubMed
- Maucieri, C., Nicoletto, C., Junge, R., Schmautz, Z., Sambo, P., Borin, M. (2018). Hydroponic systems and water management in aquaponics: a review. *Ital. J. Agron.* 13, 1e11. <https://doi.org/10.4081/ija.2017.1012>.
- Moertini, V. (2002). Introduction to Five DataClustering Algorithms Clustering Algorithm. *Integral*, 7(2).
- Piedrahita, R.H. (2003). Reducing the potential environmental impact of tank aquaculture effluents through intensification and recirculation. *Aquaculture* 226 (1-4), 35–44 [https://doi.org/10.1016/S0044-8486\(03\)00465-4](https://doi.org/10.1016/S0044-8486(03)00465-4).
- Quesada, F. J., Graciani, M. A., Bonal, M. T., & Díaz-Mata, M. A. (1994). Aprendizaje con redes neuronales artificiales. *Ensayos: Revista de la Facultad de Educación de Albacete*, (9), 169-180.
- Ren, Q., Zhang, L., Wei, Y., & Li, D. (2018). A method for predicting dissolved oxygen in aquaculture water in an aquaponics system. *Computers and Electronics in Agriculture*, 151, 384–391. [doi:10.1016/j.compag.2018.06.013](https://doi.org/10.1016/j.compag.2018.06.013)

- Rurangwa, E., Verdegem .C.,J. (2015). Microorganisms in recirculating aquaculture systems and their management. *Rev. Aquac.* 7, 117–130.
- Sallenave, R. (2016). Important water quality parameters in aquaponics systems. College of Agricultural, Consumer and Environmental Sciences.
- Somerville C, Cohen M, Pantonnella E, Stankus A, Lovatelli A. (2014). Small-scale aquaponic food production, Food and Agriculture Organization of the United Nation, Rome, p. 261. <https://doi.org/10.1016/B978-0-444-64309-4.00020-9>
- Tyson, R. V., Simonne, E. H., White, J. M., & Lamb, E. M. (2004). Reconciling water quality parameters impacting nitrification in aquaponics: the pH levels. In *Proceedings of the Florida State Horticultural Society* (Vol. 117, pp. 79-83).
- Vasdravanidis, C., Alvanou, M.V., Lattos, A., Papadopoulos, D.K., Chatzigeorgiou, I., Ravani, M., Liantas, G., Georgoulis, I., Feidantsis, K., Ntinis, G.K., et al. (2022). Aquaponics as a Promising Strategy to Mitigate Impacts of Climate Change on Rainbow Trout Culture. *Animals*, 12, 2523. <https://doi.org/10.3390/ani12192523>
- Verdegem, M.C., Bosma, R.H., and Verreth, J.A. (2006). Reducing water use for animal production through aquaculture. *Int. J. Water Resour. Dev.* 22 (1), 101–113 <https://doi.org/10.1080/07900620500405544>
- Wesolowski, M., Suchacz, B. (2012). Artificial neural networks: theoretical background and pharmaceutical applications: a review. *J AOAC Int*;95:652-68.
- Wongkiew, S., Hu Z., Chandran, K., Lee, J. W., Khanal, S. K. (2017) Nitrogen transformations in aquaponic systems: a review. *Aquac Eng* 76:9–19. <https://doi.org/10.1016/j.aquaeng.2017.01.004>
- Wongkiew, S., Hu, Z., Nhan, H. T., & Khanal, S. K. (2020). Aquaponics for resource recovery and organic food productions. *Current Developments in Biotechnology and Bioengineering*, 475–494. doi:10.1016/b978-0-444-64309-4.00020-9
- Xu, G., Fan, X., Miller, A. (2012). Plant nitrogen assimilation and use efficiency. *Annu Rev Plant Biol* 63:153–182. <https://doi.org/10.1146/annurev-arplant-042811-105532>
- Yildiz, H. Y., Robaina, L., Pirhonen, J., Mente, E., Domínguez, D., Parisi, G. (2017). Fish welfare in Aquaponic systems: its relation to water quality with

an emphasis on feed and Faeces—a review. *Water* 9.
<https://doi.org/10.3390/w9010013>

Zhang, Z. (2016). A gentle introduction to artificial neural networks. *Annals of Translational Medicine*, 4(19), 370–370. doi:10.21037/atm.2016.06.20

Zhu, X., Zhang, S., Hu, R., He, W., Lei, C., & Zhu, P. (2018). One-step Multi-view Spectral Clustering. *IEEE Transactions on Knowledge and Data Engineering*, 1–1. doi:10.1109/tkde.2018.2873378

Zou, Y., Hu, Z., Zhang, J., Xie, H., Guimbaud, C., & Fang, Y. (2016). Effects of pH on nitrogen transformations in media-based aquaponics. *Bioresource Technology*, 210, 81–87. doi:10.1016/j.biortech.2015.12

3. ANÁLISIS DE CALIDAD DE AGUA EN UN SISTEMA ACUAPÓNICO MEDIANTE ANALISIS DE SENSIBILIDAD Y CONGLOMERADOS

3.1 Resumen

La acuaponía es una técnica sustentable de producción de alimentos que es eficiente en el uso del agua, energía y nutrientes. Sin embargo, bajos niveles de oxígeno disuelto pueden causar la muerte de los organismos acuáticos en cuestión de minutos, por esta razón el objetivo de este estudio fue analizar las variables ambientales, de calidad de agua, y concentración de amonio, nitritos y nitratos, que influyen en la concentración de oxígeno disuelto, a través del análisis de correlación y de sensibilidad utilizando redes neuronales, así como de conglomerados, lo anterior, es con el fin de identificar patrones de comportamiento de las variables y construir diferentes escenarios críticos que se pueden presentar en un sistema acuapónico a pequeña escala. El estudio se realizó en un invernadero ubicado en la Universidad Autónoma Chapingo, México, durante el periodo de mayo 2022 – enero 2023, en donde se estableció el sistema acuícola (sin lechugas) con cultivo de Tilapia (*Oreochromis niloticus*) y a partir de octubre 2022, se implementó un sistema acuapónico, durante dos ciclos del cultivo de lechuga (*Lactuca sativa*). Se monitorearon las variables ambientales (temperatura del aire, humedad relativa y radiación fotosintéticamente activa) y de calidad de agua (temperatura del agua, conductividad eléctrica, pH y oxígeno disuelto). Las variables que más influyeron en la concentración de oxígeno disuelto fueron: temperatura del agua, pH, humedad relativa y conductividad eléctrica. Para la construcción de los conglomerados la información se dividió en día y noche, ambos casos mostraron una tendencia negativa entre oxígeno disuelto y temperatura del agua. Los conglomerados identificados revelaron condiciones críticas que propician una baja concentración de oxígeno en el agua. Esta investigación proporciona una base para el entendimiento de las relaciones entre variables ambientales y de calidad de agua dentro de un ambiente acuapónico.

Palabras clave: Tilapia, lechuga, oxígeno disuelto, temperatura, pH

Tesis de Maestría en Ingeniería Agrícola y Uso Integral del Agua, Universidad Autónoma Chapingo.

Autor: Josue Santillan Illescas

Director: Dra. Raquel Salazar Moreno

3.2 Abstract

Aquaponics is a sustainable food production technique that is efficient in water, energy, and nutrient use. However, low levels of dissolved oxygen can lead to the death of aquatic organisms within minutes. For this reason, the objective of this study was to analyze environmental variables, water quality, and concentrations of ammonia, nitrites, and nitrates, which influence dissolved oxygen concentration. This was done through correlation and sensitivity analysis using neural networks, as well as clustering. The aim was to identify behavioral patterns of variables and construct different critical scenarios that may occur in a small-scale aquaponic system. The study was conducted in a greenhouse at the Autonomous University of Chapingo, Mexico, from May 2022 to January 2023. An aquaculture system (without lettuce) was established with Tilapia (*Oreochromis niloticus*), and from October 2022, an aquaponic system was implemented, involving two cycles of lettuce cultivation (*Lactuca sativa*). Environmental variables (air temperature, relative humidity, and photosynthetically active radiation) and water quality parameters (water temperature, electrical conductivity, pH, and dissolved oxygen) were monitored. The variables that most influenced dissolved oxygen concentration were water temperature, pH, relative humidity, and electrical conductivity. For clustering, the information was divided into day and night, both cases showing a negative trend between dissolved oxygen and water temperature. The identified clusters revealed critical conditions that lead to low oxygen concentration in the water. This research provides a foundation for understanding the relationships between environmental and water quality variables within an aquaponic environment.

Keywords: Tilapia, lettuce, dissolved oxygen, temperature, pH.

3.3 INTRODUCCIÓN

Para el año 2050 se estima una población entre 8.3 y 10.9 miles de millones de personas (Bringezu et al., 2014), esto aunado al cambio climático representa un riesgo inminente a la seguridad alimentaria. El Banco Mundial (2010) sostiene que será necesario incrementar al doble la tasa existente de crecimiento del rendimiento agrícola, pero disminuyendo el deterioro ambiental causado por dicha actividad. Debido a lo anterior, las técnicas de producción de alimentos deben ser más eficientes a fin de producir más con menos recursos.

La acuaponía es una tecnología emergente cuyo fin es la recuperación de nutrientes combinando la acuacultura con la hidroponía, en donde el desecho metabólico de los peces es aprovechado por las plantas (Wongkiew et al., 2020). Dicha tecnología surge como una alternativa bajo el enfoque sostenible de producción.

Al ser un sistema combinado, requiere de un constante monitoreo y control para garantizar el correcto desarrollo de peces y plantas, las variables ambientales a controlar son diversas (luz, temperatura, pH, humedad, etc.) , y pueden llegar a ser sistemas muy complejos a medida que se incrementa el número de variables y la escala de producción (Yanes et al., 2020; Karimanzira, 2021).

Asimismo, la calidad del agua puede afectar a los organismos que intervienen en el sistema (peces, bacterias y plantas) (Aleksic, 2020). Dentro de las variables de control más importantes para mantener la calidad del agua se encuentran: el oxígeno disuelto, pH, conductividad eléctrica, temperatura, la concentración de amonio, nitritos y nitratos (Carbajal-Hernández et al., 2013).

El oxígeno disuelto es una de las variables más importantes de calidad de agua para la acuaponía, ya que se tiene que mantener dentro de niveles óptimos ($> 4 \text{ mg L}^{-1}$) para garantizar la supervivencia de los peces y la correcta transformación de amonio mediante las bacterias nitrificantes (Sallenave, 2016). El oxígeno disuelto tiene un efecto inmediato y drástico en sistemas acuapónicos, los peces podrían morir en cuestión de horas cuando se exponen a bajos niveles de

oxígeno disuelto. Sin embargo, el monitoreo de este parámetro es desafiante ya que los dispositivos precisos para la medición pueden ser muy costosos o difíciles de encontrar (Somerville, 2014).

De acuerdo con Somerville (2014), el pH del agua tiene un gran impacto en todos los aspectos de la acuaponía, mayormente en las bacterias y en las plantas. Un pH entre 6.0 a 6.5 facilita la disponibilidad de los nutrientes hacia las plantas. Un pH mayor a 7.5 dificulta la disponibilidad de los nutrientes e incluso puede causar deficiencias de hierro, fósforo y manganeso. Por otro lado, las bacterias nitrificantes experimentan dificultades a un pH menor a 6, y su capacidad de transformar amonio en nitritos y luego en nitratos se reduce en condiciones ácidas, en contraste, un pH elevado puede incrementar la toxicidad del amonio (Yanes et al., 2020; Somerville, 2014). La mayoría de los peces utilizados en acuaponía tienen un rango más amplio de tolerancia a pH que va desde 6 a 8.5.

La temperatura influye en todos los parámetros del sistema acuapónico, ya que afecta la solubilidad del oxígeno disuelto y la toxicidad del amonio. A altas temperaturas existe poco oxígeno disuelto y más amonio no ionizado (tóxico). Asimismo, se limita la absorción de algunos nutrientes para las plantas como el calcio. Peces de agua cálida y bacterias nitrificantes pueden prosperar a temperaturas del agua entre 22 a 30 °C, mientras que la temperatura óptima para las plantas en acuaponía está entre 18 – 30 °C (Somerville, 2014; Aleksic, 2020).

El nitrógeno, en sus diferentes formas, juega un papel importante en la calidad del agua. El nitrógeno entra al sistema acuapónico principalmente por la comida de los peces, los desechos se concentran mayormente en forma de amonio (NH_4^+). La concentración de amonio depende, también, de los niveles de pH, temperatura y la salinidad. El amonio es nitrificado por las bacterias y convertido en nitritos (NO_2^-) y después en nitratos (NO_3^-). Las 3 formas de nitrógeno pueden ser aprovechadas por las plantas, sin embargo, el nitrato es el más disponible y no representa tanta toxicidad para los peces como las otras formas (Somerville, 2014; Ebeling et al., 2006).

El impacto negativo del amonio depende de la especie, la Tilapia muestra síntomas de envenenamiento por amonio desde 1 mg L^{-1} . Prolongar la exposición por arriba de este nivel puede causar daños a los peces, incluso la muerte. Los nitritos, al igual que el amonio, puede causar problemas en los peces desde concentraciones de 0.25 mg L^{-1} , aunque de acuerdo con Aleksic (2020) la concentración de NO_2^- debe estar por debajo de 1 mg L^{-1} . La exposición prolongada a niveles altos de nitritos puede resultar en estrés, enfermedades y muerte (Somerville, 2014).

El objetivo de este estudio fue analizar las variables ambientales, de calidad de agua y concentración de amonio, nitritos y nitratos de un sistema acuapónico a pequeña escala, y que influyen en la concentración de oxígeno disuelto. Se llevará a cabo un análisis de correlaciones, análisis de sensibilidad utilizando redes neuronales, así como conglomerados, con el fin de identificar los patrones de comportamiento de las variables y construir diferentes escenarios críticos que se pueden presentar en el sistema acuapónico a pequeña escala.

3.4 Materiales y métodos

El presente estudio se realizó en un invernadero perteneciente al área de Preparatoria Agrícola, en el campo experimental San Ignacio de la Universidad Autónoma Chapingo, Texcoco, México (Latitud: $19^\circ 29' 55'' \text{ N}$ Longitud: $98^\circ 53' 16'' \text{ O}$).

Se estableció un sistema acuapónico de recirculación cerrada entre el tanque de peces y una cama con sustrato de tezontle (Figura 3). El área de plantas fue de 0.72 m^2 y el volumen de agua utilizado en el tanque de peces fue de 150 L. El experimento se llevó a cabo en tres etapas, la primera del 4 al 31 de mayo del 2022 con 260 peces de tilapia (*Oreochromis niloticus*) con una biomasa total de 260 g en el estanque de peces, para conocer las condiciones de calidad del agua en la parte acuícola, esta etapa se llevó a cabo sin cultivo de lechuga y se utilizó como testigo. La segunda fase del experimento fue del 31 de octubre al 28 de noviembre, utilizando una biomasa inicial de 2.54 kg correspondiente a 16 tilapias. La tercera fase se llevó a cabo desde el 5 de diciembre de 2022 hasta el

3 de enero de 2023, con una biomasa inicial de 3.14 kg de 16 tilapias. El tanque de peces fue oxigenado con una bomba de aire de 370W y piedras difusoras, el agua fue recirculada con un flujo de 2.3 L min^{-1} . Durante el desarrollo del testigo se colocó una resistencia sumergible de 100 W dentro del tanque de peces mientras que en las otras fases del experimento se utilizaron 2 resistencias de 100 W para mantener la temperatura del agua en el rango óptimo.




Figura 3. Sistema acuapónico de recirculación con cama de tezontle y ubicación de los sensores de calidad de agua.

3.4.1 Sensores

Se instaló un sistema de sensores para el monitoreo de las variables ambientales y de calidad de agua. El sensor HMP60 se utilizó para medir la temperatura ambiental (T_a , $^{\circ}\text{C}$) y la humedad relativa (HR, %) dentro del invernadero y se colocó a una altura de 1.8 m. El sensor Apogee SQ-520 se colocó dentro del invernadero a una altura de 3.2 m para la medición de la radiación fotosintéticamente activa (PAR, $\mu\text{mol m}^{-2} \text{s}^{-1}$). El sensor de oxígeno disuelto (OD, mg L^{-1}) se colocó en el centro del tanque a una profundidad de 30 cm. Los sensores anteriores se conectaron a un Datalogger CR1000X de la marca Campbell en el cual se registraron los datos durante el desarrollo del experimento. Para el monitoreo de pH, conductividad eléctrica (CE) y

temperatura del agua (T_w , °C), se empleó un sensor GroLine HI981420 colocado en el tanque de peces a una profundidad de 30 cm. Los sensores de calidad del agua se ubicaron como se muestra en la Figura 3.

Tratamiento de datos y valores fuera de rango

En la información generada en los experimentos, existieron valores fuera de rango e incluso datos faltantes, debido al uso continuo de los sensores, fallas en el equipo y a factores ambientales externos. Esto podría tener consecuencias en el tiempo de entrenamiento de la red y su desempeño (Cao et al., 2021; Shi et al., 2019). Los valores fuera del rango de 3 desviaciones estándar se eliminaron y se reemplazaron con una interpolación lineal simple (Ecuación 8), el mismo procedimiento se aplicó a los datos faltantes en intervalos de tiempo corto.

$$y = y_1 + \frac{(y_2 - y_1) * (x - x_1)}{x_2 - x_1} \quad (8)$$

En donde: y_1 y y_2 son los valores conocidos en los tiempos x_1 , x_2 ; y es el valor estimado en el tiempo x .

3.4.2 Sincronización de la información.

Los dos sistemas de sensores descritos anteriormente son capaces de medir con un intervalo de tiempo de 15 minutos, sin embargo, debido a factores externos (fallas eléctricas, calibración o mantenimiento) la información recabada se encontró desincronizada en los tiempos de medición. Es por ello que se empleó una metodología de sincronización de datos aunada al tratamiento de valores fuera de rango.

La función `synchronize` de MATLAB 2022b crea una nueva serie de tiempo para sincronizar dos vectores de datos, por medio de un método de interpolación. Para este trabajo, la serie de tiempo que se utilizó para la sincronización fue la registrada en el Datalogger por lo que la única información interpolada fue la recabada por el GroLine. Se utilizó una interpolación lineal al ser un intervalo de tiempo corto.

3.4.3 Análisis de correlación

Se llevó a cabo el análisis de correlación con el fin de determinar las relaciones entre las variables medidas durante el experimento (Ta, HR, PAR, OD, pH, CE y Tw). Los coeficientes de correlación entre las variables se obtuvieron utilizando la Ecuación 9 implementada en Matlab 2023.

$$\rho_{XY} = \frac{Cov(X,Y)}{\sqrt{Var(X) \cdot Var(Y)}} \quad (9)$$

En donde ρ_{XY} es el coeficiente de correlación de Pearson entre las variables X y Y, $Cov(X,Y)$ representa la covarianza entre las dos variables y $Var(X)$ la varianza de la variable X, $Var(Y)$ la varianza de la variable Y.

3.4.4 Redes neuronales

En años recientes se han utilizado diferentes métodos de aprendizaje automático para predicción de variables que influyen en la calidad de agua, algunos de los más comunes son las redes neuronales artificiales (RNA) (Cao et.al., 2020).

Se entrenó una red neuronal artificial perceptrón multicapa que incluye tres capas: capa de entrada, capa oculta y capa de salida. En donde la capa de entrada incluyó las variables medidas (Tw, CE, pH, PAR, HR y Ta) y la capa de salida es el oxígeno disuelto. Se entrenó con el método Levenberg-Marquart y gradiente descendente como función de aprendizaje. Los pesos generados en esta red neuronal artificial se utilizaron en el análisis de sensibilidad de Garson.

3.4.5 Análisis de sensibilidad de Garson

Con el fin de evaluar las variables con mayor importancia relativa se aplicó el análisis de sensibilidad propuesto por Garson, que infiere la significancia relativa de las variables de entrada, basado en los valores de los pesos para las diferentes conexiones en la estructura de la red neuronal artificial (Ghanizadeh, 2020). Para cada neurona oculta i, se multiplican los valores absolutos del peso de la variable de entrada y el peso de la variable de salida. Esto se realiza para cada variable de entrada j (Ecuación 10).

$$P_{ij} = |W_{ij}| \times |W_{i1}| \quad (10)$$

En donde W_{ij} es el peso de la neurona de entrada j en la neurona oculta i , y $|W_{i1}|$ es el peso de la neurona de salida 1 en la neurona oculta i .

Para cada neurona oculta i , P_{ij} se divide entre la suma de todos los P_{ij} para las variables de entrada a fin de calcular Q_{ij} como se muestra en la Ecuación (11).

$$Q_{ij} = \frac{P_{ij}}{P_{i1} + P_{i2} + \dots + P_{im}} \quad (11)$$

El primer subíndice representa el número de neuronas ocultas, el segundo representa la variable de entrada y m representa el número total de entradas.

Posteriormente, para cada variable de entrada j se calcula S_j usando la Ecuación 12.

$$S_j = Q_{1j} + Q_{2j} + Q_{3j} + \dots + Q_{kj} \quad (12)$$

En donde k es el número de neuronas ocultas.

Por último, se calcula la importancia relativa (RI) con la Ecuación (13).

$$RI_j = S_j \times \frac{100}{S_1 + S_2 + S_3 + \dots + S_m} \quad (13)$$

3.4.6 Método de conglomerados

El método de conglomerados (clustering en inglés) es un método de aprendizaje no supervisado que está diseñado con el fin de particionar un conjunto de datos en grupos (conglomerados o clusters), de tal manera que los datos dentro de cada grupo son más similares entre ellos que los que están en otros grupos (Zhu et.al, 2019). Este cálculo se puede realizar a través de distintos métodos, dentro de los más utilizados se encuentra la distancia euclidiana, la cuál es una métrica de distancia local que se enfoca únicamente en la distancia entre dos muestras (Junye et al., 2017).

Se implementó el método de conglomerados utilizando el algoritmo k-means, el cual busca particionar los puntos en k grupos minimizando la suma del total de distancias entre los puntos y los centroides de los grupos, y lo hace a través de una iteración de asignación y actualización de centroides. Esta función utiliza el cuadrado de la distancia euclidiana. De acuerdo con Khan et al. (2004), este proceso consta de los siguientes pasos:

1. Inicialización de centroides: Se eligen aleatoriamente los centros iniciales para los k grupos.
2. Asignación de puntos: Se calcula la distancia euclidiana (Ecuación 7) entre cada punto de datos y los centroides. Los puntos son asignados al grupo más cercano.
3. Cálculo de los nuevos centroides: Se recalcula la posición de los centroides de acuerdo con el centro de masa de los datos en cada conglomerado (Ecuación 14).
4. Se repite el paso 2 y 3: Se itera este proceso hasta que no exista cambio en los centros de cada grupo.

$$dist(d_i, c_k) = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2 + (z_2 - z_1)^2 + \dots} \quad (14)$$

En donde $dist(d_i, c_k)$ es la distancia euclidiana entre los datos d_i hacia el centroide c_k ; “x”, “y” y “z” son las coordenadas de los puntos de los centroides.

El método descrito se implementó en MATLAB 2023^a, utilizando la función k-means y separando los datos en periodos de día y noche para tener mayor precisión en la formación de grupos.

3.5 RESULTADOS Y DISCUSIÓN

Para estudiar el comportamiento de las variables ambientales y de calidad de agua (Figura 4) se graficaron las variables 24 días a partir de la fecha de siembra, para el testigo se grafica del 4 al 28 de mayo de 2022, para el experimento 1 del 31 de octubre al 23 de noviembre y para el experimento 2 del 5 al 29 de diciembre 2022.

La Ta más alta (20.1 °C promedio) se registró durante los meses abril-mayo que corresponde al testigo, esta temperatura coincide con la HR más baja y el PAR más elevado (Figura 11). La Ta promedio en el experimento 1 (17.2 °C) fue superior a la Ta promedio del experimento 2 (14 °C), por consecuencia, también se registró HR menor en el experimento 2. Este comportamiento se atribuye a que el experimento 1 se realizó durante el mes de noviembre y el experimento 2 durante diciembre-enero.

El pH en el tanque de peces durante el periodo del testigo comenzó en 9 y posteriormente se mantuvo entre 8-8.4, la media de pH del testigo fue de 8.2. Por otro lado, el pH en el primer experimento comenzó con un valor de 7 con una tendencia a la baja y terminó el ciclo con un valor de 6, la media del pH fue de 6.36. Los picos positivos que se muestran tanto en el experimento 1 y 2 corresponden a la reposición de agua que se realizó diariamente a las 10 am, además se agregó una solución compuesta de nitrato de calcio, nitrato de potasio y micronutrientes para el control de pH. El segundo experimento tuvo una tendencia negativa en el pH, al igual que el primero, la media de pH fue de 6.3. Esta tendencia se debe al incremento en la biomasa y por consecuencia el aumento en el desecho de los peces.

La conductividad eléctrica mostró una tendencia ascendente en todos los casos (Figura 11) lo que indica el aumento de la biomasa y en los desechos de los peces en los experimentos 1 y 2 con respecto al testigo.

La temperatura del agua del testigo fue la menor de los experimentos con una media de 23.9 °C, el primer experimento tuvo la mayor temperatura media con 26.1 °C y el segundo experimento una media de 25°C (Figura 11). La temperatura del agua fue menor durante el desarrollo del testigo en el mes de abril, debido a que el agua solo fue calentada con una resistencia de 100 Watts. Para los siguientes experimentos, el agua se mantuvo con 2 resistencias de 100 Watts, por ello la diferencia de medias en la temperatura del agua.




Figura 4. Variables ambientales y de calidad de agua durante el testigo y los 2 experimentos.

El análisis de correlación realizado con los datos del testigo (Cuadro 4) muestra relaciones ya estudiadas como la correlación negativa entre la temperatura ambiental y la humedad relativa (-0.91), y entre la temperatura ambiental y el PAR (0.84). Sin embargo, con las variables de calidad de agua, el oxígeno disuelto tiene una correlación alta con la temperatura del agua (-0.69), con el pH (0.68) y en tercer lugar con la conductividad eléctrica (-0.39).

Cuadro 4. Análisis de correlación de variables ambientales y de calidad de agua (Testigo) (4-31 de mayo).

	Ta	HR	PAR	OD	pH	CE	Tw
Ta	1	-0.91	0.84	-0.19	-0.22	0.15	0.66
HR		1	-0.74	0.06	-0.05	0.11	-0.56
PAR			1	0.07	-0.06	0.11	0.44
OD				1	0.68	-0.39	-0.69
pH					1	-0.85	-0.51
CE						1	0.26
Tw							1

Lo anterior, se respalda con lo obtenido en el análisis de sensibilidad de Garson el cual se implementó con los pesos de la red neuronal retro propagada (entrada con Levenberg-Marquart y con una eficiencia de 99.3%). Este análisis mostró que el pH es la variable más importante para la predicción de oxígeno disuelto en un sistema acuícola (28.5%), seguido de la temperatura del agua (21.7%), la conductividad eléctrica (21.18%), temperatura ambiental (11.24%), el PAR (9.53%) y por último la humedad relativa (7.73%). Estos resultados coinciden con los obtenidos por Cao y colaboradores (2021), en donde se destacan estas tres primeras variables como las más importantes en el análisis de calidad de agua para predecir oxígeno disuelto.

Los resultados del análisis de correlación del primer y segundo experimento tuvieron un comportamiento similar, se muestra el análisis del experimento 2 el cual respalda las conclusiones del análisis anterior y destacan las relaciones identificadas entre la temperatura del agua, temperatura ambiental, humedad relativa, el pH y la conductividad eléctrica (Cuadro 5).

El análisis de conglomerados para la información que se registró durante el día (7:00 – 19:00) (Figura 5) se dividió en 3 grupos con base en el método del codo, el cual se basa en la evaluación de la varianza intragrupo en función del número de grupos. Se buscó el punto en la gráfica en donde la disminución de la varianza muestre un punto de inflexión donde se sugiere un posible número óptimo de grupos.

Cuadro 5. Análisis de correlación de variables ambientales y de calidad de agua (Testigo)(4-31 de mayo).

	Ta	HR	PAR	OD	pH	CE	Tw
Ta	1	-0.95	0.84	-0.42	0.08	0.02	0.73
HR		1	-0.83	0.37	-0.02	0.06	-0.65
PAR			1	-0.06	-0.03	0.03	0.34
OD				1	-0.30	-0.30	-0.82

pH	1	-0.31	0.13
CE		1	0.04
Tw			1

La temperatura ambiental y el PAR muestran un comportamiento similar que se ve reflejado en la alta correlación entre ambas variables. Además, se puede apreciar una línea de tendencia positiva para el pH con el oxígeno disuelto, a mayor pH mayor concentración de oxígeno disuelto.

En los resultados de conglomerados durante el día se destaca que los valores más altos de oxígeno disuelto se encuentran cuando el pH está por arriba de la media. Existe una tendencia negativa con la temperatura del agua, a menor temperatura menor oxígeno disuelto. Los grupos 2 y 3 agrupan concentraciones de oxígeno superiores a la media y coinciden con una temperatura del agua menor a la media (Figura 5).




Figura 5. Grupos conformados para el testigo con el algoritmo k-means.

Se conformaron 2 grupos de datos para la noche (19:00 – 07:00) (Figura 12) en los cuales se pueden ver tendencias más evidentes entre las variables. Los valores de oxígeno por arriba de la media se concentran en el grupo 1, el cual agrupa las menores temperaturas, mayor pH, mayor humedad relativa. Por su parte en el grupo 2 ocurre lo contrario, la concentración de oxígeno disuelto se encuentra por debajo de la media cuando la temperatura del agua y del aire están por arriba de la media y la humedad relativa y pH se encuentran por debajo de la media.

El experimento 1 y 2 tuvieron un comportamiento similar durante el análisis de conglomerados. Los grupos formados durante el día para el primer experimento (Figura 6) revelan que las relaciones de T_a , T_w , PAR y HR con el oxígeno disuelto fueron similares con el testigo. El conglomerado 3 agrupa las concentraciones de oxígeno disuelto más altas, las menores temperaturas de aire y de agua, y la humedad relativa más alta. Lo anterior respalda las relaciones que se encontraron en el testigo, sin embargo, no se notó una relación evidente con el oxígeno disuelto y el pH, esto pudo ser causado debido al gran incremento de la biomasa en el tanque de peces y, por consecuencia, un incremento en los desechos de los peces.

Para los datos durante la noche (19:00 – 07:00) del experimento 1 (Figura 6) se conformaron dos grupos. El grupo 2 agrupa los datos con una concentración de oxígeno arriba de la media que hace evidente la tendencia positiva con la humedad relativa y la tendencia negativa con la temperatura del aire y del agua. Por otro lado, el grupo 1 muestra que el oxígeno disuelto se encuentra por debajo de la media cuando la temperatura ambiental y del agua están arriba de la media y la humedad por debajo. Durante la noche, las tendencias entre la temperatura del aire, del agua y la humedad relativa con el oxígeno disuelto son más evidentes que durante el día. El conglomerado 1 es un grupo de transición en donde se encuentran valores cercanos a la media de oxígeno disuelto y comparten rangos con los otros conglomerados (Cuadro 6).




Figura 6. Grupos conformados para el experimento 1 con el algoritmo k-means.

Los grupos formados destacan relaciones importantes sobre el comportamiento del oxígeno. El comportamiento de la Ta, Tw, PAR y HR es similar entre los experimentos y el testigo. En ambos experimentos durante el periodo de la noche se distinguen dos grupos, los que están por arriba y debajo de la media en concentración de oxígeno (Cuadro 3). A diferencia del pH, se siguen manteniendo las relaciones de OD con Tw, HR y Ta como en el caso del Testigo.

Cuadro 6. Rangos de los conglomerados del testigo, experimento 1 y 2.

Variable	Testigo	Experimento 1	Experimento 2
Conglomerados durante el día			
Conglomerado 1			
OD [mg L ⁻¹]	5.74 - 7.61	4.9 - 7.14	5.92 - 8.46
Ta [°C]	18.64 - 34.8	17.3 - 31.9	2.11 - 15.48
HR [%]	7.85 - 58.9	16.94 - 63.8	47.3 - 91.6
PAR [μmol m ⁻¹ s ⁻¹]	34.7 - 903	30.5 - 708.2	0-272
pH	7.9 - 8.2	5.8 - 6.7	5.49 - 6.47
CE [mS cm ⁻¹]	0.66 - 0.8	1.28 - 2.01	1.29 - 2.1
Tw [°C]	24.6 - 32.3	23.5 - 29.6	20.4 - 26

Conglomerado 2			
OD [mg L ⁻¹]	7.14 – 8.68	4.32 – 6.8	4.45 – 7.13
Ta [°C]	7.74 – 22.3	13.6 – 29.8	16.17 - 30.39
HR [%]	40.6 – 86.1	10.2 – 78.4	5.7 – 60.9
PAR [μmol m ⁻¹ s ⁻¹]	0 – 379.8	37.8 – 765.7	58.72 – 652.2
pH	8.07 – 8.41	6.31 – 7.9	5.51 – 7.51
CE [mS cm ⁻¹]	0.62 – 0.77	0.94 – 1.7	1.27 – 2.08
Tw [°C]	17.9 – 26.4	24.1 – 29.8	25.25 – 29

Conglomerado 3			
OD [mg L ⁻¹]	7.25 – 8.8	5.98 – 7.2	5.78 – 8.45
Ta [°C]	20.8 – 33.8	5.87 – 21.8	12.62 - 27.85
HR [%]	11.05 – 44.4	42.3 – 91.3	15.7 – 65
PAR [μmol m ⁻¹ s ⁻¹]	192 – 920	0 – 411	64.24-598
pH	8.1 – 8.36	5.81 – 7.29	5.5 – 7.9
CE [mS cm ⁻¹]	0.66 – 0.76	1 – 1.98	1.26 – 2.09
Tw [°C]	19.5 – 26.7	22 – 25.6	21.63 – 27.02

Conglomerados durante la noche

Conglomerado 1			
OD [mg L ⁻¹]	6.14 – 8.21	4.5 – 6.1	4.5 – 7.0
Ta [°C]	8.71 – 18.2	12.7 – 26.1	10.5 – 24.5
HR [%]	14.77 – 85.3	26.13 – 84.7	21 – 80.6
PAR [μmol m ⁻¹ s ⁻¹]	0 - 1920	0 – 267.3	0 – 270
pH	8.0 – 8.9	5.9 – 7.38	5.5 – 7.5
CE [mS cm ⁻¹]	0.64 – 0.74	1.01 – 1.92	1.28 – 2.1
Tw [°C]	18.8 - 25	25.9 – 29.1	24.8 – 28.8
Conglomerado 2			
OD [mg L ⁻¹]	5.2 – 7.2	5.38 – 7.1	5.6 – 7.9
Ta [°C]	12.6 – 32.1	6.4 – 17.3	3.5 – 14.7
HR [%]	10.3 – 85.3	61.6 – 90.7	57.5 – 91.2
PAR [μmol m ⁻¹ s ⁻¹]	0 – 0.1920	0	0 – 15
pH	7.6 – 8.1	5.8 – 7.2	5.5 - 7.6
CE [mS cm ⁻¹]	0.65 – 0.78	1.02 – 1.94	1.26 – 2.11
Tw [°C]	23.3 - 31	22.9 – 27.5	21.5 – 26.8

Los resultados del análisis de conglomerados para el experimento 1 y 2 (Cuadro 9), revelan una clara influencia de la biomasa de los peces en las variables clave del sistema acuapónico. En el testigo (260 g de biomasa) se muestran relaciones consistentes entre el pH, la temperatura y la humedad relativa con el oxígeno disuelto, como se ha mencionado anteriormente (Ren et al., 2018). Sin embargo, al aumentar la biomasa en los experimentos posteriores para el mismo volumen

de agua y la introducción de las plantas, se notaron cambios significativos en el comportamiento del pH, lo cual pudo ser causado por el incremento de la carga de desechos en el sistema y la composición química del agua. Lo anterior generó una correlación baja entre el pH y el oxígeno disuelto en los experimentos posteriores. No obstante, las relaciones con la temperatura del agua, la temperatura ambiental y la humedad relativa se mantuvieron, demostrando la importancia de estos factores en la disponibilidad de oxígeno en el sistema. Las tendencias entre la temperatura de agua, temperatura ambiental y humedad relativa con el oxígeno disuelto fueron más evidentes durante el periodo nocturno (Figura 6). Por otro lado, el pH demostró tener rangos muy amplios en cada conglomerado lo que demuestra la poca correlación que se obtuvo con el oxígeno disuelto.

Durante los dos experimentos el comportamiento de nitritos, nitratos y amonio se mantuvo dentro de las tolerancias de calidad de agua, a excepción de la primera semana del segundo experimento en donde el amonio excede 2 décimas del límite recomendado (Figura 7), posterior a esa fecha el consorcio bacteriano cumplió con su función de transformación del amonio el cual se mantuvo dentro del límite. La tendencia de los nitratos es ascendente con el paso del tiempo debido a la transformación de nitritos a nitratos. Sin embargo, durante la última semana del primer experimento se aprecia que dicha transformación disminuyó considerablemente por lo que la concentración de nitritos se incrementó al igual que la concentración de amonio debido a la poca actividad bacteriana durante ese periodo (Figura 14).

Al inicio del segundo experimento (5 diciembre) existía una cantidad de nitratos baja debido al recambio de agua para disminuir la conductividad eléctrica. Sin embargo, los niveles de amonio son altos, pero después disminuyen por efecto de la transformación amonio-nitritos-nitratos. El nivel de nitratos se mantuvo en aumento hasta el final del experimento.




Figura 7. Comportamiento de amonio, nitritos y nitratos durante el desarrollo del primer y segundo experimento.

3.6 CONCLUSIONES

En este estudio se realizó un análisis de las variables ambientales y de calidad del agua que influyen en la concentración de oxígeno disuelto, la cual es una variable de suma importancia en los sistemas acuapónicos ya que garantiza la supervivencia de los seres vivos.

El análisis de Garson resalta la importancia de la temperatura del agua, el pH, la humedad relativa y la conductividad eléctrica para la explicación de la concentración de oxígeno disuelto en sistemas acuapónicos, las primeras dos variables demuestran una importancia relativa elevada que coincide con los resultados del análisis de correlación. Estos hallazgos respaldan investigaciones previas y demuestran que estos factores son cruciales para comprender las fluctuaciones del oxígeno disuelto en el agua.

Al aumentar la biomasa en los sistemas se observaron cambios sustanciales en el pH, lo cual influyó en la correlación con el oxígeno disuelto, sin embargo, la

temperatura ambiental, la temperatura del agua y la humedad relativa mantuvieron su relación con el oxígeno disuelto.

El análisis de conglomerados proporcionó una visualización de los patrones diurnos y nocturnos del comportamiento del oxígeno disuelto. Durante la noche, el comportamiento fue similar al del testigo. Durante el día el comportamiento es más dinámico y la tendencia es menos evidente. Sin embargo, este análisis destaca que la concentración de oxígeno disuelto se asocia a temperaturas más bajas y una mayor humedad relativa.

Los resultados sugieren que el oxígeno disuelto no solo está influenciado por una sola variable, sino por la combinación de factores interrelacionados. Sin embargo, la temperatura del agua es clave para controlar la concentración de oxígeno disuelto dentro del rango óptimo ($>4 \text{ mg L}^{-1}$).

Este trabajo demuestra la complejidad de las relaciones entre las variables ambientales y de calidad de agua con el oxígeno disuelto, proporcionando una base para futuras investigaciones en el área de acuaponía.

3.7 Literatura citada

Aleksić, N., & Šušteršič, V. (2020). Analysis of application of aquaponic system as a model of the circular economy: A review. *Recycling and Sustainable Development*. vol. 13(1), pp. 73-86. <https://doi.org/10.5937/ror2001073A>

Banco Mundial. (2010). Informe sobre el desarrollo mundial. (2010). Desarrollo y Cambio Climático. Washington. Banco Internacional de Reconstrucción y Fomento / Banco Mundial.

Bringezu, S., Schütz, H., Pengue, W., OBrien, M., Garcia, F., Sims, R. (2014). Assessing global land use: balancing consumption with sustainable supply. UNEP/International Resource Panel, Nairobi/ Paris

- Carbajal, J.J., Sánchez, F.P., Villa-Vargas, L. A., Carrasco-Ochoa, J. A., Martínez-Trinidad, J. F. (2013). Water quality assessment in shrimp culture using an analytical hierarchical process. *Ecological indicators*. vol. 29, 148-158. <https://doi.org/10.1016/j.ecolind.2012.12.017>
- Cao, S., Zhou, L, Zhang, Z. (2021). Prediction of dissolved oxygen content in aquaculture based on clustering and improved ELM. *IEEE Access*. vol. 9, pp.40372-40387. <https://doi.org/10.1016/j.ecolind.2012.12.01710.1109/ACCESS.2021.3064029>
- Ebeling, J.M., Timmons, M.B., Bisogni, J.J., (2006). Engineering analysis of the stoichiometry of photoautotrophic, autotrophic, and heterotrophic removal of ammonia nitrogen in aquaculture systems. *Aquaculture*. vol. 257, 346e358. <https://doi.org/10.1016/j.aquaculture.2006.03.019>.
- Garson, G.D., Ghanizadeh, A.R., Heidarabadizadeh, N., Jalali, F. Artificial neural network back-calculation of flexible pavements with sensitivity analysis using Garson's and connection weights algorithms. (2020). *Innov. Infrastruct. Solut.* vol. 5, 63. <https://doi.org/10.1007/s41062-020-00312-z>
(1991) Interpreting neural-network connection weights. *AI Expert* 6:46–51
- Junye, G. U., Mingxia, L. I., Daoqiang, Z. (2017). Application of effective distance in clustering algorithms. *Journal of Frontiers of Computer Science & Technology*. vol. 11(3),pp 406.
- Karimanzira, D., Rauschenbach, T. (2021). An intelligent management system for aquaponics. *at-Automatisierungstechnik*. vol. 69(4), pp 345-350. <https://doi.org/10.1515/auto-2020-0036>
- Khan, S., Ahmad, A. (2004). Cluster center initialization algorithm for K-means clustering. *Pattern Recognition Letters*. vol 25(11), 1293–1302. doi:10.1016/j.patrec.2004.04.007

- Ren, Q., Zhan, L., Wei, Y., Li, D. (2018). A method for predicting dissolved oxygen in aquaculture water in an aquaponics system. *Computers and electronics in agriculture*, 151, 384-391. <https://doi.org/10.1016/j.compag.2018.06.013>
- Somerville, C., Cohen, M., Pantonella, E., Stankus, A., Lovatelli, A. (2014). Small-scale aquaponic food production, Food and Agriculture Organization of the United Nation, Rome, p. 261. <https://doi.org/10.1016/B978-0-444-64309-4.00020-9>
- Wongkiew, S., Hu, Z., Nhan, H. T., Khanal, S. K. (2020). Aquaponics for resource recovery and organic food productions. In *Current Developments in Biotechnology and Bioengineering* pp. 475-494. Elsevier. <https://doi.org/10.1016/B978-0-444-64309-4.00020-9>
- Yanes, A. R., Martinez, P., Ahmad, R. (2020). Towards automated aquaponics: A review on monitoring, IoT, and smart systems. *Journal of Cleaner Production*.vol. 263, 121571. <https://doi.org/10.1016/j.jclepro.2020.121571>
- Zhu, X., Zhang, S., He, W., Hu, R., Lei, C., & Zhu, P. (2018). One-step multi-view spectral clustering. *IEEE Transactions on Knowledge and Data Engineering*, vol. 31(10), pp 2022-2034.