



Redes IoT e Inteligencia Artificial para Monitoreo Ambiental y Automatización de Camaroneras en Isla Manglecito

IoT Networks and Artificial Intelligence for Environmental Monitoring and Automation of Shrimp Farms on Manglecito Island

Redes IoT e Inteligência Artificial para Monitorização Ambiental e Automação de Explorações de Camarão na Ilha de Manglecito

Luis Armando Rueda Rodríguez ^I

luis.ruedarodriguez2051@upse.edu.ec

<https://orcid.org/0009-0005-5514-2027>

Lucrecia Llerena Guevara ^{II}

l.llerena@upse.edu.ec

<https://orcid.org/0000-0002-4562-6723>

Correspondencia: luis.ruedarodriguez2051@upse.edu.ec

Ciencias Técnicas y Aplicadas

Artículo de Investigación

* **Recibido:** 26 de septiembre de 2025 * **Aceptado:** 14 de octubre de 2025 * **Publicado:** 18 de noviembre de 2025

I. Universidad Estatal Península de Santa Elena, Ecuador.

II. Universidad Estatal Península de Santa Elena, Ecuador.

Resumen

Las camaroneras en zonas remotas como la Isla Manglecito enfrentan limitaciones de conectividad que dificultan el monitoreo ambiental y la gestión productiva. Este estudio tuvo como objetivo diseñar y simular una arquitectura IoT con inteligencia artificial (IA) para habilitar monitoreo en tiempo real, generar alertas tempranas y automatizar procesos críticos. En nuestra metodología se realizaron dos simulaciones. Primero realizamos el enlace inalámbrico de largo alcance (cercano a 90 kilómetros) utilizando la herramienta de simulación Radio Mobile. Segundo la red interna IoT, que se simula dentro de la camaronera utilizando el software Cisco Packet Tracer. Los resultados demostraron la estabilidad en el enlace a larga distancia, con márgenes cercanos a 36 dB y latencias que no superaron los 30 milisegundos. El consumo de energía promedio de los equipos es de unos 3,7 kWh diarios. Los modelos de IA demostraron una (precisión 0,988, recall 0,938 y R^2 arriba de 0,93). Esto respalda contundentemente nuestra hipótesis: la arquitectura integrada de IoT e IA es totalmente viable para mejorar la eficiencia y sostenibilidad en el contexto de las camaroneras rurales.

Palabras Clave: Inteligencia Artificial; IoT; Monitoreo Ambiental; Automatización; Cultivo de Camarones; hipoxia; biomasa.

Abstract

Shrimp farms in remote areas like Manglecito Island face connectivity limitations that hinder environmental monitoring and production management. This study aimed to design and simulate an IoT architecture with artificial intelligence (AI) to enable real-time monitoring, generate early warnings, and automate critical processes. Our methodology involved two simulations. First, we simulated a long-range wireless link (approximately 90 kilometers) using the Radio Mobile simulation tool. Second, we simulated the internal IoT network within the shrimp farm using Cisco Packet Tracer software. The results demonstrated stability in the long-distance link, with margins close to 36 dB and latencies that did not exceed 30 milliseconds. The average energy consumption of the equipment is approximately 3.7 kWh per day. The AI models demonstrated high accuracy (0.988), recall (0.938), and an R^2 above 0.93. This strongly supports our hypothesis: integrated IoT and AI architecture is entirely viable for improving efficiency and sustainability in the context of rural shrimp farms.

Keywords: Artificial Intelligence; IoT; Environmental Monitoring; Automation; Shrimp Farming; Hypoxia; Biomass.

Resumo

As explorações de camarão em áreas remotas, como a Ilha de Manglecito, enfrentam limitações de conectividade que dificultam a monitorização ambiental e a gestão da produção. Este estudo teve como objetivo projetar e simular uma arquitetura IoT com inteligência artificial (IA) para permitir a monitorização em tempo real, gerar alertas precoces e automatizar processos críticos. A nossa metodologia envolveu duas simulações. Em primeiro lugar, simulámos um enlace sem fios de longo alcance (aproximadamente 90 quilómetros) utilizando a ferramenta de simulação Radio Mobile. Em seguida, simulámos a rede IoT interna dentro da exploração de camarão, utilizando o software Cisco Packet Tracer. Os resultados demonstraram estabilidade no enlace de longa distância, com margens próximas dos 36 dB e latências que não ultrapassaram os 30 milissegundos. O consumo médio de energia do equipamento é de aproximadamente 3,7 kWh por dia. Os modelos de IA demonstraram uma elevada precisão (0,988), recall (0,938) e um R^2 acima de 0,93. Isto corrobora fortemente a nossa hipótese: a arquitetura integrada de IoT e IA é totalmente viável para melhorar a eficiência e a sustentabilidade no contexto das explorações de camarão rurais.

Palavras-chave: Inteligência Artificial; IoT; Monitorização Ambiental; Automação; Criação de Camarão; Hipóxia; Biomassa.

Introducción

La acuicultura, y más específicamente la producción de camarón, es uno de los sectores más importantes del mundo porque ayuda a producir divisas y a garantizar la seguridad alimentaria y a la generación de divisas. Sin embargo, enfrenta problemas estructurales relacionados con el control de la calidad del agua, la presencia de enfermedades y la eficiencia en la administración de recursos. Las granjas todavía dependen de un monitoreo tradicional, lo que hace que las dificultades se incrementen. Este procedimiento requiere una gran intervención humana, es inexacto y lento (García Sánchez et al., 2018).

La integración de tecnologías como la Inteligencia Artificial (IA) y el Internet de las Cosas (IoT) brinda, en estas circunstancias, una nueva perspectiva para mejorar la administración de los sistemas acuícolas. No solamente hace más fácil la recolección y el análisis de datos en tiempo real

su implementación, sino que también posibilita que se realicen controles automáticos y modelos predictivos sobre variables críticas del agua y del equipo de cultivo. El uso conjunto de estos dos instrumentos permite una mejor capacidad de respuesta y facilita la toma de decisiones más precisas en las camaroneras (Ahmed et al., 2024). Simultáneamente, promueve la sostenibilidad del sector: disminuyen los costos, se mejoran los recursos y se reduce el riesgo de muerte en las piletas, un elemento esencial para la digitalización de la acuicultura. Estas propuestas tecnológicas son importantes y pueden aplicarse a las camaroneras pequeñas y medianas de la provincia y el Ecuador, que no tienen infraestructura tecnológica.

Las investigaciones actuales demuestran el gran potencial de las redes IoT basadas en Wi-Fi extendido, que han demostrado que se pueden monitorear en tiempo real y ejecutar la corrección autónoma de parámetros fisicoquímicos, como temperatura, pH, turbidez, salinidad y oxígeno disuelto en las piscinas de cultivo de camarón. Asimismo la validación de sistemas IoT de bajo consumo en el sector agroindustrial (Ahmed et al., 2024; Pereira Pontón et al., 2023) confirma la validación de aplicarlos en ambientes rurales. Pero, a pesar de estos avances, aún existen lagunas, como que la mayoría de las innovaciones solo se validaron en laboratorios o entornos industriales. Esto es costoso y dependiente de Wi-Fi, lo que restringe la implementación de tecnología en las granjas rurales de camarón en América Latina, afectando a lugares como Isla Manglecito.

Esta investigación se realizó en una zona rural del cantón La Libertad (provincia de Santa Elena), donde la cría de camarones tiene inconvenientes para ser competitiva y sostenible debido a que todavía depende del manejo manual y no cuenta con una automatización tecnológica estable (Sánchez-Ulloa y Palma-Macías, 2023). Ante esta realidad, este trabajo propone establecer un modelo de red IoT-IA que sea fácilmente aplicable en estas zonas donde el cultivo de camarón es manual. De esta manera, aportaremos evidencia práctica para impulsar la transición de la acuicultura hacia un futuro más digital y sostenible. A partir de esta realidad surge la pregunta principal: ¿cómo diseñar y simular una red IoT inalámbrica con sensores ambientales y cámaras de visión artificial? complementada con modelos de IA que permitan monitorear en tiempo real, generar alertas tempranas y automatizar procesos críticos en camaroneras remotas de la Isla Manglecito? El objetivo general se centra en desarrollar esa red integrada para facilitar el monitoreo continuo y la automatización de tareas clave.

TRABAJOS RELACIONADOS

Singh et al. (2024) desarrollaron un sistema inteligente de recirculación de agua dulce con sensores y modelos predictivos, aunque dependiente de infraestructura avanzada. Ahmed et al. (2024) también desarrolló un sistema que combina sensores e inteligencia artificial en las granjas camaroneras de Bangladesh, el cual alcanzó una precisión del 97,84 %, aunque el sistema tuvo dificultades para la implementación en zonas rurales. Por su parte, Kanwal et al. (2024) desarrollaron un sistema con una precisión superior al 99 %, aunque la duración de los sensores fue corta.

De una manera análoga, Shete et al. (2024) lanzaron un modelo prototipo de bajo costo que tenía un margen de error máximo del 4,87 %, que se vio influenciada por temas relacionados con la seguridad de los datos. Olanubi et al. (2024) implementaron un sistema IoT basado en ESP32 con monitoreo en la nube. En el ámbito de la visión artificial, Chiu et al. (2022) Demostraron una alta eficacia al integrar deep learning para estimar el crecimiento de peces, logrando un R^2 de 0,94, si bien el estudio se vio restringido por la dependencia de la conectividad Wi-Fi. De manera similar, Correia et al. (2025) utilizaron los modelos YOLOv8 y MBBBox; sin embargo, se observó sensibilidad en los resultados frente a cambios de la iluminación.

En cuanto a las predicciones en el tiempo, Cai et al. (2023) validaron un modelo LSTM que demostró ser más preciso que el SVM, aunque no se comprobó su desempeño en condiciones reales en el campo. De manera similar, Huang y Khabusi (2025) estudiaron cómo aplicar inteligencia artificial de Internet de las cosas en la acuicultura. Afirmaron que hay progresos significativos en campos como la alimentación, la salud y la biomasa; sin embargo, indicaron que todavía persisten restricciones vinculadas con los costos elevados y con la sostenibilidad operativa. En resumen, la literatura lo define con precisión: la acuicultura tiene un gran potencial para emplear inteligencia artificial e Internet de las cosas a través de sensores y algoritmos predictivos. Sin embargo, la mayoría de estos trabajos se centran en ambientes industriales o estrictamente controlados, lo que da lugar a una elevada dependencia del Wi-Fi, altos costos y una escasez de validación práctica en áreas rurales. Por lo tanto, este trabajo tiene como objetivo desarrollar y simular una red IoT-IA adaptada a granjas de camarón remotas, como las situadas en la isla Manglecito (Ver Tabla 1).

Tabla 1: Trabajos relacionados en IoT–IA para acuicultura


Autor(es)	Entorno de validación	Tecnología de comunicación	Enfoque de IA / Analítica	Limitaciones reportadas
(M. Singh et al., 2024)	Acuicultura en agua dulce (RAS)	Arquitectura distribuida (nube)	Random Forest, Gradient Boosting, M5	Requiere infraestructura avanzada; validación en escala limitada
(Ahmed et al., 2024)	Camaroneras de agua dulce (Bangladesh)	Wi-Fi / Internet	RF, MLP, XGBoost, AdaBoost	Costos elevados e infraestructura limitada en zonas rurales
(Chiu et al., 2022)	Granja acuícola experimental	Wi-Fi	Deep Learning con optimización bayesiana	Cobertura restringida por Wi-Fi en entornos rurales
(Huang & Khabusi, 2025b)	Revisión panorámica (AIoT en acuicultura)	Variada	CNN, LSTM, RF, aprendizaje por refuerzo	No incluye arquitectura validada; predominan pilotos controlados
(Shete et al., 2024)	Prototipo para acuicultura de tilapia (India)	GSM / nube	Procesamiento en servidor con calibración	Seguridad de datos y escalabilidad limitada
(Correia et al., 2025)	Camaroneras (P. vannamei)	Raspberry Pi + nube	YOLOv8, MBBBox	Sensibilidad a luz y oclusiones
(Cai et al., 2023)	conjuntos de datos abiertos (sin campo)	IoT + nube	LSTM (series temporales)	Sin validación en campo; solo datos abiertos

(Kanwal et al., 2024)	Estanques multiespecie (India)	ESP32 + ThingSpeak/Firebase	Árboles de decisión	Vida útil limitada de sensores; mantenimiento frecuente
(Olanubi et al., 2024)	Acuicultura	ESP32 + nube (BD)	Analítica básica / visualización	Escalabilidad, costos y validación en campo real pendientes

METODOLOGÍA

La investigación se fundamenta en el enfoque Design Science Research (DSR), el cual integra los principios de relevancia, diseño y rigor metodológico (Brendel et al., 2021). Para abordar la problemática planteada, se adoptó una estrategia de carácter técnico organizada en cuatro fases: (i) diseño de la red IoT inalámbrica, (ii) integración de sensores ambientales y visión artificial, (iii) recolección y procesamiento de datos, y (iv) entrenamiento de modelos de inteligencia artificial. Esta estructura metodológica asegura la alineación entre los fundamentos teóricos del DSR y los objetivos propuestos, al tiempo que respalda la validez de los resultados obtenidos en el estudio (Ver **Figura 1**).


Figura 1: Marco metodológico DSR aplicado a IoT–IA en camaroneras



Diseño de la arquitectura de red IoT-IA

La arquitectura de red propuesta asegura la transmisión confiable de datos al combinar un enlace inalámbrico de largo alcance para la conexión externa y una red IoT interna para la comunicación local en la camaronera de Isla Manglecito. Este enfoque resulta adecuado para entornos rurales y acuícolas, donde redes híbridas que combinan sensores locales de corto alcance con backhauls inalámbricos de largo alcance permiten mejorar cobertura, robustez de conectividad externa y favorecen la escalabilidad y resiliencia del sistema (Shabeer et al., 2025). La Figura 2 muestra la integración del enlace Machala-Isla Manglecito con la red local IoT.

Figura 2: Arquitectura de red IoT-IA propuesta



Enlace inalámbrico de largo alcance

El enlace inalámbrico fue diseñado y simulado en el software Radio Mobile; en este escenario se consideraron equipos con radio Mimosa C5C junto con antenas tipo dish blindadas de 35 dBi. Se seleccionó esta combinación porque tiene la capacidad de mantener un enlace inalámbrico de larga distancia con un rendimiento estable y confiable. Estos equipos se pueden adaptar a diferentes antenas de alta ganancia. Esta configuración resultó adecuada para las necesidades del proyecto, ya que ofrece baja latencia y alto ancho de banda. Con esta combinación podemos realizar enlaces superiores de más de 50 km sin perder señal, siendo una alternativa superior a otras tecnologías, especialmente en zonas rurales y remotas como las camaroneras de Isla Manglecito. Para garantizar la cobertura completa, fue necesario instalar torres de 50 metros de altura en Machala y en la Isla Puná. Las dos estructuras fueron equipadas con el mismo modelo de antena y radio. Desde la isla Puná, que funcionó como repetidor, se orientó el enlace hacia una torre de 20 metros de altura con la misma combinación de equipos, ubicada en la camaronera de la Isla Manglecito, que recibió la señal de manera estable. De esta manera, la simulación comprobó la viabilidad técnica del enlace bajo condiciones de propagación reales. Estudios recientes han evidenciado que la instalación de redes inalámbricas fijas en bandas altas (como 60 GHz u otras de microondas y radioenlaces específicos) puede proporcionar una cobertura eficaz, una tasa de datos aceptable y robustez frente a condiciones del medio ambiente en áreas rurales (Castellanos et al., 2023).

Red interna de distribución IoT-IA

La red interna IoT de la camaronera ubicada en la isla Manglecito fue simulada en el software Cisco Packet Tracer, con el propósito de validar la conectividad y el correcto funcionamiento de los equipos instalados. La señal proveniente de Machala se recibe inicialmente en una torre de 20 metros de altura, donde un PowerBeam M5 coge la señal. Desde este punto la señal se transmite mediante un enlace punto a punto hacia una segunda torre, también de 20 metros ubicada en el centro de la camaronera, la cual cuenta con otro PowerBeam M5 que recibe la transmisión. En esta torre central, se instaló un Rocket Prism 5AC Omni, encargado de distribuir la señal de forma multipunto con cobertura de 360° hacia todos los dispositivos IoT ubicados en los alrededores. Cada piscina tiene un LiteBeam 5AC que recibe la señal del equipo central y la conecta a una controladora SF200 que recoge la información de los sensores y la envía por protocolo MQTT reforzado con TLS 1.3 al servidor central. Se empleó el protocolo MQTT por su eficiencia en IoT, complementado con TLS 1.3 para asegurar la transmisión de datos con bajo consumo de ancho de

banda y mínima latencia, asegurando la confidencialidad, integridad y autenticidad de los datos frente a posibles ataques en redes inalámbricas de larga distancia. Además, la SF200 enlaza mediante XBee de 900 MHz los aireadores y alimentadores, asegurando la automatización y el monitoreo en tiempo real de los procesos productivos. Esta configuración representó un escenario donde la red mantiene un balance entre eficiencia en la transmisión de datos y seguridad en la comunicación, aspectos críticos en entornos acuícolas con restricciones de conectividad (Gavriilidis et al., 2025).

Integración de sensores ambientales y cámara con inteligencia artificial

El sistema se basa en la integración de un conjunto de sensores especializados para monitorear variables críticas del agua (oxígeno disuelto, pH, temperatura, salinidad, turbidez y amoníaco) y una cámara con algoritmos de visión artificial, los cuales se describen a continuación:

- **Sensores ambientales:** Estos dispositivos se modelaron para detectar y anticipar episodios de hipoxia, un problema crítico en la producción de camarón.
- **Cámara con inteligencia artificial:** Utilizada para estimar la biomasa del camarón a partir de mediciones biométricas (longitud y peso), lo que permite proyectar y ajustar automáticamente las raciones de alimento en tres periodos diarios.

Ambos componentes se integran en un controlador central (SF200) que transmite los datos al servidor de monitoreo a través del protocolo **MQTT sobre TLS 1.3**, garantizando seguridad y eficiencia.

- **Recolección y procesamiento de datos**

El sistema se validó mediante la simulación con datos provenientes de dos repositorios públicos:

- **Datos ambientales:** Se utilizaron más de 74.000 registros de sensores IoT en estanques de peces, recopilados entre 2022 y 2023.
- **Datos biométricos:** Se empleó un conjunto de datos de más de 5.000 imágenes y mediciones manuales de camarones para la estimación de la biomasa.

Los datos fueron sometidos a un proceso de depuración y estandarización para asegurar su consistencia y fiabilidad. Una vez procesados, se integraron en la simulación para alimentar los modelos de inteligencia artificial.

Entrenamiento de modelos de inteligencia artificial


Para la simulación, se implementaron dos modelos de IA complementarios:

- **Predicción de hipoxia mediante Random Forest:** Para la detección temprana de hipoxia, se entrenó un modelo Random Forest utilizando como variables principales la temperatura y el oxígeno disuelto. El modelo fue diseñado para anticipar la ocurrencia de hipoxia con una anticipación de 60 minutos. Para asegurar la confiabilidad de los resultados, se realizó una validación cruzada temporal que evaluó el desempeño en distintos períodos.

Cálculo de la biomasa mediante el perceptrón multicapa (MLP): Para calcular el peso individual de los camarones, utilizamos el modelo (MLP) que analizó la relación entre dos dimensiones clave (longitud total y el tamaño del cefalotórax), una vez entrenado el modelo, permitió predecir el peso de cada espécimen y a partir de ello calcular la biomasa total (Ver

- **Figura 3).**

Figura 3: Integración de modelos IA para hipoxia y biomasa en la simulación IoT-IA



RESULTADOS


Respaldan la propuesta. La simulación de los enlaces de larga distancia (Machala–Repetidor–Camaronera) obtuvo resultados técnicos sólidos, el tramo Machala–Repetidor (58,27 km), mostró una pérdida de trayecto de -151 dB y un nivel de señal recibido de -71 dBm. EL margen de enlace se mantuvo en 36 dB (con un despeje de Fresnel de 0,5), resultado suficiente para una operación estable. Mientras que el tramo Repetidor–Camaronera (32,37 km) obtuvo un rendimiento aún más estable ya que la pérdida de trayecto fue de -158,5 dB, el nivel recibido fue de -58,5 dBm (con un despeje de Fresnel de 1,4). Esto se tradujo en un margen de enlace y una relación de señal excelente, ambos situados en 48,5 dB, lo que deja en claro la solidez del diseño, al igual que la combinación de los resultados valida la viabilidad técnica del enlace simulado. (Ver Tabla 2)

Tabla 2: Enlace Machala–Repetidor–Camaronera

Enlace	Distancia (km)	Path Loss (dB)	Nivel recibido (dBm)	Fresnel (F1)	Relación señal (dB)	Margen de enlace (dB)
Machala ↔ Repetidor	58,27	−151,0	−71,0	0,5	36,0	36,0
Repetidor ↔ Camaronera	32,37	−158,5	−58,5	1,4	48,5	48,5

La simulación de la red interna en Cisco Packet Tracer también confirmó la conectividad local. Las pruebas de conectividad ICMP mostraron que todos los nodos (sensores, cámara y actuadores) respondieron correctamente al servidor local sin pérdida de paquetes, validando que la cobertura es suficiente para la transmisión de datos hacia el *backhaul* de largo alcance. La Figura 4 muestra la simulación de la red interna en la camaronera, validando la conectividad de sensores, cámara y actuadores en Cisco Packet Tracer.

Figura 4: Simulación de la red interna en la camaronera (Cisco Packet Tracer).



Latencia

Las Tablas 3 y 4 presentan los resultados de latencia y conectividad del sistema, evidenciando retardos bajos (18–25 ms en el backhaul) y respuestas ICMP exitosas sin pérdida de paquetes en la red interna, lo que confirma la eficiencia de la comunicación IoT–IA.

La latencia del sistema se estimó en función de la distancia total del enlace de 90 km, que incluye dos saltos. Cada salto generó un retardo estimado de 3 a 5 ms, dando una latencia total del backhaul

entre 18 y 25 ms, adecuada para telemetría y transmisión de video en tiempo real. En la red interna, las pruebas realizadas en Cisco Packet Tracer mostraron respuestas menores a 5 ms y sin pérdida de paquetes, lo que confirma una latencia muy baja en el sistema local.

Tabla 3: Estimación de la latencia en el enlace Machala–Cameronera a través del repetidor

Tramo	Distancia (km)	Latencia estimada (ms)
Machala ↔ Repetidor	58,27	10–15
Repetidor ↔ Camaronera	32,37	6–10
Distancia y Latencia Total esperada	90	18–25

Tabla 4: Resultados de conectividad ICMP en la red interna

Dispositivo IoT	Rol simulado	Respuesta ICMP	Pérdida	Retardo estimado
Sensor ambiental	Temperatura, pH, OD	Exitosa	0%	<5 ms
Ventilador	Aireadores	Exitosa	0%	<5 ms
Alarma	Alimentador automático	Exitosa	0%	<5 ms
Cámara IA	Visión artificial	Exitosa	0%	<5 ms

Consumo energético

El consumo energético del sistema se estimó con las especificaciones de los equipos de telecomunicaciones y los ciclos de operación de los actuadores. La demanda diaria se aproxima a 3,73 kWh/día, lo que es compatible con una solución de energía fotovoltaica y un banco de baterías, asegurando la operación continua del sistema en un entorno rural (Ver Tabla 5).

Tabla 5: Consumo energético estimado del sistema

Equipo / Nodo	Cant.	Potencia típica (W)	Horas/día	Energía diaria (Wh)
Mimosa C5c (con plato 35 dBi)	4	9,2	24	884
LiteBeam 5AC (PtP Machala→Torre central)	2	7,0	24	336
Rocket Prism 5AC Omni	1	9,5	24	228
LiteBeam 5AC (4 piscinas → Rocket Prism)	4	7,0	24	672
Cisco SF200-08 (8 puertos, 1 por piscina)	4	7,0	24	672
Cámara IP con IA (1 por piscina)	4	7,0	24	672
Sensores (3 por piscina → 12 en total)	12	0,5	24	144
Aireadores (módulo de control, 1 por piscina)	4	3,5	6	84
Alimentadores (módulo de control, 1 por piscina)	4	4,5	2	36
Total diario estimado	—	—	—	3.727 Wh 3,73 kWh/día

Preprocesamiento del Conjunto de datos Ambiental

Para simular el monitoreo ambiental, se utilizó un conjunto de datos público que fue sometido a un riguroso proceso de preprocesamiento para garantizar su consistencia y fiabilidad. Los pasos clave incluyeron la unificación de marcas de tiempo, la estandarización de los nombres de las estaciones de monitoreo, la conversión de variables a formato numérico, la imputación de valores faltantes utilizando la mediana por estación, y la eliminación de registros duplicados. El resultado final fue un conjunto de datos limpio y estructurado con 74,745 registros y nueve variables, listo para ser utilizado en el entrenamiento de los modelos de inteligencia artificial (Ver **Tabla 6**).

Tabla 6: Preprocesamiento del conjunto de datos ambiental

Variable	Valores faltantes	Método de corrección	Estado final	% de registros afectados
nitrito_ppm	6	Imputación con mediana por estación	0 faltantes	0,0080 %
ph	2	Imputación con mediana por estación	0 faltantes	0,0027 %
amoníaco_mg_l	0	No requerido	0 faltantes	0,0000 %
temperatura_c	6	Imputación con mediana por estación	0 faltantes	0,0080 %
oxígeno_disuelto_mg_l	10	Imputación con mediana por estación	0 faltantes	0,0134 %
turbidez_ntu	0	No requerido	0 faltantes	0,0000 %
manganeso_mg_l	25	Imputación con mediana por estación	0 faltantes	0,0334 %

En el preprocesamiento se identificaron valores faltantes en nitrato, pH, temperatura, oxígeno disuelto y manganeso, los cuales se corrigieron mediante imputación con la mediana por estación. Amoníaco y turbidez no presentaron vacíos. Tras la corrección, el conjunto de datos quedó completo, con afectación mínima (<0,04 %), asegurando su consistencia para los modelos de IA. El conjunto de datos ambientales integra 74.745 registros distribuidos de forma equilibrada entre las tres estaciones: 31,82 % en la Estación 1 y 34,09 % en las Estaciones 2 y 3, garantizando una base representativa para el análisis (Ver **Tabla 7**).

Tabla 7: Distribución de registros por estación en el conjunto de datos ambiental

Estación	Número de registros	% del total
Estación 1	23,782	31,82 %
Estación 2	25,481	34,09 %
Estación 3	25,482	34,09 %
Total	74,745	100,00 %

El esquema final del conjunto de datos ambiental, conformado por nueve variables con sus respectivas unidades de medida. Incluye identificadores básicos (estación, marca de tiempo) y parámetros fisicoquímicos clave como nitrato, pH, amoníaco, temperatura, oxígeno disuelto,

turbidez y manganeso, expresados en sus unidades estándar. Este esquema garantiza la claridad y consistencia necesarias para el análisis y modelado de datos (Ver **Tabla 8**).

Tabla 8: Esquema final de variables y unidades del conjunto de datos ambiental

Variable	Descripción	Unidad
estacion	Identificador de estación (1–3)	—
marca_tiempo	Fecha y hora del registro	—
nitrito_ppm	Nitrato	ppm
ph	Potencial de hidrógeno	—
amoniacal_mg_l	Amoníaco	mg/L
temperatura_c	Temperatura	°C
oxigeno_disuelto_mg_l	Oxígeno disuelto	mg/L
turbidez_ntu	Turbidez	NTU
manganeso_mg_l	Manganeso	mg/L

Extracción de Características para la Predicción de Hipoxia

Para el entrenamiento del modelo se generó un conjunto de características a partir de los datos obtenidos por los sensores ambientales , en nuestro caso, el conjunto de datos originales crudos. El proceso inició con la creación de la etiqueta binaria hipoxia, asignando el valor 1 cuando el oxígeno disuelto es inferior a 3 mg/L y 0 en caso contrario. Las variables generadas constituyen los predictores de entrada del modelo de aprendizaje automático. Gracias a estas características, el modelo logró identificar variaciones y patrones temporales importantes para anticipar episodios de hipoxia, obteniendo un conjunto de datos finales de aproximadamente 74.000 observaciones y 29 variables derivadas (Ver **Tabla 9**).

Tabla 9: Características para hipoxia

Categoría	Variable derivada	Descripción técnica	Propósito principal
Estadísticos en ventana (1h)	temperatura_c_media_1h, min_1h, max_1h, std_1h	Resumen de tendencia y variabilidad de temperatura en la última hora	Capturar fluctuaciones térmicas locales
	ph_media_1h, min_1h, max_1h, std_1h	Estadísticos de pH en ventanas móviles	Reflejar estabilidad o variación de acidez
	amoniaco_mg_l_media_1h, min_1h, max_1h, std_1h	Dinámica del amoníaco en corto plazo	Relacionar toxicidad con riesgo de hipoxia
	nitrato_ppm_media_1h, min_1h, max_1h, std_1h	Resumen del nitrato en intervalos horarios	Evaluar acumulación de nutrientes
	turbidez_ntu_media_1h, min_1h, max_1h, std_1h	Indicadores de variabilidad en turbidez	Identificar episodios de baja calidad de agua
	manganeso_mg_l_media_1h, min_1h, max_1h, std_1h	Estadísticos de manganeso en la última hora	Evaluar condiciones químicas críticas
Tendencias de oxígeno disuelto	oxigeno_dif_1_prev	Diferencia simple respecto al valor anterior	Medir cambios inmediatos en oxígeno
	oxigeno_pendiente_h_prev	Tasa de variación por hora del DO	Capturar aceleración o descenso de oxígeno
	oxigeno_ewma_1h_prev	Suavizado exponencial móvil del DO	Reflejar tendencia general previa
Codificación temporal	hora_sin, hora_cos	Transformación cíclica de la hora del día	Representar periodicidad circadiana de la hipoxia

Módulos de visión artificial y estimación de biomasa

Para la estimación de biomasa, se utilizaron dos modelos de regresión: el Perceptrón Multicapa (MLP) y un modelo alométrico ($W = a \cdot L^b$). El MLP alcanzó un error absoluto medio (MAE) de

1,8 g y un coeficiente de determinación (R^2) de 0,93, lo que refleja alta precisión en la estimación del peso individual. El modelo alométrico obtuvo un R^2 (log) de 0,95 y un MAE de 2,7 g. Ambos resultaron viables para estimar la biomasa total y calcular la ración de alimento. Se presentan los resultados del MLP aplicado a cinco estanques, con estimaciones de biomasa y raciones cada 8 horas. En total se registraron 170 individuos con una biomasa acumulada de 4,322 g y una ración total de 216 g. Los valores por estanque muestran variaciones moderadas, con coeficientes de variación entre 5,20 % y 11,20 %, lo que refleja una distribución relativamente homogénea en las predicciones del modelo (Ver **Tabla 10**).

Tabla 10: Biomasa y raciones (8 h) por estanque — modelo MLP

Estanque	Nº individuos	Biomasa (g)	Longitud media (cm)	Ración 8h (g)	Coeficiente de variación (%)
DB1	22	701	12,06	35	7,91
DB2	58	1747	11,17	87	11,20
DB3	50	1513	11,25	76	6,99
DB4	20	178	8,21	9	5,61
DB5	20	183	8,27	9	5,20
Total	170	4322	-	216	nan

Nota: Los valores *nan* reflejan que esas columnas no aplican en el total, pues no se pueden promediar de manera directa.

Resultados del modelo alométrico por estanque: se registran 170 individuos, con biomasa total de 4,298 g y ración total de 215 g cada 8 horas. Los coeficientes de variación oscilan entre 5,20 % y 11,20 %, indicando variabilidad moderada y consistente entre estanques. En comparación con el MLP, el alométrico entrega biomasa y ración totales muy cercanas (4,298 g vs. 4,322 g; 215 g vs. 216 g), lo que sugiere concordancia entre métodos para la planificación de alimentación (Ver **Tabla 11**).

Tabla 11: Biomasa y ración (8 h) por estanque — modelo alométrico

Estanque	Nº individuos	Biomasa (g)	Longitud media (cm)	Ración 8h (g)	Coeficiente de variación (%)
DB1	22	806	12,06	40	7,91
DB2	58	1660	11,17	83	11,20
DB3	50	1437	11,25	72	6,99
DB4	20	195	8,21	10	5,61
DB5	20	200	8,27	10	5,20
Total	170	4298	nan	215	nan

Nota: Los valores *nan* reflejan que esas columnas no aplican en el total, pues no se pueden promediar de manera directa.

Rendimiento del modelo de IA (precisión, recall)

El clasificador Random Forest para la predicción de hipoxia mostró un rendimiento excelente. Con precisión de 0,988 para la clase "Hipoxia", identifica la mayoría de sus alertas. El valor de recall de 0,938 indica que detecta la mayoría de los eventos de hipoxia reales. La exactitud global de 0,998 y el área bajo la curva (AUC) de 0,994 confirman que el modelo es fiable y adecuado para la activación de alertas y aireadores de manera preventiva (Ver **Tabla 12**).

Tabla 12: Métricas por clase en prueba Random Forest

Clase	Precisión	Recall (sensibilidad)	F1(equilibrio precisión– recall)	Soporte
No hipoxia (0)	0,998	1,000	0,999	29 001
Hipoxia (1)	0,988	0,938	0,963	890
Exactitud (global)	0,998			29 891
AUC (ROC)	0,994			

El desempeño del modelo alométrico en la estimación de biomasa por lote. Los errores absolutos fueron bajos (MAE = 23 g, MAPE = 2,06 %, RMSE = 32 g), lo que indica gran precisión en las predicciones. El R^2 de 0,997 refleja un ajuste global muy alto del modelo a los datos observados. El sesgo negativo (–23 g) señala una ligera tendencia a subestimar la biomasa, aunque sin comprometer la confiabilidad general del método (Ver

Tabla 13).

Tabla 13: Desempeño del modelo alométrico en la estimación de biomasa por lote

Métrica	Valor	Interpretación breve
MAE biomasa (g)	23	Error promedio por lote
MAPE biomasa (%)	2,06	Error relativo medio
RMSE biomasa (g)	32	Dispersión típica del error
R² biomasa	0,997	Ajuste global muy alto
Sesgo biomasa (g)	-23	Ligera subestimación

El rendimiento del modelo MLP en la estimación de biomasa se evaluó mediante validación cruzada, utilizando métricas de error y ajuste estadístico. Los valores obtenidos se resumen en la (Ver Tabla 14).

Tabla 14: Rendimiento del modelo MLP en la estimación de biomasa por lote

Métrica	Valor
Error Medio Absoluto (MAE, g)	1,80 g
Coefficiente de Determinación (R²)	0,936

Comparación con sistemas tradicionales de monitoreo

El sistema IoT–IA propuesto supera al monitoreo manual tradicional en múltiples aspectos, destacando su capacidad para la medición continua, la detección temprana y la automatización. El sistema reduce la latencia de detección, minimiza el riesgo de pasar por alto eventos críticos y permite una planificación más precisa de las raciones de alimento (Ver

Tabla 15).

Tabla 15: Comparación entre el sistema IoT–IA propuesto y el monitoreo tradicional

Criterio	Sistema IoT–IA (este trabajo)	Sistema tradicional (manual)
Frecuencia de medición	Continua/alta	Puntual y esporádica (1–3 veces/día)

Latencia de detección	Baja	Alta
Cobertura espacial	Multiestación simultánea	Muestreo por rondas
Criterio de alarma	Clasificación IA + umbrales dinámicos	Umbral fijo
Falsas alarmas	Bajas	Variables
Fugas/no detecciones (FN)	Reducidas	Probables si el evento ocurre fuera del horario de muestreo
Automatización	Integrable con actuadores	Activación manual/reactiva
Estimación de biomasa	Automática y continua	Manual, por muestreo y pesaje
Planificación de raciones	Cálculo automático ajustado a biomasa	Basado en tablas generales y criterio del operador
Trazabilidad	Total	Limitada
Operación nocturna	Sin guardia presencial	Requiere turnos o visitas
Escalabilidad	Alta	Baja/media
Costo operativo	Optimizable	Mayor en mano de obra
Mantenimiento	Calibración periódica	Bajo tecnológico; alto en tiempo del personal
Resiliencia	Depende de backhaul/energía	Resiliente a fallas tecnológicas

El enfoque propuesto se destaca por su medición continua, su baja latencia de detección, la cobertura simultánea en varias estaciones y la incorporación de alarmas inteligentes basadas en IA, lo que reduce falsas alertas como las omisiones. La arquitectura diseñada permite anticipar los episodios de hipoxia, calcular y programar de forma automática las raciones de alimento y la estimación precisa de la biomasa de los camarones. El sistema IoT-IA demuestra mejoras significativas respecto al sistema manual, que se basa en mediciones irregulares y poco confiables, utiliza umbrales fijos y responde únicamente cuando el problema ya se ha manifestado, disminuyendo así su eficacia frente al sistema propuesto. El sistema IoT-IA logra un funcionamiento más eficiente, reduce los costos de operación y puede ampliarse con mayor facilidad. Los resultados obtenidos son claros, aunque el buen desempeño del sistema depende de la energía y la conexión disponibles. El proyecto resulta viable y aporta grandes beneficios para las

empresas camaroneras que trabajan en áreas rurales. La utilización de energías renovables es una buena opción ya que la red funciona de manera estable y requiere poca energía. También, los modelos de inteligencia artificial permiten predecir y automatizar procesos en lugares con poca infraestructura, lo que contribuye a modernizar las camaroneras como la de Isla Manglecito.

Discusión

Los resultados de la simulación demuestran la viabilidad técnica de implementar una arquitectura IoT-IA para la gestión de camaroneras en zonas remotas como la Isla Manglecito, respondiendo afirmativamente a la pregunta de investigación. Los resultados demuestran que la propuesta funciona bien. La simulación de conectividad a 90 km resultó ser muy buena, con valores que superaban los 36 dB, latencias entre 18 y 25 ms, y una red interna que funcionó bien sin pérdida de paquetes. Gracias a que los modelos de inteligencia artificial funcionan excelente, el sistema se vuelve más estable y confiable. El Random Forest logró una precisión de 0,988 y un recall de 0,938, a la vez que el Perceptrón Multicapa ($R^2 > 0,93$) determinó la biomasa con mucha precisión. En resumen, estas métricas demuestran de manera definitiva que es posible superar los obstáculos de conectividad para avanzar hacia una administración preventiva y automatizada.

Este trabajo, en comparación con los estudios anteriores, muestra claramente su contribución al cultivo de camarón automatizado. Por ejemplo, estudios como el de Ahmed et al. (2024), enfocado en predecir la productividad en Bangladesh, o el de Chiu et al. (2022) que exploró sensores en entornos controlados, demostró la utilidad en la acuicultura. Sin embargo, estas investigaciones se basaron en redes ya consolidadas o se limitaron a pruebas de menor escala. Nuestro trabajo da un salto importante al abordar la conectividad en zonas rurales aisladas sin infraestructura tecnológica. La propuesta presentada aquí incluye redes internas, protocolos seguros para la transmisión y conexiones inalámbricas de largo alcance, a diferencia de las propuestas anteriores. Este diseño de red permite que se implemente directamente en situaciones con una infraestructura limitada. Por consiguiente, este estudio se sitúa entre los primeros en Ecuador que incorporan la producción acuícola rural y definen un modelo que tiene el potencial de ser reproducido a lo largo y ancho de la costa ecuatoriana.

Los resultados que hemos obtenido tienen un impacto significativo en la producción de camarón en esta zona, especialmente en los pequeños y medianos productores. Si se anticipa la hipoxia con una hora de antelación y se establecen las cantidad de alimento que debe suministrar cada ocho

horas, no solo se reducen los costos y la mortalidad; también mejora la competitividad del cultivo de camarones.

No obstante, admitimos las restricciones propias de este trabajo. La dificultad principal es que las pruebas se ejecutaron en contextos de simulación y utilizando datos públicos. Por este motivo, no logramos incluir totalmente las condiciones reales y variables de la Isla Manglecito, como su clima, posibles interferencias, la geografía o los rasgos distintivos de la dinámica productiva local. Además, la utilización de datos provenientes de fuentes externas disminuye la habilidad de los modelos para mostrar con precisión los patrones singulares y propios de las camaroneras en Ecuador. Por lo tanto, es esencial considerar estos elementos al analizar los resultados y planear su aplicación en la práctica.

CONCLUSIONES

Esta investigación tuvo como objetivo diseñar y simular una arquitectura IoT-IA para el monitoreo ambiental y la automatización de camaroneras en la Isla Manglecito, superando las limitaciones de conectividad en zonas rurales aisladas. Los resultados alcanzados confirman contundentemente este propósito. Validamos con éxito un enlace inalámbrico de 90 km, el cual presentó márgenes de diseño superiores y latencias bajas (18-25 ms). Asimismo, los modelos de Inteligencia Artificial han mostrado un rendimiento elevado (con una precisión de 0,988 y un recall de 0,938 en la predicción de hipoxia; con un R^2 superior a 0,93 en biomasa). Los sistemas fotovoltaicos demostraron ser compatibles con el consumo energético estimado de 3,73 kWh por día.

Estos estudios no solo validan la viabilidad técnica del sistema, sino que también ofrecen una alternativa adecuada para zonas rurales que carecen de infraestructura. Esto es un aporte importante, ya que la mayoría de las investigaciones anteriores se han realizado en laboratorios, en entornos con un desarrollo tecnológico más avanzado.

Sin embargo, es necesario señalar que estos resultados provienen de simulaciones y de datos públicos y que, por ello, los datos aún no están validados directamente en la zona de estudio. Por lo tanto, proponemos avanzar hacia prototipos piloto, recolectar datos locales para reentrenar los modelos e incluir fuentes de energía sustentables que incorporen almacenamiento inteligente. En conclusión, la arquitectura propuesta es una opción factible y efectiva para modernizar los criaderos de camarones aislados, optimizando así su desempeño y asegurando que la acuicultura sea más digital y sostenible.

References

- Ahmed, F., Bijoy, M. H. I., Hemal, H. R., & Noori, S. R. H. (2024b). Smart aquaculture analytics: Enhancing shrimp farming in Bangladesh through real-time IoT monitoring and predictive machine learning analysis. *Heliyon*, 10(17). <https://doi.org/10.1016/j.heliyon.2024.e37330>
- Cai, H., Zhang, C., Xu, J., Wang, F., Xiao, L., Huang, S., & Zhang, Y. (2023b). Water Quality Prediction Based on the KF-LSTM Encoder-Decoder Network: A Case Study with Missing Data Collection. *Water (Switzerland)*, 15(14). <https://doi.org/10.3390/w15142542>
- Castellanos, G., De Beelde, B., Plets, D., Martens, L., Joseph, W., & Deruyck, M. (2023). Evaluating 60 GHz FWA Deployments for Urban and Rural Environments in Belgium. *Sensors*, 23(3). <https://doi.org/10.3390/s23031056>
- Chiu, M. C., Yan, W. M., Bhat, S. A., & Huang, N. F. (2022a). Development of smart aquaculture farm management system using IoT and AI-based surrogate models. *Journal of Agriculture and Food Research*, 9. <https://doi.org/10.1016/j.jafr.2022.100357>
- Correia, B., Pacheco, O., Rocha, R. J. M., & Correia, P. L. (2025a). Image-Based Shrimp Aquaculture Monitoring. *Sensors*, 25(1). <https://doi.org/10.3390/s25010248>
- García Sánchez, S., Juárez Agis, A., Olivier Salome, B., Rivas González, M., & Zeferino Torres, J. (2018). [ENVIRONMENTAL PHYSICOCHEMICAL VARIABLES THAT AFFECT THE SHRIMP FARMING *Litopenaeus vannamei*, COYUCA DE BENÍTEZ, GUERRERO, MEXICO]. In *Revista Mexicana de Agroecosistemas* (Vol. 5, Issue 2).
- Gavriilidis, N. O., Halkidis, S. T., & Petridou, S. (2025). Empirical Evaluation of TLS-Enhanced MQTT on IoT Devices for V2X Use Cases. *Applied Sciences*, 15(15), 8398. <https://doi.org/10.3390/app15158398>
- Huang, Y. P., & Khabusi, S. P. (2025a). Artificial Intelligence of Things (AIoT) Advances in Aquaculture: A Review. In *Processes* (Vol. 13, Issue 1). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/pr13010073>
- Kanwal, S., Abdullah, M., Kumar, S., Arshad, S., Shahroz, M., Zhang, D., & Kumar, D. (2024a). An Optimal Internet of Things-Driven Intelligent Decision-Making System for Real-Time Fishpond Water Quality Monitoring and Species Survival. *Sensors*, 24(23). <https://doi.org/10.3390/s24237842>
- Olanubi, O. O., Akano, T. T., & Asaolu, O. S. (2024a). Design and development of an IoT-based intelligent water quality management system for aquaculture. *Journal of Electrical Systems and Information Technology*, 11(1). <https://doi.org/10.1186/s43067-024-00139-z>

- Pereira Pontón, J. M., Ojeda, V., Asanza, V., Lorente-Leyva, L. L., Peluffo-Ordóñez, D. H., Superior, E., & Del Litoral, P. (2023). Design and Implementation of an IoT Control and Monitoring System for the Optimization of Shrimp Pools using LoRa Technology. In IJACSA) International Journal of Advanced Computer Science and Applications (Vol. 14, Issue 8). www.ijacsa.thesai.org
- Sánchez-Ulloa, A., & Palma-Macías, G. (2023). Análisis de las exportaciones de la industria camaronera en la provincia de El Oro, período 2020 – 2021. 593 Digital Publisher CEIT, 8(3), 110–118. <https://doi.org/10.33386/593dp.2023.3.1654>
- Shabeer, M., Rafi, M., Behjati, M., & Rafsanjani, A. S. (2025). Reliable and Cost-Efficient IoT Connectivity for Smart Agriculture: A Comparative Study of LPWAN, 5G, and Hybrid Connectivity Models. <https://arxiv.org/pdf/2503.11162>
- Shete, R. P., Bongale, A. M., & Dharrao, D. (2024). IoT-enabled effective real-time water quality monitoring method for aquaculture. MethodsX, 13. <https://doi.org/10.1016/j.mex.2024.102906>
- Singh, K., Yadav, M., Singh, Y., Barak, D., Saini, A., & Moreira, F. (2024). Reliability on the Internet of Things with designing approach for exploratory analysis. Frontiers in Computer Science, 6. <https://doi.org/10.3389/fcomp.2024.1382347>
- Singh, M., Sahoo, K. S., & Gandomi, A. H. (2024). An Intelligent-IoT-Based Data Analytics for Freshwater Recirculating Aquaculture System. IEEE Internet of Things Journal, 11(3), 4206–4217. <https://doi.org/10.1109/JIOT.2023.3298844>

© 2025 por los autores. Este artículo es de acceso abierto y distribuido según los términos y condiciones de la licencia Creative Commons Atribución-NoComercial-CompartirIgual 4.0 Internacional (CC BY-NC-SA 4.0) (<https://creativecommons.org/licenses/by-nc-sa/4.0/>).