



DIVISIÓN DE ESTUDIOS DE POSGRADO E INVESTIGACIÓN OPCIÓN I.-

TESIS

TRABAJO PROFESIONAL

**“PREDICCIÓN Y OPTIMIZACIÓN DE LA
CALIDAD DEL AGUA EN LA PRODUCCIÓN DE
TILAPIA, MEDIANTE EL USO DE LA
INTELIGENCIA ARTIFICIAL”**

QUE PARA OBTENER EL GRADO DE:

MAESTRA EN INGENIERÍA INDUSTRIAL

PRESENTA:

I.I LUNA KARINA CORTÉS ISLAS

DIRECTOR DE TESIS: DR. OSCAR

BÁEZ SENTÍES

CODIRECTOR DE TESIS:

DRA. MARÍA ELOÍSA DE LA ASUNCIÓN GURRUCHAGA RODRÍGUEZ

ORIZABA, VERACRUZ, MÉXICO

MAYO 2026





Instituto Tecnológico de Orizaba
División de Estudios de Posgrado e Investigación

Orizaba, Veracruz, 8/mayo/2026
Dependencia: División de Estudios de
Posgrado e Investigación
Asunto: Autorización de Impresión
OPCIÓN: I

C. CORTÉS ISLAS LUNA KARINA
Candidato(a) a Grado de Maestro(a) en:
INGENIERÍA INDUSTRIAL
PRESENTE

De acuerdo con el reglamento de Titulación vigente de los Centros e Institutos Tecnológicos Federales del Tecnológico Nacional de México, de la Secretaría de Educación Pública, y habiendo cumplido con todas las indicaciones que la Comisión Revisora le hizo respecto a su Trabajo Profesional titulado:


"PREDICCIÓN Y OPTIMIZACIÓN DE LA CALIDAD DEL AGUA EN LA PRODUCCIÓN DE TLILAPIA, MEDIANTE EL USO DE LA INTELIGENCIA ARTIFICIAL"

Comunico a usted que este Departamento concede su autorización para que proceda a la impresión del mismo.

ATENTAMENTE

Excelencia en Educación Tecnológica
CIENCIA - TÉCNICA - CULTURA

DR. OSCAR BAEZ SENTIES
JEFE DE LA DIVISIÓN DE ESTUDIOS
DE POSGRADO E INVESTIGACIÓN



015/JARH

OG-13-F06



2020

Margarita
Maza

Av. Oriente 9 #857 Colonia Hincapié Papaya, C.P. 94370 Orizaba, Veracruz
Tel. 01 (222) 1105360 - info@orizaba.tecnm.mx - www.orizaba.tecnm.mx





Educación
Secretaría de Educación Pública



TECNOLOGÍA
NACIONAL DE MÉXICO



Instituto Tecnológico de Orizaba
División de Estudios de Posgrado e Investigación

Orizaba Veracruz, 16/diciembre/2025
Asunto: Revisión de trabajo escrito

C. OFELIA LANDETA ESCAMILLA
JEFA DE LA DIVISIÓN DE ESTUDIOS
DE POSGRADO E INVESTIGACIÓN
P R E S E N T E.-

Los que suscriben, miembros del jurado, han realizado la revisión de la Tesis del (la) C.:

CORTÉS ISLAS LUNA KARINA

La cual lleva el título de:

PREDICCIÓN Y OPTIMIZACIÓN DE LA CALIDAD DEL AGUA EN LA PRODUCCIÓN DE TLILAPIA,
MEDIANTE EL USO DE LA INTELIGENCIA ARTIFICIAL

y concluyen que se acepta.

ATENTAMENTE
Excelencia en Educación Tecnológica
CIENCIA - TÉCNICA - CULTURA

PRESIDENTE: DR. OSCAR BAEZ SENTIES


FIRMA

SECRETARIO: DRA. MA. ELOISA DE LA ASUNCIÓN GURRUCHAGA RODRÍGUEZ


FIRMA

VOCAL: DR. MIGUEL JOSUÉ HEREDIA ROLDÁN


FIRMA

VOCAL SUP.: M.C. JORGE ARTURO RAMÍREZ HERNÁNDEZ


FIRMA

TA-09-F18



2025
La Mujer
Indígena

Av. Oriente 54851 Colonia Emiliano Zapata, C.P. 96120
Orizaba, Veracruz. Tel. 01 (271) 1105160
e-mail: info@orizaba.tecnm.mx - www.orizaba.tecnm.mx



Agradecimientos

Expreso mi más sincero agradecimiento a todas aquellas personas que hicieron posible la realización y culminación de este trabajo de investigación como resultado de un proceso académico y formativo que, en lo personal, en algún momento considere inalcanzable; sin embargo, hoy puedo decir con gran satisfacción que es un objetivo cumplido.

Agradezco al Instituto Tecnológico de Orizaba, por brindarme la oportunidad de cursar este posgrado siendo también mi alma mater de licenciatura.

Particularmente, agradezco a mi director de tesis el Dr. Oscar Báez Senties, por su valiosa intervención, orientación, paciencia y guía durante el desarrollo de esta investigación. No sabe duda que su experiencia y conocimiento fueron fundamentales para la correcta estructuración y culminación de este trabajo.

De igual forma, agradezco a todos los docentes que formaron parte de mi trayectoria durante este periodo de dos años, quienes, a través de sus conocimientos y exigencia académica, contribuyeron significativamente a mi formación profesional. Asimismo, reconozco su calidad humana demostrada en todo momento; sin duda, son profesores que recordaré con profundo respeto y aprecio.

Dedicatoria

El presente trabajo está dedicado en primer lugar a mi madre, mi mayor apoyo incondicional que siempre está detrás mío ayudándome cuando más la he necesitado, que aun siento que le debo más de lo que ella me ha dado, pero jamás terminaría de pagar todo lo que ha hecho por mi desde niña. Mi Caty, todo lo que yo haga siempre llevará su nombre.

A mis hermanos, siempre apoyándome con sus platicas serias o con sus ocurrencias, presentes o aun a la distancia, saben que los quiero y los admiro por todo aquello que los distingue.

A mi esposo, que jamás me detiene y siempre me motiva a hacer las cosas, gracias por acompañarme en esta etapa, por tu disposición de tiempo y tu ayuda como pilar de nuestra pequeña familia tan llena de vida, por ser ese compañero y cómplice con el que crezco y hago un gran equipo.

Finalmente, y siendo esta dedicatoria especial, a mis hijos, que, siendo aun pequeños, todos los días me enseñan algo nuevo; sin querer aprendieron cuando mamá trabajaba en la computadora y me daban mi espacio, me enseñaron de lo que era capaz y aunque hubo noches de insomnio, cada desvelo y cada logro han sido y serán siempre por ustedes quienes representan mi mayor inspiración y mi motor de vida. Desde que tuve el honor de convertirme en mamá todo lo que soy, hago y haré es absolutamente por ustedes Vitaliano y Kamilah.

Resumen

La producción acuícola de tilapia enfrenta desafíos significativos relacionados con la gestión eficiente de la calidad del agua y el control de los costos operativos, debido a la interacción compleja de variables fisicoquímicas como temperatura, oxígeno disuelto, pH y compuestos nitrogenados. Estas condiciones influyen directamente en el crecimiento, salud y productividad de los organismos, lo que dificulta la toma de decisiones en sistemas de cultivo.

En este contexto, la presente investigación tiene como objetivo desarrollar un modelo integral de predicción y optimización de la calidad del agua en la producción de tilapia mediante el uso de herramientas de inteligencia artificial. La metodología propuesta integra redes neuronales artificiales (RNA) para la modelación matemática del sistema y algoritmos genéticos multiobjetivo (AGMO) para la optimización simultánea de la calidad del agua y los costos operativos.

Para la construcción del modelo, se consideraron diez variables fisicoquímicas relevantes, a partir de las cuales se generó una base de datos mediante simulación utilizando el software SIMNET II®. Posteriormente, se diseñaron, entrenaron y validaron redes neuronales tipo perceptrón multicapa (MLP) en MATLAB®, obteniendo modelos predictivos con alto nivel de precisión, alcanzando valores de correlación cercanos a $R = 1$ entre los datos simulados y los valores estimados.

En una segunda etapa, se implementó un algoritmo genético multiobjetivo que permitió optimizar las funciones de calidad del agua y costo total, generando un conjunto de soluciones no dominadas representadas a través del frente de Pareto. Este enfoque facilitó la identificación de configuraciones óptimas del sistema acuícola, permitiendo equilibrar la mejora de la calidad del agua con la minimización de costos.

Los resultados demuestran que la integración de redes neuronales artificiales y algoritmos genéticos multiobjetivo constituye una herramienta eficaz para el apoyo a la toma de decisiones en sistemas acuícolas, contribuyendo a mejorar la eficiencia operativa, la sostenibilidad y la resiliencia del cultivo de tilapia. No obstante, el modelo se basa en datos simulados, por lo que futuras investigaciones podrían incorporar datos en tiempo real para fortalecer su aplicabilidad en entornos reales.

Abstract

Tilapia aquaculture faces significant challenges related to the efficient management of water quality and the control of operational costs, due to the complex interaction of physicochemical variables such as temperature, dissolved oxygen, pH, and nitrogen compounds. These factors directly affect fish growth, health, and productivity, making decision-making processes in aquaculture systems more complex.

In this context, the present research aims to develop an integrated model for the prediction and optimization of water quality in tilapia production using artificial intelligence techniques. The proposed methodology combines Artificial Neural Networks (ANNs) for system modeling and Multi-Objective Genetic Algorithms (MOGAs) for the simultaneous optimization of water quality and operational costs.

For model development, ten key physicochemical variables were considered, and a dataset was generated through simulation using the SIMNET II® software. Subsequently, Multilayer Perceptron (MLP) neural networks were designed, trained, and validated in MATLAB®, achieving high predictive performance with correlation values close to $R = 1$ between simulated and estimated data.

In the second stage, a multi-objective genetic algorithm was implemented to optimize both water quality and total cost functions, generating a set of non-dominated solutions represented through the Pareto front. This approach enabled the identification of optimal system configurations, balancing water quality improvement with cost minimization.

The results demonstrate that the integration of Artificial Neural Networks and Multi-Objective Genetic Algorithms constitutes an effective decision-support tool for aquaculture systems, contributing to improved operational efficiency, sustainability, and resilience in tilapia production. However, the model is based on simulated data, and future research could incorporate real-time data to enhance its applicability in real-world environments.

Índice general

Introducción	1
CAPÍTULO I. GENERALIDADES.....	2
1.1 Información de la empresa	2
Marco geográfico.....	2
1.1.1. Macro localización.....	2
1.1.2. Micro localización	2
1.2 Antecedentes.....	4
1.3 Estructura organizacional.....	4
1.4 Enfoque estratégico.....	5
1.4.1 Misión	5
1.4.2 Visión.....	5
1.4.3 Valores	5
1.5 Descripción del proceso de producción de Tilapia	6
1.5.1 Distribución del área	6
1.6 Generalidades del proyecto	7
1.6.1 Planteamiento del problema	7
1.6.2 Objetivo general.....	7
1.6.3 Objetivos particulares	7
1.6.4 Justificación.....	7
1.6.5 Metodología.....	9
1.7 Estado del arte	9
CAPITULO II MARCO TEORICO.....	12
2.1 Acuicultura	12
2.1.1 Definición.....	12
2.1.2 Acuicultura en el mundo	12
2.1.2.1. Los sistemas de producción.....	13
2.1.3 Acuicultura en México	13
2.1.3.1 Inocuidad agroalimentaria, acuícola y pesquera	14

2.1.3.2 Normatividad aplicable en México	15
2.1.4 Calidad del agua en Acuicultura	16
2.1.4.1 La temperatura	16
2.1.4.2 El oxígeno disuelto.....	16
2.1.4.3 El pH	17
2.1.4.4 TAN	17
2.1.4.5 Nitrito	17
2.1.4.6 Nitrato	17
2.1.4.7 Transparencia.....	18
2.1.4.8 Dureza	18
2.1.4.9 Alcalinidad	18
2.1.4.10 Dióxido de Carbono	18
2.2 Simulación con SIMNET II.....	18
2.2.1 Nodos.....	19
2.2.2 Pruebas de bondad de ajuste.....	19
2.2.3 Muestreo no probabilístico	20
2.3 Inteligencia artificial	20
2.3.1 Orígenes y desarrollo de la inteligencia artificial	20
2.3.2 Inteligencia artificial en la industria, así como en pequeñas y medianas empresas.	22
2.3.3 Redes neuronales artificiales	23
2.3.4 Neurona artificial	24
2.3.5 Arquitectura de redes neuronales artificiales.....	24
2.3.6 Clasificación de redes neuronales	25
2.3.7 Tipos de aprendizaje	25
2.3.8 Propiedades para la creación de la red neuronal	26
2.3.9 Entrenamiento de redes neuronales.....	27
2.4 Predicciones basadas en redes neuronales artificiales.....	28
2.5 Algoritmos Genéticos (AG)	29

2.5.1 Población inicial	29
2.5.2 Generaciones	29
2.5.3 Mutación	30
2.5.4 Cruzamiento	30
2.5.5 Elitismo	30
2.6 AG mono-objetivo, mejor individuo.....	30
2.7 Algoritmos Genéticos Multiobjetivo.....	31
2.8 Frente de Pareto	31
CAPÍTULO III. MODELADO CON RED DE NEURONAS	33
3.1 Fase 1. Análisis.....	33
3.1.1 Definición de las variables	33
3.1.2 Simulación de las variables de datos.....	33
3.1.3 Creación de base de datos	34
3.1.4 Análisis de la información.....	35
3.2 Fase 2. Diseño	37
3.2.1 Determinación de parámetros para crear variables en Matlab.....	37
3.2.2 Creación de redes neuronales artificiales en Matlab.....	38
3.2.3 Entrenamiento de las redes neuronales	39
3.2.4 Arquitectura de las redes neuronales.....	40
3.2.5 Elaboración de redes neuronales artificiales en Excel	41
CAPÍTULO IV. OPTIMIZACIÓN CON ALGORITMOS GENETICOS MULTOBJETIVO	49
4.1 Fase 3. Implementación	49
4.1.1 Optimización de las funciones matemáticas.....	49
4.2 Fase 4. Operación	50
4.2.1 Resultados del frente de Pareto.....	51
CONCLUSIÓN	54
RECOMENDACIONES.....	55
Referencias.....	56

Anexos.....	60
Anexo I. Base de datos generada.....	60
Anexo I. Desglose manual de RNA para calidad.	62
Anexo I. Desglose manual de RNA para Costo	64

Índice de Figuras

Figura 1 Localización del estado de Veracruz en México	2
Figura 2 Localización del municipio Tierra Blanca en Veracruz.....	3
Figura 3 "Granja Tierra Adentro" vía satelital	3
Figura 4 Organigrama.....	5
Figura 5 Proceso de cultivo de Tilapia	6
Figura 6 Distribución del módulo.....	6
Figura 7. Metodología de apoyo a la decisión mediante la Inteligencia Artificial (IA)	9
Figura 8 Lenguaje de programación por nodos para la simulación de indicadores hídricos con SIMNET II®.....	34
Figura 9 Resultados del entrenamiento para WQ y CT, con sus valores correspondientes de MSE y porcentajes de muestra.....	39
Figura 10 Valores de prueba en Excel.	42
Figura 11 Columnas IW1 y P*WI agregadas.....	44
Figura 12 Matriz 4 x 10 para Y1	47
Figura 13 Representación conceptual del frente de Pareto y la solución ideal	50
Figura 14 Frente de Pareto con soluciones optimizadas para calidad del agua (CA) y costo total (CT)	51

Índice de Tablas

Tabla 1. Concentrado de indicadores.....	33
Tabla 2 Prueba Kolmogorov-Smirnov de normalidad para WQ y TC	34
Tabla 3 Base de datos de los indicadores de agua.	35

Tabla 4. Estimación de parámetros de los objetivos CA y CT.....	35
Tabla 5. Costos obtenidos en la BD.....	36
Tabla 6. Cálculo de costos para la calidad del agua.	36
Tabla 7. Configuración de parámetros para las RNA.....	38
Tabla 8. Pruebas de las propiedades de la red y los parámetros de entrenamiento de la red CA y CT	40
Tabla 9. Matriz de pesos de entrada a la capa oculta (IW 4 x 10) para Y2.....	41
Tabla 10. Matriz de pesos de la capa oculta a la salida (LW 1 x 4) para Y2.	42
Tabla 11. Vector de sesgos de la capa oculta (b1), y2.....	42
Tabla 12. Sesgo de la salida (b2) Y2.	42
Tabla 13 Cálculos matemáticos para determinar el valor de la suma 4 para Y2.....	45
Tabla 14. Matriz de pesos de entrada a la capa oculta (IW 4 x 10) para Y1	45
Tabla 15. Matriz de pesos de la capa oculta a la salida (LW 1 x 4) para Y1.	46
Tabla 16. Vector de sesgos de la capa oculta (b1), Y1	46
Tabla 17. Sesgo de la salida (b2) Y1	46
Tabla 18 Cálculos matemáticos para determinar el valor de la suma 4 para Y1	48
Tabla 19 Concentrado de indicadores.....	49
Tabla 20. Optimización AGMO de CA y CT	50
Tabla 21. Soluciones para CA y CT	52

Introducción

La producción de tilapia, un pez de gran importancia económica y nutricional a nivel mundial enfrenta diversos desafíos relacionados con la gestión de la calidad del agua y la sostenibilidad de los sistemas de cultivo. La calidad del agua no solo depende de la aireación, sino también de múltiples parámetros fisicoquímicos como la temperatura, el pH, el oxígeno disuelto y los compuestos nitrogenados, los cuales interactúan de forma dinámica y pueden afectar directamente el metabolismo, crecimiento y supervivencia de los organismos.

Los métodos tradicionales de monitoreo presentan limitaciones para integrar estas variables de manera simultánea y predecir su comportamiento en sistemas complejos, lo que dificulta la toma de decisiones oportunas en la operación de sistemas acuícolas. En este contexto, surge la necesidad de implementar herramientas avanzadas que permitan modelar y optimizar la calidad del agua de manera eficiente.

La inteligencia artificial, particularmente mediante el uso de redes neuronales artificiales y algoritmos genéticos multiobjetivo, ofrece una alternativa innovadora para abordar este tipo de problemas. Estas técnicas permiten modelar sistemas no lineales y encontrar soluciones óptimas considerando múltiples objetivos, como maximizar la calidad del agua y minimizar los costos operativos.

A pesar de los avances en la predicción de parámetros individuales de calidad del agua, la integración de modelos predictivos con técnicas de optimización multiobjetivo en sistemas acuícolas reales sigue siendo limitada, lo que representa un área de oportunidad para el desarrollo de herramientas más integrales y aplicables.

En este sentido, la presente investigación tiene como objetivo desarrollar un modelo de predicción y optimización de la calidad del agua en la producción de tilapia mediante herramientas de inteligencia artificial, con el fin de mejorar la eficiencia productiva, apoyar la toma de decisiones y contribuir a la sostenibilidad del sector acuícola.

CAPÍTULO I. GENERALIDADES

1.1 Información de la empresa

A continuación, se detallan características y datos de la empresa para poder comprender su contexto, inicios y giro en la industria.

Marco geográfico

1.1.1. Macro localización

El proyecto “Implementación de metodología Seis Sigma en una granja acuícola para la mejora de calidad de agua en estanques de producción” es realizado en el estado de Veracruz de Ignacio de la Llave, de los Estados Unidos Mexicanos. La Ilustración 1 muestra la localización del estado de Veracruz en México.



Figura 1 Localización del estado de Veracruz en México

1.1.2. Micro localización

El proyecto se llevó a cabo en el municipio de Tierra Blanca. La Ilustración 2 muestra la localización de Tierra Blanca dentro del estado de Veracruz




Figura 2 Localización del municipio Tierra Blanca en Veracruz

El domicilio Fiscal de la granja acuícola de la empresa Ingeniería agropecuaria del Papaloapan S.P.R. de R.L., que se encuentra ubicada en el Rancho Tierra Adentro, Abasolo No. 603, colonia Loma del Jazmín, código postal 95150, congregación de Joachín, Municipio Tierra Blanca, Veracruz, con coordenadas $18^{\circ}39'26''$ de latitud norte y $96^{\circ}17'58''$ de longitud oeste (Ilustración 3)



Figura 3 "Granja Tierra Adentro" vía satelital

1.2 Antecedentes

Con la finalidad de alcanzar grandes niveles de producción, respetando normas ambientales, sanitarias y de inocuidad alimentaria y respondiendo al creciente interés de consumidores y la creciente demanda del mercado que superaba la capacidad de oferta existente se establece la granja acuícola “Tierra adentro”. La empresa tiene sus inicios en el año 2006 como un proyecto piloto, orientado a impulsar el desarrollo del sector acuícola y diversificar su actividad comercial.

La Unidad de Producción acuícola (UPA) fue constituida legalmente bajo el nombre “Ingeniería Agropecuaria del Papaloapan”, como una Sociedad de Producción Rural de Responsabilidad Limitada (S.P.R de R.L) el 23 de enero del año 2006. Tiempo después, el 22 de septiembre del 2008, la Comisión Nacional del Agua (CONAGUA) le otorga la concesión numero 10256985474 para el uso de aguas subterráneas nacionales, por un periodo de treinta años, en cumplimiento con lo que establece la Constitución Política de los Estados Unidos Mexicanos y el 6 de octubre de ese mismo año, conforme a la Ley General de Pesca y Acuicultura Sustentable, artículo 122 fracciones I y IV, se le otorgo el Registro Nacional de Pesca con el número 569745263, abriendo paso a operar como unidad económica dedicada a la Acuicultura.

Dada la experiencia en el proceso productivo, el 4 de marzo del 2014 la UPA fue certificada con el número 569875 por cumplir con las Buenas Prácticas de Producción Acuícola, dicho reconocimiento fue otorgado por el Servicio Nacional de Sanidad, Inocuidad y Calidad Agroalimentaria (SENASICA), organismo dependiente de la entonces Secretaría de Agricultura, Ganadería, Desarrollo Rural, Pesca y Alimentación (SAGARPA). En el ámbito ambiental, el 6 de marzo del 2015 recibió un dictamen de la Subdelegación de Gestión para la Protección Ambiental y Recursos Naturales, la cual concluyo que el proyecto no genera impactos negativos en el medio ambiente, conforme al artículo 28 de la Ley General del Equilibrio Ecológico y la Protección al Ambiente.

En 2018 “Ingeniería Agropecuaria del Papaloapan S.P.R de R.L” solicitó ante la Dirección General de Inocuidad Alimentaria, Acuícola y Pesquera el inicio del proceso de evaluación para obtener la certificación de inocuidad en la Producción Primaria, mediante la implementación de Buenas Prácticas Acuícolas. Durante ese mismo año, el Comité de Sanidad Acuícola y Pesquero Veracruzano A.C. (COSAP) realizó una auditoria técnica a la UPA. Finalmente, en 2019, la Secretaría de Agricultura y Desarrollo rural (SADER), a través de SENASICA, otorgo a la empresa el certificado AC PD-30-19, avalando el cumplimiento de las Buenas Prácticas Acuícolas en la Producción Primaria

1.3 Estructura organizacional

En la Figura 4 se observa la estructura organizacional como organigrama de la empresa Ingeniería Agropecuaria del Papaloapan S.P.R. de R.L.




Figura 4 Organigrama

1.4 Enfoque estratégico

1.4.1 Misión

“Desarrollar e implantar las mejores prácticas y tecnologías que permitan la producción y la comercialización de Tilapia de calidad, fomentando la innovación en la industria acuícola, tomando en cuenta el respeto al medio ambiente y la colaboración con diferentes unidades productivas”.

1.4.2 Visión

“Ser una empresa líder en la producción y comercialización de Tilapia en el estado de Veracruz. Ser la mejor empresa acuícola del municipio y un líder de la industria”.

1.4.3 Valores

- ❖ Pasión “Servimos con Pasión: Nos entregamos en todo lo que hacemos”.
- ❖ Equipo “Trabajamos en Equipo: Colaboramos, sumamos esfuerzos, multiplicamos logros”.
- ❖ Confianza “Construimos Confianza: Cultivamos cada relación con integridad”.
- ❖ Calidad “Entregamos Calidad: Ofrecemos diariamente productos y servicios de calidad superior”.
- ❖ Efectividad “Operamos con Efectividad: Ejecutamos con precisión y excelencia”.
- ❖ Rentabilidad “Buscamos la Rentabilidad: Obtenemos resultados para seguir creciendo”.
- ❖ Persona “Valoramos a la Persona: El capital humano es lo más valioso con lo que contamos”.

1.5 Descripción del proceso de producción de Tilapia

Ingeniería agropecuaria del Papaloapan S.P.R. de R.L. es una unidad de producción acuícola (UPA) que se dedica a la Acuicultura, en específico, a la producción de la Tilapia, esta actividad económica incluye procesos o actividades como que se muestran en la Figura 5.




Figura 5 Proceso de cultivo de Tilapia

1.5.1 Distribución del área

La distribución del módulo de la unidad de producción de cultivo de Tilapia en Ingeniería agropecuaria del Papaloapan S.P.R. de R.L se observa en la Figura 6.




Figura 6 Distribución del módulo

1.6 Generalidades del proyecto

1.6.1 Planteamiento del problema

En la empresa Ingeniería agropecuaria del Papaloapan S.P.R. de R.L se requiere un modelo predictivo que permita integrar múltiples variables y optimizar la calidad del agua y sus costos. El uso de redes neuronales artificiales ofrece una alternativa innovadora para modelar matemáticamente los factores que componen la calidad del agua, para posteriormente optimizar a través de los algoritmos genéticos los objetivos primordiales de la empresa, favoreciendo la gestión acuícola y una producción más eficiente y sostenible.

1.6.2 Objetivo general

Desarrollar un modelo de predicción y optimización respecto a la calidad del agua en la producción de tilapia utilizando herramientas de inteligencia artificial, que permita mejorar la calidad del agua y maximizar la producción sostenible de esta especie acuática.

1.6.3 Objetivos particulares

1. Simulación de variables: Identificar y analizar las variables que conforman la calidad del agua.
2. Creación de una base de datos de los criterios pertinentes para determinar la calidad del agua.
3. Desarrollo del Modelo Predictivo: Crear un modelo predictivo mediante redes neuronales que relacione las variables identificadas con los niveles de calidad del agua.
4. Aplicación de Algoritmos Genéticos: Implementar algoritmos genéticos multiobjetivo para optimizar las condiciones de cultivo, enfocándose en maximizar la calidad del agua y minimizar costos operativos y ambientales.
5. Frente de Pareto: contribuye a una fuerza contradictoria de todas las soluciones optimas y factibles, encontradas durante la búsqueda para un problema multiobjetivo.

1.6.4 Justificación

La justificación de un tema como la "Predicción y optimización de la calidad del agua en la producción de tilapia mediante el uso de la inteligencia artificial" puede estar fundamentada en varios aspectos relevantes, que incluyen el contexto ambiental, la sostenibilidad de la acuicultura, la mejora en la producción y la aplicación de técnicas avanzadas en la toma de decisiones.

1. Importancia de la calidad del agua en la Acuicultura

La calidad del agua es un factor crítico en la acuicultura, especialmente en el cultivo de especies como la tilapia. Niveles adecuados de calidad son esenciales para el crecimiento, salud y la

supervivencia de los peces. La falta de esto puede llevar a estrés, enfermedades e incluso mortalidad masiva, lo que impacta negativamente en la producción y la economía de los acuicultores.

2. Aumento de la Demanda de Recursos Acuáticos

Con el incremento de la población global y la demanda de proteína de origen acuático, la producción sostenible de tilapia, que es una de las especies más cultivadas mundialmente, se vuelve esencial. Mejorar la eficiencia de producción mediante el correcto control de calidad del agua puede contribuir a satisfacer esta demanda.

3. Retos en la Gestión por mantener niveles adecuados de calidad de agua.

Los sistemas de producción acuícola a menudo enfrentan desafíos relacionados con las fluctuaciones en determinadas variables que afectan el agua, que pueden ser ocasionadas por factores como la sobrepoblación, la descomposición de materia orgánica, y las variaciones en la temperatura y la salinidad. Abordar estos retos mediante técnicas avanzadas para el monitoreo y la gestión es crucial.

4. Aplicación de Algoritmos Genéticos Multiobjetivos

Los algoritmos genéticos multiobjetivo son herramientas eficaces para resolver problemas complejos de optimización donde se deben considerar múltiples objetivos, como maximizar el crecimiento de los peces mientras se minimizan los costos operativos y el uso de recursos. Su aplicación en la predicción y optimización de la calidad del agua en sistemas de cultivo de tilapia permite encontrar soluciones equilibradas que maximicen el rendimiento y minimicen el impacto ambiental.

5. Sostenibilidad y Responsabilidad Ambiental

La optimización de la producción de tilapia no solo busca beneficios económicos, sino que también se alinea con los principios de sostenibilidad. Al mejorar la gestión de la calidad del agua se puede contribuir a prácticas de acuicultura más responsables que minimicen el deterioro del medio ambiente y promuevan el uso eficiente de los recursos naturales.

6. Innovación Tecnológica en la Acuicultura

El uso de algoritmos genéticos y modelos predictivos representa una incorporación de innovaciones tecnológicas en el sector acuícola. Esto no solo mejora la gestión y el rendimiento de las granjas de tilapia, sino que también prepara a la industria para enfrentarse a los desafíos del futuro en un mundo donde la tecnología juega un papel cada vez más importante.

La justificación del estudio sobre la predicción y optimización de niveles adecuados de la calidad del agua en la producción de tilapia mediante algoritmos genéticos multiobjetivo y redes neuronales reside en su capacidad para contribuir a una acuicultura más eficiente, sostenible y capaz de satisfacer las demandas futuras de consumo. Este enfoque no solo beneficia a los acuicultores al aumentar la

producción y reducir costos, sino que también guarda un compromiso con la conservación del medio ambiente y la salud del ecosistema acuático.

1.6.5 Metodología




Figura 7. Metodología de apoyo a la decisión mediante la Inteligencia Artificial (IA)

Para comprender el ciclo de la metodología con la que se trabajara este proyecto procedemos a realizar la descripción de los componentes:

- ✓ Simulación de indicadores de agua: Analizar los diferentes indicadores de agua utilizando aquellos cuya cualidad sea de mayor importancia para definir la calidad del agua.
- ✓ Base de datos (BD) de las variables consideradas: Analizar partiendo de una base que alimenta un conjunto de datos históricos o en tiempo real a la red neuronal.
- ✓ Redes neuronales artificiales (RNA) para modelado matemático: Generar un modelo predictivo con previo aprendizaje de patrones y relaciones a partir de los datos.
- ✓ Optimización con algoritmos genéticos multiobjetivo (AGMO): Optimizar una función objetivo, seleccionando las mejores soluciones mediante un proceso de selección y mutación partiendo de la salida de la red neuronal y utilizándola como base para generar y evaluar diversas soluciones.
- ✓ Soluciones del frente de Pareto para apoyo a la decisión: Verificar la relación entre calidad del agua y costos totales para esclarecer la toma de decisiones.
- ✓ Retroalimentación: Retroalimentar el sistema con los resultados reales para mejorar el desempeño a futuro.

1.7 Estado del arte

El estudio de la calidad del agua en acuicultura ha evolucionado notablemente en los últimos treinta años, pasando de enfoques tradicionales de monitoreo manual a metodologías avanzadas que integran sensores, inteligencia artificial y algoritmos multiobjetivo.

De acuerdo con (Tucciarone, Secci, Contiero, & Parisi, 2024) señala que la investigación en sostenibilidad acuícola ha crecido de manera sostenida, con un énfasis particular en la medición de

parámetros fisicoquímicos como oxígeno disuelto, pH, amonio, nitritos, nitratos y temperatura, los cuales son críticos para la supervivencia de especies como la tilapia y el camarón. Al demostrar que la integración de técnicas de optimización en la gestión de estos factores no solo mejora la calidad del agua, sino que incrementa la productividad y reduce los costos de operación, consolidando la calidad del agua como un eje transversal de la sostenibilidad acuícola.

En este marco, el uso de machine learning y modelos predictivos se ha posicionado como una de las herramientas más prometedoras. (Li, Lu, Wu, & Zhang, 2022) validaron que algoritmos como Random Forest y Support Vector Machines permiten pronosticar con alta precisión la dinámica de parámetros de calidad del agua, incluso en sistemas intensivos.

De forma complementaria, (Eze, Kirby, Attridge, & Ajmal, 2023) propusieron un modelo híbrido basado en redes neuronales (EEMD-LSTM) que integró múltiples variables en granjas de salmón, logrando predicciones robustas en tiempo real. Estos aportes muestran cómo la predicción de tendencias de calidad del agua puede anticipar crisis (hipoxia, toxicidad por amonio) y facilitar la toma de decisiones preventivas.

En línea con esta tendencia, el modelo IoT-machine learning presentado por (Shete, C., & Mahajan, 2025) destaca la incorporación de dispositivos de bajo costo conectados en la nube para la predicción del oxígeno disuelto, lo cual abre la puerta a una acuicultura 4.0 con monitoreo y control autónomo.

Por otra parte, la optimización multiobjetivo (MOO) ha demostrado ser esencial para enfrentar la naturaleza contradictoria de los objetivos en acuicultura: mejorar la calidad del agua, maximizar la producción y minimizar los costos y el impacto ambiental. (Kinadu, Cunha, Salomons, & Ostfeld, 2023) introdujo mejoras en el algoritmo NSGA-II que permiten una convergencia más eficiente hacia frentes de Pareto en problemas complejos de gestión hídrica.

Los estudios de campo más recientes confirman el potencial de integrar predicción y optimización. El trabajo de (RM, 2025) implementó sensores IoT conectados a un modelo Random Forest, logrando un 92% de precisión en la predicción de fluctuaciones de oxígeno disuelto y pH, con respuestas automáticas para mitigar riesgos.

Como complemento a lo anterior, (Songma, 2024) aplicó técnicas bioinspiradas de optimización combinadas con machine learning en granjas de camarón, logrando reducir la mortalidad y mejorar el índice de conversión alimenticia. Estos ejemplos muestran un acercamiento a aplicaciones prácticas, aunque con limitaciones en la cantidad de parámetros considerados y en la validación a gran escala.

(Yusoff, Umi, Ramli, & Harun, 2024) advierte que los modelos actuales tienden a centrarse en parámetros fisicoquímicos, dejando de lado indicadores de bienestar animal, comportamiento y salud. (Capetillo-Contreras, Reynoso, & Resendiz, 2024) refuerzan esta crítica al identificar que la

mayoría de los modelos basados en inteligencia artificial para acuicultura carecen de validación empírica en granjas comerciales, lo que limita su aplicabilidad en contextos reales.

Dado este historial persisten vacíos significativos: la falta de integración de indicadores biológicos y económicos, la escasa validación en empresas acuícolas reales y la necesidad de marcos metodológicos que conecten predicción, optimización.

En este contexto, la presente investigación se plantea como una contribución innovadora, al proponer un modelo integral de optimización multiobjetivo de los factores que componen la calidad del agua en una empresa acuícola, sustentado en evidencia empírica y orientado a la sostenibilidad productiva.

CAPITULO II MARCO TEORICO

2.1 Acuicultura

2.1.1 Definición

Según la Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO), la acuicultura se define como el cultivo de organismos acuáticos que implica la intervención humana para aumentar la producción. Este sector ha alcanzado una relevancia histórica reciente, pues, tal como se documenta en el informe “El estado mundial de la pesca y la acuicultura 2024 (SOFIA), la producción acuícola mundial superó a la pesca de captura por primera vez en 2022, constituyéndose como la principal fuente de animales acuáticos a nivel global. (FAO, El estado mundial de la pesca y la acuicultura , 2024)

2.1.2 Acuicultura en el mundo

La acuicultura tiene miles de años de antigüedad siendo sus primeros indicios en China hace más de cuatro mil años. A lo largo de la historia ha tenido una gran expansión abarcando áreas ambientales, sociales, económicas y culturales que son independiente a su función inicial como abastecimiento alimentario el cual por cierto es el sector más dinámico globalmente en las últimas tres décadas. Desde un 4 % de la producción mundial de animales acuáticos en la década de 1950, alcanzo un 49.2% en 2020. La producción global de animales acuáticos en 2020 fue de 122.6 millones de toneladas, con un 71% de esa cifra destinado al consumo humano. Las especies acuícolas básicas son predominantes en la producción mundial, como la carpa herbívora (acuicultura continental) y el salmón del Atlántico (acuicultura marina). Los peces de aleta, moluscos y crustáceos son los grupos más cultivados a nivel global.

Asia es la región líder en acuicultura, con 91.6% de la producción mundial de animales acuáticos y algas en 2020. Los países clave son China, Indonesia, India, Vietnam y Bangladesh. Sin embargo, hay disparidad con el desarrollo de la acuicultura dentro de Asia. La acuicultura en agua continentales ha crecido considerablemente, alcanzando el 44.4% de la producción acuícola global en 2020 (SIAP, 2022). El cultivo de peces en estanques de tierra sigue siendo el método más común. Se espera para el año 2030 que la producción acuícola incremente un 13% con el desafío de lograr dicho crecimiento manteniendo la sostenibilidad ambiental, la seguridad alimentaria y el fomento de medios inclusivos con un enfoque en innovaciones tecnológicas.

Realmente la acuicultura tiene un gran poder dentro de una población en crecimiento como la nuestra, pero debe ser sostenible. En 2020 la producción mundial alcanzo un récord de 122.6 millones de toneladas con un valor de 281.500 millones de USD. De esta cifra, 87.5 millones de toneladas fueron animales acuáticos y el resto algas. El aumento de la producción fue impulsado por países como

Chile, China y Noruega mientras que África cae en descenso productivo debido a los descensos de Egipto y Nigeria manteniéndose Asia como un dominante de esta área (FAO, Version Resumida de El estado mundial de la pesca y la acuicultura 2022. Hacia la transformacion azul, 2022)

2.1.2.1. Los sistemas de producción

El cultivo de tilapia ha ganado popularidad debido a sus cualidades como la carne más jugosa, crecimiento rápido, alta resistencia física, buena capacidad reproductiva y la fácil adaptación que tienen a diversos tipos de alimentos y condiciones del agua, incluidas el agua con poca oxigenación.

El cultivo se realiza en sistemas extensivos, semi intensivos e intensivos y esto depende de la densidad de la siembra y el tipo de alimentación, además, se puede desarrollar junto con otras especies acuáticas como camarones y langostinos. A continuación, detallamos brevemente cada uno de los sistemas mencionados:

- Sistema Extensivo: requiere una intervención humana mínima, no se lleva a cabo un control de calidad sobre los insumos requeridos y el agua; la producción en este sistema va de los 5,000 a 12,000 kg/ha
- Sistema Semi-intensivo: posee un mayor control respecto a los insumos y calidad del agua, su producción es considerada intermedia.
- Sistema Intensivo: se considera un control de calidad alto que involucra a todos los factores que tengan relación con el cultivo, regularmente las producciones en este sistema superan los 80 a 120 kg/ha/día.

El cultivo de la tilapia puede ser en estanques de barro, jaulas o canales de cemento, todo esto a criterio de quien lo cultive considerando sus recursos y las condiciones; esto va de la mano con algunos factores clave como:

Calidad del agua: considerando que es fundamental contar con un abastecimiento de agua limpia y oxigenada, ya que, de no ser así, se puede afectar a la especie y al consumidor.

Alimentación: una alimentación adecuada para los es fundamental para el correcto crecimiento de la tilapia, es recomendable combinar suplementos alimenticios con fertilizantes para estimular el crecimiento del plancton el cual sirve como alimento natural para los peces. (Murnyak, 2010)

Reproducción: como ya sabemos, una característica de la tilapia es su alta reproducción, una forma de maximizar la producción es separar los sexos durante la temporada de engorde. (Martinez, 2006)

2.1.3 Acuicultura en México

México realmente juega un papel importante en la acuicultura, especialmente en la producción de especies marinas como el camarón, trucha y la tilapia la cual por ejemplo se cultiva tanto en agua dulce como en agua salada mientras que el camarón es la especie con mayor exportación. La

acuicultura mexicana ha crecido considerablemente y el país es un importante productor y exportador de este tipo de productos.

Aunque la acuicultura en México ha crecido, se enfrenta a desafíos relacionados con la sostenibilidad ambiental, tales como el uso de agua, la gestión de residuos y el impacto en los ecosistemas acuáticos. Es necesario implementar prácticas acuícolas más sostenibles para asegurar el desarrollo a largo plazo en la industria.

Nuestro país por su parte ha promovido innovaciones en acuicultura, como el uso de tecnologías avanzadas para mejorar la producción, la calidad del agua y la salud de las especies cultivadas, sin embargo, aún hay retos en la optimización de los alimentos acuícolas y la adaptación de estas al cambio climático (SIAP, 2022).

El cultivo de tilapia es uno de los más populares en México y ha cobrado fuerza gracias a las cualidades reproductivas del pez, pues su ciclo es relativamente sencillo y rápido, además de que puede adaptarse a condiciones de cautiverio tanto en estanques como jaulas, lo que favorece positivamente a la acuicultura nacional (Castillo, 2022)

La acuicultura, consiste en la reproducción controlada, pre-engorda y engorda de especies de fauna acuática, por medio de técnicas de cría o cultivo. En México, esta actividad registra antecedentes desde el siglo pasado y ha impulsado a nuestro país como uno de los 10 principales productores del sector a nivel mundial.

México es el noveno mayor productor de tilapia en el mundo, con una producción que representa el 94.3% de la pesquería nacional de la especie. Los principales estados productores son Jalisco, Chiapas, Sinaloa, Nayarit, Veracruz, entre otros. La tilapia es un componente clave en la economía regional, especialmente en áreas dedicadas a la acuicultura. A través del programa de la SAGARPA y FIRCO, se brinda apoyo para el desarrollo de la Acuicultura en diversas regiones del país. (FIRCO, 2017)

2.1.3.1 Inocuidad agroalimentaria, acuícola y pesquera

Derivado de la globalización de los mercados y el intercambio comercial en expansión de los alimentos, los gobiernos han tenido la necesidad de implementar estrategias que contribuyan al aseguramiento de la inocuidad de los productos alimenticios, es por ello, que se define el término de inocuidad como “la característica que tiene un alimento de no causar daño a la salud del consumidor por efecto de algún contaminante” (Servicio Nacional de Sanidad, 2025).

Existen factores que pueden poner en riesgo la inocuidad de un producto, entre ellos:

- Químicos: hormonas, antibióticos, plaguicidas, etc.
- Biológicos: virus, bacterias, etc.
- Físicos: pedazos de metal, astillas, entre otros.

Todas estas características junto con las organolépticas, comerciales y nutricionales, integran los requisitos básicos que deben considerarse para poder acceder a los diferentes mercados, ya que estos incrementan el nivel de confianza en el consumidor.

En la actualidad, todos los países que gusten de exportar sus productos agropecuarios para el consumo humano requieren de certificaciones sanitarias que aporten una garantía sobre su producto. Para lograrlo, se requieren de controles de calidad precisos y actividades que sirvan para minimizar los riesgos de contaminación. Todo lo anterior, aparte de brindar un buen producto al consumidor ayuda que la parte comercial sea beneficiada con una participación competitiva y permanente en el amplio mercado.

2.1.3.2 Normatividad aplicable en México

La acuicultura y todos los diferentes productos pesqueros en nuestro país, México, se encuentran regularizados bajo normas oficiales que buscan asegurar el manejo adecuado, la inocuidad y la protección al consumidor.

De acuerdo con el artículo 118, 119 Bis y 119 Bis 1, de la ley General de Pesca y Acuicultura Sustentables (LGPAS), (México, 2024) “tiene como objeto establecer las medidas de inocuidad de los productos acuícolas y pesqueros, desde su captura o cosecha y hasta su procesamiento primario, incluyendo actividades tales como: cortado, refrigerado y congelado, a través de las Buenas Prácticas Acuícolas y Pesqueras y Buenas Prácticas de Manufactura. Entre las normas sanitarias más relevantes en este ámbito encontramos la NOM-242-SSA1-2009, “Productos y servicios. Productos de la pesca frescos, refrigerados, congelados y procesados. Especificaciones sanitarias y métodos de prueba” que establece ciertas especificaciones sanitarias para ese tipo de productos, así como los métodos para su prueba y verificación (DOF, NORMA Oficial Mexicana NOM-242-SSA1-2009, Productos y servicios. Productos de la pesca frescos, refrigerados, congelados y procesados. Especificaciones sanitarias y métodos de prueba., 2009). Complementario a esto la NOM-251-SSA1-2009, “Prácticas de higiene para el proceso de alimentos, bebidas y suplementos alimenticios”, como su nombre lo indica, define las prácticas de higiene con las que deben cumplir los establecimientos dedicados a la producción y procesamiento de alimentos, que de igual forma son aplicables a unidades de producción acuícolas (DOF, Prácticas de higiene para el proceso de alimentos, bebidas o suplementos alimenticios., 2009).

En el aspecto ambiental la NOM-001-SEMARNAT-2021 (SEMARNAT, 2021), “Que establece los límites permisibles de contaminantes en las descargas de aguas residuales en cuerpos receptores propiedad de la nación”, regula los límites máximos permitidos en descargas de aguas residuales en cuerpos que los requieren, situación que es considerada en aquellos efluentes generados por granjas acuícolas.

Respecto a la bioseguridad, el Servicio Nacional de Sanidad, Inocuidad y Calidad Agroalimentaria (SENASICA), emite lineamientos complementarios y programas de certificación en buenas prácticas acuícolas.

Por su parte la Comisión Nacional de Acuicultura y Pesca (CONAPESCA) se encarga de regular permisos concesiones y los alimentos.

En conjunto, estas normas son el marco jurídico encargado de la regularización de la producción acuícola en México y el cumplimiento de cada una de ellas es indispensable para garantizar un producto de calidad proporcionado al consumidor, protección y cuidado del medio ambiente y aseguramiento de la sostenibilidad del sector.

2.1.4 Calidad del agua en Acuicultura

En la Acuicultura, la calidad del agua es claramente el factor más importante para la sostenibilidad, supervivencia de la especie acuática y por ende importante también para la productividad de los sistemas acuícolas. El control adecuado de la misma permite que en este caso, la tilapia tenga la salud adecuada, su proceso de alimentación, engorda y crecimiento sea el ideal, así como la prevención de enfermedades.

Al existir una interacción entre los parámetros fisicoquímicos del agua, su monitoreo constante es esencial en la acuicultura actual.

A continuación, describiremos aquellos parámetros considerados los más relevantes para la calidad del agua según la literatura dedicada al estudio del proceso de cultivo de tilapia.

2.1.4.1 La temperatura

La temperatura es un factor un alto nivel de influencia en la salud y fisiología de los peces, ya que, afecta directamente al metabolismo, crecimiento, alimentación y su mal control puede provocar un consumo de oxígeno que perjudica a todos los peces de un solo estanque.

En el caso de la tilapia, la temperatura regularmente oscila entre los 26°C y 30°C que es donde las tasas de crecimiento se perciben mayores, al contrario de temperaturas que van por debajo de los 20°C en donde se reduce la actividad metabólica de la tilapia y valores superiores a 36°C provocan estrés severo, bajo consumo de oxígeno y aumento en la mortalidad. (Sayed, 2020)

2.1.4.2 El oxígeno disuelto

El oxígeno disuelto es identificado en la literatura como un parámetro crítico en un sistema intensivo de tilapia debido a la relación directa que tiene con la morfología que deberá poseer el pez para su supervivencia.

En el caso de la tilapia se requieren valores superiores a 5mg/L para un crecimiento y desempeño óptimo del pez como del agua respectivamente. Se considera que los valores menores a 3mg/L pueden generar una disminución hipoxia, estrés y hasta la mortalidad, pero particularmente estos casos suelen darse durante la madrugada cuando los niveles de concentración de OD son mínimos debido a la actividad microbiana que se presenta al interior de los estanques. (Boyd C. , 2015)

2.1.4.3 El pH

El pH o potencial de Hidrogeno, se encarga de indicar el grado de alcalinidad o acidez de una disolución en una escala que va del 0 al 14 en donde:

$\text{pH} = 7.0 \rightarrow$ sustancia neutra

$\text{pH} < 7.0 \rightarrow$ sustancia ácida

$\text{pH} > 7.0 \rightarrow$ sustancia alcalina

En la práctica acuícola el pez solo puede vivir en un pH aproximadamente neutro que generalmente en el rango 6.5 a 8.5 (Tucker, 1998). De esta forma, el pH modula el riesgo de toxicidad del amoníaco.

2.1.4.4 TAN

El Amonio total, por sus siglas en inglés: Total Ammonium Nitrogen (nitrógeno amoniacal total), es un producto de las excreciones, orina y descomposición de la materia fecal, materia vegetal y proteínas de alimento no consumido considerados como elementos tóxicos (Boyd C. , 2015). Existe un cambio inmediato cuando el amonio pasa a ser amoníaco y el amoníaco nuevamente regresa a ser amonio nuevamente, situación que depende de la cantidad de protones presentes en el agua del estanque.

Un nivel ≥ 0.6 mg/L de amoníaco, suele tener efectos letales en las tilapias.

2.1.4.5 Nitrito

Los nitritos son considerados parámetros de vital importancia, esto radica en su capacidad de toxicidad y alto grado como agente contaminante que se genera durante la transformación del amoníaco a nitratos.

Dicha toxicidad depende de la cantidad o concentración de oxígeno en el agua, temperatura y cloruros. Debido a esto, la concentración de nitritos debe situarse por debajo de los 0.5 mg/L para ser considerados como niveles seguros para la tilapia. De igual forma altos niveles de nitritos son considerados letales para la especie en estudio (Boyd C. , 2015).

2.1.4.6 Nitrato

De los productos llamados como “nitrogenados” el nitrato es una sal considerada como muy poco tóxica para los animales acuáticos, pero, si esta sal se acumula puede generar estrés crónico y retraso

del crecimiento de la especie. Dentro de la práctica acuícola se recomienda como adecuada o segura una concentración que oscile entre los 50 y 100 mg/L. (Boyd C. , 2015)

2.1.4.7 Transparencia

Otro factor importante es la transparencia del agua. Las aguas verdes de muy poca transparencia brindan un inicio de productividad e incorporación de oxígeno al agua. Regularmente la medición de la transparencia se realiza mediante el disco de secchi, tomando en cuenta la profundidad de visibilidad de un objeto abajo del agua en un rango de los 25 y 40 cm. Únicamente se debe tomar en cuenta que el productor no debe confundir la turbidez con la producción de plancton (Tucker, 1998)

2.1.4.8 Dureza

La dureza se conoce como la medida de concentración de iones de Ca y Mg. ara el cultivo de tilapia se recomiendan valores mayores a 40 mg/L (Boyd C. , 2015). Se considera que la dureza también tiene la capacidad de modular la toxicidad de algunos metales pesados.

2.1.4.9 Alcalinidad

En los estanques de cultivo de tilapia, la alcalinidad tiene una gran importancia. El rango recomendado en sistemas acuícolas es 50 a 200 mg/L CaCO_3 . (Boyd C. , 2015). Es considerado como fundamental para mantener una estabilidad física y para procesos de nitrificación.

2.1.4.10 Dióxido de Carbono

El dióxido de carbono (CO_2). Se activa durante la respiración nocturna de todos los organismos y microorganismos del sistema de cultivo o el estanque, el CO_2 no puede ser mayor a 15 mg/L debido a que si supera ese parámetro puede causar acidosis, reducir el paso y fluidez del oxígeno en la sangre y provocar estrés (Tucker, 1998)

2.2 Simulación con SIMNET II

En Ingeniería Industrial la simulación es una herramienta con gran aplicabilidad en diversas áreas; en la investigación la simulación brinda apertura a la exploración de comportamientos de múltiples variables con un sinfín de combinaciones posibles minimizando algunos costos que se generen por la experimentación y reduciendo el tiempo para la obtención de un modelo matemático.

En un estudio ambiental o acuícola, la simulación es utilizada cuando lo que se requiere es analizar el comportamiento de múltiples variables en condiciones limitadas. En este caso, SIMNET II® está basado en principios de simulación por eventos discretos y la generación de datos mediante redes de nodos conectados entre sí, regularmente esta técnica es empleada por modelos como SLAM II (Pritsker, 1995), a futuro desarrollada en plataformas novedosas de simulación (Law, 2015).

En la acuicultura con el apoyo de la simulación, es posible generar bases de datos con valores aproximados y coherentes de las variables fisicoquímicas determinadas del agua situados dentro de los rangos que se establecen, esto permite la creación de escenarios hipotéticos los cuales aplicados en la realidad serian costosos. Este escenario ficticio pasa a ser de gran utilidad cuando el objetivo es la retroalimentación de un modelo de predicción como las redes neuronales artificiales, siendo que estas requieren grandes volúmenes de datos para su entrenamiento. (Law, 2015)

2.2.1 Nodos

En el programa SIMNET II®, los nodos son unidades funcionales dentro de la red de simulación. Estos nodos se convierten en bloques con la capacidad de recibir entradas, procesarlas y generar salidas. Esta estructura de red interconectada proviene del enfoque de simulación que describe Pritsker en su metodología del modelado mediante redes (Pritsker, 1995) .

Estos nodos nos permiten establecer los limites inferior y superior las variables, seleccionar distribuciones de generación, ya sea uniforme, aleatoria o determinística, controlar la dependencia existente entre variables, así como conectar múltiples nodos para simular el sistema completamente. Este tipo de enfoque coincide con los fundamentos de la simulación en sistemas complejos como los que describe Banks, en donde cada uno de los nodos representa una entidad lógica que interactúa con otras entidades dentro de un sistema (Banks, Nicol, Carson, & Nelson, 2013)

2.2.2 Pruebas de bondad de ajuste

Las pruebas de bondad de ajuste permiten analizar y determinar qué tipo de distribución estadística siguen los datos generados y obtenidos mediante el simulador. Estas pruebas son particularmente esenciales para justificar la coherencia del modelo y de igual forma, asegurar que los datos simulados cumplan con los supuestos estadísticos del análisis y no exhibir sesgos sistemáticos. (Razali & Wah, 2011)

Las pruebas más utilizadas son:

- Kolmogórov-Smirnov: la cual se utiliza para comparar una distribución empírica con una teoría continua, regularmente aplicada en estudios de simulación por forma simple de aplicación y su robustez. (Massey, 2019)
- Shapiro-Wilk: una prueba considerada como una de las más precisas para evaluar normalidad entorno a pequeñas y medianas muestras.
- Anderson-Darling: una prueba que brinca mayor peso a los extremos de la distribución, este tipo de prueba es especialmente útil en análisis de datos obtenidos mediante simulación. (Farrel & Rogers-Stewart, 2017)

El uso y aplicación de estas pruebas permite validar la suficiencia de los datos simulados antes de utilizarlos en procesos de entrenamiento de modelos de IA, lo cual disminuye el riesgo de trabajar o introducir errores derivados de distribuciones que no son adecuadas. (Aggarwal, 2023)

2.2.3 Muestreo no probabilístico

El muestreo no probabilístico tiene como principal característica la selección de datos aun sin tener una probabilidad conocida de integración para sus elementos. En el área de simulación, este tipo de muestreos es común debido a que los datos utilizados no provienen de una población objetivo real, sino de un entorno ficticio y artificial creado para explorar el comportamiento de un sistema (Montgomery & Runger, 2018).

Pese a esta limitación, el Teorema del Limite Central permite justificar el uso de datos simulados en gran volumen, ya que este, establece que la distribución media muestral tiende a una distribución normal a medida que el tamaño de la muestra aumenta pese a la distribución original. (Blitzstein & Hwuang, 2019). Con este principio se sustenta la estabilidad estadística de los datos simulados y respalda el uso de estos para la posteridad en el entrenamiento de modelos de predicción, en los cuales la normalidad aproximada de las medias facilite la convergencia y desempeño del modelo matemático obtenido.

2.3 Inteligencia artificial

La Inteligencia Artificial (IA) es una rama de las ciencias de la computación que se enfoca en el desarrollo de sistemas con la capacidad de realizar tareas que con regularidad requieren de la inteligencia humana, es decir, la IA tiene la capacidad de aprender, razonar, reconocer patrones e inclusive tomar decisiones.

En la actualidad el uso de la IA ha tenido un crecimiento importante gracias a la capacidad computacional, la disposición y apertura a volúmenes de datos grandes y el desarrollo de ciertos algoritmos tan avanzados, que dan paso al autoaprendizaje. (Russell & Norvig, 2021)

Actualmente la IA es considerada como una tecnología multifacética al considerar su aplicación en sectores industriales, de salud, energéticos, ambientales, agrícolas, acuícolas entre otros, en los cuales demuestra ser una herramienta eficaz para la modelación de sistemas bastante complejos y no lineales. (Bishop, 2020)

2.3.1 Orígenes y desarrollo de la inteligencia artificial

Se sugiere que el concepto de la inteligencia artificial surgió formalmente en 1956, durante la llamada “Conferencia de Dartmouth”, realizada en el Dartmouth College de New Hampshire, Estados

Unidos por John McCarthy¹. En sus primeras etapas la IA se basó en sistemas únicamente de reglas y lógica simbólica, sin embargo, estas aproximaciones demostraban sus limitantes al encararse con problemas más complejos y altamente variables. (Russell & Norvig, 2021). Sin embargo, según la literatura existen otras fechas que acunan e impulsan su nacimiento:

En 1940, surge el “Modelo de neurona McCulloch-Pitts, donde Warren McCulloch y Walter Pitts proponen el primer modelo matemático de una neurona artificial. Dicho modelo sentó las bases para el desarrollo de las redes neuronales artificiales y la computación neuronal.

En el año de 1940, Alan Turing propone la “Prueba de Turing”, la cual evaluaba la inteligencia de las máquinas. Esta prueba planteaba un método que determinaba si una máquina puede mostrar un comportamiento inteligente que sea equivalente al pensamiento de un ser humano.

En 1956 como lo mencionamos anteriormente se lleva a cabo la conferencia de Dartmouth organizada por John McCarthy, Marvin Minsky, Nathaniel Rochester y Claude Shannon, en la cual se discute la posibilidad de crear máquinas que pudieran simular aspectos que solo posee la inteligencia humana.

1959, abre paso al desarrollo del perceptrón el cual fue el primer modelo de red neuronal implementado en hardware, creado por Frank Rosenblatt. Este dispositivo tenía la capacidad de aprender patrones simples, dejando así, una huella importante en el desarrollo de las redes neuronales artificiales y el aprendizaje automático.

En 1956 surge ELIZA, considerado el primer programa de chat o chatbot. ELIZA creado por Joseph Weizenbaum fue diseñada con la capacidad de simular una conversación con un psicoterapeuta utilizando técnicas de procesamiento de lenguaje natural simple y efectivo.

En el año de 1979 nace el “Stanford Cart”, uno de los primeros robots móviles con la capacidad de navegar de forma autónoma en entornos con obstáculos, el cual fue desarrollado en la universidad de Stanford. Este pequeño vehículo hacía uso de una cámara para poder observar los obstáculos puestos y esquivarlos, su función era lenta pero independiente.

David Rumelhart, Geoffrey Hinton y Ronald Williams publican un artículo en 1986 sobre el algoritmo de la retro propagación, el cual se convierte en un método fundamental para el entrenamiento de redes neuronales profundas.

En 1997, surge un evento histórico, la Deep Blue de IBM vence al campeón mundial de ajedrez Garry Kasparov y se consolida como la primera vez que una computadora derrota a un campeón

¹ John McCarthy, considerado uno de los pioneros en el campo de la inteligencia artificial que desempeñó un papel fundamental en la “conferencia de Dartmouth, además de acuñar el término “inteligencia artificial”, realizó contribuciones importantes en el desarrollo de lenguajes de programación y conceptos fundamentales de la IA.

mundial en un match a seis partidas con condiciones de torneo. Es entonces cuando la IA demostró su potencial para superar a los humanos en tareas cognitivas complejas y específicas.

En el 2005, “Stanley”, un vehículo autónomo desarrollado por la universidad de Stanford gana el DARPA Grand Challenge², su victoria marco un hito importante al demostrar la viabilidad de la tecnología de conducción autónoma en entornos complejos y sin estructuración previa.

En el año 2011, “Watson” un sistema de inteligencia artificial desarrollado por IBM gana un concurso de preguntas y respuestas llamado “Jeopardy”, este logro demostró la capacidad de la IA para procesar y comprender el lenguaje natural en un contexto competitivo y en tiempo real.

Para el Año 2012 surge AlexNet, una red neuronal convolucional profunda desarrollada por Alex Krizhevsky, Ilya Sutskever y Geoffrey Hinton la cual, demuestra aprendizaje profundo en tareas de visión por computadora con especial énfasis y éxito en la clasificación de imágenes a gran escala.

Ian Goodfellow con apoyo, introduce las Redes Generativas Adversarias (GANs) en 2014. Un nuevo enfoque para el aprendizaje automático que implica dos redes neuronales compitiendo entre sí, lo cual permite la generación de datos sintéticos muy realistas. Actualmente las GANs han tenido un impacto de importancia en áreas como la generación de imágenes y el aprendizaje sin supervisión.

En el año 2023 OpenAI lanza GTP-3 (Generative Pre-trained Transformer 3), un modelo de lenguaje de gran escala con 175 mil millones de parámetros, con un procesamiento del lenguaje natural debido a su capacidad para generar un texto coherente y la realización de diversas tareas lingüísticas sin necesidad de ajustes para la elaboración de cada tarea.

En la actualidad nos situamos en la Era de la IA Generativa (2023-2025) teniendo modelos de lenguaje de gran escala como GTP-4, Claude 3 y Gemini que transforman industrias enteras. Durante estos años hemos presenciado avances significativos en capacidades multimodales, razonamiento complejo y aplicaciones especializadas en campos como la ciencia, educación y medicina (Olivares, 2025).

Tal como podemos observar, la IA es la representación de uno de los desarrollos más importantes en nuestra era, mostrando que en un inicio comenzó como un campo especializado de investigación académica, sin embargo, hoy día, es una tecnología que se encuentra al alcance de la mano en todos los aspectos que rigen a nuestra sociedad.

2.3.2 Inteligencia artificial en la industria, así como en pequeñas y medianas empresas.

En la industria, la IA ha sido adoptada con éxito en la optimización de diferentes tipos de procesos, el control de calidad, reducción de costos operativos y mantenimiento predictivo. Varios modelos

² Competencia organizada por la Agencia de Proyectos de Investigación Avanzados de Defensa de EE. UU

basados en IA permiten analizar grandes volúmenes de datos en tiempo real, lo cual colabora eficientemente con la toma de decisiones y la productividad. (Zhang L. , 2019).

En las pequeñas y medianas empresas la IA aporta beneficios en:

- ✓ Automatización de tareas repetitivas: permite optimizar procesos como la gestión de inventario, facturación o atención al cliente mediante chatbots o sistemas de machine learning, que son los encargados de responder las preguntas más frecuentes de los clientes, procesar pedidos o actualizar automáticamente bases de datos.
- ✓ Análisis predictivo para decisiones informadas: es posible analizar grandes volúmenes de datos y a su vez, identificar patrones como la predicción de tendencias de ventas, optimizar precios según la demanda o anticipar necesidades de los clientes, abriendo oportunidad de reducir los riesgos y aprovechar las oportunidades nuevas de mercado.
- ✓ Personalización de marketing y ventas: muchas plataformas de IA permiten crear campañas de acuerdo con un análisis del comportamiento del cliente, así como “email marketing automatizado” o sistemas de recomendación en e-commerce que muestran productos o servicios adaptados a cada usuario.
- ✓ Gestión eficiente de recursos humanos: la IA aporta en la simplificación de procesos como la filtración automática de currículos con Procesamiento de Lenguaje Natural (Natural Language Processing), plataformas de entrenamiento adaptativas, monitoreo de productividad con analytics, de esta forma, muchas organizaciones reducen sus costos operáticos y mejoran la retención de talento.
- ✓ Soporte técnico y mantenimiento predictivo: en empresas con equipos físicos o digitales la IA es capaz de anticipar fallos mediante sensores y análisis de datos, de forma que evita paradas inesperadas y extiende la vida útil de maquinaria o software crítico para operaciones diarias.

Como podemos observar, la IA ha comenzado a implementarse de forma masiva y progresiva gracias a la disponibilidad de múltiples herramientas de bajo costo y con plataformas accesibles. Este tipo de tecnología permite mejorar la gestión de recursos y optimizar procesos productivos en diferentes áreas y aumentar la productividad incluso en sectores tradicionales como la agricultura y la acuicultura. (OECD, 2021; Inteligencia Artificial, 2025)

2.3.3 Redes neuronales artificiales

Las Redes Neuronales Artificiales (RNA) son modelos inspirados en la estructura y funcionamiento del cerebro humano, compuestas por unidades de procesamiento interconectados que permiten modelar relaciones complejas entre variables de entrada y salida, regularmente en sistemas no lineales. (Bishop, 2020)

Dichas redes han demostrado un alto desempeño respecto a la predicción, clasificación y optimización, lo cual las convierte en una herramienta adecuada para aplicaciones ambientales, en donde intervienen múltiples factores interdependientes. (Aggarwal, 2023)

2.3.4 Neurona artificial

Una neurona artificial es una unidad básica de una red neuronal compuesta cuyo funcionamiento es básicamente ser un receptor de señales de entrada, multiplicarlas por pesos sinápticos, sumarlas y aplicar una función de activación que determinara la salida del nodo. Matemáticamente, dicho proceso se puede expresar como una combinación lineal seguida de una función no lineal (Goodfellow, Bengio, & Courville, 2016).

El termino sesgo y su inclusión en este tema, permite ajustar el umbral de activación, incrementando la flexibilidad del modelo para poder representar patrones complejos en los datos.

2.3.5 Arquitectura de redes neuronales artificiales

La arquitectura de una red neuronal artificial (RNA) hace referencia a la forma en que se organizan sus neuronas y las conexiones entre ellas, lo cual determina su capacidad para modelar relaciones complejas entre variables. Esta estructura es fundamental en el desempeño del modelo, ya que define cómo fluye la información desde las entradas hasta las salidas (Goodfellow, Bengio, & Courville, 2016)

De manera general, una RNA está compuesta por tres tipos de capas: capa de entrada, capas ocultas y capa de salida. La capa de entrada recibe las variables independientes del sistema, las capas ocultas procesan la información mediante combinaciones lineales y funciones de activación no lineales, y la capa de salida genera la respuesta del modelo en función del problema planteado, ya sea de regresión o clasificación (Aggarwal, 2023)

El número de capas ocultas y de neuronas en cada capa influye directamente en la capacidad de aprendizaje de la red. Una red con una sola capa oculta puede aproximar funciones continuas bajo ciertas condiciones, sin embargo, arquitecturas más profundas permiten representar relaciones altamente no lineales y complejas, lo cual es especialmente útil en sistemas ambientales donde múltiples variables interactúan simultáneamente (Bishop, 2020).

Dentro de las arquitecturas más utilizadas se encuentran las redes tipo perceptrón multicapa (MLP), las cuales pertenecen a la categoría feedforward. Estas redes han demostrado ser eficientes en problemas de modelación matemática y predicción, particularmente en contextos donde existe incertidumbre y alta variabilidad, como es el caso de la calidad del agua en sistemas acuícolas (Aggarwal, 2023)

En este estudio, la selección de la arquitectura se orienta a un modelo feedforward multicapa, debido a su capacidad para aproximar funciones no lineales y su compatibilidad con técnicas de

entrenamiento supervisado, lo que permite establecer relaciones entre los indicadores físicoquímicos del agua y las variables objetivo.

2.3.6 Clasificación de redes neuronales

Las redes neuronales artificiales pueden clasificarse de acuerdo con distintos criterios, tales como su estructura, el flujo de información y el tipo de problema que resuelven. Esta clasificación permite identificar el tipo de red más adecuado según las características del sistema a modelar (Goodfellow, Bengio, & Courville, 2016)

Una de las clasificaciones más relevantes distingue entre redes feedforward y redes recurrentes. Las redes feedforward se caracterizan porque la información fluye en una sola dirección, desde la capa de entrada hacia la capa de salida, sin ciclos o retroalimentación. Este tipo de redes es ampliamente utilizado en problemas de regresión y clasificación debido a su simplicidad y eficiencia (Bishop, 2020)

Por otro lado, las redes recurrentes (RNN) incorporan conexiones que permiten la retroalimentación de información, lo que les confiere la capacidad de modelar dependencias temporales. Estas redes son utilizadas principalmente en el análisis de series de tiempo y datos secuenciales, donde el orden de los datos es relevante (Aggarwal, 2023)

Otra clasificación importante incluye:

- Redes convolucionales (CNN): utilizadas principalmente en procesamiento de imágenes y visión por computadora.
- Redes recurrentes (RNN y LSTM): enfocadas en datos secuenciales y temporales.
- Redes autoorganizadas (SOM): empleadas en tareas de agrupamiento y reducción de dimensionalidad.
- Redes profundas (Deep Learning): conformadas por múltiples capas ocultas que permiten modelar sistemas altamente complejos.

En el contexto de la presente investigación, se emplean redes tipo perceptrón multicapa (MLP), debido a su capacidad para modelar relaciones no lineales entre múltiples variables de entrada y salida, lo cual resulta adecuado para la predicción de la calidad del agua y el análisis de costos en sistemas acuícolas.

2.3.7 Tipos de aprendizaje

El aprendizaje en redes neuronales artificiales (RNA) se refiere al proceso mediante el cual el modelo ajusta sus parámetros internos, principalmente pesos y sesgos, a partir de la información contenida

en los datos. Este proceso permite que la red identifique patrones, relaciones y comportamientos dentro del sistema analizado (Goodfellow, Bengio, & Courville, 2016)

Existen tres tipos principales de aprendizaje en redes neuronales:

- ❖ **Aprendizaje supervisado:** Es el enfoque más utilizado en problemas de predicción y modelación. Se basa en el uso de un conjunto de datos etiquetados, donde se conocen tanto las variables de entrada como las salidas esperadas. La red aprende ajustando sus parámetros para minimizar la diferencia entre la salida predicha y el valor real mediante una función de error. Este tipo de aprendizaje es ampliamente utilizado en aplicaciones de regresión y clasificación (Bishop, 2020).
- ❖ **Aprendizaje no supervisado:** En este tipo de aprendizaje no se dispone de datos etiquetados. El modelo busca identificar estructuras ocultas, patrones o agrupamientos dentro de los datos. Es comúnmente utilizado en tareas como segmentación, reducción de dimensionalidad y análisis exploratorio (Aggarwal, 2023).
- ❖ **Aprendizaje por refuerzo:** Se basa en la interacción del modelo con un entorno dinámico. La red aprende a través de un sistema de recompensas y penalizaciones, ajustando su comportamiento para maximizar una recompensa acumulada. Este tipo de aprendizaje es utilizado en problemas de control, optimización y toma de decisiones (Sutton & Barto, 2018).

En la presente investigación se emplea el aprendizaje supervisado, debido a que se cuenta con variables de entrada claramente definidas y objetivos específicos, como la calidad del agua y el costo total, lo cual permite entrenar el modelo mediante la minimización del error entre los valores predichos y los observados.

2.3.8 Propiedades para la creación de la red neuronal

El diseño de una red neuronal artificial implica considerar diversas propiedades que influyen directamente en su desempeño, capacidad de generalización y estabilidad. Estas propiedades permiten construir modelos robustos capaces de representar sistemas complejos y no lineales (Goodfellow, Bengio, & Courville, 2016).

Una de las propiedades fundamentales es la capacidad de aproximación universal, la cual establece que una red neuronal con al menos una capa oculta puede aproximar cualquier función continua bajo ciertas condiciones. Esta característica es especialmente relevante en sistemas donde las relaciones entre variables no son lineales, como ocurre en la calidad del agua en acuicultura (Aggarwal, 2023).

Otra propiedad clave es la capacidad de generalización, que se refiere a la habilidad del modelo para producir resultados adecuados cuando se enfrenta a datos nuevos no utilizados durante el entrenamiento. Una red con buena generalización es capaz de representar el comportamiento real del sistema sin depender exclusivamente de los datos de entrenamiento (Bishop, 2020)

La robustez también es un aspecto importante, ya que permite que la red mantenga un desempeño adecuado aun en presencia de ruido o variaciones en los datos de entrada. Esto es particularmente relevante en sistemas reales donde las mediciones pueden presentar incertidumbre.

Asimismo, la flexibilidad de las redes neuronales les permite adaptarse a diferentes tipos de problemas, desde regresión hasta clasificación, mientras que la escalabilidad facilita su aplicación en escenarios con grandes volúmenes de datos.

Finalmente, la correcta selección de hiperparámetros, como el número de neuronas, funciones de activación, tasa de aprendizaje y número de capas ocultas, es fundamental para lograr un equilibrio entre precisión del modelo y complejidad computacional, evitando problemas como el sobreajuste o sub-ajuste (Aggarwal, 2023)

2.3.9 Entrenamiento de redes neuronales

El entrenamiento de una red neuronal artificial (RNA) consiste en el ajuste iterativo de sus parámetros internos (pesos y sesgos) con el objetivo de minimizar el error entre la salida predicha y los valores reales. Este proceso es fundamental para que la red logre modelar adecuadamente las relaciones existentes entre las variables del sistema (Goodfellow, Bengio, & Courville, 2016)

Uno de los métodos más utilizados es el algoritmo de retro propagación del error (backpropagation), el cual calcula el gradiente de la función de pérdida respecto a los pesos de la red y permite su actualización mediante técnicas de optimización como el descenso por gradiente. Este enfoque es ampliamente utilizado en redes tipo perceptrón multicapa (MLP) debido a su eficiencia y estabilidad (Bishop, 2020)

En aplicaciones más recientes, especialmente en sistemas complejos como la acuicultura, se han incorporado algoritmos de optimización avanzados como Levenberg–Marquardt, así como técnicas basadas en aprendizaje profundo (deep learning), que permiten mejorar la velocidad de convergencia y la precisión del modelo (Aggarwal, 2023)

El proceso de entrenamiento generalmente incluye las siguientes etapas:

- ✓ Inicialización de pesos
- ✓ Propagación hacia adelante
- ✓ Cálculo del error
- ✓ Retro propagación
- ✓ Actualización de parámetros

Un aspecto crítico durante el entrenamiento es evitar el sobreajuste (overfitting), el cual ocurre cuando el modelo se adapta excesivamente a los datos de entrenamiento y pierde capacidad de generalización. Para mitigar este problema, se utilizan técnicas como la validación cruzada,

regularización y la división de datos en conjuntos de entrenamiento, validación y prueba (Goodfellow, Bengio, & Courville, 2016)

En el contexto actual, el entrenamiento de redes neuronales en sistemas acuícolas ha evolucionado hacia el uso de modelos híbridos y arquitecturas profundas que integran múltiples fuentes de datos, mejorando significativamente la precisión en la predicción de variables ambientales complejas.

2.4 Predicciones basadas en redes neuronales artificiales

Las redes neuronales artificiales se han consolidado como una de las herramientas más eficaces para la predicción de sistemas complejos debido a su capacidad para modelar relaciones no lineales y multivariantes. En particular, su aplicación en sistemas acuícolas ha permitido mejorar significativamente la estimación de parámetros críticos de calidad del agua.

Una vez entrenada la red neuronal, el modelo puede utilizar nuevos datos de entrada para generar predicciones, lo cual permite anticipar comportamientos futuros del sistema. Este enfoque es especialmente útil en entornos donde la medición directa de variables es costosa o limitada.

Estudios recientes han demostrado que las RNA, junto con otros modelos de aprendizaje automático, pueden predecir variables como oxígeno disuelto, pH y compuestos nitrogenados con altos niveles de precisión, superando en muchos casos a los modelos estadísticos tradicionales. (Li, Lu, Wu, & Zhang, 2022)

Además, el desarrollo de tecnologías emergentes como el Internet de las Cosas (IoT) y el aprendizaje profundo ha permitido integrar datos en tiempo real con modelos predictivos, facilitando sistemas inteligentes de monitoreo y control en acuicultura. (Regino, Hoyos, & Lopez, 2025)

Investigaciones recientes han incorporado arquitecturas avanzadas como redes LSTM, GRU y modelos híbridos, los cuales permiten capturar dependencias temporales y mejorar la precisión en la predicción de la calidad del agua, incluso en condiciones dinámicas y con datos limitados.

Asimismo, el uso de modelos predictivos basados en inteligencia artificial no solo permite estimar variables ambientales, sino también optimizar la toma de decisiones en sistemas acuícolas, contribuyendo a mejorar la eficiencia operativa, reducir costos y prevenir eventos críticos que puedan afectar la producción. (Alnemari, Elmessery, Qazad, & Rakhimgaliyeva, 2025)

En este sentido, las redes neuronales representan una herramienta clave dentro de los sistemas de soporte a la decisión en acuicultura moderna, alineándose con el concepto de acuicultura inteligente o Acuicultura 4.0.

2.5 Algoritmos Genéticos (AG)

Los algoritmos genéticos (AG) son técnicas de optimización inspiradas en los principios de la evolución natural, como la selección, reproducción y mutación. Estos algoritmos pertenecen al campo de la inteligencia artificial y son ampliamente utilizados para resolver problemas complejos, no lineales y con múltiples variables, donde los métodos tradicionales presentan limitaciones (Aggarwal, 2023).

El funcionamiento de los AG se basa en la evolución de una población de soluciones candidatas a lo largo de varias generaciones. Cada solución, denominada individuo, representa una posible respuesta al problema y es evaluada mediante una función de aptitud (fitness), la cual mide qué tan adecuada es respecto a los objetivos planteados.

A través de operadores genéticos como selección, cruzamiento y mutación, los individuos más aptos tienen mayor probabilidad de transmitir sus características a las siguientes generaciones, permitiendo así una mejora progresiva en la calidad de las soluciones.

En aplicaciones recientes, los algoritmos genéticos han sido utilizados en combinación con modelos de inteligencia artificial, como redes neuronales, para optimizar sistemas complejos en áreas como ingeniería ambiental, agricultura y acuicultura, donde múltiples variables interactúan de forma no lineal (Tapabrata, Mohiuddin, & Kumar, 2022)

2.5.1 Población inicial

La población inicial corresponde al conjunto de soluciones generadas al inicio del algoritmo genético. Estas soluciones se crean generalmente de forma aleatoria dentro de los límites definidos del problema, con el objetivo de cubrir diversas regiones del espacio de búsqueda (Aggarwal, 2023)

Una adecuada diversidad en la población inicial es fundamental, ya que permite explorar diferentes combinaciones de variables y evita que el algoritmo converja prematuramente hacia soluciones subóptimas. En el contexto de sistemas acuícolas, esto implica generar distintas combinaciones de parámetros de calidad del agua que puedan representar escenarios reales de operación.

2.5.2 Generaciones

Las generaciones representan las iteraciones del algoritmo genético. En cada generación, los individuos son evaluados mediante la función de aptitud, y posteriormente se aplican los operadores genéticos para producir una nueva población.

Este proceso evolutivo permite que, con el paso de las generaciones, las soluciones mejoren progresivamente, acercándose a valores óptimos. La convergencia del algoritmo depende de factores como el número de generaciones, el tamaño de la población y los parámetros de los operadores genéticos (Lu & Luo, 2021)

2.5.3 Mutación

La mutación es un operador genético que introduce cambios aleatorios en los individuos de la población. Su principal función es mantener la diversidad genética y permitir la exploración de nuevas regiones del espacio de búsqueda.

Este operador es fundamental para evitar la convergencia prematura del algoritmo hacia óptimos locales, ya que permite generar soluciones diferentes a las existentes. En problemas complejos, como la optimización de sistemas acuícolas, la mutación contribuye a descubrir configuraciones no evidentes que pueden mejorar el desempeño del sistema (Aggarwal, 2023)

2.5.4 Cruzamiento

El cruzamiento, también conocido como recombinación, consiste en combinar la información genética de dos individuos seleccionados para generar nuevos descendientes. Este proceso permite aprovechar las mejores características de cada solución y combinarlas en nuevas configuraciones.

El cruzamiento es considerado uno de los operadores más importantes en los algoritmos genéticos, ya que favorece la explotación de las regiones más prometedoras del espacio de búsqueda (Lu & Luo, 2021)

2.5.5 Elitismo

El elitismo es una estrategia que consiste en preservar los mejores individuos de cada generación para garantizar que no se pierdan las soluciones de mayor calidad durante el proceso evolutivo.

Este mecanismo mejora la eficiencia del algoritmo, ya que asegura que la calidad de la población no disminuya entre generaciones y favorece la convergencia hacia soluciones óptimas (Aggarwal, 2023)

2.6 AG mono-objetivo, mejor individuo.

En los algoritmos genéticos de optimización mono-objetivo, el propósito es encontrar una única solución óptima que maximice o minimice una función de aptitud específica. En este enfoque, todas las soluciones candidatas son evaluadas con base en un solo criterio, lo que permite establecer una jerarquía clara entre los individuos de la población.

El mejor individuo corresponde a aquel que presenta el valor más favorable de la función objetivo dentro de la población evaluada. A lo largo de las generaciones, el algoritmo busca mejorar progresivamente este individuo mediante la aplicación de operadores genéticos, hasta alcanzar una solución óptima o cercana al óptimo global.

Sin embargo, este enfoque presenta limitaciones cuando el problema involucra múltiples objetivos que pueden ser conflictivos entre sí, como es el caso de la acuicultura, donde se busca simultáneamente maximizar la calidad del agua y minimizar los costos operativos. En estos casos, la

optimización mono-objetivo resulta insuficiente, dando paso al uso de enfoques multiobjetivo (K, A, S, & Meyarivan, 2016).

2.7 Algoritmos Genéticos Multiobjetivo

Los algoritmos genéticos multiobjetivo (AGMO) permiten abordar problemas en los cuales existen múltiples funciones objetivo que deben optimizarse simultáneamente y que, en muchos casos, son contradictorias entre sí.

A diferencia de la optimización mono-objetivo, en los AGMO no se busca una única solución óptima, sino un conjunto de soluciones que representen diferentes compromisos entre los objetivos. Estas soluciones son conocidas como soluciones no dominadas (Deb, 2016).

Una solución se considera no dominada cuando no existe otra que mejore al menos uno de los objetivos sin empeorar otro. Este enfoque es particularmente útil en sistemas complejos como la acuicultura, donde variables como calidad del agua, costos, productividad y sostenibilidad deben ser consideradas de manera simultánea.

Entre los algoritmos multiobjetivo más utilizados se encuentra el NSGA-II (Non-dominated Sorting Genetic Algorithm II), el cual se caracteriza por su eficiencia en la clasificación de soluciones no dominadas y su capacidad para mantener diversidad en la población (Deb, 2002). Este algoritmo ha sido ampliamente aplicado en problemas de ingeniería y gestión ambiental, mostrando resultados robustos en escenarios con múltiples variables y restricciones.

En aplicaciones recientes, los AGMO han sido combinados con modelos de inteligencia artificial, como redes neuronales, para optimizar sistemas dinámicos y no lineales, logrando mejoras significativas en la toma de decisiones y en la eficiencia operativa (Tapabrata, Mohiuddin, & Kumar, 2022)

2.8 Frente de Pareto

El frente de Pareto es un concepto fundamental en la optimización multiobjetivo y representa el conjunto de soluciones no dominadas que constituyen las mejores alternativas posibles dentro del espacio de soluciones.

Cada punto en el frente de Pareto corresponde a una solución en la cual no es posible mejorar un objetivo sin deteriorar al menos otro. Por esta razón, no existe una única solución óptima, sino un conjunto de soluciones igualmente válidas que reflejan distintos niveles de compromiso entre los objetivos (Aggarwal, 2023)

La representación gráfica del frente de Pareto permite visualizar la relación entre los objetivos en conflicto, facilitando la selección de la solución más adecuada según las prioridades del tomador de decisiones. En el caso de la acuicultura, esto puede implicar elegir entre diferentes combinaciones de calidad del agua y costos operativos.

El uso del frente de Pareto es especialmente relevante en sistemas de soporte a la decisión, ya que proporciona una base objetiva para evaluar múltiples escenarios y seleccionar estrategias óptimas en función de criterios técnicos, económicos y ambientales.

En estudios recientes, la aplicación del frente de Pareto en combinación con algoritmos genéticos y modelos predictivos ha demostrado ser una herramienta eficaz para la optimización de sistemas complejos, contribuyendo al desarrollo de soluciones sostenibles en sectores como la acuicultura y la gestión de recursos hídricos (Aggarwal, 2023); (Tapabrata, Mohiuddin, & Kumar, 2022).

CAPÍTULO III. MODELADO CON RED DE NEURONAS

3.1 Fase 1. Análisis

3.1.1 Definición de las variables

En este paso se realizó una búsqueda tanto en libros como artículos exclusivos de granjas de tilapia en el cual definieran cuales son las variables que pueden afectar directamente la calidad del agua. Con el objetivo de identificar los indicadores que influyen directamente en la calidad del agua, se determinó los elementos de control, que componen la calidad del agua en granjas de tilapia. Se definieron los 10 indicadores de agua, como fundamentales para su calidad. Estas variables fueron recopiladas y presentadas en la Tabla 1, mismas que a su vez, con el apoyo del programa SIMNET II®, se realizó la simulación de datos tomando como referencia los rangos establecidos en la misma.

Tabla 1. Concentrado de indicadores

Variables	Rango
Temperatura	18°C a 30°C
Oxígeno disuelto	4 a 10 mg/l
pH	6.5 a 8.5
TAN	< 0.5 mg/l
Nitrito	< 1.64 mg/l
Nitrato	< 180 mg/l
Transparencia	40 a 45 cm
Dureza	40 a 100 mg/l
Alcalinidad	50 a 120 mg/l
Dióxido de carbono	< 20 mg/l

Fuente: datos propios (2025)

Asimismo, se establecieron dos variables de salida:

Y₁: Calidad del agua (CA), una métrica clasificatoria construida a partir del rango mostrado en los indicadores de entrada.

Y₂: Costo total (CT), el cual corresponde al costo mensual estimado respecto al mantenimiento que ayuda a cumplir con los parámetros establecidos de calidad del agua en un estanque de 500 m³.

3.1.2 Simulación de las variables de datos

El uso de la distribución uniforme se justifica por ser el enfoque más conservador y menos sesgado en ausencia de datos reales, adhiriéndose al principio de que todo valor dentro de un rango conocido es igualmente probable. Para los 10 indicadores de agua, se determinó la utilización de una distribución uniforme, la elección por esta distribución se adoptó como criterio conservador para

reflejar la incertidumbre sin sesgos previos (Standridge, 2013) . Un tamaño de muestra de 100 es suficiente para invocar la validez del Teorema del Límite Central (Anderson & Gerbing, 1984), asegurando que los métodos inferenciales subsiguientes sean apropiados. Cabe mencionar que en la prueba Kolmogorov-Smirnov of Normality para CA y CT, se obtuvieron los siguientes resultados:

Tabla 2 Prueba Kolmogorov-Smirnov de normalidad para WQ y TC

	(D)	valor-p	Resultados
CA	0.07428	0.61249	Los datos no difieren significativamente de los que siguen una distribución normal.
CT	0.07428	0.6125	Los datos no difieren significativamente de los que siguen una distribución normal.

Fuente: datos propios (2025)

En la Figura 8 se muestra el lenguaje de programación por nodos, para la generación de los datos de entrada al simulador.

```

Top of File   Line 1   Col 1   Size 12   • C:INDICATORS
$PROJECT: WATER:22/08/25:TEMPERATURE:
$DIMENSION: ENTITY(100) :A(1):
$ATTRIBUTES: ENTRA:
$BEGIN, MSGOFF:

    S1      *S:5:/L/LIM=100:
           *B:A1:: ENTRA=UN(18, 30)%:
    A1      *A: 15:
           *B: TERM: :WRITE(40)=(ENTRA)%:

$END:
$STOP:

```

Figura 8 Lenguaje de programación por nodos para la simulación de indicadores hídricos con SIMNET II®

Fuente: datos propios (2025)

La estrategia de generación de la base de datos mediante SIMNET II® permitió reproducir escenarios operativos creíbles en ausencia de registros históricos, apoyándose en rangos de referencia descritos por Kemmer (Kemmer & Company, 1982) y en la estructura del simulador (SIMNET, 2025).

3.1.3 Creación de base de datos

Tras haber realizado las simulaciones de los indicadores del agua, se concentró la información en la BD. En la Tabla 3, se puede observar información detallada de la simulación para cada indicador de agua.

Tabla 3 Base de datos de los indicadores de agua.

BD	Temperatura	Oxígeno disuelto	pH	TAN (Nitrogeno Amoniacal Total)	Nitrito	Nitrato	Transparencia	Dureza	Alcalinidad	Dióxido de Carbono
no	18 A 30 °c	4 a 10 mg/l	6.5 a 8.5	< 0.5 mg/l	< 1.64 mg/l	< 180 mg/l	40 a 45 cm	40 a 100 mg/l	50 a 120 mg/l	Hasta 20 mg/l
1	22.7708	6.3854	7.2951	0.1988	0.6520	71.5612	41.9878	63.8537	77.8294	7.9512
2	27.9339	8.9669	8.1556	0.4139	1.3576	149.0083	44.1391	89.6694	107.9477	16.5565
3	20.7888	5.3944	6.9648	0.1162	0.3811	41.8318	41.1620	53.9439	66.2679	4.6480
4	29.1199	9.5600	8.3533	0.4633	1.5197	166.7985	44.6333	95.5995	114.8661	18.5332
5	22.1621	6.0811	7.1937	0.1734	0.5688	62.4315	41.7342	60.8105	74.2789	6.9368
6	22.4094	6.2047	7.2349	0.1837	0.6026	66.1412	41.8373	62.0471	75.7216	7.3490
7	27.0514	8.5257	8.0086	0.3771	1.2370	135.7708	43.7714	85.2569	102.7998	15.0857
8	20.6647	5.3323	6.9441	0.1110	0.3642	39.9702	41.1103	53.3234	65.5440	4.4411
9	19.2910	4.6455	6.7152	0.0538	0.1764	19.3650	40.5379	46.4550	57.5308	2.1517
10	19.8399	4.9200	6.8067	0.0767	0.2515	27.5986	40.7666	49.1996	60.7328	3.0665
.	.	.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.	.	.
96	25.2266	7.6133	7.7044	0.3011	0.9876	108.3988	43.0111	76.1329	92.1551	12.0443
97	23.2163	6.6082	7.3694	0.2173	0.7129	78.2449	42.1735	66.0816	80.4286	8.6939
98	28.7625	9.3812	8.2937	0.4484	1.4709	161.4372	44.4844	93.8124	112.7811	17.9375
99	27.0207	8.5104	8.0035	0.3759	1.2328	135.3109	43.7586	85.1037	102.6209	15.0346
100	21.3919	5.6960	7.0653	0.1413	0.4636	50.8785	41.4133	56.9595	69.7861	5.6532

Fuente: datos propios (2025)

3.1.4 Análisis de la información

Con la BD de los indicadores de agua, se cuantificó conceptualmente, la clasificación y la calificación de la calidad de agua (CA), con la Fórmula 1. Para CT, se establecieron valores mínimo y máximo de costo mensual de los indicadores de calidad para un estanque de tierra de 500 m³, (equivalente aproximadamente al costo anual, en proporción, a estanque de recirculación de 50 m³), sin tomar en cuenta factores como: energía eléctrica, personal especializado, automatización, entre otros.

$$CA = \sum_{n=1}^i X_i \quad (1)$$

Estos parámetros estimados en la para ambos objetivos clave se concentran en la Tabla 4 cuya importancia radica en que los valores CA y CT aquí definidos (como el rango de costo) son los objetivos de rendimiento que las RNA modelarán y que el MOGA optimizará.

Tabla 4. Estimación de parámetros de los objetivos CA y CT

CA	
CLASIFICACIÓN	CALIFICACIÓN
160.67 - 249.07	ACEPTABLE
249.08 - 337.48	MEDIO
337.49 - 425.89	REGULAR
425.90 - 514.30	MALO

Fuente: datos propios (2025)

Después de aplicar la formula mostrada, se concentró de igual forma la información en la BD. En la Tabla 5 se puede observar información resumida de los costos obtenidos.

Tabla 5. Costos obtenidos en la BD.

BD no	Y₁ Q H₂O	Y₂ Costo
1	300.485365	\$ 239,081.72
2	454.149022	\$ 393,390.71
3	241.498909	\$ 179,847.52
4	489.446775	\$ 428,836.76
5	282.371036	\$ 220,891.29
6	289.731572	\$ 228,282.75
7	427.884413	\$ 367,015.82
8	237.805328	\$ 176,138.42
9	196.922312	\$ 135,083.69
10	213.258769	\$ 151,488.76
	.	.
	.	.
	.	.
96	373.575255	\$ 312,478.58
97	313.746509	\$ 252,398.54
98	478.809327	\$ 418,154.67
99	426.971887	\$ 366,099.50
100	259.448582	\$ 197,872.57

Fuente: datos propios (2025)

Posterior a la realización de todos los cálculos por cada dato, en la Tabla 6 se definen cuáles son los costos totales para el mantenimiento de la calidad del agua, a considerar de acuerdo con la toma de decisiones.

Tabla 6. Cálculo de costos para la calidad del agua.

CT		
MÍNIMO	\$	98,689.16
MÁXIMO	\$	453,800.86

Fuente: datos propios (2025)

La definición de las variables y de los objetivos CA y CT facilitó la construcción de funciones objetivo-robustas para el modelado posterior; este enfoque se alinea con trabajos sobre pronóstico y preparación de datos para redes neuronales y otras técnicas predictivas (Zhang, Patuwo, & Hu, 1998). Asimismo, la partición de los datos en conjunto de entrenamiento, validación y prueba respeta las recomendaciones metodológicas para garantizar reproducibilidad y reducir sobreajuste (Aggarwal, 2023).

3.2 Fase 2. Diseño

3.2.1 Determinación de parámetros para crear variables en Matlab

Las RNA actúan como modelos matemáticos no lineales que aprenden a partir de datos. La función de entrada, la arquitectura de la red y el proceso de entrenamiento mediante algoritmos como la retro propagación permiten que la red ajuste sus pesos para aproximar funciones complejas y relaciones no lineales a los datos. Las aplicaciones de las RNA en modelación matemática son vastas. En ingeniería, se utilizan para modelar sistemas dinámicos, control y predicción de procesos. Las investigaciones actuales se enfocan en mejorar los algoritmos de entrenamiento, en arquitecturas más eficientes y en técnicas de interpretación de modelos.

La media cuadrática del error (MSE, Mean Square Error) se seleccionó como la función de desempeño para el entrenamiento supervisado. Cuando cada entrada se aplica a la red, su salida se compara con el valor objetivo. El objetivo es minimizar la suma promedio de estos errores. El algoritmo MSE ajusta los pesos y sesgos de la red lineal con el fin de minimizar dicho error cuadrático medio. El error se calcula como la diferencia entre los valores objetivo y las salidas generadas por la red. La función de error corresponde al MSE, y el error de aprendizaje ($e(k)$) se define como:

$$MSE = \frac{1}{Q} \sum_{k=1}^Q e(k)^2 \quad (2)$$

$$e(k) = y_i(k) - g_i(k) \quad (3)$$

donde Q se refiere al número de patrones de ejemplo de entrada–salida utilizados durante el entrenamiento, i es el índice del patrón de ejemplo (vector), y $y_i(k)$ y $g_i(k)$ representan, respectivamente, los valores deseados (objetivo) y los valores predichos por la red neuronal artificial (RNA) en el nodo de salida k , respectivamente.

El proceso de minimización de MSE, no garantiza que el entrenamiento de la red sea completo. Puede producirse un sobre entrenamiento de la red cuando esta se entrena excesivamente o cuando la arquitectura de la red comprende un número de neuronas ocultas mayor del necesario (sobre parametrización).

Existen varios procedimientos para definir la arquitectura de la RNA; en este estudio se utiliza el siguiente procedimiento de dos fases. Se seleccionó el uso del software MATLAB® en línea, que contiene un módulo dedicado al desarrollo de RNA (MATLAB, 2025).

Fase 1: Configuración de los parámetros de las RNA, con todos los elementos requeridos para el aprendizaje, estos se muestran en la Tabla 7. Es de suma importancia dividir los 100 datos en tres grupos: Entrenamiento, Validación y Prueba, para este estudio se utilizaron 75%, 15% y 15%,

respectivamente. Dividir los datos en estos tres conjuntos ayuda a construir modelos más precisos y confiables, evitando el sobre ajuste y apoyando a asegurar que el modelo pudiera generalizar en datos nuevos y reales. Esta arquitectura y división son esenciales para la reproducibilidad del modelo matemático.

Tabla 7. Configuración de parámetros para las RNA

PARÁMETROS DE ENTRENAMIENTO	
Tipo de red	RetroPropagación (RP)
Entrada	Matrices variables entrada
Meta 1	Vector variable Objetivo_1: WQ
Meta 2	Vector variable Objetivo_2: CT
Función de entrenamiento	Algoritmo de Levenberg-Marquardt
Función de adaptación para aprendizaje	Gradiente descendente con momento
Función de rendimiento	Error cuadrático medio
Número de capas ocultas	1
Número de neuronas ocultas	4
Función de transferencia capa oculta	Tangente hiperbólica
Función de transferencia en capa de salida	Lineal
Número de Iteraciones	1000

Fuente: datos propios (2025)

3.2.2 Creación de redes neuronales artificiales en Matlab

Mediante el programa de Matlab®, se realizaron las diferentes arquitecturas de RNA (redes neuronales artificiales), para poder determinar la mejor arquitectura posible que represente el modelo de la red. Las redes utilizadas fueron de retro propagación, el algoritmo de aprendizaje fue Levenberg- Marquardt, la función de evaluación para el aprendizaje es la correlación de las variables simuladas contra calculadas por la red, donde se espera obtener $R \geq 0.99$

Fase 2: Con la información obtenida anteriormente se procedió a trabajar con las RNA en el entrenamiento. Asimismo, se busca encontrar el mejor resultado de MSE y de la regresión R (para Entrenamiento, Validación y Prueba). Los datos de entrenamiento son los datos utilizados para ajustar los pesos y parámetros de la red neuronal durante el proceso de aprendizaje. Permiten que la red aprenda patrones y relaciones en los datos, optimizando su capacidad para predecir. Los datos de validación se utilizan para sintonizar hiperparámetros, prevenir sobreajuste y tomar decisiones sobre cuándo detener el entrenamiento. Igualmente, ayuda a evaluar cómo está generalizando el modelo durante el entrenamiento, permitiendo ajustar la estructura o parámetros, lo que evita sesgos y sobreajuste. Los datos de prueba son datos completamente nuevos y no vistos por la red durante el entrenamiento ni la validación. Sirven para evaluar de manera objetiva y al final la capacidad del modelo para generalizar a datos no vistos, asegurando que el modelo sea robusto y confiable en aplicaciones reales. Los resultados se presentan en la Figura 9 para CA y CT, con valores de MSE de 1.71169e-06 y 0.49159, respectivamente, junto con la distribución porcentual de las muestras.




Figura 9 Resultados del entrenamiento para WQ y CT, con sus valores correspondientes de MSE y porcentajes de muestra.

Fuente: datos propios (2025)

3.2.3 Entrenamiento de las redes neuronales

Como se puede apreciar en la Tabla 8 en ambos resultados, se ha considerado que una capa oculta es suficiente para representar el comportamiento de los objetivos. Asimismo, se determinó la arquitectura de 4 neuronas ocultas debido al menor valor de MSE, en ambos objetivos CA y CT. Estas cifras destacan la buena concordancia entre los valores calculados y medidos, y por lo tanto la eficacia de las RNA para modelar estos objetivos. Estos modelos basados en RNA pueden ahora integrarse en un procedimiento de modelación matemática para determinar para determinar las funciones de CA y CT.

Tabla 8. Pruebas de las propiedades de la red y los parámetros de entrenamiento de la red CA y CT

PRUEBAS DE LAS PROPIEDADES DE LA RED Y PARÁMETROS DE ENTRENAMIENTO DE LA RED CA									
NÚMERO DE CONFIGURACIÓN	PROPIEDADES DE RED		PARAMETROS DE ENTRENAMIENTO			RESULTADOS DE REDES			
	CAPAS	NEURONAS	EPOCAS	META	MAXIMO FALLO	ENTRENAMIENTO	PRUEBA	VALIDACIÓN	MSE
1	2	1,1	40	0.0	6	0.99475	0.99631	0.99444	80.1640
2	2	2,1	16	0.0	6	0.98551	0.97856	0.99203	174.8620
3	2	3,1	10	0.0	6	0.99911	0.99891	0.99992	0.6450
4	2	4,1	66	0.0	6	0.99999	0.99999	0.99999	0.0001
5	2	5,1	840	0.0	6	0.99998	0.99997	0.99996	0.0440
6	2	6,1	46	0.0	6	0.9996	0.9995	0.99971	5.9840
7	2	7,1	54	0.0	6	0.9998	0.99992	0.99997	0.7940

PRUEBAS DE LAS PROPIEDADES DE LA RED Y LOS PARÁMETROS DE ENTRENAMIENTO DE LA RED CT									
NÚMERO DE CONFIGURACIÓN	PROPIEDADES DE RED		PARAMETROS DE ENTRENAMIENTO			RESULTADOS DE REDES			
	CAPAS	NEURONAS	EPOCAS	META	MAXIMO FALLO	ENTRENAMIENTO	PRUEBA	VALIDACIÓN	MSE
1	2	1,1	28	0.00	6	0.99522	0.99236	0.99367	111.1055
2	2	2,1	20	0.00	6	0.99277	0.99713	0.98831	179.1784
3	2	3,1	64	0.00	6	0.99993	0.99992	0.99994	183.7075
4	2	4,1	1000	0.00	6	0.99999	0.99999	0.99999	0.8445
5	2	5,1	16	0.00	6	0.99999	0.99999	0.99999	1.4120
6	2	6,1	15	0.00	6	0.90436	0.90488	0.92486	512.7797
7	2	7,1	31	0.00	6	0.9999	0.99993	0.99995	174.1735

Fuente: datos propios (2025)

3.2.4 Arquitectura de las redes neuronales

Para la generación del modelado a través de las ecuaciones matemáticas se necesitó extraer los siguientes datos de las redes entrenadas: Pesos iniciales (IW), sesgo primera capa (b1), últimos pesos (LW) y sesgo última capa (b2), con estos valores se crearon dos funciones a partir de la RNA en mención, una para cada objetivo, tal como se muestra a continuación:

Modelo matemático del objetivo 1: CA

$$\begin{aligned}
 CA = & ((\tanh(((x(1)*0.0049968)+(x(2)*0.034285)+(x(3)*-0.019807)+(x(4)*-0.0017199)+(x(5)*- \\
 & 0.028447)+(x(6)*0.21671)+(x(7)*0.0026845)+(x(8)*0.65055)+(x(9)*-0.54799)+(x(10) \\
 & *0.29388))-1.2197)*(0.98079))+(\tanh(((x(1)*0.023596)+(x(2)*-0.023796)+(x(3)*0.017018)+(\\
 & x(4)*-0.0017697)+(x(5)*0.01408)+(x(6)*0.19465)+(x(7)*0.0088156)+(x(8)*0.0022432) \\
 & +(x(9)*0.2251)+(x(10)*-0.054291))+0.35684)*(2.5357))+(\tanh(((x(1)*0.51644)+(x(2)*- \\
 & 0.67643)+(x(3)*0.42876)+(x(4)*-0.050383)+(x(5)*0.33247)+(x(6)*-0.40687)+(x(7)*0.23169)+(\\
 & x(8)*0.62352)+(x(9)*-0.1063)+(x(10)*0.10346))+0.44275)*(-0.098809))+(\tanh(((x(1) \\
 & *0.18712)+(x(2)*0.22074)+(x(3)*-0.34564)+(x(4)*0.11958)+(x(5)*0.8441)+(x(6)*0.91911)+(\\
 & x(7)*0.35738)+(x(8)*-0.32313)+(x(9)*-0.57589)+(x(10)*0.70755))+1.7017)*(-0.0066347))) \\
 & +(0.0024435)
 \end{aligned}$$

Modelo matemático del objetivo 2: CT

$$CT = ((\tanh(((x(1)*-0.12296) + (x(2)*-0.023867) + (x(3)*0.0034111) + (x(4)*-0.0035701) + (x(5)*0.0053158) + (x(6)*0.060386) + (x(7)*0.0081848) + (x(8)*0.057618) + (x(9)*-0.57626) + (x(10)*0.1538)) - 1.0877) * (-0.93585)) + (\tanh(((x(1)*-0.010018) + (x(2)*-0.00054628) + (x(3)*0.00012626) + (x(4)*-0.00034296) + (x(5)*0.00065472) + (x(6)*0.18945) + (x(7)*0.0013192) + (x(8)*-0.00048837) + (x(9)*0.0041064) + (x(10)*0.013708)) - 0.3333)*(4.7887)) + (\tanh(((x(1)*0.16722) + (x(2)*-0.054691) + (x(3)*1.4496) + (x(4)*1.9163) + (x(5)*-1.1945) + (x(6)*-0.69915) + (x(7)*-0.40534) + (x(8)*-1.2844) + (x(9)*-0.73376) + (x(10)*-1.0179)) + 1.265) * (0.0013304)) + (\tanh(((x(1)*-0.95432) + (x(2)*-0.8476) + (x(3)*-0.02556) + (x(4)*1.3022) + (x(5)*-0.90819) + (x(6)*-0.78808) + (x(7)*-0.31321) + (x(8)*0.47276) + (x(9)*0.18617) + (x(10)*-0.34263)) - 0.73638) * (-0.00036176))) + (0.79315)$$

Finalmente, gracias a su gran capacidad de las RNA para interpolar y extrapolar, en esta etapa es posible utilizar los modelos matemáticos obtenidos, para la predicción del comportamiento presente y futuro del sistema en ambos objetivos, esto ayuda a encontrar las mejores decisiones operativas para la empresa acuícola.

El procedimiento de configuración y entrenamiento de las RNA, implementado con el entorno MATLAB (MATLAB, 2024), permite obtener modelos con alto poder de interpolación y baja incertidumbre (Goodfellow, Bengio, & Courville, 2016). La selección de la topología mediante criterios automatizados y la discusión sobre riesgo de sobre parametrización siguen la literatura sobre búsqueda y selección de arquitecturas (Elsken, Metzen, & Hutter, 2019) mientras que las técnicas de interpretación y evaluación de la robustez del modelo se sustentan en enfoques de aplicabilidad en IA (Samek, Wiegand, & Müller, 2017).

3.2.5 Elaboración de redes neuronales artificiales en Excel

Con el propósito de demostrar la evaluación del modelo predictivo desarrollado en MATLAB, se elaboró una réplica de la RNA seleccionada con la herramienta Microsoft Excel, de esta forma se da paso a calcular de manera directa la salida de la red utilizando las ecuaciones matemáticas obtenidas del entrenamiento en MATLAB, mediante los pesos y sesgos asociados a la arquitectura considerada optima 10-4-1. A continuación se muestran los parámetros del modelo por bloques en la Tabla 9, 10, 11 y 12 respectivamente.

Tabla 9. Matriz de pesos de entrada a la capa oculta (IW 4 x 10) para Y2

IW									
-0.6084445	-0.3719226	-0.606017012	0.25509442	0.12383094	0.60146599	-0.0064804	0.5844053	-0.3036725	-0.1744574
-0.3348523	-0.4853089	0.030623574	0.01901942	-0.0145512	0.33186429	0.02894092	-0.1867787	-0.0185783	0.25944036
0.08903069	0.69456092	-0.48212861	0.65594489	0.29499904	0.48473801	-0.0731538	-0.3171867	-0.6519992	-0.1687222
0.23825973	-0.7621391	0.214604298	0.41199697	0.80559363	-0.0062122	-0.8846555	-0.3082364	0.5768274	-0.1287818

Fuente: datos propios (2025)

Tabla 10. Matriz de pesos de la capa oculta a la salida (LW 1 x 4) para Y2.

LW			
-1.1145747	-1.8994057	1.05270482	-0.5623103

Fuente: datos propios (2025)

Tabla 11. Vector de sesgos de la capa oculta (b1), y2.

B1
1.21410718
-0.0329898
1.29998791
1.61278843

Fuente: datos propios (2025)

Tabla 12. Sesgo de la salida (b2) Y2.

B2
0.48346921

Fuente: datos propios (2025)

Posteriormente se creó un bloque para las entradas $X_1 - X_{10}$, en la cual se introducen los valores mínimos y máximos de los indicadores hídricos, dando énfasis en el valor mínimo de cada variable X , el cual corresponde a X_i . Con fines de demostrar el proceso básico se dará el ejemplo de la aplicación en este apartado con solo una variable en la Figura 10:

X1	P1
36146.5	-1
59910.38	

Figura 10 Valores de prueba en Excel.

Fuente: datos propios (2025)

Con los valores anteriores procedemos a la aplicación de la Ecuación 4 para la obtención de P1.

$Normalizar = \frac{2 * (Xi - Xmin)}{(Xmax - Xmin) - 1}$	(4)
--	-----

Sabemos que la aplicación de la ecuación es correcta cuando nuestro resultado es -1.

Posteriormente procedemos a agregar otro bloque denominado "IW1", el cual llevara la información de la primera columna de la Tabla IW.

Posterior a ello se procede a agregar otra columna en donde se comienza a indicar el cálculo respectivo como se muestra en la Figura 11 en la cual se acumularán todos los valores de las variables X_i , por lo tanto, la estructura de esta columna estará constituida por una matriz 4×10 .

X1		P1	IW1	P*IW
36146.5 36146.5		-1	-0.608444515	0.60844452
59910.4			-0.33485235	0.37192262
			0.089030693	0.60601701
			0.238259725	-0.2550944
X2		P2		-0.1238309
20183.1 20183.1		-1	-0.371922621	-0.601466
49888			-0.485308886	0.00648039
			0.694560921	-0.5844053
			-0.762139128	0.30367252
X3		P3		0.17445736
6512.21 6512.21		-1	-0.606017012	
8492.53			0.030623574	0.33485235
			-0.48212861	0.48530889
			0.214604298	-0.0306236
X4		P4		-0.0190194
12.2081 12.2081		-1	0.255094423	0.01455115
1992.53			0.019019419	-0.3318643
			0.655944894	-0.0289409
			0.411996968	0.1867787
X5		P5		0.01857829
10.0107 10.0107		-1	0.123830936	-0.2594404
1633.88			-0.014551151	
			0.294999042	-0.0890307
			0.805593627	-0.6945609
X6		P6		0.48212861
1098.73 1098.73		-1	0.601465988	-0.6559449
179328			0.331864289	-0.294999
			0.484738008	-0.484738
			-0.006212161	0.07315377
X7		P7		0.31718668
8006.1 8006.1		-1	-0.006480386	0.6519992
8996.27			0.028940922	0.16872218
			-0.073153769	
			-0.884655495	-0.2382597
X8		P8		0.76213913
16146.5 16146.5		-1	0.584405297	-0.2146043
39910.4			-0.186778702	-0.411997
			-0.31718668	-0.8055936
			-0.308236404	0.00621216
X9		P9		0.88465549
10085.5 10085.5		-1	-0.303672518	0.3082364
23947.7			-0.018578291	-0.5768274
			-0.651999203	0.12878181
			0.576827405	
X10		P10		
488.324 488.324		-1	-0.17445736	
79701.3			0.259440363	
			-0.168722184	
			-0.128781813	

Figura 11 Columnas IW1 y P*IW agregadas.

Fuente: datos propios (2025)

Luego, se realiza una serie de cálculos matemáticos básicos (como lo indica el título de cada columna de la Tabla 13).

Si todos los datos son correctamente analizados y calculados, la SUMA 4 nos dará un valor de -1 a 1, tal como se muestra en la Tabla 13.

Tabla 13 Cálculos matemáticos para determinar el valor de la suma 4 para Y2

SUMA	b1	SUMA 2	a1	LW	a1*LW	SUMA 3	b2	SUMA 4
0.506197768	1.21410718	1.72030495	0.93789974	-1.114574702	-1.045359324	-1.4834635	0.48346921	-1
0.370180813	-0.0329898	0.33719101	0.32496734	-1.899405705	-0.617244825			
-0.526083113	1.29998791	0.7739048	0.64919429	1.05270482	0.68340996			
-0.157257024	1.61278843	1.4555314	0.89678122	-0.562310285	-0.504269303			

Fuente: datos propios (2025)

Dados los resultados anteriores, continuamos esta vez aplicando la fórmula de desnormalización del sistema para la obtención de Y₂:

$$\begin{aligned}
 &\text{Desnormalizar} && (5) \\
 &= 0.5 * (Z_i + 1) * (X_{\max} - X_{\min}) \\
 &+ X_{\min}
 \end{aligned}$$

Donde el valor de Y₂ (Costo Total) es igual al valor mínimo de CT calculado con MATLAB y la ecuación corresponde con la anteriormente vista para el modelo matemático del objetivo 2 CT.

De esta misma forma también es posible calcular los valores para Y₁; para una mejor visualización se presentan los valores para la red para Y₁ (Calidad del agua) resumidas y elaboradas en Excel en la Tabla 14, 15, 16 y 17 respectivamente.

Tabla 14. Matriz de pesos de entrada a la capa oculta (IW 4 x 10) para Y1

IW									
157.802505	814.513408	-537.71749	-25.284557	-532.4451	330.095998	1088.41426	285.87557	398.797533	284.544866
34.0271237	32.4465623	31.7722123	32.7930395	29.0231199	31.9000615	31.4250436	32.4159125	32.0081281	32.4024047
2.66106279	-42.924786	26.2096346	-0.3853335	12.4929029	13.3735786	-47.248149	41.9045259	-25.671498	20.3147272
20.0375507	14.281947	8.80821228	75.1583541	23.4063865	17.8373965	14.212212	17.4928002	17.9319274	16.2510588

Fuente: datos propios (2025)

Tabla 15. Matriz de pesos de la capa oculta a la salida (LW 1 x 4) para Y1.

LW			
-0.3333374	-0.3333345	6.05325	-0.3333343

Fuente: datos propios (2025)

Tabla 16. Vector de sesgos de la capa oculta (b1), Y1

b1
-1128.3361
-4.7529347
-7.5439401
108.817664

Fuente: datos propios (2025)

Tabla 17. Sesgo de la salida (b2) Y1

b2
6.05324249

Fuente: datos propios (2025)

X1		P1	IW1	P*IW
18.07325	18.07325	-1	157.802505	-157.80251
29.95519			34.0271237	-814.51341
			2.66106279	537.717486
			20.0375507	25.284557
				532.445101
X2		P2	IW2	-330.096
4.036624	4.036624	-1	814.513408	-1088.4143
9.977596			32.4465623	-285.87557
			-42.924786	-398.79753
			14.281947	-284.54487
X3		P3	IW3	
6.512208	6.512208	-1	-537.717486	-34.027124
8.492533			31.7722123	-32.446562
			26.2096346	-31.772212
			8.80821228	-32.79304
				-29.02312
X4		P4	IW4	-31.900061
0.003052	0.003052	-1	-25.284557	-31.425044
0.498133			32.7930395	-32.415913
			-0.38533352	-32.008128
			75.1583541	-32.402405
X5		P5	IW5	
0.010011	0.010011	-1	-532.445101	-2.6610628
1.633876			29.0231199	42.924786
			12.4929029	-26.209635
			23.4063865	0.38533352
				-12.492903
X6		P6	IW6	-13.373579
1.09873	1.09873	-1	330.095998	47.2481493
179.3279			31.9000615	-41.904526
			13.3735786	25.6714977
			17.8373965	-20.314727
X7		P7	IW7	
40.03052	40.03052	-1	1088.41426	-20.037551
44.98133			31.4250436	-14.281947
			-47.2481493	-8.8082123
			14.212212	-75.158354
				-23.406386
X8		P8	IW8	-17.837396
40.36624	40.36624	-1	285.87557	-14.212212
99.77597			32.4159125	-17.4928
			41.9045259	-17.931927
			17.4928002	-16.251059
X9		P9	IW9	
50.42728	50.42728	-1	398.797533	
119.7386			32.0081281	
			-25.6714977	
			17.9319274	
X10		P10	IW10	
0.122081	0.122081	-1	284.544866	
19.92532			32.4024047	
			20.3147272	
			16.2510588	

Figura 12 Matriz 4 x 10 para Y1

Fuente: datos propios (2025)

Tabla 18 Cálculos matemáticos para determinar el valor de la suma 4 para Y1

SUMA	b1	SUMA 2	a1	LW	a1*LW	SUMA 3	b2	SUMA 4	Y1
-2264.597	-1128.3361	-3392.9331	-1.00000	-0.3333374	0.33333745	-5.053243	6.05324249	0.99999952	4
-320.2136	-4.7529347	-324.96654	-1.00000	-0.3333345	0.33333451				
-0.726666	-7.5439401	-8.2706056	-1.00000	6.05325	-6.0532492				
-225.4178	108.81766	-116.60018	-1.00000	-0.3333343	0.33333428				

Fuente: datos propios (2025)

Con esto queda demostrado que es posible realizar los cálculos en Excel obteniendo datos relativamente cercanos a los obtenidos en MATLAB, de igual forma demostrar un entorno operativo sencillo donde quizá solo se requiera de la evaluación de una nueva condición de la calidad del agua o estimación de costos a partir de los indicadores que se establecen.

CAPÍTULO IV. OPTIMIZACIÓN CON ALGORITMOS GENÉTICOS MULTOBJETIVO

4.1 Fase 3. Implementación

En la optimización basada en algoritmos genéticos, la población inicial constituye un punto fundamental de la búsqueda, ya que la eficiencia posterior del algoritmo está estrechamente relacionada con la calidad de la primera generación de individuos. Un algoritmo genético opera con cromosomas numéricos para calcular la aptitud para la ejecución de operadores genéticos. La codificación de procedimientos tiene como objetivo representar los cromosomas en forma de cadenas de bits que contienen toda la información necesaria.

4.1.1 Optimización de las funciones matemáticas

Las RNA se utilizan para calcular la aptitud según los diversos objetivos de rendimiento a optimizar. Para este efecto, es necesario la utilización de los límites de los indicadores de agua (véase la Tabla 19).

El objetivo principal del estudio es considerar simultáneamente los criterios de rendimiento involucrados, tomados por pares.

Tabla 19 Concentrado de indicadores

Variables	Rango
Temperatura	18°C a 30°C
Oxígeno disuelto	4 a 10 mg/l
pH	6.5 a 8.5
TAN	< 0.5 mg/l
Nitrito	< 1.64 mg/l
Nitrato	< 180 mg/l
Transparencia	40 a 45 cm
Dureza	40 a 100 mg/l
Alcalinidad	50 a 120 mg/l
Dióxido de carbono	< 20 mg/l

Fuente: datos propios (2025)

Para la optimización con AGMO, de los objetivos CA y CT, se utilizaron los operadores genéticos típicos para alterar la composición de la descendencia en la siguiente generación, con base en los valores de probabilidad preestablecidos que se presentan en la Tabla 20.

Tabla 20. Optimización AGMO de CA y CT

Parámetros del AGMO	
Tamaño de la población	200
Numero de generaciones	1000
Mutación	0.2
Cruzamiento	intermedio

Fuente: datos propios (2025)

La integración de las funciones que derivan de las RNA en un esquema AGMO permite explorar eficientemente el espacio de soluciones y hallar frentes de Pareto representativos de la relación CA y TC. El diseño de operadores evolutivos y las estrategias de ordenación empleadas se fundamentan en estudios recientes sobre algoritmos evolutivos y marcos híbridos para optimización multiobjetivo como lo menciona (Mandal, Mukhopadhyay, & Dutta, 2018) y (Tapabrata, Mohiuddin, & Kumar, 2022). Esta combinación facilita la identificación de soluciones no dominadas que pueden ser validadas operacionalmente.

4.2 Fase 4. Operación

Recordemos que una solución óptima de Pareto corresponde a una solución en la que no se puede obtener ninguna disminución, en ninguno de los objetivos sin provocar un aumento simultáneo en el otro (Mandal, Mukhopadhyay, & Dutta, 2018). Una solución óptima de Pareto también se denomina no dominada. Por lo tanto, la mejor solución es punto de intersección que presenta la menor distancia al vector ideal dentro del espacio de los objetivos, como se muestra en la Figura 13.




Figura 13 Representación conceptual del frente de Pareto y la solución ideal

Fuente: datos propios (2025)

Esta herramienta se considera importante no solo para ingeniería, su beneficio principal de hacer uso de ella es que permite tener una mejor visualización representativa de todas las combinaciones posibles y tomar una decisión en base a las prioridades, preferencias o restricciones específicas del responsable de la toma de decisiones.

4.2.1 Resultados del frente de Pareto

Los resultados presentados corresponden a los obtenidos tras la ordenación de Pareto final, aplicada a todas las soluciones óptimas y factibles encontradas durante la búsqueda para identificar posibles comportamientos conflictivos. En general, puede que no exista una solución óptima específica para un problema multiobjetivo, ya que una función objetivo solo se beneficia cuando los demás objetivos se deterioran, debido a su naturaleza conflictiva: la optimalidad es, por lo tanto, una ilusión cuando los objetivos son conflictivos.

La Figura 14, destaca un comportamiento contradictorio existente entre los dos objetivos considerados CA y CT, como era de esperar.




Figura 14 Frente de Pareto con soluciones optimizadas para calidad del agua (CA) y costo total (CT)

Fuente: datos propios (2025)

Estos criterios son de suma importancia para evitar cualquier exceso o carencia en sus valores finales para cualquiera de ellos. La metodología de resolución híbrido de problemas de optimización multiobjetivo se basa en AGMO acoplando las RNA como funciones de evaluación. La reducción de los CT contribuye a los costos de mantenimientos de los indicadores del agua. Sin embargo, la mantener el estándar CA constituye una importante fuerza contradictoria. En la Tabla 21 se muestran

10 de los 52 resultados que se generaron con el frente de Pareto. CA presenta los valores mínimos y máximos asociados a la inversión de CT, para asegurar la calidad del agua como aceptable.

Tabla 21. Soluciones para CA y CT

CA	CT	Temperatura	Oxígeno Disuelto	pH	TAN	Nitrito	Nitrato	Transparencia	Dureza	Alcalinidad	Dióxido de Carbono
162.1	\$ 76,614.47	19.818	5.905	7.061	0.31	1.205	0.768	41.426	65.343	50.253	19.241
163.4	\$ 76,329.68	19.757	5.847	7.046	0.31	1.202	0.764	41.418	65.999	50.274	19.216
166.85	\$ 75,485.84	19.61	5.698	7.009	0.308	1.199	0.739	41.394	67.685	50.313	19.2
196.67	\$ 70,279.92	19.414	5.052	6.905	0.288	1.264	0.49	41.247	79.198	50.368	19.471
199.47	\$ 70,028.27	19.434	5.02	6.904	0.286	1.274	0.453	41.237	80.084	50.428	19.523
200.23	\$ 69,882.39	19.453	5.017	6.906	0.286	1.277	0.483	41.235	80.315	50.375	19.53
203.16	\$ 69,590.12	19.49	4.989	6.907	0.284	1.287	0.528	41.225	81.208	50.353	19.561
239.57	\$ 66,748.62	19.861	4.673	6.922	0.259	1.406	0.534	41.106	91.427	50.591	19.933
241.87	\$ 66,713.21	19.877	4.651	6.922	0.257	1.412	0.571	41.101	92.017	50.642	19.956
243.61	\$ 66,525.09	19.894	4.636	6.923	0.256	1.408	0.543	41.095	94.481	50.644	19.972

Fuente: datos propios (2025)

Finalmente, en la medida que este ciclo se repita, las herramientas de I.A., podrán robustecer sus cálculos para una mayor precisión y eficiencia a través de la retroalimentación de la información a la contribución de una base de datos actualizada de manera permanente.

El frente de Pareto obtenido hace evidente la situación entre maximizar la calidad del agua y minimizar los costos operativos; dicha contradicción es consistente con hallazgos previos en la gestión acuícola y en indicadores de sostenibilidad, lo que resalta la utilidad práctica de ofrecer un conjunto de soluciones que podrá tomar la persona/equipo encargado de la toma de decisiones. En consecuencia, el marco RNA-AGMO propuesto aporta una herramienta metodológica que, aunque fue realizada con datos simulados, establece una base para implementaciones con datos obtenidos en tiempo real y validación posterior (Mandal, Mukhopadhyay, & Dutta, 2018; Tapabrata, Mohiuddin, & Kumar, 2022; Samek, Wiegand, & Müller, 2017).

El objetivo general de la presente investigación consistió en desarrollar un modelo de predicción y optimización de la calidad del agua en la producción de tilapia mediante el uso de herramientas de inteligencia artificial. Este objetivo fue cumplido satisfactoriamente a través de la integración de redes neuronales artificiales (RNA) y algoritmos genéticos multiobjetivo (AGMO), lo que permitió modelar y optimizar de manera simultánea las variables asociadas a la calidad del agua y los costos operativos.

En relación con los objetivos particulares, se logró en primer lugar la identificación y análisis de las variables fisicoquímicas que influyen en la calidad del agua, estableciendo un conjunto de indicadores relevantes como temperatura, oxígeno disuelto, pH, compuestos nitrogenados, entre otros. Posteriormente, se desarrolló una base de datos mediante simulación utilizando el software SIMNET II®, lo cual permitió generar información consistente para el entrenamiento del modelo.

Asimismo, se cumplió con el desarrollo del modelo predictivo mediante redes neuronales artificiales tipo perceptrón multicapa (MLP), logrando representar con alta precisión la relación entre las

variables de entrada y las variables objetivo, calidad del agua (CA) y costo total (CT). De igual forma, se implementaron algoritmos genéticos multiobjetivo, los cuales permitieron optimizar simultáneamente ambas funciones, generando soluciones no dominadas representadas mediante el frente de Pareto.

Finalmente, se logró establecer un conjunto de soluciones óptimas que facilitan la toma de decisiones en la gestión de sistemas acuícolas, cumpliendo así con los objetivos planteados en la investigación y aportando una herramienta integral para la mejora de la eficiencia y sostenibilidad en la producción de tilapia.

CONCLUSIÓN

En el estudio realizado es importante destacar que, para cada una de las soluciones desarrolladas existe una combinación específica de valores respecto a los indicadores hídricos que cumplen los objetivos, por una parte, MOGA logro calcular la mejor solución posible para la calidad del agua (WQ) respetando la restricción de TC.

Para mantener el rango de WR dentro de los parámetros deseados, el TC debe mantenerse entre \$66,525 y \$76,615 en costos mensuales para un estanque de tierra de 500 m³ (aproximadamente equivalente al costo anual, en proporción a un estanque de recirculación de 50 m³). Gracias a la topología óptima de las RNA para ambos objetivos, con cuatro neuronas ocultas, fue posible validar las redes, con datos diferentes al entrenamiento, obteniendo una predicción superior al 99% de precisión (0.9999 resultado de la validación de RNA, Tabla 8). Estos resultados permiten la generación de un sistema de soporte de decisiones mediante herramientas de IA en una empresa acuícola.

Lo anterior sirve como referencia para soluciones que ayudan a las personas encargadas de la toma de decisiones a lograr los resultados deseados según sus prioridades, preferencias o restricciones.

Esta flexibilidad permite la identificación de todas las posibles soluciones a través de los frentes de Pareto generados por AGMO en futuros entornos operativos reales mediante la integración de datos en tiempo real provenientes de sensores, dicho paso permitirá que el ciclo de retroalimentación a la base de datos funcione de manera continua, adaptando los modelos de IA para lograr mayor precisión y eficiencia en la gestión del sistema, en contribución con la sostenibilidad del cultivo.

RECOMENDACIONES

En futuras investigaciones es recomendable se integren datos reales obtenidos mediante sensores y sistemas de monitoreo en tiempo real, con el fin de validar y fortalecer el modelo propuesto en condiciones operativas reales. Esto permitiría mejorar la precisión del sistema y su aplicabilidad en entornos productivos.

Asimismo, se sugiere explorar la incorporación de variables adicionales relacionadas con el bienestar animal, el comportamiento de los organismos y factores ambientales externos, con el objetivo de enriquecer el modelo y ampliar su alcance.

Otra línea de trabajo relevante consiste en la implementación del modelo en plataformas digitales o sistemas de apoyo a la decisión, que permitan su uso práctico por parte de productores acuícolas, facilitando la gestión eficiente de los recursos.

Finalmente, se recomienda evaluar el desempeño del modelo en diferentes escalas de producción y en otros sistemas acuícolas, con el propósito de analizar su adaptabilidad y potencial de generalización.

Referencias

- Aggarwal, C. C. (2023). *Neural Networks and Deep Learning*. Springer.
- Agricultura, O. d. (2024). *FAO*. FAO.
- Alnemari, A., Elmessery, W., Qazad, A., & Rakhimgaliyeva, S. (2025). *Developing highly accurate machine learning models for optimizing water quality management decisions in tilapia aquaculture*. Scientific Reports.
- Anderson, J., & Gerbing, D. W. (1984). *The Effect of Sampling Error on Convergence, Improper Solutions, and Goodness-of-Fit Indices for Maximum Likelihood Confirmatory Factor Analysis*. *Psychometrika*.
- Banks, J., Nicol, D., Carson, J., & Nelson, B. (2013). *Discrete Event System Simulation*. Pearson.
- Bishop, C. M. (2020). *Patter Recognition and Machine Learnign*. Ukrania: Springer.
- Blitzstein, J. K., & Hwuang, J. (2019). *Introduction to Probability, Second Edition*. New York: Chapman and Hall/CRC.
- Boyd, C. (2015). *Water Quality: An Introduction*. Berlin: Springer.
- Boyd, C. E. (2018). *Dinamica del Oxigeno disuelto*. Global Seafood.
- Capetillo-Contreras, O., Reynoso, F. D., & Resendiz, J. R. (2024). Sistema de acuicultura basado en inteligencia artificial para optimizar la calidad del agua: un análisis sistemático. *Journal of Marine Science and Engineering*.
- Castillo, A. (2022). *México entre los 10 principales productores acuicolas a nivel mundial*. MDS Salud Animal.
- Deb. (2002). *Multiobjective genetic algorithm: NSGA-II*. Evolutionary Computation.
- DOF. (2009). *NORMA Oficial Mexicana NOM-242-SSA1-2009, Productos y servicios. Productos de la pesca frescos, refrigerados, congelados y procesados. Especificaciones sanitarias y métodos de prueba*.
- DOF. (2009). *Prácticas de higiene para el proceso de alimentos, bebidas o suplementos alimenticios*.
- Elliot, K. (2018). *La importancia de los niveles de oxigeno disuelto para el crecimiento de los peces*.
- Elsken, T., Metzen, J. H., & Hutter, F. (2019). Neural Architecture Search: A Survey. *Journal of Machine Learning Research*.
- Eze, E., Kirby, S., Attridge, J., & Ajmal, T. (2023). Aquaculture 4.0: hybrid neural network multivariate water quality parameters forecasting model. *Scientific Reports*.

FAO. (2022). *Version Resumida de El estado mundial de la pesca y la acuicultura 2022. Hacia la transformacion azul*. Roma: FAO.

FAO. (2024). *El estado mundial de la pesca y la acuicultura* . Roma: FAO.

Farrel, P. J., & Rogers-Stewart, K. (2017). Comprehensive study of tests for normality and symmetry. *Journal of Statistical Computation and Simulation*.

FIRCO. (01 de Marzo de 2017). Produccion de Tilapia a traves de la Acuicultura.

Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.

Gratacap, R. L., & Wargelius, A. (2019). *Potencial de edición del genoma para mejorar la cría y producción de acuicultura*. Global Seafood Alliance.

Inteligencia Artificial. (24 de junio de 2025). Obtenido de <https://inteligenciaartificial.io/casos-de-exito-de-ia-en-pequenas-y-medianas-empresas/>

K, D., A, P., S, A., & Meyarivan. (2016). *A fast elitist multiobjective genetic algorithm*. Transactions on evolutionary computation.

Kemmer, F. N., & Company, N. C. (1982). *Manual del agua: su naturaleza, tratamiento y aplicaciones*. Mc.Graw-Hill.

Kinadu, R. A., Cunha, M., Salomons, E., & Ostfeld, A. (2023). Improving Multi-Objective Optimization Methods of Water Distribution Networks. *Technion*.

Law, A. M. (2015). *Simulation modeling and analysis*. Boston: Mc Graw-Hill.

Li, T., Lu, J., Wu, J., & Zhang, Z. (2022). *Predicting Aquaculture Water Quality Using Machine Learning Approaches*. Yantai: Water.

Lu, G., & Luo, M. (2021). *Genomas de varias especies de peces importantes en la pesca y la acuicultura mundiales*. Global Seafood Alliance.

Mandal, J. K., Mukhopadhyay, S., & Dutta, P. (2018). *Multi-Objective Optimization: Evolutionary to Hybrid Framework*. Springer.

Martinez, M. A. (2006). *Manejo del Cultivo de Tilapia*. Managua, Nicaragua.

Massey, F. (2019). The Kolmogorov-Smirnov Test. *Journal of the American Statistical Association*.

MATLAB. (2024).

MATLAB. (2025). Obtenido de <https://la.mathworks.com/products/matlab.html>

México, G. d. (2024). *Ley General de Pesca y Acuicultura Sustentables*. Ciudad de México: Secretaria de servicios parlamentarios.

- Montgomery, D., & Runger, G. (2018). *Applied Statistics and Probability for Engineers*. Wiley.
- Murnyak, D. (2010). *Piscicultura: Fundamentos de la Cría de Tilapia e Implementacion de Proyectos de Piscicultura*. Notas Tecnicas de ECHO.
- OECD. (2021). Artificial Intelligence, Innovation and Productivity for SMEs. *OECD*.
- Olivares, R. (3 de Abril de 2025). Obtenido de ia.com: <https://herramientas-ia.com/linea-de-tiempo-de-la-inteligencia-artificial/>
- Pritsker, A. A. (1995). *Introduction to Simulation and SLAM II*.
- Razali, N. M., & Wah, Y. B. (2011). Power comparisons of Shapiro-Wilk, Kolmogorov-Smirnov, Lilliefors and Anderson-Darling tests. *Journal of Statistical Modeling and Analytics*, 21-33.
- Regino, R. B., Hoyos, F. T., & Lopez, J. P. (2025). *Intelligent Prediction and Continuous Monitoring of Water Quality in Aquaculture: Integration of Machine Learning and Internet of Things for Sustainable Managemen*. Colombia: Water.
- RM, R. (2025). Predictive Water Quality Monitoring in Aquaculture Using Machine Learning and IoT Automation. *ACIS*.
- Rodriguez, J. C. (2021). *A new culture medium based on genetic algorithms for Isochrysis galbana production relevant to hatcheries*. Appl Phycol.
- Russell, S., & Norvig, P. (2021). *Artificial Intelligence: A Modern Approach*. Pearson.
- Samek, W., Wiegand, T., & Müller, K.-R. (2017). Explainable Artificial Intelligence: Understanding, Visualizing and Interpreting Deep Learning Models. *Journal of Machine Learning*.
- Sayed, A. F. (2020). *Chapter 3 - Tilapia distribution, transfers and introductions*. Alexandria.
- SEMARNAT. (2021). *Que establece los límites permisibles de contaminantes en las descargas de aguas residuales en cuaspor receptores propiedad de la nación*.
- Servicio Nacional de Sanidad, I. y. (2025). Sistemas de control que disminuyen los riesgos de contaminación en la producción agropecuaria para mantener estándares de calidad. *Gobierno de México*.
- Shete, C., R. S., & Mahajan, A. (2025). IoT-driven ensemble machine learning model for accurate dissolved oxygen prediction in aquaculture. *Discov Internet Things*, 5, 94.
- SIAP. (30 de Noviembre de 2022). *Gobierno de México*. Obtenido de Secretaria de Agricultura y Desarrollo Rural: <https://www.gob.mx/siap/articulos/seis-tendencias-de-la-acuicultura-mundial>
- SIMNET, I. (2025). Simulation with SIMNET II.

- Songma, S. (2024). Mejorar el monitoreo de la calidad del agua en estanques de camarones mediante aprendizaje automático y optimización bioinspirada. *Revista de agricultura y tecnologia*.
- Standridge, C. R. (2013). *Beyond Lean: Simulation in Practice*. Grand Valley State University.
- Tapabrata, R., Mohiuddin, M. M., & Kumar, S. H. (2022). A Simple Evolutionary Algorithm for Multi-modal: Multi-objective Optimization .
- Tucciarone, I., Secci, G., Contiero, B., & Parisi, G. (2024). *Sustainable aquaculture over the last 30 years: An analysis of the scientific literature by the Text Mining approach*. Florence, Italy: Reviews in aquaculture.
- Tucker, C. B. (1998). *Pond Aquaculture Water Quality Management*. Kluwer Academic Publishers.
- Yusoff, F. M., Umi, W. A., Ramli, N., & Harun, R. (2024). *Water quality management in aquaculture*. Cambridge, Inglaterra: Cambridge Prisms.
- Zhang, G., Patuwo, B. E., & Hu, M. Y. (1998). Forecasting with artificial neural networks:: The state of the art. *International Journal of Forecasting*, 35-62.
- Zhang, L. (2019). *Applications of Artificial Intelligence in Industrial Systems*. Elsevier.

Anexos

Anexo I. Base de datos generada

X1	X2	X3	X4	X5	X6	X7	X8	X9	X10
Temperatura	Oxígeno disuelto	pH	TAN	Nitrito	Nitrato	Transparencia	Dureza	Alcalinidad	Dioxido de carbono
18 A 30 °c	4 a 10 mg/l	6.5 a 8.5	Hasta 0.5 mg/l	Hasta 1.64 mg/l	Hasta 180 mg/l	40 a 45 cm	40 a 100 mg/l	50 a 120 mg/l	Hasta 20 mg/l
22.77075	6.385373	7.295125	0.1987811	0.652002	71.5612	41.98781	63.85373	77.82935	7.951244
27.93388	8.966942	8.155647	0.4139118	1.357631	149.0083	44.13912	89.66942	107.9477	16.55647
20.78879	5.394393	6.964797	0.1161994	0.381134	41.83179	41.16199	53.94393	66.26791	4.647976
29.1199	9.55995	8.353316	0.4633292	1.51972	166.7985	44.63329	95.5995	114.8661	18.53317
22.1621	6.08105	7.193683	0.1734208	0.5688203	62.4315	41.73421	60.8105	74.27892	6.936832
22.40942	6.204708	7.234902	0.1837257	0.6026201	66.14124	41.83726	62.04708	75.72159	7.349026
27.05139	8.525694	8.008565	0.3771411	1.237023	135.7708	43.77141	85.25694	102.7998	15.08565
20.66468	5.32324	6.944113	0.1110284	0.364173	39.97021	41.11028	53.3234	65.54397	4.441134
19.291	4.6455	6.715167	0.05379167	0.1764367	19.365	40.53792	46.455	57.53083	2.151667
19.83991	4.919955	6.806652	0.07666288	0.2514543	27.59864	40.76663	49.19955	60.7328	3.066515
29.35462	9.677311	8.392437	0.4731092	1.551798	170.3193	44.73109	96.77311	116.2353	18.92437
19.11888	4.559439	6.68648	0.04661988	0.1529132	16.78316	40.4662	45.59439	56.52678	1.864795
18.9688	4.484402	6.661467	0.04036679	0.1324031	14.53204	40.40367	44.84401	55.65135	1.614672
28.67184	9.335918	8.278639	0.4446598	1.458484	160.0775	44.4466	93.35918	112.2524	17.78639
27.54417	8.772083	8.090694	0.3976736	1.304369	143.1625	43.97673	87.72083	105.6743	15.90694
22.79156	6.395783	7.298594	0.1996486	0.6548473	71.87349	41.99649	63.95783	77.9508	7.985943
29.84763	9.923815	8.474605	0.4936512	1.619176	177.7144	44.93651	99.23814	119.1112	19.74605
25.1031	7.551549	7.68385	0.2959624	0.9707567	106.5465	42.95963	75.51549	91.43474	11.8385
23.76585	6.882924	7.460975	0.2402436	0.7879992	86.48771	42.40244	68.82924	83.63411	9.609746
24.59654	7.298271	7.599424	0.2748559	0.9015275	98.94814	42.74856	72.98271	88.47984	10.99424
18.09401	4.047006	6.515669	0.00391717	0.01284832	1.410181	40.03917	40.47006	50.5484	1.57E-01
26.06093	8.030466	7.843489	0.3358721	1.101661	120.914	43.35872	80.30466	97.0221	13.43489
18.07325	4.036624	6.512208	0.003052027	0.01001065	1.09873	40.03052	40.36624	50.42728	1.22E-01
25.08992	7.54496	7.681653	0.2954133	0.9689556	106.3488	42.95413	75.4496	91.35786	11.81653
18.27474	4.137372	6.545791	0.01144771	0.03754848	4.121175	40.11448	41.37373	51.60268	4.58E-01
27.63866	8.819331	8.106443	0.4016109	1.317284	144.5799	44.01611	88.19331	106.2255	16.06444
27.00059	8.500297	8.000099	0.3750247	1.230081	135.0089	43.75025	85.00297	102.5035	15.00099
18.96442	4.482208	6.660736	0.040184	0.1318035	14.46624	40.40184	44.82208	55.62576	1.60736
26.9388	8.469398	7.989799	0.3724499	1.221636	134.082	43.7245	84.69398	102.143	14.89799
24.36214	7.181069	7.560357	0.2650891	0.8694923	95.43208	42.65089	71.81069	87.11248	10.60357
26.46821	8.234106	7.911369	0.3528422	1.157322	127.0232	43.52842	82.34106	99.39791	14.11369
23.25517	6.627582	7.375861	0.2189652	0.7182058	78.82747	42.18965	66.27583	80.65513	8.758608
21.55165	5.775823	7.091941	0.1479852	0.4853915	53.27468	41.47985	57.75822	70.71793	5.919409
22.49969	6.249847	7.249949	0.1874873	0.6149583	67.49542	41.87487	62.49847	76.24822	7.499492
20.37455	5.187273	6.895758	0.09893942	0.3245213	35.61819	40.9894	51.87273	63.85152	3.957577
26.99446	8.497232	7.999078	0.3747694	1.229244	134.917	43.74769	84.97233	102.4677	14.99078
23.97472	6.987359	7.495787	0.2489466	0.8165449	89.62078	42.48947	69.8736	84.85252	9.957865
19.09253	4.546265	6.682088	0.04552204	0.1493123	16.38793	40.45522	45.46264	56.37309	1.820881
20.13367	5.066836	6.855612	0.08890297	0.2916017	32.00507	40.88903	50.66836	62.44641	3.556119
22.61419	6.307095	7.269032	0.1922579	0.630606	69.21285	41.92258	63.07095	76.91611	7.690317
24.69254	7.346271	7.615424	0.2788559	0.9146474	100.3881	42.78856	73.46271	89.03983	11.15424
23.55182	6.775907	7.425303	0.2313256	0.7587479	83.27721	42.31326	67.75907	82.38558	9.253024
27.34065	8.870325	8.056775	0.3891938	1.276556	140.1098	43.89194	86.70325	104.4871	15.56775
22.32857	6.164283	7.221428	0.1803569	0.5915707	64.9285	41.80357	61.64283	75.24997	7.214277
24.21521	7.107605	7.535869	0.2589671	0.8494122	93.22816	42.58967	71.07606	86.2654	10.35869
29.05531	9.527654	8.342551	0.4606378	1.510892	165.8296	44.60638	95.27654	114.4893	18.42551
28.53418	9.267088	8.255695	0.438924	1.439671	158.0126	44.38924	92.67088	111.4494	17.55696
29.88039	9.940195	8.480065	0.4950162	1.623653	178.2059	44.95016	99.40195	119.3023	19.80065
23.71579	6.857893	7.452631	0.2381578	0.7811575	85.7368	42.38158	68.57893	83.34209	9.526311
23.22704	6.613518	7.371172	0.2177932	0.7143615	78.40553	42.17793	66.13518	80.49104	8.711726
28.78854	9.39427	8.29809	0.4495225	1.474434	161.8281	44.49522	93.9427	112.9332	17.9809
20.99249	5.496246	6.998749	0.1246872	0.4089739	44.88738	41.24687	54.96246	67.45621	4.987487
20.81569	5.407845	6.969282	0.1173205	0.3848111	42.23537	41.17321	54.07846	66.42487	4.692819
25.31944	7.659719	7.719907	0.3049766	1.000323	109.7916	43.04977	76.5972	92.69673	12.19907
23.81401	6.907007	7.469002	0.2422506	0.794582	87.21022	42.4225	69.07008	83.91508	9.690024
18.14115	4.070576	6.523525	0.005881347	0.01929082	2.117285	40.05882	40.70576	50.82339	2.35E-01
26.34699	8.173494	7.891165	0.3477912	1.140755	125.2048	43.47791	81.73494	98.69077	13.91165
25.82657	7.913283	7.804428	0.326107	1.069631	117.3985	43.26107	79.13284	95.65498	13.04428
27.11116	8.555578	8.018526	0.3796315	1.245191	136.6674	43.79631	85.55579	103.1484	15.18526
29.21474	9.607369	8.369123	0.4672808	1.532681	168.2211	44.67281	96.07369	115.4193	18.69123
20.10688	5.053442	6.851148	0.08778687	0.2879409	31.60327	40.87787	50.53442	62.29016	3.511475
28.41423	9.207113	8.235704	0.4339261	1.423277	156.2134	44.33926	92.07113	110.7496	17.35704
29.8932	9.946598	8.482199	0.4955498	1.625403	178.3979	44.9555	99.46597	119.377	19.82199
22.93505	6.467528	7.322509	0.2056273	0.6744576	74.02583	42.05627	64.67528	78.78783	8.225093
29.48456	9.742278	8.414093	0.4785232	1.569556	172.2683	44.78523	97.42278	116.9932	19.14093
18.9337	4.466851	6.655617	0.03890422	0.1276058	14.00552	40.38904	44.66851	55.44659	1.556169
26.71549	8.357744	7.952581	0.3631453	1.191117	130.7323	43.63145	83.57744	100.8403	14.52581
27.20356	8.601782	8.033927	0.3834818	1.25782	138.0535	43.83482	86.01781	103.6875	15.33927
22.28615	6.143077	7.214359	0.1785897	0.5857743	64.2923	41.7859	61.43077	75.00256	7.143589
19.38236	4.691181	6.730393	0.05759839	0.1889227	20.73542	40.57598	46.91181	58.06377	2.303936
19.34876	4.674382	6.724794	0.0561985	0.1843311	20.23146	40.56199	46.74382	57.86779	2.24794
18.6766	4.338299	6.612766	0.02819157	0.09246834	10.14896	40.28191	43.38299	53.94682	1.127663
25.57588	7.787941	7.762647	0.3156618	1.035371	113.6382	43.15662	77.87941	94.19265	12.62647
25.84857	7.924283	7.808094	0.3270236	1.072637	117.7285	43.27024	79.24283	95.7833	13.08094
24.8455	7.422748	7.640916	0.285229	0.935551	102.6824	42.85229	74.22748	89.93205	11.40916
26.23903	8.119517	7.873172	0.3432931	1.126001	123.5855	43.43293	81.19518	98.06104	13.73172
23.4555	6.727752	7.409251	0.2273127	0.7455855	81.83256	42.27312	67.27752	81.82377	9.092506
28.65377	9.326885	8.275628	0.4439071	1.456015	159.8065	44.43907	93.26885	112.147	17.75628
23.91723	6.958614	7.486205	0.2465511	0.8086877	88.75841	42.46551	69.58614	84.51716	9.862045
24.84234	7.421172	7.64039	0.2850976	0.9351202	102.6351	42.85098	74.21172	89.91367	11.4039
21.26547	5.632736	7.044245	0.1360613	0.4462811	48.98208	41.36061	56.32736	69.04858	5.442453
24.78268	7.391339	7.630446	0.2826116	0.926966	101.7402	42.82611	73.91339	89.56562	11.30446
26.4696	8.234981	7.91166	0.352915	1.157561	127.0494	43.52915	82.34981	99.4081	14.1166
28.63429	9.317145	8.272382	0.4430954	1.453353	159.5144	44.43095	93.17146	112.0334	17.72382
20.5192	5.259598	6.919866	0.1049665	0.34429	37.78793	41.04966	52.59598	64.6953	4.198659
22.11689	6.058446	7.186149	0.1715371	0.5626419	61.75337	41.71537	60.58446	74.0152	6.861486
18.59337	4.296884	6.598895	0.0247237	0.08109372	8.900531	40.24724	42.96684	53.46132	9.89E-01
18.74737	4.373683	6.624561	0.03114025	0.10214	11.21049	40.3114	43.73683	54.35963	1.24561
26.98174	8.490872	7.996957	0.3742394	1.227505	134.7262	43.74239	84.90872	102.3935	

Anexo I. Desglose manual de RNA para calidad.

X1		P1	IW1	P*IW	SUMA	b1	SUMA 2	a1	LW	a1*LW	SUMA 3	b2	SUMA 4	Y1
18.07325	18.07325	-1	157.802505	-157.80251	-2264.597	-1128.3361	-3392.9331	-1.00000	-0.3333374	0.33333745	-5.053243	6.05324249	1	4
29.95519			34.0271237	-814.51341										
			2.66106279	537.717486										
			20.0375507	25.284557										
				532.445101	-320.21361	-4.7529347	-324.96654	-1.00000	-0.3333345	0.33333451				
				-330.096										
X2		P2	IW2	-1088.4143										
4.036624	4.036624	-1	814.513408	-285.87557										
9.977596			32.4465623	-398.79753	-0.7266655	-7.5439401	-8.2706056	-1.00000	6.05325	-6.0532492				
			-42.924786	-284.54487										
			14.281947											
				-34.027124	-225.41785	108.817664	-116.60018	-1.00000	-0.3333343	0.33333428				
X3		P3	IW3	-32.446562										
6.512208	6.512208	-1	-537.71749	-31.772212										
8.492533			31.7722123	-32.79304										
			26.2096346	-29.02312	0.33333745	0.33333745								
			8.80821228	-31.900061	0.33333451	0.33333451								
				-31.425044	-6.0532492	-6.0532492								
				-32.415913	0.33333428	0.33333428								
X4		P4	IW4	-32.008128										
0.00305203	0.00305203	-1	-25.284557	-32.402405										
0.4981331			32.7930395											
			-0.3853335											
			75.1583541	-2.6610628										
				42.924786										
				-26.209635										
X5		P5	IW5	0.38533352										
0.01001065	0.01001065	-1	-532.4451	-12.492903										
1.633876			29.0231199	-13.373579										
			12.4929029	47.2481493										
			23.4063865	-41.904526										
				25.6714977										
				-20.314727										
X6		P6	IW6											
1.09873	1.09873	-1	330.095998											
179.3279			31.9000615	-20.037551										
			13.3735786	-14.281947										
			17.8373965	-8.8082123										
				-75.158354										
				-23.406386										
X7		P7	IW7	-17.837396										
40.03052	40.03052	-1	1088.41426	-14.212212										
44.98133			31.4250436	-17.4928										
			-47.248149	-17.931927										
			14.212212	-16.251059										
X8		P8	IW8											
40.36624	40.36624	-1	285.87557											
99.77597			32.4159125											
			41.9045259											
			17.4928002											
X9		P9	IW9											
50.42728	50.42728	-1	398.797533											
119.7386			32.0081281											
			-25.671498											
			17.9319274											
X10		P10	IW10											
0.1220811	0.1220811	-1	284.544866											
19.92532			32.4024047											
			20.3147272											
			16.2510588											

Formula generada

((TANH(((N3*157.802505146886)+(N10*814.513407824989)+(N17*-537.717486428361)+(N24*-25.2845569921074)+(N31*-532.445101150397)+(N38*330.095998119578)+(N45*1088.41426312855)+(N52*285.875569584492)+(N59*398.797532599565)+(N66*284.5448664121))-1128.33610243893)*(-0.333337446471983)))+(TANH(((N3*34.0271236657595)+(N10*32.446562255051)+(N17*31.7722123227857)+(N24*32.7930395427045)+(N31*29.0231199439486)+(N38*31.9000614631909)+(N45*31.4250436444826)+(N52*32.4159125224059)+(N59*32.0081280603393)+(N66*32.4024046768566))-4.75293471898188)*(-0.333334512693177)))+(TANH(((N3*2.66106278672544)+(N10*-42.9247860025045)+(N17*26.2096346043925)+(N24*-0.385333522275381)+(N31*12.4929029287829)+(N38*13.3735786131764)+(N45*-47.2481493310478)+(N52*41.9045259390063)+(N59*-25.6714977475983)+(N66*20.3147272487879))-7.54394011457956)*(6.0532500011556)))+(TANH(((N3*20.0375506571274)+(N10*14.2819469981761)+(N17*8.80821228327623)+(N24*75.1583540528039)+(N31*23.4063864979145)+(N38*17.8373964514202)+(N45*14.212211962043)+(N52*17.4928002030249)+(N59*17.9319274309419)+(N66*16.2510588270883))*108.817663839007)*(-0.333334275271332)))+(6.05324249397452)

Anexo I. Desglose manual de RNA para Costo

X1		P1	IWI	P*IW	SUMA	b1	SUMA 2	a1	LW	a1*LW	SUMA 3	b2	SUMA 4	Y2
36146.5	36146.5	-1	-0.608444515	0.60844452	0.50619777	1.21410718	1.720304949	0.9378997	-1.1145747	-1.04533593	-1.483463494	0.48346921	-1	98690.175
59910.4			-0.33485235	0.37192262										
			0.089030693	0.60601701										
			0.238259725	-0.2550944										
X2		P2		-0.1238309	0.37018081	-0.0329898	0.33719101	0.3249673	-1.8994057	-0.6172448				
20183.1	20183.1	-1	-0.371922621	-0.601466										
49888			-0.485308886	0.00648039										
			0.694560921	-0.5844053										
			-0.762139128	0.30367252	-0.5260831	1.29998791	0.773904797	0.6491943	1.05270482	0.68340996				
X3		P3		0.17445736										
6512.21	6512.21	-1	-0.606017012											
8492.53			0.030623574	0.33485235										
			-0.48212861	0.48530889	-0.157257	1.61278843	1.455531403	0.8967812	-0.5623103	-0.5042693				
			0.214604298	-0.0306236										
X4		P4		-0.0190194										
12.2081	12.2081	-1	0.255094423	0.01455115										
1992.53			0.019019419	-0.3318643										
			0.655944894	-0.0289409										
			0.411996968	0.1867787										
				0.01857829										
X5		P5		-0.2594404										
10.0107	10.0107	-1	0.123830936	-0.2594404										
1633.88			-0.014551151											
			0.294999042	-0.0890307										
			0.805593627	-0.6945609										
X6		P6		0.48212861										
1098.73	1098.73	-1	0.601465988	-0.6559449										
179328			0.331864289	-0.294999										
			0.484738008	-0.484738										
			-0.006212161	0.07315377										
X7		P7		0.31718668										
8006.1	8006.1	-1	-0.006480386	0.6519992										
8996.27			0.028940922	0.16872218										
			-0.073153769											
			-0.884655495	-0.2382597										
X8		P8		0.76213913										
16146.5	16146.5	-1	0.584405297	-0.2146043										
39910.4			-0.186778702	-0.411997										
			-0.31718668	-0.8055936										
			-0.308236404	0.00621216										
X9		P9		0.88465549										
10085.5	10085.5	-1	-0.303672518	0.3082364										
23947.7			-0.018578291	-0.5768274										
			-0.651999203	0.12878181										
			0.576827405											
X10		P10												
488.324	488.324	-1	-0.17445736											
79701.3			0.259440363											
			-0.168722184											
			-0.128781813											

Formula generada

((TANH(((N3*-0.608444515314784)+(N10*-0.371922621451251)+(N17*-0.606017011868659)+(N24*0.255094422599411)+(N31*0.123830935992925)+(N38*0.601465987835003)+(N45*-0.0064803856193757)+(N52*0.584405297179769)+(N59*-0.303672518184749)+(N66*-0.174457359600687))+1.2141071802906)*(-1.11457470206503)))+(TANH(((N3*-0.334852349510726)+(N10*-0.485308886067068)+(N17*0.0306235735535184)+(N24*0.01901941872404)+(N31*-0.0145511512110524)+(N38*0.331864288700723)+(N45*0.0289409224674228)+(N52*-0.18677870212672)+(N59*-0.0185782910672696)+(N66*0.259440363322481)))-0.0329898028747517)*(-1.89940570475038)))+(TANH(((N3*0.0890306928882418)+(N10*0.694560921309898)+(N17*-0.482128609916293)+(N24*0.655944894093496)+(N31*0.294999042250035)+(N38*0.484738007666795)+(N45*-0.0731537689259289)+(N52*-0.317186680241707)+(N59*-0.651999202594106)+(N66*-0.168722183612332))+1.29998791001952)*(1.05270482392553)))+(TANH(((N3*0.762139127657905)+(N17*0.21460429815991)+(N24*0.411996968244009)+(N31*0.805593627400525)+(N38*-0.00621216061249312)+(N45*-0.884655494580872)+(N52*-0.308236404245864)+(N59*0.576827404624919)+(N66*-0.128781813078337))+1.6127884268698)*(-0.562310285252411)))+(0.483469207693522)