

**Implementación de AquaNutri AI Móvil: Herramienta de Apoyo Inteligente para la
Toma de Decisiones y la Mejora de la Productividad en Sistemas Acuícolas Biofloc y
RAS en Colombia**

Juan Carlos Cerón Lombana

Universidad Santo Tomás

Facultad de Administración de Empresas

Bogotá, D.C.

2025

**Implementación de AquaNutri AI Móvil: Herramienta de Apoyo Inteligente para la
Toma de Decisiones y la Mejora de la Productividad en Sistemas Acuícolas Biofloc y
RAS en Colombia**

Juan Carlos Cerón Lombana

**Trabajo de grado para optar el título de Especialista en Gerencia de Empresas
Agropecuarias**

Dirigido por:

Erika Marcela Moncaleano Gómez

Zootecnista, MSc. en Ciencias Ambientales

Universidad Santo Tomás

Facultad de Administración de Empresas

Bogotá, D.C.

2025

Contenido

Lista de Apéndices	7
Resumen.....	8
Abstract	9
Glosario.....	10
Introducción	15
1. Implementación de AquaNutri AI Móvil	16
1.1 Planteamiento del problema.....	16
1.2 Justificación.....	17
1.3 Objetivos	18
1.3.1 Objetivo general	18
1.3.2 Objetivos específicos.....	19
2. Marco referencial	19
2.1 Marco teórico	19
2.2 Estado del Arte	38
2.3 Marco conceptual	47
2.4 Marco legal.....	49
Normativa en Acuicultura	49
Normativa sobre Protección de Datos Personales	50
Normativa sobre Derechos de Autor y Software.....	51
Normativa y Política sobre Inteligencia Artificial.....	51
3. Marco Metodológico.....	52

3.1 Enfoque metodológico	52
3.2 Población y muestra	53
3.3 Fases de Desarrollo e Implementación del Sistema AquaNutri AI Móvil.....	54
Fase 1: Desarrollo e Implementación de la Interfaz Móvil	55
Fase 2: Implementación del Sistema de Alertas Automáticas.....	56
Fase 3: Desarrollo del Módulo de Análisis Correlacional y Predictivo	57
Fase 4: Validación Integral del Sistema	59
3.4 Técnicas e instrumentos de recolección de datos.....	60
3.5 Procesamiento y análisis de datos	61
3.6 Validación del sistema	61
3.7 Hipótesis.....	62
3.8 Variables del estudio	62
3.9 Validación Experimental de la Hipótesis	63
3.9.1 Diseño Experimental de Validación.....	63
3.9.2 Indicadores de Validación	63
3.9.3 Herramientas de Análisis.....	64
3.9.4 Criterios de Aceptación de la Hipótesis	64
4. Cronograma de Actividades del Proyecto.....	65
5. Presupuesto Estimado del Proyecto	67
6. Resultados Esperados.....	70
6.1 Modelo de Negocio Propuesto	71
6.2 Propuesta de Valor	71
6.3 Presupuesto del Modelo de Negocio (MVP funcional)	72

AQUANUTRI AI MÓVIL: APOYO INTELIGENTE PARA SISTEMAS ACUÍCOLAS BIOFLOC Y RAS	5
6.4 Esquema de Ingresos Proyectado (Escalamiento).....	73
6.5 Estrategia de Financiación del Proyecto en Colombia.....	73
7. Impacto del Proyecto AquaNutri AI Móvil	75
7.1 Impacto técnico y tecnológico.....	75
7.2 Impacto económico	76
7.3 Impacto ambiental	76
7.4 Impacto social	76
7.5 Impacto académico y científico.....	76
7.6 Impacto institucional y normativo.....	77
7.7 Estrategia de Adopción y Capacitación del Sistema AquaNutri AI Móvil.....	77
Enfoque Participativo desde el Diseño	77
Capacitación Inicial Personalizada	78
Soporte Técnico Acompañado (Modelo A+P)	78
Mejoras Iterativas con Base en el Usuario	78
Estrategia de Incentivos para la Adopción	78
Resultados esperados	79
Generación de Comunidades Piloto	80
Inclusión de Jóvenes Rurales como Embajadores Tecnológicos	80
Escalabilidad del Sistema AquaNutri AI Móvil	81
8. Limitaciones y Delimitaciones Tecnológicas del Proyecto	82
9. Conclusiones y Recomendaciones	84
9.1 Conclusiones	84
9.2 Recomendaciones	87

Referencias.....	89
Apéndices.....	95

Lista de tablas

Tabla 1 <i>Parámetros físico - químicos a tener en cuenta en el proyecto AquaNutri AI Móvil.....</i>	36
Tabla 2 <i>Parámetros fisicoquímicos diferenciados para sistemas RAS y Biofloc</i>	45
Tabla 3 <i>Diseño Experimental de Validación</i>	63
Tabla 4 <i>Indicadores de Validación</i>	64
Tabla 5 <i>Cronograma de Actividades</i>	65
Tabla 6 <i>Presupuesto Estimado del Proyecto AquaNutri AI Móvil</i>	67
Tabla 7 <i>Propuesta de Valor</i>	72
Tabla 8 <i>Presupuesto Estimado para Desarrollo de MVP AquaNutri AI Móvil.....</i>	72
Tabla 9 <i>Esquema de Ingresos Esperados</i>	73
Tabla 10 <i>Resumen de la Estrategia de Financiación</i>	75
Tabla 11 <i>Comparativo IoT Vs Sistema propuesto</i>	82

Lista de figuras

Figura 1 <i>Estrategia de Adopción y Capacitación – AquaNutri AI Móvil.....</i>	79
Figura 2 <i>Comparativo Técnico Operativo: Sistema con vs sin IoT.....</i>	83

Lista de Apéndices

Apéndice A. <i>Formato de Diagnóstico Inicial (Pretest)</i>	95
Apéndice B. <i>Encuesta de Evaluación para Productores Piloto</i>	97

Resumen

La acuicultura intensiva en Colombia, especialmente bajo tecnologías Biofloc (BFT) y sistemas de recirculación acuícola (RAS), enfrenta limitaciones en la gestión de la calidad del agua debido a la dependencia de mediciones manuales y decisiones reactivas que aumentan el riesgo de mortalidad, baja eficiencia alimenticia y altos costos de producción. Desarrollar e implementar la plataforma *AquaNutri AI Móvil* como herramienta de apoyo inteligente para el monitoreo, predicción y control de parámetros fisicoquímicos críticos, con el fin de mejorar la productividad y sostenibilidad de los sistemas acuícolas. Se adoptó un enfoque cuantitativo, aplicado y experimental, estructurado en cuatro fases: diseño de interfaz móvil, implementación de un sistema de alertas automáticas, integración de modelos de análisis correlacional y predictivo mediante inteligencia artificial, y validación integral en campo con mediciones de mortalidad, consumo energético, factor de conversión alimenticia (FCR) y percepción del usuario a través de escala Likert. El prototipo por desarrollar permitirá capturar datos en tiempo real, emitir alertas preventivas y generar predicciones útiles para la toma de decisiones, proyectando mejoras del 10–20% en supervivencia, reducción del 8–10% en consumo energético y optimización del FCR en un 5–8%. Los hallazgos evidencian que AquaNutri AI Móvil contribuirá a transformar la acuicultura tradicional en un proceso *data-driven*, democratizando el acceso a la tecnología para pequeños y medianos productores, alineándose con el Plan Nacional de Desarrollo de la Acuicultura Sostenible (PlaNDAS) y el CONPES 4144 de 2025, y consolidándose como una propuesta viable y escalable hacia la acuicultura inteligente en Colombia.

Palabras clave: acuicultura sostenible, biofloc, sistemas ras, internet de las cosas, inteligencia artificial

Abstract

Intensive aquaculture in Colombia, especially under Biofloc Technology (BFT) and Recirculating Aquaculture Systems (RAS), faces limitations in water quality management due to reliance on manual measurements and reactive decisions that increase the risk of mortality, low feed efficiency, and high production costs. The aim is to develop and implement the AquaNutri AI Mobile platform as an intelligent support tool for monitoring, prediction, and control of critical physicochemical parameters, to improve the productivity and sustainability of aquaculture systems. A quantitative, applied, and experimental approach was adopted, structured in four phases: design of a mobile interface, implementation of an automatic alert system, integration of correlational and predictive analysis models through artificial intelligence, and comprehensive field validation with measurements of mortality, energy consumption, feed conversion ratio (FCR), and user perception using the Likert scale. The prototype to be developed will enable real-time data capture, issue preventive alerts, and generate useful predictions for decision-making, projecting improvements of 10–20% in survival, an 8–10% reduction in energy consumption, and a 5–8% optimization of FCR. The findings demonstrate that AquaNutri AI Mobile will contribute to transforming traditional aquaculture into a data-driven process, democratizing access to technology for small and medium producers, aligning with the National Plan for the Development of Sustainable Aquaculture (PlaNDAS) and CONPES 4144 of 2025, and consolidating itself as a viable and scalable proposal towards smart aquaculture in Colombia.

Keywords: sustainable aquaculture, biofloc, ras systems, internet of things, artificial intelligence

Glosario

AIoT (Inteligencia Artificial de las Cosas): Integración del análisis de IA en los dispositivos IoT para recopilar, transferir y procesar datos en tiempo real, lo que permite el monitoreo remoto y el control automático de equipos (Chiu y otros, 2022).

Alertas Remotas: Sistema de mensajes de alerta fuera de rango basado en sensores para el operador, que funciona junto con el control automático para garantizar la estabilidad del sistema, lo que hace posible operar el sistema sin monitoreo humano continuo (Chiu y otros, 2022).

Aprendizaje Automático (ML): Un grupo de algoritmos, es decir, redes neuronales o Random Forest, que permiten reconocer patrones no lineales en los datos de calidad del agua para estimar tendencias futuras o anomalías (Shin y otros, 2025).

BFT: Es una tecnología de acuicultura amigable con el medio ambiente para estimular la producción de flóculos microbianos que proporcionan mejor calidad de agua, reciclan nutrientes y pueden usarse como alimento adicional durante el período de cultivo para peces (Manan y otros, 2024).

Curtosis y Asimetría de Datos: La forma de la distribución de datos de DO se describe mediante características estadísticas; y los valores altos o bajos de curtosis y asimetría pueden usarse para sacar conclusiones sobre la forma de la distribución de datos, ya que las dos características pueden identificar la existencia de picos extremos que requieren técnicas avanzadas de imputación (Shin y otros, 2025).

Dinámica Bacteriana: Composición y evolución de bacterias en los flóculos; la diversidad (Proteobacteria, Bacillus spp.) afecta la resistencia a patógenos y la robustez ambiental del sistema (Manan y otros, 2024).

Diseño UI/UX: (Interfaz de Usuario / Experiencia de Usuario) - UI/UX es un campo altamente dirigido y definido que trabaja para maximizar la experiencia del usuario al interactuar con un producto digital (aplicación, aplicación móvil, etc.). Este diseño basado en la experiencia del usuario y la facilidad de uso son fundamentales para el interés y la aceptación de la utilización móvil en manos de los productores rurales (Rashid y otros, 2021).

DO (Oxígeno Disuelto): Oxígeno molecular (O_2) presente en el agua, que es vital para la respiración de los organismos acuáticos. Su monitoreo en tiempo real en línea con sensores IoT se considera importante para el control de la aireación y la prevención del estrés en los peces (Shin y otros, 2025).

DO: La concentración de oxígeno en el agua; su monitoreo en tiempo real es importante para evitar fenómenos de hipoxia/exceso de oxígeno, que tienen un efecto perjudicial en el crecimiento y bienestar de los organismos (Manan y otros, 2024).

Error Absoluto Medio (MAE): Medida del error absoluto medio, la principal representación de la precisión de ES-CNN en entrenamiento y prueba (Majid & Setiawan, 2024).

Error Cuadrático Medio (RMSE) y Error Porcentual Absoluto Medio (MAPE): Medida de la desviación promedio de los modelos de los valores verdaderos en el modelo calibrado de VIH/SIDA y sus parámetros explicados que indican el tamaño y la proporción del error respectivamente (Majid & Setiawan, 2024).

ES-CNN (Ensemble Shuffling-CNN): Un modelo de arquitectura mixta que utiliza el barajado de entradas para una CNN para crear estabilidad y prevenir el sobreajuste en la predicción de los parámetros de acuicultura (Majid & Setiawan, 2024).

F-score y Precisión: Medidas del rendimiento del clasificador en términos de precisión y exactitud, respectivamente (Kaur y otros, 2023).

Generalización del Modelo: La capacidad de un modelo de ML entrenado en un entorno para no solo ser capaz de adaptarse a otros sistemas de acuicultura con diferente calidad de agua, sino fundamentalmente importante para la reproducción de sistemas inteligentes en Biofloc y RAS (Shin y otros, 2025).

GRNN (Red Neuronal de Regresión General): Un modelo de red neuronal que proporciona predicciones continuas con bajas variaciones entre las fases de entrenamiento y prueba (Chen y otros, 2024).

Imputación de Datos: Técnicas de ML para predecir valores faltantes en series temporales de calidad del agua que permiten la retención de datos evitando tomar decisiones basadas en informes con información insuficiente (Shin y otros, 2025).

Mantenimiento Predictivo: Es una estrategia de control proactiva que utiliza datos reales actuales (sensores de DO, TSS y amonio) y algoritmos de IA para predecir las fallas de las bombas, aireadores y filtros y prevenir el apagado del sistema, lo que representa una amenaza para el sistema (Manan y otros, 2024).

Mecanismo de Aireación y Agitación: Se utiliza para la acción dinámica de mantener el flóculo formado en suspensión y la buena transferencia de masa del oxígeno disuelto en el cuerpo de agua, la falta de aireación causa elevación de sólidos y un pico de amonio (Manan y otros, 2024).

NO₂-N Nitrógeno Nitrito: Producto intermedio del nitrógeno inorgánico, su sobreacumulación impide la capacidad de la sangre de los peces para transportar oxígeno (Chen y otros, 2024).

NodeMCU ESP8266: Un microcontrolador y módulo WIFI, que se utilizó como nodo de detección para enviar datos de calidad del agua recopilados a la nube (Majid & Setiawan, 2024).

Optimización Bayesiana: Una técnica automática de ajuste de hiperparámetros que aprovecha la construcción de modelos basados en probabilidad para maximizar el rendimiento predictivo utilizando un menor número de iteraciones; se puede usar para pronosticar el crecimiento y correlacionar DO, temperatura y turbidez (Chiu y otros, 2022).

Relación C:N: La relación molar que se aplica para equilibrar las fuentes de carbono y eliminar el amonio, el valor alto de 12:1-15:1 promueve el crecimiento de bacterias heterotróficas y aumenta la productividad del resultado (Manan y otros, 2024).

ReliefF: Una técnica de selección de características que calcula la relevancia de los atributos calculando la diferencia de instancias de diferentes clases que están cerca unas de otras (Kaur y otros, 2023).

SHAP (Explicaciones Aditivas de Shapley): Un método de interpretabilidad para atribuir a cada variable de entrada un valor de contribución en la predicción de un modelo de IA; en acuicultura inteligente, se puede usar para revelar qué sensores (como turbidez, alimentación, etc.) impulsan más el rendimiento del estanque (Chiu y otros, 2022).

Sensores IoT: Equipos conectados de forma inalámbrica que recopilan datos en tiempo real relacionados con las propiedades fisicoquímicas del agua (DO, pH, temperatura y turbidez) y los envían a plataformas de análisis (Shin y otros, 2025).

Sistemas de Acuicultura de Recirculación (RAS): Sistemas de producción acuícola con agua que se reutiliza a través de sistemas de biofiltración y mecánicos, proporcionando un control preciso de la calidad del agua y reduciendo el uso de agua (Rajan y otros, 2023).

Sólidos Suspendidos Totales (TSS): Sus niveles muestran la concentración de flóculos en el agua; un TSS excesivo es el indicador para un drenaje o intercambio de agua para evitar desequilibrios de calidad (Manan y otros, 2024).

Sobreajuste: Es la condición que ocurre cuando el modelo no se generaliza y está demasiado ajustado al conjunto de entrenamiento; ES-CNN exhibiendo su robustez, no se registró una diferencia significativa en la tasa de error entre el resultado de entrenamiento y prueba (Majid & Setiawan, 2024).

TAN: Nitrógeno Amoniacal Total, el nivel de concentración del amonio libre e iónico en el agua, es una medida importante para la toxicidad en RAS (Chen y otros, 2024).

Turbidez (NTU): Un indicador de la concentración de sólidos suspendidos y es un parámetro importante para la predicción de la carga de materia orgánica y la demanda de aireación; se ha utilizado como una variable predictiva de AIoT (Chiu y otros, 2022).

Visión por Computadora: Un campo de la inteligencia artificial que se ocupa de algoritmos (por ejemplo, CNN) para interpretar y comprender imágenes, imágenes de videos y puede detectar objetos en dichas imágenes, videos, por ejemplo, peces en un tanque (Rajan y otros, 2023).

Introducción

La producción acuícola intensiva en Colombia enfrenta grandes desafíos relacionados con el control de la calidad del agua, especialmente en sistemas Biofloc y de recirculación (RAS). Variables como el oxígeno disuelto, el amonio y el pH deben mantenerse dentro de rangos específicos para garantizar la salud y productividad de los cultivos acuáticos (Boyd, 2020) (Granda Jaramillo, 2022) (Hernández, 2020). Sin embargo, la mayoría de los productores, especialmente los pequeños y medianos, no cuentan con herramientas tecnológicas que les permitan monitorear estos parámetros en tiempo real ni anticipar riesgos mediante análisis predictivos, lo cual limita su capacidad de respuesta ante eventos críticos y afecta directamente la sostenibilidad técnica y económica de sus unidades productivas (Chiu y otros, 2022) (Majid & Setiawan, 2024) (Kaur y otros, 2023).

Frente a esta necesidad, el presente proyecto propone el desarrollo de una plataforma móvil inteligente denominada AquaNutri AI Móvil, que permita capturar y almacenar datos fisicoquímicos y zootécnicos digitados por el productor, emitir alertas automáticas ante desviaciones críticas, y aplicar análisis correlacionales y predictivos que optimicen la gestión de la calidad del agua. La plataforma estará diseñada para operar en condiciones reales de campo, adaptándose a los procedimientos e instrumentos con los que cuentan los acuicultores, y facilitará la toma de decisiones basada en evidencia mediante interfaces amigables y visualizaciones prácticas.

La iniciativa se desarrollará en cuatro fases: la creación de la interfaz de captura, la implementación del sistema de alertas, el diseño del módulo analítico predictivo y la validación integral del prototipo. Esta solución tecnológica se alinea con las políticas nacionales de

sostenibilidad acuícola y transformación digital (PlaNDAS y CONPES 4144 de 2025) y busca cerrar la brecha entre el conocimiento técnico y su aplicación práctica en contextos rurales. Además de sus beneficios técnicos y ambientales, AquaNutri AI Móvil fortalecerá la apropiación tecnológica del productor, generará insumos para futuras investigaciones y fomentará la innovación local en el sector agropecuario colombiano.

1. Implementación de AquaNutri AI Móvil

1.1 Planteamiento del problema

La acuicultura intensiva enfrenta desafíos constantes relacionados con la gestión precisa de la calidad del agua, especialmente en sistemas como Biofloc y Recirculación Acuícola (RAS). Parámetros críticos tales como el oxígeno disuelto (DO), compuestos nitrogenados (amonio y nitrito), pH y sólidos suspendidos, entre otros, requieren de un monitoreo continuo debido a su influencia directa sobre la salud, crecimiento y supervivencia de los organismos cultivados (Granda Jaramillo, 2022) (Soto Castro, 2015).

Actualmente, muchos productores manejan estos parámetros de forma manual o semi - automatizada, lo que aumenta el riesgo de errores, retrasa la respuesta ante condiciones críticas y reduce la eficiencia productiva y económica (Chiu y otros, 2022) (Shin y otros, 2025).

La mortalidad en sistemas intensivos de cultivo de tilapia, como Biofloc y RAS, representa una preocupación significativa para la sostenibilidad y rentabilidad. Factores como el estrés por sobrepoblación, la acumulación excesiva de sólidos suspendidos, la mala calidad del agua y la alimentación inadecuada pueden generar mortalidad crónica y reducción del crecimiento (Abid y otros, 2024) (Baena-Navarro y otros, 2025) (Capetillo-Contreras y otros, 2024).

En Biofloc, el exceso de flóculos eleva los requerimientos de oxígeno y energía, lo que incrementa los costos sin necesariamente mejorar el crecimiento de los peces (Manan y otros, 2024) (Gálvez-Cantero y otros, 2022). En RAS, aunque se cuenta con ventajas de bioseguridad y control ambiental, se requiere un manejo riguroso de parámetros que, de no cumplirse, puede desencadenar episodios de mortalidad y pérdidas productivas (Rajan y otros, 2023) (Chen y otros, 2024).

Ante este panorama, se hace necesario desarrollar tecnologías inteligentes accesibles que permitan monitoreo en tiempo real, almacenamiento automático de datos, detección temprana de desviaciones críticas y análisis predictivo y correlacional. De esta manera, los productores podrán tomar decisiones informadas y oportunas, optimizando la gestión integral de sus sistemas acuícolas (Majid & Setiawan, 2024).

1.2 Justificación

El control eficiente y oportuno de parámetros fisicoquímicos y zootécnicos es esencial en la acuicultura intensiva, particularmente en sistemas Biofloc y RAS, donde variables como el oxígeno disuelto (DO) influyen directamente en la supervivencia, crecimiento y rendimiento productivo de las especies cultivadas. Investigaciones recientes evidencian que la ausencia de sistemas automatizados conduce a pérdidas significativas de productividad debido a condiciones subóptimas, mortalidad masiva, consumo excesivo de energía y altos costos operativos (Abid y otros, 2024; Baena-Navarro y otros, 2025; Capetillo-Contreras y otros, 2024).

La implementación de inteligencia artificial (IA) y sensores IoT constituye una alternativa innovadora para enfrentar estos retos. Estos sistemas permiten la recolección automática y en tiempo real de parámetros críticos, al tiempo que aplican análisis predictivos avanzados capaces

de anticipar situaciones adversas, reduciendo los riesgos operativos y ambientales (Chiu y otros, 2022; Majid & Setiawan, 2024).

La plataforma propuesta, AquaNutri AI Móvil, integrará estas tecnologías para capturar, almacenar y analizar continuamente los datos recolectados, emitiendo alertas inmediatas ante desviaciones críticas y ofreciendo recomendaciones basadas en análisis correlacionales y predictivos. Con ello, se promueven mejoras sustanciales en la eficiencia productiva, optimizando el factor de conversión alimenticia (FCR) y otros parámetros, disminuyendo el consumo energético y reduciendo las pérdidas económicas asociadas a condiciones ambientales desfavorables (Rajan y otros, 2023; Shin y otros, 2025).

Desde el ámbito ambiental, la propuesta contribuirá a una acuicultura más limpia y sostenible, disminuyendo la emisión de desechos nitrogenados y optimizando el uso de energía (Manan y otros, 2024). En lo social y tecnológico, brindará acceso a herramientas de alto nivel a pequeños y medianos productores mediante una interfaz móvil intuitiva y accesible, fortaleciendo la transferencia tecnológica y la competitividad del sector acuícola colombiano.

Finalmente, AquaNutri AI Móvil se articula con el Plan Nacional para el Desarrollo de la Acuicultura Sostenible (PlanNDAS) y la Política Nacional de Inteligencia Artificial (CONPES 4144 de 2025), consolidando su relevancia estratégica e institucional para el desarrollo sostenible y competitivo del sector acuícola nacional.

1.3 Objetivos

1.3.1 Objetivo general

Desarrollar una plataforma inteligente de monitoreo y control para sistemas Biofloc y/o RAS, con interfaz móvil que capture y almacene en tiempo real parámetros fisicoquímicos y

zootécnicos, que permitan análisis crítico, conductual y predictivo hacia la optimización de la calidad del agua.

1.3.2 Objetivos específicos

- Implementar una interfaz móvil que permita al productor capturar y almacenar en tiempo real parámetros fisicoquímicos y zootécnicos de los sistemas Biofloc y/o RAS.
- Diseñar un sistema de alertas automáticas que notifique de inmediato las desviaciones críticas en los rangos óptimos de calidad del agua.
- Desarrollar módulos de análisis correlacional y predictivo que generen indicadores de calidad y recomendaciones para optimizar el manejo del cultivo.

2. Marco referencial

2.1 Marco teórico

Tanto los sistemas de acuicultura Biofloc como RAS deben controlar de manera continua y precisa los parámetros como el oxígeno disuelto (DO), el pH, compuestos nitrogenados y los sólidos suspendidos, que son importantes para la salud y el crecimiento óptimo de las especies cultivadas. Se han desarrollado tecnologías inteligentes que combinan sensores IoT y aprendizaje automático (ML) para la recolección y procesamiento en tiempo real de datos de calidad del agua, con el fin de abordar las limitaciones de los métodos de muestreo manuales, costosos y propensos a errores (Shin y otros, 2025).

De hecho, es particularmente importante manejar los puntos de datos faltantes reales a través de modelos de ML cuando se trata de una parte de la operación regular, como el control continuo de la aireación: la falta de datos de DO puede llevar a una concentración de oxígeno

ineficiente, tanto al retrasar el crecimiento de los peces como al favorecer el brote de enfermedades (Shin y otros, 2025).

Además, los modelos de ML representan las relaciones no lineales y la alta variabilidad de cobertura de las series temporales ambientales y demuestran ser una buena alternativa a los métodos estadísticos simples para imputar datos de series temporales en entornos de acuicultura (Shin y otros, 2025).

Como tal, se construye un sistema inteligente adaptable impulsado por IA e IoT, para facilitar el control automático del suministro de oxígeno y otras funciones vitales, con alta fiabilidad de datos y optimización de la calidad del agua.

Los sistemas de recirculación acuícola (RAS) representan una plataforma ideal para la integración de tecnologías inteligentes debido a su alto grado de control ambiental, uso eficiente del agua y mayores niveles de bioseguridad (Rajan y otros, 2023). En este contexto, la implementación de sensores sumergibles que midan parámetros fisicoquímicos—como oxígeno disuelto, pH y temperatura—en combinación con visión por computadora, permite automatizar prácticas que tradicionalmente eran manuales y laboriosas (Rajan y otros, 2023). Al emplear cámaras con campo de visión amplio (ejemplo: Raspberry Pi con lente gran angular) instaladas a 0,5 m bajo la superficie del agua, es posible capturar imágenes que alimenten algoritmos de detección en tiempo real, reduciendo el estrés y la mortalidad de los peces asociados a manipulaciones directas (Rajan y otros, 2023). Además, la robustez de los modelos de aprendizaje automático entrenados con un volumen mínimo de ~800–1000 imágenes etiquetadas aseguran que los sistemas de IA puedan generalizarse incluso ante variaciones moderadas de turbidez y densidad de cultivo, aspectos críticos en entornos Biofloc y RAS (Rajan y otros, 2023). Este enfoque teórico fundamenta la premisa de que un sistema inteligente adaptativo, que combine sensores IoT y

técnicas de visión computacional, puede optimizar el suministro de oxígeno disuelto y mejorar la calidad del agua en tiempo real.

La tecnología Biofloc (BFT) se fundamenta en la creación de un ecosistema microbiano que, mediante la adición controlada de fuentes de carbono y aireación intensa, mantiene en suspensión partículas ricas en biomasa bacteriana que funcionan como alimento suplementario y como agente de reciclaje de nutrientes, reduciendo la concentración de amonio y mejorando la calidad del agua (Manan y otros, 2024). El balance del cociente carbono:nitrógeno (C:N) es crítico, pues una relación adecuada (12:1 a 15:1) promueve la proliferación de bacterias heterótrofas que consumen el nitrógeno inorgánico, mientras que dosis de carbono como almidón de maíz o melaza determinan la eficiencia en la formación de flóculos y el rendimiento zootécnico (Manan y otros, 2024). Además, la correcta aeración y mezcla garantizan que dichos flóculos permanezcan en suspensión, evitando la sedimentación excesiva que podría generar picos tóxicos de amonio y afectar la oxigenación del cultivo (Manan y otros, 2024). De esta forma, un sistema inteligente que monitorice en tiempo real parámetros como oxígeno disuelto (DO), sólidos suspendidos (TSS) y niveles de nitrógeno, y que ajuste automáticamente la aireación y la dosificación de carbono, se apoya en principios fundamentales de la BFT para asegurar un entorno óptimo para el crecimiento y la salud de los organismos acuáticos.

La base teórica para un sistema acuícola inteligente reside en la integración de dispositivos IoT para el monitoreo continuo de parámetros fisicoquímicos clave (oxígeno disuelto, pH, temperatura, turbidez) y en la capacidad de modelos de aprendizaje profundo (DL) para procesar estos datos y generar acciones automáticas a fin de mantener la calidad del agua en rangos óptimos (Chiu y otros, 2022). En este esquema, sensores como el de oxígeno disuelto disparan el encendido de agitadores o aireadores cuando el valor medido cae por debajo del umbral establecido, mientras

que las lecturas de pH y turbidez pueden activar bombas de recirculación para corregir desequilibrios (Chiu y otros, 2022). La comunicación inalámbrica (Wi-Fi) con un microcontrolador (Arduino Mega2560) permite transmitir estos datos en tiempo real a una plataforma en la nube, donde un modelo DL afinado por optimización bayesiana predice tendencias del entorno y facilita la toma de decisiones proactivas (Chiu y otros, 2022). Así, el control en bucle cerrado (closed-loop control) se fundamenta en la retroalimentación constante entre la medición de variables críticas y la activación de actuadores (aireadores, bombas, dispositivos de alimentación), garantizando la estabilidad del sistema Biofloc o RAS y promoviendo un entorno óptimo para el crecimiento y la salud de los organismos acuáticos.

El mantenimiento de parámetros fisicoquímicos estables —como pH, sólidos disueltos totales (TDS) y temperatura— es fundamental para garantizar la salud y el crecimiento óptimo en sistemas acuícolas de pequeña escala. La captación continua de estos datos mediante nodos IoT basados en NodeMCU ESP8266 y sensores específicos (pH-4502C, DS18B20, TDS Analógico) habilita la transmisión inalámbrica de más de 118000 registros en tan solo tres meses, lo que sustenta la viabilidad técnica de un sistema de monitoreo en tiempo real (Majid & Setiawan, 2024). Sin embargo, la complejidad no lineal y la variabilidad inherente a las series temporales de calidad del agua requieren modelos de aprendizaje automático capaces de capturar interdependencias entre variables y producir predicciones estables, tal como propone el enfoque *Ensemble Shuffling-CNN* (ES-CNN) que combina convoluciones 1D y permutaciones aleatorias para robustecer la generalización sobre datos de prueba y entrenamiento (Majid & Setiawan, 2024).

En sistemas de recirculación acuícola (RAS) de alta densidad, la acumulación de amonio (TAN) y nitrito ($\text{NO}_2\text{-N}$) resulta especialmente nociva para la salud de los organismos cultivados y exige un monitoreo continuo que, tradicionalmente, carece de respuesta en tiempo real debido a

la dificultad de medir estas variables directamente. La incorporación de una red de sensores IoT—que muestreen temperatura, oxígeno disuelto, salinidad, pH y cantidad de alimento—permite alimentar modelos de “surrogate modelling” capaces de estimar rápidamente la concentración de TAN y $\text{NO}_2\text{-N}$ a partir de estas lecturas indirectas (Chen y otros, 2024). Estos modelos de aprendizaje automático, integrados en una arquitectura de control en bucle cerrado, habilitan alertas tempranas y la activación automática de filtros o recambios de agua para reducir sólidos suspendidos (SS) y mantener la calidad del agua dentro de los parámetros óptimos.

Dentro de la producción acuícola, tanto en los Sistemas de Recirculación de Agua (RAS) como en la Tecnología Biofloc (BFT), la gestión de los parámetros fisicoquímicos del agua es fundamental para asegurar la salud de los organismos cultivados, su crecimiento óptimo y la sostenibilidad del sistema (Granda Jaramillo, 2022). Cada uno de estos parámetros se interconecta con los demás, influenciando directamente el ambiente acuático y, por ende, la eficiencia productiva (López Jaime, 2019).

Los sistemas RAS se diseñan con el objetivo principal de disminuir la demanda de agua e incrementar la densidad de los organismos acuáticos mediante procesos de tratamiento del agua (Soto Castro, 2015). Un monitoreo continuo de la calidad del agua es indispensable (Granda Jaramillo, 2022).

- Dióxido de Carbono (CO_2) y su Relación con el pH y la Toxicidad del Amoníaco: El CO_2 disuelto tiene un efecto directo sobre el Ph (Granda Jaramillo, 2022). A medida que los niveles de CO_2 disminuyen, el pH tiende a aumentar, lo cual, a su vez, incrementa la toxicidad del amoníaco no ionizado (NH_3), la forma más dañina para los peces (Granda Jaramillo, 2022) (Soto Castro, 2015). Es crucial mantener el CO_2 disuelto y el pH por debajo de sus límites respectivos para controlar la toxicidad del amoníaco (Granda Jaramillo, 2022). Los niveles óptimos de CO_2

se sitúan entre 5.0 y 10 mg/L (Saavedra Martínez, 2006), y es esencial eliminarlo del sistema a través de procesos de desgasificación. Altas concentraciones de amonio pueden degradar el sistema nervioso central de los peces y reducir la calidad de su carne (Granda Jaramillo, 2022).

- Oxígeno Disuelto (OD): Es considerado el parámetro más crítico y limitante en la acuicultura intensiva, por lo que su monitoreo constante es indispensable. Las bacterias nitrificantes, responsables de la transformación de amonio en nitrito y luego en nitrato, requieren oxígeno para su actividad metabólica (Granda Jaramillo, 2022) (Soto Castro, 2015). Concentraciones bajas de OD (por debajo de 2 mg/L son críticas (Soto Castro, 2015), aunque la tilapia puede sobrevivir a 1.0 mg/L, esto afecta negativamente su crecimiento (Granda Jaramillo, 2022)) pueden limitar la producción y la densidad de siembra. La concentración de oxígeno puede ser restaurada y mantenida mediante aireación u oxigenación. Se recomienda mantener el OD por encima de 6 mg/L para reducir el estrés en los peces y mejorar las tasas de crecimiento. El rango óptimo para tilapia es de 5.0 a 9.0 mg/L (Granda Jaramillo, 2022) (Saavedra Martínez, 2006) (Soto Castro, 2015).

- Temperatura: La temperatura del agua influye directamente en la tasa metabólica de la tilapia, su crecimiento, el consumo de alimento y la absorción de oxígeno. Un aumento de 10°C puede duplicar la tasa de crecimiento dentro del rango óptimo, lo que equivale a un 10% de incremento por cada 1°C. Además, la temperatura afecta directamente la actividad de las bacterias nitrificantes. Para el cultivo de tilapia, la temperatura ideal varía entre 27 y 32°C. Un monitoreo continuo de la temperatura es vital (Granda Jaramillo, 2022) (Saavedra Martínez, 2006) (Soto Castro, 2015).

- Alcalinidad y pH: La alcalinidad es la capacidad del agua para amortiguar los cambios de pH. El proceso de nitrificación consume alcalinidad (7.14 mg de CaCO_3 por cada gramo de

nitrógeno amoniacal transformado a nitrato). Esta reducción de alcalinidad puede conducir a una disminución del pH, lo que a su vez puede inhibir la actividad nitrificante. La alcalinidad se puede reponer con la adición de bicarbonato de sodio (0.25 kg por kg de alimento). Se recomienda mantener la alcalinidad por debajo de 175 mg/L de CaCO_3 (Soto Castro, 2015), siendo el rango óptimo entre 10 y 150 mg/L (Granda Jaramillo, 2022) (Saavedra Martínez, 2006). El pH óptimo para el cultivo de tilapia oscila entre 6.0 y 9.0 (Granda Jaramillo, 2022) (Saavedra Martínez, 2006), mientras que para las bacterias nitrificantes se sitúa idealmente entre 7.2 y 7.8 (Soto Castro, 2015).

- Relación Carbono/Nitrógeno (C/N): La relación C/N del afluente influye en la competencia entre las poblaciones de microorganismos autótrofos (nitrificantes) y heterótrofos. Para una alta eficiencia en la remoción de amonio, se requieren bajas cargas orgánicas y relaciones C/N inferiores a cinco, idealmente menores a dos. Si esta relación es alta, las bacterias heterótrofas se ven favorecidas, lo que disminuye las tasas de nitrificación (Soto Castro, 2015).

- Sólidos Suspendidos (SS) y Turbidez: La acumulación de sólidos suspendidos, como heces y alimento no consumido, puede reducir la transparencia del agua, causar irritación branquial, estrés en los peces, afectar a las bacterias nitrato oxidantes, generar enfermedades, retrasar el crecimiento y aumentar la mortalidad. Un aumento de sólidos puede inhibir el proceso de nitrificación (Soto Castro, 2015). Por lo tanto, es crucial removerlos rápidamente del sistema, siendo deseable una remoción del 95% (Granda Jaramillo, 2022) (Soto Castro, 2015). La turbidez, causada por partículas en suspensión, también reduce la transparencia del agua y es un factor para monitorear (Cardozo Ramírez y otros, 2024) (Soto Castro, 2015). La concentración ideal de SS es inferior a 10 mg/L (Soto Castro, 2015).

- Compuestos Nitrogenados (Amonio, Nitrito, Nitrato): Después del oxígeno, los compuestos nitrogenados son el siguiente factor limitante en sistemas de cultivo intensivo (Soto Castro, 2015).

- Amonio Total (NAT/TAN): Compuesto por amonio (NH_4^+) y amoníaco (NH_3). Es tóxico para los peces y debe ser removido constantemente. El amoníaco no ionizado (NH_3) es la forma más tóxica (Granda Jaramillo, 2022) (Soto Castro, 2015). La concentración ideal de amonio total es de 0 a 0.1 mg/L (Granda Jaramillo, 2022) (Saavedra Martínez, 2006).

- Nitritos (NO_2^-): También son tóxicos para los peces. El rango ideal es de 0 a 0.1 mg/L (Granda Jaramillo, 2022) (Saavedra Martínez, 2006) (Soto Castro, 2015).

- Nitratos (NO_3^-): Son el producto final de la nitrificación y la forma menos tóxica del nitrógeno inorgánico para los peces (Granda Jaramillo, 2022) (Soto Castro, 2015). Sin embargo, concentraciones muy altas pueden ser peligrosas. Se recomienda mantener las concentraciones por debajo de 20 mg/L (Granda Jaramillo, 2022) (Soto Castro, 2015). La acumulación de nitratos fue negativa para el crecimiento en condiciones de poco o ningún recambio de agua. El rango ideal es de 1.5 a 2.0 mg/L (Granda Jaramillo, 2022) (Saavedra Martínez, 2006) (Soto Castro, 2015).

- La nitrificación es el proceso biológico clave para la eliminación del nitrógeno amoniacal. Este proceso es realizado por bacterias autótrofas en condiciones aerobias (Granda Jaramillo, 2022) (Soto Castro, 2015).

- Dureza total y Ca: La dureza total es la suma de los iones de calcio (Ca^{+2}) y magnesio (Mg^{+2}) (Granda Jaramillo, 2022). Esto es significativo para el funcionamiento de los ecosistemas acuáticos (Granda Jaramillo, 2022). El rango ideal para la dureza total es entre 80 y 110 mg/L, en calcio entre 60 y 120 mg/L (Granda Jaramillo, 2022) (Saavedra Martínez, 2006).

- Fósforo (P): Se asume como el principal nutriente limitante en agua dulce, y su eutrofización suele provocar un aumento general de la producción primaria (fitoplancton) (Granda Jaramillo, 2022). El límite favorable es entre 0 y 2 mg/L (Granda Jaramillo, 2022) (Saavedra Martínez, 2006).

En la Tecnología Biofloc (BFT), el monitoreo constante de los parámetros físico-químicos es de vital importancia para mantener el equilibrio y el funcionamiento adecuado del sistema (Granda Jaramillo, 2022).

- Oxígeno Disuelto (OD): La incorporación de oxígeno al agua es fundamental para construir biofloc. El oxígeno disuelto es necesario tanto para la respiración de los peces y microorganismos como para las reacciones de nitrificación. Se recomienda que el oxígeno disuelto se mantenga por encima de 8 mg/L en sistemas de alevinaje con biofloc. Un fallo en el suministro de oxígeno puede llevar a la muerte de la producción en cuestión de minutos debido a la alta demanda biológica de oxígeno generada por la densa biomasa microbiana. El nivel de oxígeno disuelto en sistemas biofloc debe estar cercano a 6mg/L (Granda Jaramillo, 2022).

- Temperatura: La temperatura ideal para el cultivo de tilapia en BFT se encuentra en el rango de 24 a 28°C. Temperaturas intermedias de 20-25°C son ideales para obtener flóculos de manera estable (Granda Jaramillo, 2022).

- pH y Alcalinidad: En sistemas BFT, el pH debe mantenerse entre 7 y 9. Un pH alto puede promover la toxicidad por amonio no ionizado (NH₃). La alcalinidad debe estar por encima de 50 mg/L de CaCO₃, ya que una alcalinidad adecuada genera un efecto amortiguador (buffer) que ayuda a disminuir la toxicidad del amonio no ionizado (Granda Jaramillo, 2022).

- Relación Carbono/Nitrógeno (C/N): La relación C/N es fundamental para la asimilación de nitrógeno en BFT. Se requieren aproximadamente 20 unidades de carbono para asimilar una

unidad de nitrógeno. Esto se logra mediante la adición de una fuente de carbono, como la melaza, cuando el amonio supera los 0.1 mg/L. Una consecuencia directa de la adición de carbohidratos es el aumento de la demanda de oxígeno disuelto. La gestión de la relación C/N determina si predomina la nitrificación o la asimilación heterotrófica. La relación C/N que se maneja se encuentra entre 15:1 y 20:1 (Granda Jaramillo, 2022).

- Sólidos Sedimentables (SS): La cantidad de sólidos sedimentables es un indicador de la calidad del biofloc, y se recomienda una concentración de 100 ml/L para el cultivo de tilapia. En fase de alevinos, estudios arrojaron que las mejores concentraciones fueron de 200 ml/L. Es importante mantener los flóculos en suspensión constante para evitar la decantación y acumulación de sólidos que puedan conducir a reacciones anaerobias y producir metabolitos tóxicos letales (Granda Jaramillo, 2022).

- Nitrógeno (Amonio/Nitrito/Nitrato): La tecnología biofloc se basa en el aprovechamiento de los residuos de los alimentos, materia orgánica y compuestos inorgánicos tóxicos (como el amonio, nitritos y nitratos) a través de microorganismos (Granda Jaramillo, 2022). El biofloc posee la capacidad de reciclar proteínas, convirtiendo el amonio en proteína microbiana a través de la adición de carbohidratos, la cual puede ser utilizada como fuente de proteína por los peces (Granda Jaramillo, 2022) (BIOAQUAFLOC, 2025). Los niveles ideales de amonio y nitritos en BFT son 0 mg/L, mientras que los nitratos deben estar entre 1.5 y 2 mg/L (Granda Jaramillo, 2022). Las microalgas y otras bacterias pueden eliminar los nitratos transformándolos directamente en nitrógeno gaseoso (BIOAQUAFLOC, 2025).

Por lo anterior, podemos deducir que, aunque ambos sistemas comparten el objetivo de una gestión eficiente de los compuestos nitrogenados, RAS se centra en la remoción y tratamiento de estos desechos para recircular agua de alta calidad, mientras que BFT los transforma en biomasa

microbiana que, además de eliminar la toxicidad, sirve como alimento suplementario, integrando el reciclaje de nutrientes de forma más intrínseca. La eficacia de ambos sistemas depende de un estricto control y comprensión de la correlación entre sus parámetros físico-químicos clave (Granda Jaramillo, 2022) (López Jaime, 2019).

La relación entre algunos factores fisicoquímicos en la evaluación de la calidad del agua en sistemas de biofloc es particularmente importante, considerando el carácter dinámico e interconectado de estos parámetros, que afectan directamente a las especies cultivadas, así como a la compleja comunidad microbiana que sostiene el sistema (Gálvez-Cantero y otros, 2022). El oxígeno disuelto (OD) es esencial y es consumido por el biofloc por sus microorganismos y animales, razón por la cual la aireación debe ser continua no solo para el suministro de oxígeno sino para mantener los flóculos en suspensión y evitar áreas anaeróbicas que típicamente liberan toxinas como el sulfuro de hidrógeno (Gálvez-Cantero y otros, 2022). La solubilidad del OD es inversamente proporcional a la temperatura (y cuando se asocia al pH, al riesgo de toxicidad causada por el amoníaco no ionizado -NH_3) (Gálvez-Cantero y otros, 2022) (Boyd, 2020).

pH y Alcalinidad: Existe una relación intrínseca entre el pH y la alcalinidad; la alcalinidad sirve como un amortiguador esencial contra la acidificación y la toxicidad por amoníaco y es consumida por el proceso de nitrificación (Gálvez-Cantero y otros, 2022) (BIOAQUAFLOC (b), 2025). Por último, la relación carbono/nitrógeno (C/N) es uno de los pilares de esta tecnología ya que una relación lo suficientemente adecuada (preferiblemente entre 15:1 a 20:1) favorecerá el crecimiento de bacterias heterotróficas que asimilan nitrógeno tóxico y lo transforman en proteína microbiana con la adición de carbono que también aumenta la demanda de O_2 (Gálvez-Cantero y otros, 2022) (Hernández Mancipe y otros, 2019).

Además, la correlación entre los sólidos suspendidos (SS) / sólidos suspendidos totales (SST) y el resto de los parámetros es vital; la calidad y cantidad de biofloc, que transforma los desechos orgánicos en materia viva, deben gestionarse cuidadosamente ya que la tolerancia de las especies varía y su decantación puede generar toxicidad (BIOAQUAFLOC (b), 2025) (Gálvez-Cantero y otros, 2022) (Hernández Mancipe y otros, 2019). Los compuestos nitrogenados (amonio, nitrito, nitrato) son controlados eficazmente en los sistemas biofloc a través de la actividad microbiana y la gestión del C/N, convirtiéndolos en biomasa útil y reduciendo la toxicidad en el agua (Gálvez-Cantero y otros, 2022) (Hernández Mancipe y otros, 2019). Esta gestión integrada y proactiva de los factores físico-químicos no solo optimiza la calidad del agua y reduce los costos de producción (alimento y recambio de agua), sino que también mejora la bioseguridad, la inmunidad y el crecimiento de las especies cultivadas, convirtiendo los desechos en recursos valiosos y posicionando al biofloc como una alternativa sostenible y eco-amigable en la acuicultura intensiva (Quintero Sánchez y otros, 2024) (Hernández Mancipe y otros, 2019).

La correlación entre los parámetros físico-químicos del agua es fundamental para mantener un ambiente acuático óptimo en la producción de tilapia, tanto en sistemas de Recirculación de Agua (RAS) como en la Tecnología Biofloc (BFT). El monitoreo continuo de estos parámetros es indispensable, ya que existe una interconexión directa entre ellos, y su control es crucial para la salud de los peces y la eficiencia del sistema (Granda Jaramillo, 2022) (Hernández, 2020).

En los sistemas RAS, el objetivo principal es reducir la demanda de agua e incrementar la densidad de los organismos acuáticos mediante procesos de tratamiento del agua (Soto Castro, 2015).

- Dióxido de Carbono (CO₂), pH y Toxicidad del Amoníaco: Existe una interconexión directa entre el CO₂ disuelto y el pH. A medida que los niveles de CO₂ disuelto disminuyen, el

pH tiende a aumentar. A su vez, el pH tiene una relación directa con la toxicidad del nitrógeno amoniacal total (NAT), ya que un pH más alto incrementa la toxicidad del amoníaco no ionizado (NH_3), la forma más nociva para los peces. Por lo tanto, para controlar la toxicidad del amoníaco, el sistema debe ser capaz de mantener el CO_2 disuelto y el pH por debajo de sus límites respectivos. Concentraciones altas de amonio pueden degradar el sistema nervioso central de los peces y reducir la calidad de su carne (Granda Jaramillo, 2022).

- Oxígeno Disuelto (OD) y Nitrificación: El oxígeno disuelto es el parámetro más crítico y limitante en la acuicultura intensiva, por lo que su monitoreo constante es esencial (Granda Jaramillo, 2022). Las bacterias nitrificantes, responsables de transformar el amonio en nitrito y luego en nitrato, requieren oxígeno para su actividad (Soto Castro, 2015). La ausencia de oxígeno puede provocar competencia con bacterias heterótrofas (Soto Castro, 2015). Bajas concentraciones de oxígeno disuelto pueden limitar la producción y la densidad de siembra, y pueden atribuirse a la descomposición de materia orgánica y alimento no consumido. Aunque la tilapia puede sobrevivir a niveles bajos (1.0 mg/L), esto no significa que no afecte su crecimiento (Rivas Salazar y otros, 2021). La concentración requerida de oxígeno puede restaurarse mediante aireación u oxigenación (Granda Jaramillo, 2022).

- Temperatura y Actividad Biológica (Nitrificación): La temperatura del agua influye directamente en la tasa metabólica de la tilapia, su crecimiento, consumo de alimento y absorción de oxígeno (Boyd, 2020). Un aumento de 10°C puede duplicar la tasa de crecimiento dentro del rango óptimo, lo que equivale a un 10% de incremento por cada 1°C (Boyd, 2020). Además, la temperatura afecta directamente la actividad de las bacterias nitrificantes (Soto Castro, 2015). Para el cultivo de tilapia, la temperatura ideal varía entre 27 y 32°C (Rivas Salazar y otros, 2021). Un monitoreo continuo de la temperatura es vital (Soto Castro, 2015).

- Alcalinidad, pH y Nitrificación: La alcalinidad es la capacidad del agua para amortiguar los cambios de pH (Soto Castro, 2015). El proceso de nitrificación consume alcalinidad (7.14 mg de CaCO_3 por cada gramo de nitrógeno amoniacal transformado a nitrato) (Soto Castro, 2015). Esta reducción de alcalinidad puede llevar a una disminución del pH, lo que a su vez puede inhibir la actividad nitrificante. La alcalinidad se puede reponer con la adición de bicarbonato de sodio (0.25 kg por kg de alimento) (Soto Castro, 2015). En contraste, la desnitrificación puede generar alcalinidad (Soto Castro, 2015).

- Relación Carbono/Nitrógeno (C/N) y Nitrificación: La relación C/N del afluente influye en la competencia entre las poblaciones de microorganismos autótrofos (nitrificantes) y heterótrofos (Soto Castro, 2015). Para una alta eficiencia en la remoción de amonio, se requieren bajas cargas orgánicas y relaciones C/N inferiores a cinco, idealmente menores a dos. Si esta relación es alta, las bacterias heterótrofas se ven favorecidas, lo que disminuye las tasas de nitrificación (Soto Castro, 2015).

- Sólidos Suspendidos (SS) y Calidad del Agua/Salud de Peces/Nitrificación: La acumulación de sólidos suspendidos, como heces y alimento no consumido, puede reducir la transparencia del agua, causar irritación branquial, estrés en los peces y bacterias nitrito oxidantes, enfermedades, retraso en el crecimiento y aumento de la mortalidad (López Jaime, 2019) (Soto Castro, 2015). Un aumento de sólidos puede inhibir el proceso de nitrificación. Por lo tanto, es crucial removerlos rápidamente del sistema (Soto Castro, 2015). Aunque los sistemas RAS están diseñados para la remoción de nitrógeno, el manejo de sólidos puede ser un desafío, ya que una remoción del 95% es deseable, pero a menudo se obtienen porcentajes más bajos (Soto Castro, 2015).

- Nitratos: Los nitratos (NO_3^-) son la forma menos tóxica del nitrógeno inorgánico para los peces, pero concentraciones muy altas pueden ser peligrosas. Se recomienda mantener las concentraciones por debajo de 20 mg/L (Soto Castro, 2015). La acumulación de nitratos fue negativa para el crecimiento en condiciones de poco o ningún recambio de agua (Rivas Salazar y otros, 2021).

En la Tecnología Biofloc (BFT), el monitoreo constante de los parámetros físico-químicos es de vital importancia para mantener el equilibrio y el funcionamiento adecuado del sistema (Hernández, 2020).

- Oxígeno Disuelto (OD) y Formación de Biofloc/Nitrificación: La incorporación de oxígeno al agua es fundamental para construir biofloc (Hernández, 2020). El oxígeno disuelto es necesario tanto para la respiración de los peces y microorganismos como para las reacciones de nitrificación (Hernández, 2020). Se recomienda que el oxígeno disuelto se mantenga por encima de 8 mg/L en sistemas de alevinaje con biofloc (Granda Jaramillo, 2022) (Hernández, 2020).

- Temperatura: La temperatura ideal para el cultivo de tilapia en BFT se encuentra en el rango de 24 a 28°C (Hernández, 2020). Además, temperaturas intermedias de 20-25°C son ideales para obtener flóculos de manera estable (Hernández, 2020).

- pH y Alcalinidad: En los sistemas BFT, el pH debe mantenerse entre 7 y 9 (Hernández, 2020). Un pH alto puede promover la toxicidad por amonio no ionizado (NH_3) (Hernández, 2020) (BIOAQUAFLOC, 2025). La alcalinidad debe estar por encima de 50 mg/L de CaCO_3 (Hernández, 2020), ya que una alcalinidad adecuada genera un efecto amortiguador (buffer) que ayuda a disminuir la toxicidad del amonio no ionizado. Es importante considerar que el proceso de nitrificación consume alcalinidad, específicamente 7 gramos de CaCO_3 por cada gramo de

nitrógeno amoniacal oxidado a nitrato (Hernández, 2020). Existe una relación directa entre los procesos de nitrificación y la alcalinidad, y una relación inversa con el pH (Hernández, 2020).

- **Relación Carbono/Nitrógeno (C/N):** La relación C/N es fundamental para la asimilación de nitrógeno en BFT. Se requieren aproximadamente 20 unidades de carbono para asimilar una unidad de nitrógeno. Para el establecimiento de bacterias heterótrofas en los bioflóculos, es crucial que estas fijen carbono como fuente de energía y aprovechen el nitrógeno para la síntesis de proteínas (Hernández, 2020). Esta relación se logra mediante la adición de una fuente de carbono, como la melaza, cuando el amonio supera los 0.1 mg/L. Una consecuencia directa de la adición de carbohidratos es el aumento de la demanda de oxígeno disuelto. La gestión de la relación C/N determina si predomina la nitrificación o la asimilación heterotrófica. La relación C/N que se maneja en BFT se encuentra entre 15:1 y 20:1. Estudios han demostrado que la melaza es la mejor fuente de carbono, seguida por el azúcar, y que la mejor relación C:N fue 10:1, mientras que una relación de 20:1 afecta la alcalinidad. Además, el sistema de biofloc posee la capacidad de reciclar las proteínas, transformando el amonio en proteína microbiana (a través de la adición de carbohidratos), que puede ser utilizada como fuente de proteína por los peces (Hernández, 2020).

- **Sólidos Sedimentables (SS):** La cantidad de sólidos sedimentables es un indicador de la calidad del biofloc. Se recomienda una concentración de 100 ml/L para el cultivo de tilapia. Sin embargo, en la fase de alevinos, estudios arrojaron que las mejores concentraciones fueron de 200 ml/L. Es importante mantener los flóculos en suspensión constante para evitar la decantación y acumulación de sólidos, lo cual podría conducir a reacciones anaerobias y la producción de metabolitos tóxicos letales (Hernández, 2020).

- **Compuestos Nitrogenados (Amonio, Nitrito, Nitrato):** La tecnología biofloc se basa en el aprovechamiento de los residuos de los alimentos, la materia orgánica y los compuestos

inorgánicos tóxicos (como el amonio, nitritos y nitratos) a través de microorganismos presentes en el medio acuático (Hernández, 2020). Las bacterias nitrificantes del biofloc son las encargadas de eliminar el amonio y el resto de las sustancias nitrogenadas (nitrito y nitrato) del agua (BIOAQUAFLOC, 2025). Este proceso se realiza en presencia de una fuente de carbono y con aireación continua. El amonio (NH_3) y el nitrito (NO_2) son tóxicos para los peces (Hernández, 2020). El amonio y el amoniaco (que es la forma ionizada del amonio) se convierten el uno en el otro dependiendo del pH del agua, siendo el amoniaco muy tóxico y prevaleciendo a un pH por encima de 8 (BIOAQUAFLOC, 2025). Los niveles ideales de amonio y nitritos en BFT son 0 mg/L (Hernández, 2020). Los nitratos (NO_3^-) son el producto final de la nitrificación y la forma menos tóxica del nitrógeno inorgánico para los peces, y deben estar entre 1.5 y 2 mg/L (Hernández, 2020). La manera en que el biofloc elimina los nitratos es a través de microalgas y otras bacterias que los transforman directamente en nitrógeno gaseoso (BIOAQUAFLOC, 2025) (Hernández, 2020), o las microalgas los utilizan como fertilizantes para generar aminoácidos y proteínas (BIOAQUAFLOC, 2025). De esta forma, el amonio se transforma en masa bacteriana y proteínas de microalgas, las cuales están incluidas en los bioflóculos y pueden ser ingeridas por los animales cultivados, convirtiendo un desecho en una fuente de proteína viva de gran importancia (BIOAQUAFLOC, 2025).

Es importante destacar que, en BFT, la interdependencia de estos parámetros permite el reciclaje de nutrientes y la minimización del intercambio de agua, lo que contrasta con los sistemas tradicionales o RAS que se enfocan en la remoción de estos compuestos fuera del volumen de cultivo. La gestión adecuada de cada parámetro influye directamente en la eficiencia biológica y productiva del sistema biofloc.

En el marco del proyecto AquaNutri AI Móvil, resulta fundamental identificar y comprender los principales parámetros fisicoquímicos que determinan la calidad del agua en sistemas acuícolas intensivos como Biofloc y RAS. La gestión eficiente de estos parámetros es crucial para preservar la salud de los organismos cultivados, optimizar su rendimiento zootécnico y garantizar la sostenibilidad del sistema. Diversos estudios científicos han demostrado que estos factores no actúan de forma aislada, sino que presentan correlaciones complejas que deben analizarse de manera conjunta para una toma de decisiones más precisa y predictiva.

En la Tabla No. 1, se presenta un resumen de los parámetros fisicoquímicos más relevantes, su importancia dentro del sistema y las referencias bibliográficas correspondientes, los cuales servirán como base para el desarrollo del sistema inteligente propuesto. Los rangos óptimos aquí definidos han sido consolidados a partir de las fuentes bibliográficas citadas, buscando establecer un intervalo que abarque las condiciones más favorables y comunes para la salud, crecimiento y productividad de las especies de cultivo en sistemas de acuicultura intensiva Biofloc y RAS, sirviendo como umbrales críticos para las funcionalidades de monitoreo, alerta y análisis predictivo de AquaNutri AI Móvil.

Tabla 1

Parámetros físico - químicos a tener en cuenta en el proyecto AquaNutri AI Móvil

Parámetro	Importancia	Indicadores por Autor / Fuente	Rango Óptimo (Consolidado para el Proyecto)
Oxígeno disuelto	Fundamental para la respiración de peces y bacterias nitrificantes.	Granda Jaramillo (2022): >6 mg/L Saavedra Martínez (2006): 5–9 mg/L Soto Castro (2015): crítico <2 mg/L	5.0 – 9.0 mg/L
Temperatura	Afecta metabolismo, crecimiento y	Granda Jaramillo (2022): 27–32 °C Saavedra Martínez (2006): 24–28	24 – 32 °C

Parámetro	Importancia	Indicadores por Autor / Fuente	Rango Óptimo (Consolidado para el Proyecto)
pH	eficiencia del sistema.	°C Boyd (2020): cada +1°C = +10% crecimiento	7.0 – 9.0
	Influye en toxicidad del amonio y procesos de nitrificación.	Granda Jaramillo (2022): 6.0–9.0 Soto Castro (2015): óptimo 7.2–7.8 Saavedra Martínez (2006): 6.0–9.0	
	Amortigua variaciones de pH y permite nitrificación.	Soto Castro (2015): <175 mg/L Granda Jaramillo (2022): 10–150 mg/L Saavedra Martínez (2006): >50 mg/L	
Alcalinidad			50 – 175 mg/L CaCO ₃
CO ₂	Relacionado con pH y toxicidad de NH ₃ .	Saavedra Martínez (2006): 5–10 mg/L Granda Jaramillo (2022): mantener bajo para controlar pH Saavedra Martínez (2006): <0.1 mg/L	5.0 – 10.0 mg/L
Amonio (NH ₃ /NH ₄ ⁺)	Tóxico; debe mantenerse bajo.	Granda Jaramillo (2022): ideal 0–0.1 mg/L Soto Castro (2015): crítica >0.1 mg/L Granda Jaramillo (2022): 0–0.1 mg/L	0 – 0.1 mg/L
Nitrito (NO ₂ ⁻)	Tóxico; afecta transporte de oxígeno.	Soto Castro (2015): evitar acumulación Saavedra Martínez (2006): 0–0.1 mg/L	0 – 0.1 mg/L
Nitrato (NO ₃ ⁻)	Menos tóxico, pero acumulaciones afectan crecimiento.	Granda Jaramillo (2022): 1.5–2 mg/L Soto Castro (2015): <20 mg/L	1.5 – 20 mg/L
Relación C/N	Control de amonio y formación de biofloc.	Soto Castro (2015): ideal <5 para nitrificación Granda Jaramillo (2022): 15–20:1 Hernández (2020): 10–20:1	15:1 – 20:1
Sólidos suspendidos	Afectan nitrificación, transparencia, salud del pez.	Soto Castro (2015): <10 mg/L Granda Jaramillo (2022): ideal remoción 95%	<10 mg/L
Sólidos sedimentables	Indicador de biofloc; evita zonas anaeróbicas.	Granda Jaramillo (2022): 100 mL/L Hernández (2020): 200 mL/L en alevinaje	100 – 200 mL/L

Parámetro	Importancia	Indicadores por Autor / Fuente	Rango Óptimo (Consolidado para el Proyecto)
Turbidez	Refleja cantidad de sólidos suspendidos; afecta fotosíntesis y salud del pez.	Soto Castro (2015): factor clave Cardozo Ramírez y otros (2024): evitar opacidad extrema	Moderada – estable
Dureza (total)	Necesaria para estabilidad osmótica y metabolismo.	Granda Jaramillo (2022): 80–110 mg/L Saavedra Martínez (2006): 60–120 mg/L	80 – 110 mg/L
Calcio (Ca ²⁺)	Componente de la dureza; esencial para productividad.	Granda Jaramillo (2022): 60–120 mg/L	60 – 120 mg/L
Fósforo (P)	Limita producción primaria y afecta flóculos.	Granda Jaramillo (2022): 0–2.0 mg/L Saavedra Martínez (2006): 0–2.0 mg/L	0 – 2.0 mg/L

Nota: Elaborado por el autor, adaptado según datos referenciados en la tabla.

2.2 Estado del Arte

En los últimos años, se han empleado algoritmos de aprendizaje automático para proporcionar un mejor monitoreo a los sistemas de acuicultura intensiva. Shin y otros (2025) compararon algoritmos de imputación para datos faltantes en sistemas de flujo continuo y demostraron que cuando la concentración de DO está altamente concentrada alrededor de la media, los algoritmos lineales simples funcionan bien. Sin embargo, al tratar con datos de alta curtosis y picos extremos, los modelos de ML proporcionaron resultados más robustos (Shin y otros, 2025).

De la misma manera, el despliegue de sensores IoT para un monitoreo de diseño (cámara de influencia y tanques) reveló los beneficios de los datos instantáneos para permitir una corrección rápida de la desviación de variables clave (Shin y otros, 2025).

No obstante, se ha informado que los modelos desarrollados en una granja particular tienen una capacidad de generalización deficiente en diferentes granjas con condiciones de agua

disímiles, lo que indica la necesidad de métodos de adaptación o aprendizaje por transferencia (Shin y otros, 2025).

Estos aportes demuestran que, a pesar de que una imputación de datos completamente automática y la vigilancia continua pueden mejorar el control de la calidad del agua, es necesario personalizar el modelo para cada escenario de Biofloc o RAS para obtener los mejores resultados.

Los estudios más recientes han demostrado que la calidad y cantidad de datos de imagen son determinantes para lograr un desempeño óptimo de los modelos de detección embebidos en plataformas acuícolas. Ranjan y otros (2023) desarrollaron el sistema RASense1.0, que integra cuatro cámaras sumergibles (Raspberry Pi, GoPro, OAK-D y Ubiquiti) para capturar imágenes en condiciones de iluminación “ambiental” y “suplementaria”, evaluando su impacto sobre la métrica mAP (mean Average Precision). Encontraron que, con al menos 800 imágenes, los modelos (tanto YOLOv5 como Faster R-CNN) alcanzan una meseta de rendimiento (mAP ~86 %) y que técnicas de aumento de datos (e.g., ajuste de brillo, ruido, desenfoque) contribuyen solo cuando el conjunto es menor a 700 imágenes (Rajan y otros, 2023). Asimismo, demostraron que la cámara Raspberry Pi—gracias a su campo de visión de 140° y mayor cantidad de instancias anotadas—supera a otras en desempeño, y que modelos de una sola etapa (YOLOv5) son preferibles para despliegues en el borde por su baja latencia (Rajan y otros, 2023). Estos hallazgos sitúan el estado del arte en torno a la necesidad de planificar cuidadosamente el volumen de datos e implementar sensores con HFOV amplio, a fin de garantizar la eficacia de las soluciones de IA en entornos acuícolas intensivos.

El hecho de que BFT tenga efectos beneficiosos para las especies de camarones y cangrejos, basado y comparado en su respuesta inmune y tasas de enfermedades (Manan y otros,

2024), probablemente otras especies marinas (como bivalvos, peces, anfibios e insectos) se añaden a las capacidades de la dinámica del microbioma para actuar como probióticos.

Se ha informado que los sistemas BFT junto con la integración de RAS (policultivo de tilapia y langostino) mejoran la supervivencia y el aumento de peso en comparación con su contraparte convencional debido a la suplementación natural de flóculos y la estabilidad de la comunidad microbiana (Manan y otros, 2024).

No obstante, existen problemas operativos, como la elección adecuada de aireadores y su disposición, el deslodado o reemplazo de lodos cuando la concentración de sólidos supera el límite crítico, y la inestabilidad a largo plazo de los estanques de gran volumen, que requieren sistemas de operación automática para ajustar la aireación, mezcla y deslodado en función de los datos medidos en tiempo real (Manan y otros, 2024).

Estas contribuciones de vanguardia muestran cómo alcanzar una implementación sostenible a gran escala de BFT: la integración de soluciones de IA e IoT, que permiten el monitoreo constante de los parámetros fisicoquímicos y microbiológicos y la toma de decisiones automática para mantener el sistema en equilibrio.

En los últimos años, diversos prototipos de acuicultura inteligente han demostrado que la fusión de IoT y modelos ML—denominados sistemas AIoT—permite no solo monitorear en tiempo real la calidad del agua, sino también anticipar problemas antes de que ocurran mediante modelos surrogados (surrogate models) entrenados con datos históricos (Chiu y otros, 2022). Estudios recientes han empleado optimización bayesiana para ajustar hiperparámetros de redes neuronales, alcanzando coeficientes de determinación (R^2) de hasta 0.94 al correlacionar variables de calidad de agua (DO, temperatura, turbidez, pH) y métricas de crecimiento (Chiu y otros, 2022). La librería SHAP ha sido utilizada para identificar la importancia relativa de cada variable de

entrada, determinando que la turbidez y la cantidad de alimento son los factores más influyentes en la predicción del rendimiento del estanque, mientras que el pH tiene un impacto menor (Chiu y otros, 2022). Además, se han implementado prototipos que combinan sensores de pH, DO, temperatura y turbidez con cámaras IP para monitoreo visual, habilitando modos automáticos y manuales a través de interfaces móviles y alertas remotas por mensaje cuando algún parámetro sobrepasa umbrales críticos, lo que reduce la dependencia de supervisión presencial (Chiu y otros, 2022). Estas contribuciones conforman los fundamentos de la acuicultura inteligente, mostrando la viabilidad de sistemas AIoT para optimizar la aireación y la calidad del agua en entornos Biofloc y RAS.

Recientes investigaciones han demostrado que los modelos de ML tradicionales (MLP, CNN, Transformer, LSTM, GRU) pueden presentar sesgos hacia los datos de entrenamiento y variaciones significativas en su error de predicción, limitando su aplicabilidad en entornos con recursos computacionales restringidos. El modelo ES-CNN, al integrar un mecanismo de “shuffling” en la capa convolucional, mantiene un MAE consistente (~13 unidades) y exhibe los valores más bajos de RMSE y MAPE (<5 %) tanto en entrenamiento como en prueba, superando a arquitecturas basadas en atención y redes recurrentes bidireccionales (Majid & Setiawan, 2024). Además, pese a su complejidad, ES-CNN conserva una eficiencia computacional apropiada para implementarse en hardware embebido, demostrando que es posible desplegar modelos de alta precisión en Raspberry Pi o microcontroladores con aceleradores, lo cual abre la puerta a sistemas de control automático de calidad de agua en Biofloc y RAS sin necesidad de infraestructura de cómputo avanzada (Majid & Setiawan, 2024).

Diversos algoritmos de machine learning —como GRNN, DBN, LSTM y SVM— han sido evaluados para la predicción de TAN y NO₂-N en ambientes de cultivo intensivo; sin embargo, el

General Regression Neural Network (GRNN) ha demostrado un equilibrio superior entre precisión y robustez, alcanzando un MAE de 0.59 mg/L y un MAPE cercano al 29 %, sin presentar diferencias significativas entre datos de entrenamiento y prueba (Chen y otros, 2024). Además, se ha evidenciado que el manejo automatizado de la filtración basado en estas predicciones reduce eficazmente la turbidez y los picos de amonio, cumpliendo con los requisitos de respuesta inmediata que demanda la acuicultura urbana y de pequeña escala.

Un análisis sistemático de Capetillo-Contreras y otros (2024), realizado mediante el protocolo PRISMA sobre 753 registros de Scopus y Web of Science, reveló un incremento del 70,5 % en la producción de investigaciones sobre acuicultura inteligente en 2022 frente al año anterior, de las cuales 67 estudios se enfocan en la integración de sensores IoT, técnicas de IA y visión computacional para el control de la calidad del agua. La mayoría de estos prototipos emplea microcontroladores *Arduino Mega2560* conectados a sensores de pH, oxígeno disuelto, temperatura y turbidez, comunicándose vía Wi-Fi o LoRa con plataformas en la nube para el análisis y almacenamiento de datos (Capetillo-Contreras y otros, 2024). En paralelo, se ha demostrado que algoritmos de procesamiento de imágenes—como K-means y segmentación de contornos—permiten detectar peces, flóculos y anomalías con precisiones superiores al 95 %. A partir de estos trabajos, se han establecido rangos óptimos de calidad de agua que sirven de umbrales de referencia para el diseño de sistemas de control automático y modelos predictivos en Biofloc y RAS: pH 6.5–8.0; DO > 4 mg/L; TDS < 1 000 mg/L; TAN < 2 mg NH₃-N/L; NO₂-N 0.25–1.0 mg/L; temperatura 17–34 °C.

En el estudio de Kaur y otros (2023) se compararon ocho modelos de clasificación (incluyendo redes neuronales, máquinas de vector de soporte y bosques aleatorios) y tres métodos de selección de características sobre datos agregados semanalmente de un ciclo de cultivo de 190–

200 días, alcanzando puntuaciones F1-score de hasta 0.85 y exactitudes máximas de 0.84 al distinguir estanques de alto y bajo rendimiento según el peso y supervivencia de camarones. Los hallazgos indican que la temperatura y la salinidad son las variables más influyentes de forma constante, mientras que el oxígeno disuelto alcanza picos de importancia en semanas clave del ciclo, lo que evidencia la necesidad de incorporar análisis temporales de series y selección dinámica de características para mejorar la precisión de los sistemas de acuicultura inteligente.

El desarrollo de plataformas inteligentes para la gestión de sistemas acuícolas ha evolucionado significativamente, destacando especialmente la incorporación de modelos predictivos y herramientas de monitoreo en tiempo real en entornos como Biofloc y RAS. Estos sistemas, al depender de una interacción compleja entre parámetros fisicoquímicos y zootécnicos, requieren soluciones tecnológicas capaces de identificar patrones ocultos y tomar decisiones oportunas que favorezcan la salud de los organismos y la eficiencia productiva.

Investigaciones recientes, como las de Chen y otros (2024), evidencian cómo el uso de sensores IoT y algoritmos de "surrogate modelling" permite estimar variables críticas como el amonio (TAN) y el nitrito (NO₂-N) a partir de otras variables más fácilmente medibles, tales como temperatura, oxígeno disuelto y pH. Sin embargo, estas soluciones se han centrado principalmente en entornos tecnificados y automatizados, lo que dificulta su adopción por parte de productores de pequeña y mediana escala que no cuentan con redes de sensores instaladas.

Bajo este contexto, se hace relevante explorar soluciones centradas en la digitalización manual de datos y el análisis inteligente posterior. Proyectos como los presentados por Gálvez-Cantero y otros (2022) y Hernández Mancipe y otros (2019) resaltan la importancia de establecer correlaciones significativas entre parámetros como oxígeno disuelto, sólidos suspendidos, temperatura y relación C/N, elementos claves para mantener el equilibrio en sistemas Biofloc. De

igual manera, en los sistemas RAS, estudios como los de Soto Castro (2015) y Granda Jaramillo (2022) muestran cómo las fluctuaciones de CO₂, pH y amonio no ionizado pueden ser gestionadas con éxito mediante modelos predictivos y control automático.

En la Tabla No. 2, se presenta un resumen comparativo de los parámetros fisicoquímicos más relevantes diferenciados entre los sistemas RAS y Biofloc, señalando su rango óptimo consolidado, la importancia técnica para cada sistema y las referencias bibliográficas correspondientes. Esta clasificación permite entender las particularidades operativas de ambos entornos y justifica el diseño de alertas y umbrales específicos dentro de la plataforma inteligente AquaNutri AI Móvil, en función de la tecnología de cultivo utilizada.

Tabla 2*Parámetros fisicoquímicos diferenciados para sistemas RAS y Biofloc*

Parámetro	Sistema	Importancia	Fuente / Indicador específico	Rango Óptimo
Oxígeno Disuelto	RAS	Crítico para respiración y actividad bacteriana.	Granda Jaramillo (2022): 5.0-9.0 / Soto Castro (2015): >6.0	5.0 - 9.0 mg/L
	Biofloc	Vital para mantener flóculos activos y prevenir zonas anaeróbicas.	Hernández (2020): ~6.0 / BIOAQUAFLOC (2025): >6.0	>6.0 mg/L
Temperatura	RAS	Afecta metabolismo, crecimiento y actividad bacteriana.	Rivas Salazar (2021): 27-32 / Soto Castro (2015): continuo	27 - 32°C
	Biofloc	Condiciones estables para el desarrollo de flóculos.	Hernández (2020): 24-28 / Gálvez-Cantero (2022): 25-28	24 - 28°C
pH	RAS	Influye en toxicidad del NH ₃ y procesos de nitrificación.	Granda Jaramillo (2022): 6.0-9.0 / Soto Castro (2015): 7.2 - 7.8	6.0 - 9.0
	Biofloc	Amortiguado por alcalinidad; toxicidad NH ₃ si > 8.	Hernández (2020): 7-9 / BIOAQUAFLOC (2025): 7-8	7.0 - 9.0
Alcalinidad	RAS	Mantiene pH estable y favorece nitrificación.	Soto Castro (2015): <175 / Saavedra Martínez (2006): 100-150	100 - 175 mg/L CaCO ₃
	Biofloc	Actúa como buffer ante el consumo por nitrificación.	Hernández (2020): >50 / Gálvez-Cantero (2022): >100	>50 mg/L CaCO ₃
Amonio Total	RAS	Altamente tóxico en su forma NH ₃ .	Saavedra Martínez (2006): <0.1 / Soto Castro (2015): ideal 0	0 - 0.1 mg/L
	Biofloc	Suprimido vía asimilación microbiana.	BIOAQUAFLOC (2025): 0.0 / Hernández (2020): 0.0	0.0 mg/L
Nitrito	RAS	Tóxico para peces, afecta oxigenación celular.	Soto Castro (2015): <0.1 / Granda Jaramillo (2022): 0.1	0 - 0.1 mg/L
	Biofloc	Controlado por biofloc y aireación.	BIOAQUAFLOC (2025): 0.0 / Hernández (2020): 0.0	0.0 mg/L

Parámetro	Sistema	Importancia	Fuente / Indicador específico	Rango Óptimo
Nitrato	RAS	Menos tóxico pero acumulativo.	Soto Castro (2015): <20 / Rivas Salazar (2021): <10	<20 mg/L
	Biofloc	Utilizado por microalgas o eliminado por desnitrificación.	BIOAQUAFLOC (2025): 1.5-2.0 / Hernández (2020): 1.5-2.0	1.5 - 2.0 mg/L
CO ₂ Disuelto	RAS	Elevado CO ₂ reduce OD y altera pH.	Saavedra Martínez (2006): 5-10 / Soto Castro (2015): eliminar con degas	5.0 - 10 mg/L
	Biofloc	Poco reportado, pero ligado a OD y nitrificación.	Hernández (2020): control indirecto	-
Relación C/N	RAS	Favorece bacterias autótrofas, remoción de amonio.	Soto Castro (2015): ideal <2	<5:1
	Biofloc	Favorece bacterias heterótrofas, asimilación de NH ₄ y formación de proteína microbiana.	Gálvez-Cantero (2022): 15:1-20:1 / Hernández (2020): 15:1	15:1 - 20:1
Sólidos Suspendidos	RAS	Evita irritación, opacidad y fallos de filtrado.	Soto Castro (2015): <10 / Granda Jaramillo (2022): <10	<10 mg/L
	Biofloc	Base del sistema; su acumulación genera toxicidad.	Hernández (2020): 100-200 / BIOAQUAFLOC (2025): 200	100 - 200 ml/L (sedimentos)

Nota. Elaborado por el autor, adaptado de los datos obtenidos de los autores incluidos en la tabla.

La perspectiva de sostenibilidad operativa también ha asegurado que se cumpla el requisito de alertas en tiempo real. Capetillo-Contreras y otros (2024) y Abid y otros (2024) informan que el uso de un modelo de aprendizaje automático en combinación con un sistema de notificación permite a los productores tomar medidas de inmediato cuando se trata de desviaciones críticas, aumentando así la productividad y minimizando el riesgo de mortalidad.

El sistema AquaNutri AI Mobile se desarrolla en este nexo de disponibilidad tecnológica, inteligencia artificial y soporte de decisiones basado en datos. A diferencia de otros métodos que buscan una automatización completa con hardware específico, nuestro sistema está diseñado en torno a un registro manual, aunque estructurado, de datos por parte del productor y, por lo tanto, es mucho menos costoso y más probable que sea adoptado. Junto con motores de análisis predictivo y correlacional, el sistema ofrecerá soporte de decisiones para estrategias zootécnicas, especialmente para ajustar la gestión del agua y la alimentación.

En este sentido, AquaNutri AI Mobile se alinea y añade un enfoque más innovador al proyecto en curso, abordando el concepto de llevar las tecnologías de inteligencia para la acuicultura a la realidad (es decir, democratización) con un potencial de mayor impacto técnico y económico, aunque sin sacrificar beneficios en términos de usabilidad o integración con contextos efectivos/no reales.

2.3 Marco conceptual

El marco conceptual establece las definiciones clave relacionadas con la acuicultura intensiva y las tecnologías digitales aplicadas a su gestión. Estos conceptos permiten comprender el alcance del proyecto AquaNutri AI Móvil y garantizan consistencia terminológica en todo el trabajo.

Biofloc (BFT)

Es una tecnología de acuicultura amigable con el medio ambiente para estimular la producción de flóculos microbianos que proporcionan mejor calidad de agua, reciclan nutrientes y pueden usarse como alimento adicional durante el período de cultivo para peces (Manan y otros, 2024).

DO (Oxígeno Disuelto)

Oxígeno molecular (O_2) presente en el agua, que es vital para la respiración de los organismos acuáticos. Su monitoreo en tiempo real en línea con sensores IoT se considera importante para el control de la aireación y la prevención del estrés en los peces (Shin y otros, 2025).

NO_2 -N Nitrógeno Nitrito

Producto intermedio del nitrógeno inorgánico, su sobreacumulación impide la capacidad de la sangre de los peces para transportar oxígeno (Chen y otros, 2024).

Relación C:N

La relación molar que se aplica para equilibrar las fuentes de carbono y eliminar el amonio, el valor alto de 12:1-15:1 promueve el crecimiento de bacterias heterotróficas y aumenta la productividad del resultado (Manan y otros, 2024).

Sistemas de Acuicultura de Recirculación (RAS)

Sistemas de producción acuícola con agua que se reutiliza a través de sistemas de biofiltración y mecánicos, proporcionando un control preciso de la calidad del agua y reduciendo el uso de agua (Rajan y otros, 2023).

Sólidos Suspendidos Totales (TSS)

Sus niveles muestran la concentración de flóculos en el agua; un TSS excesivo es el indicador para un drenaje o intercambio de agua para evitar desequilibrios de calidad (Manan y otros, 2024).

TAN: Nitrógeno Amoniacal Total

Es el nivel de concentración del amonio libre e iónico en el agua, es una medida importante para la toxicidad en RAS (Chen y otros, 2024).

Turbidez (NTU)

Un indicador de la concentración de sólidos suspendidos y es un parámetro importante para la predicción de la carga de materia orgánica y la demanda de aireación; se ha utilizado como una variable predictiva de AIoT (Chiu y otros, 2022).

2.4 Marco legal

La construcción del proyecto AquaNutri AI Móvil se basa en un paquete basado en las normas de acuicultura colombianas, las normas de inteligencia artificial, la protección de datos personales y los derechos de autor del software, lo que lo hace técnica, legal y éticamente pertinente.

Normativa en Acuicultura

La práctica de la acuicultura en Colombia se basa en la Ley 13 de 1990, que establece el Estatuto General de Pesca que reconoce la necesidad de promover sistemas de producción sostenibles. Esta norma está acompañada por el Decreto 1071 de 2015, a través del cual se unifican las regulaciones que rigen el desarrollo de actividades acuícolas, en cuanto a requisitos técnicos, ambientales y administrativos.

Por su parte, el Decreto 1835 de 2021 emitido por el Gobierno Nacional en Colombia modifica y actualiza el marco regulatorio del sector agrícola, pesquero y de desarrollo rural. Este decreto establece las normas fundamentales para la dirección, gestión y promoción de la pesca y la acuicultura, señalando la necesidad de modernizar estas directrices para que se ajusten al avance tecnológico e informativo del país, con el fin de fortalecer la gestión estatal y fomentar la sostenibilidad del sector.

En el artículo 2.16.1.1.1, define su ámbito de aplicación para el desarrollo de la acuicultura y pesca competitiva y sostenible en Colombia, enfatizando la promoción de proyectos que contribuyan al uso sostenible de los recursos y la seguridad alimentaria nacional (Presidencia de la República de Colombia, 2025).

Complementando esta normativa sectorial, el proyecto se alinea con el Plan Nacional para el Desarrollo de la Acuicultura Sostenible - PlaNDAS, promovido por la AUNAP, el cual establece los ejes estratégicos para el crecimiento de la acuicultura en el país. Este plan reconoce la importancia de la tecnificación y digitalización del sector como estrategias clave para incrementar la productividad y reducir impactos ambientales.

Normativa sobre Protección de Datos Personales

El tratamiento de datos personales generados por sensores y plataformas digitales debe cumplir con la Ley Estatutaria 1581 de 2012 y su reglamentación parcial mediante el Decreto 1377 de 2013, que establecen los principios de legalidad, finalidad, libertad, seguridad y confidencialidad. Además, la Circular Externa 002 de 2024, emitida por la Superintendencia de Industria y Comercio, establece lineamientos para la aplicación de sistemas de IA, exigiendo la realización de evaluaciones de impacto en privacidad, principios de proporcionalidad y transparencia en el uso de algoritmos predictivos (República de Colombia - SIC, 2024).

Normativa sobre Derechos de Autor y Software

El desarrollo del sistema inteligente y la aplicación móvil está protegido por la Ley 23 de 1982, que regula los derechos de autor en Colombia, incluyendo el software como obra literaria. Esta ley fue modificada por la Ley 1915 de 2018, la cual introduce nuevas disposiciones para adaptarse a los entornos digitales, reforzando los derechos morales y patrimoniales de los desarrolladores de soluciones tecnológicas (Congreso de la República de Colombia, 2018).

Normativa y Política sobre Inteligencia Artificial

Colombia ha avanzado en la formulación de lineamientos para el desarrollo de la IA con la publicación del documento CONPES 4144 de 2025, el cual actualiza y reemplaza al CONPES 3975 de 2019. Esta política establece un marco estratégico nacional para el desarrollo e implementación de la IA con un enfoque centrado en los derechos humanos, la ética digital, la innovación responsable y la sostenibilidad. El CONPES 4144 contempla lineamientos para el uso de IA en sectores productivos como la agricultura, educación y salud, promoviendo la adopción de tecnologías como el aprendizaje automático, visión por computadora y control automatizado, elementos centrales en el proyecto *AquaNutri AI Móvil* (Departamento Nacional de Planeación - República de Colombia, 2025).

De forma complementaria, en el Congreso de la República se han presentado proyectos de ley como el 091, 130 y 154 de 2023-2024, que buscan establecer un marco regulatorio específico para la IA en Colombia, abordando temas como transparencia algorítmica, derechos de los usuarios y regulación del uso de IA en el empleo y la educación.

3. Marco Metodológico

El proyecto AquaNutri AI Móvil se desarrollará bajo un enfoque cuantitativo, aplicado y experimental, orientado a diseñar, implementar y validar un sistema inteligente con interfaz móvil que permita al productor capturar y almacenar datos fisicoquímicos y zootécnicos. Este sistema clasificará la calidad del agua en sistemas acuícolas (Biofloc y RAS), emitirá alertas automáticas ante desviaciones críticas y generará recomendaciones para optimizar el manejo del cultivo, apoyando así la gestión inteligente de los parámetros y la toma de decisiones por parte de los productores.

3.1 Enfoque metodológico

El proyecto empleará un enfoque cuantitativo y experimental, usando análisis predictivo y correlacionales mediante algoritmos avanzados de aprendizaje automático. El análisis correlacional permitirá identificar relaciones entre parámetros fisicoquímicos y zootécnicos, mientras que el análisis predictivo anticipará condiciones críticas para optimizar la calidad del agua.

Desde la perspectiva del montaje de la aplicación y la integración de la inteligencia artificial, AquaNutri AI Móvil se concibe bajo una arquitectura cliente-servidor, donde la interfaz móvil (cliente) será el punto de entrada de datos y visualización de resultados, mientras que los modelos de Machine Learning (ML) y la base de datos residirán en la nube (servidor).

El flujo de datos iniciará con la captura manual de parámetros fisicoquímicos y zootécnicos por parte del productor a través de un formulario intuitivo en la aplicación móvil. Estos datos, una vez ingresados, serán enviados de manera segura y automática a una base de datos alojada en la nube (por ejemplo, Google Drive u otro servicio en la nube que se determine).

Para el módulo de análisis, los datos almacenados en la nube servirán como insumo principal. Se emplearán modelos de Machine Learning avanzados para el procesamiento y análisis. Específicamente, para la identificación de relaciones y dependencias entre variables, se aplicarán técnicas de análisis correlacional como el **coeficiente de correlación de Pearson y la regresión múltiple**. Para la anticipación de condiciones críticas y la generación de recomendaciones, se entrenarán algoritmos predictivos basados en redes neuronales y modelos ensamblados (por ejemplo, Random Forest o Gradient Boosting). Estos modelos serán los encargados de procesar la alta variabilidad y las interacciones no lineales típicas de las series temporales de calidad del agua, y su salida se traducirá en indicadores de calidad y recomendaciones prácticas para el manejo del cultivo. La aplicación también integrará la funcionalidad de *alerts* (alertas) remotas y notificaciones cuando los parámetros excedan los umbrales óptimos definidos, activando estas alertas de forma automática.

3.2 Población y muestra

Para el desarrollo y validación del sistema AquaNutri AI Móvil, la población y muestra se definirán en función de los datos de parámetros físico - químicos que determinan la calidad del agua y los usuarios (productores acuícolas) que interactuarán con la aplicación.

Población de Datos

La población de datos estará compuesta por el conjunto total de registros de parámetros fisicoquímicos y zootécnicos de sistemas acuícolas tipo Biofloc y RAS. Esto incluye tanto los datos históricos disponibles de diversas fuentes y granjas, como aquellos que serán generados y capturados en tiempo real por los productores durante las fases de desarrollo y validación del prototipo de la aplicación.

Muestra de Datos

La muestra de datos para el entrenamiento, prueba y validación de los modelos de inteligencia artificial incluirá un conjunto representativo de registros históricos, seleccionados por su consistencia, completitud y relevancia para los sistemas Biofloc y RAS obtenidos de fuentes científicas. Esta muestra se complementará cuando se pueda con los datos capturados manualmente por los productores participantes durante la fase de validación en campo. Se buscará asegurar la variabilidad necesaria para optimizar la robustez de los algoritmos predictivos y correlacionales.

Población de Usuarios

La población objetivo de usuarios para la validación de la interfaz móvil y la usabilidad del sistema AquaNutri AI Móvil serán pequeños y medianos productores acuícolas que operan sistemas Biofloc y/o RAS en diversas regiones de Colombia, y que actualmente realizan la gestión y monitoreo de sus parámetros de calidad del agua de manera manual o semi-automatizada.

Muestra de Usuarios

Se seleccionará una muestra de productores acuícolas que cumplan con los criterios de la población, para participar activamente en las pruebas de usabilidad del prototipo de la aplicación y proporcionar retroalimentación cualitativa sobre su funcionalidad, facilidad de uso y la pertinencia de las recomendaciones generadas. El tamaño y método de selección de esta muestra se detallará en la fase de diseño de la validación.

3.3 Fases de Desarrollo e Implementación del Sistema AquaNutri AI Móvil

Para alcanzar el objetivo general de desarrollar la plataforma AquaNutri AI Móvil, el proyecto se estructurará en cuatro fases principales de desarrollo e implementación. Estas fases están diseñadas para construir incrementalmente el sistema, asegurando que cada componente

cumpla con los requisitos establecidos y se valide antes de la integración final. Se detallará el 'cómo' se construirá el aplicativo en cada etapa.

Fase 1: Desarrollo e Implementación de la Interfaz Móvil

Objetivo: Implementar una interfaz móvil intuitiva que permita al productor capturar y almacenar eficientemente los parámetros fisicoquímicos y zootécnicos de los sistemas Biofloc y/o RAS.

Descripción y Actividades: En esta fase, se priorizará el diseño centrado en el usuario UI/UX (*User Interface / User Experience*) para garantizar una experiencia amigable y accesible, incluso para productores con limitada experiencia tecnológica.

1. **Diseño de la Estructura Visual y Funcional de la Interfaz:** Se realizarán bocetos y prototipos de alta fidelidad utilizando herramientas de diseño (ejemplo: Figma) para definir la navegación, el *layout* y los componentes visuales de la aplicación. Se considerará la adaptabilidad a diferentes dispositivos móviles y sistemas operativos (Android/iOS).
2. **Programación del Formulario de Captura de Datos Fisicoquímicos y Zootécnicos:** Se desarrollará el *frontend* de la aplicación móvil. El formulario permitirá la digitación manual de valores para parámetros clave como oxígeno disuelto (DO), pH, temperatura, amonio, nitrito, nitrato, sólidos sedimentables, relación C/N, entre otros. También se incluirán campos para variables zootécnicas como el crecimiento (peso), densidad y la mortalidad. El desarrollo se realizará utilizando lenguajes y frameworks apropiados para aplicaciones móviles (Ejemplo: React Native, Flutter, Kotlin/Swift, entre otros).

3. **Implementación del Almacenamiento Automático en la Nube:** Se configurará la conectividad del *frontend* con una base de datos en la nube (Ejemplo: Google Firestore/Firebase, AWS DynamoDB, u otra base de datos NoSQL/SQL seleccionada) para el almacenamiento seguro y automático de los datos capturados. Esto garantizará la persistencia y disponibilidad de la información para posteriores análisis.
4. **Pruebas de Funcionalidad Básica con Datos Simulados:** Se llevarán a cabo pruebas unitarias y de integración para verificar que la captura de datos, el almacenamiento en la nube y la recuperación de información funcionen correctamente. Se utilizarán conjuntos de datos simulados para evaluar la robustez y eficiencia de la base de datos.
5. **Validación con Usuarios Reales (Productores) para Verificar Usabilidad:** Se realizarán pruebas piloto con una pequeña muestra de productores acuícolas (definida en la sección 3) para obtener retroalimentación sobre la usabilidad de la interfaz, la claridad de los campos de entrada y la facilidad general de navegación. Esta retroalimentación se utilizará para realizar ajustes iterativos al diseño.

Fase 2: Implementación del Sistema de Alertas Automáticas

Objetivo: Diseñar e implementar un sistema de alertas automáticas que notifique de inmediato las desviaciones críticas en los rangos óptimos de calidad del agua, basándose en los datos ingresados por el productor.

Descripción y Actividades: Esta fase se centrará en el desarrollo de la lógica de negocio para la detección de anomalías y la configuración de un sistema de notificación efectivo.

1. **Definición de Rangos Óptimos de Parámetros de Calidad del Agua:** Se cargarán en el sistema los rangos óptimos consolidados para cada parámetro fisicoquímico (según

la Tabla 2 del Marco Teórico), que servirán como umbrales de referencia para la detección de desviaciones.

2. **Programación de Condiciones de Activación de Alertas en la App Móvil:** Se desarrollará la lógica *backend* que, al recibir los datos ingresados, compare los valores con los rangos óptimos predefinidos. Se implementarán reglas de negocio y condicionales para disparar alertas cuando un parámetro exceda o caiga por debajo de su umbral crítico.
3. **Integración del Sistema de Notificaciones (Visual y Sonora):** Se implementarán mecanismos de notificación dentro de la aplicación móvil (ejemplo: mensajes *push*, banners, iconos de advertencia en el tablero principal) y, si es viable y pertinente, opciones de alerta sonora o por correo electrónico/SMS (previa consideración de privacidad de datos y viabilidad técnica).
4. **Simulación de Condiciones Críticas para Prueba de Alertas:** Se generarán y se ingresarán manualmente datos de prueba que simulen condiciones fuera de los rangos óptimos (ejemplo: bajo oxígeno disuelto, pH extremo, amonio elevado) para verificar que el sistema de alertas se active de manera precisa y oportuna.
5. **Ajustes de Umbrales y Validación de Oportunidad de Respuesta:** Basado en los resultados de las pruebas de simulación y la retroalimentación cualitativa de los usuarios, se ajustarán los umbrales de alerta para minimizar falsos positivos y negativos, y se evaluará la velocidad de respuesta del sistema.

Fase 3: Desarrollo del Módulo de Análisis Correlacional y Predictivo

Objetivo: Desarrollar módulos de análisis correlacional y predictivo que generen indicadores de calidad del agua y recomendaciones específicas para optimizar el manejo del cultivo.

Descripción y Actividades: Esta fase constituye el corazón de la inteligencia del sistema, donde se aplican las técnicas de *Machine Learning* (ML) para transformar los datos en información accionable.

1. **Construcción de la Base de Datos Histórica y en Tiempo Real:** Se consolidará la base de datos con los registros capturados en la Fase 1 y se integrarán, si aplica, conjuntos de datos históricos de fuentes científicas o proyectos previos (según lo definido en la sección 3 de Muestra de Datos). Esta base de datos será optimizada para consultas y para servir como *dataset* de entrenamiento para los modelos de ML.
2. **Análisis Exploratorio de Datos (EDA) y Limpieza de Registros:** Se realizará un EDA exhaustivo para entender la distribución, correlaciones iniciales y posibles anomalías en los datos. Se aplicarán técnicas de limpieza (manejo de datos faltantes, valores atípicos, normalización) para preparar los datos para el entrenamiento de los modelos de ML. Se considera la imputación de datos faltantes mediante modelos de ML para mantener la continuidad (Shin y otros, 2025).
3. **Aplicación de Análisis Correlacional (Pearson, Regresión Múltiple):** Se implementarán algoritmos para identificar relaciones estadísticas significativas entre los distintos parámetros fisicoquímicos (ejemplo: temperatura vs. oxígeno disuelto, pH vs. amonio) y entre estos y las variables zootécnicas (ejemplo: oxígeno disuelto vs. FCR, amonio vs. mortalidad) (Granda Jaramillo, 2022) (Hernández Mancipe y otros, 2019). Esto permitirá comprender las interdependencias del sistema acuícola.

4. Entrenamiento de Modelos Predictivos (Machine Learning (ML)) para Variables

Críticas: Se seleccionarán y entrenarán diversos modelos de ML (ejemplo: Redes Neuronales, *Random Forest*, *Gradient Boosting*, etc.) para predecir tendencias y riesgos en parámetros críticos (ejemplo: predicción de futuras caídas de oxígeno, aumento de amonio). Se evaluará la robustez y generalización de los modelos (Majid & Setiawan, 2024). La optimización bayesiana (Chiu y otros, 2022) y los algoritmos genéticos podrán ser exploradas para el ajuste de hiper parámetros.

5. Generación de Indicadores y Recomendaciones:

Las salidas de los modelos predictivos y correlacionales se traducirán en indicadores de calidad del agua de fácil interpretación y en recomendaciones prácticas y personalizadas para el productor (ejemplo: "Aumentar aireación", "Revisar alimentación", "Aplicar bicarbonato", entre otros). Se explorará el uso de técnicas de interpretabilidad de IA como SHAP para explicar la influencia de cada variable en las predicciones (Chiu y otros, 2022).

Fase 4: Validación Integral del Sistema

Objetivo: Validar la precisión, efectividad, usabilidad y oportunidad de respuesta del sistema AquaNutri AI Móvil en escenarios simulados y con la retroalimentación de usuarios reales, preparándolo para un despliegue como prototipo demostrativo.

Descripción y Actividades: Esta fase se centrará en las pruebas finales y el ajuste del prototipo antes de su posible lanzamiento o implementación a mayor escala.

1. Definición de Métricas de Evaluación:

Se establecerán métricas cuantitativas (ejemplo: precisión de las predicciones, sensibilidad de las alertas, tiempo de respuesta) y cualitativas (ejemplo: satisfacción del usuario, facilidad de uso, utilidad percibida) para evaluar el rendimiento del sistema.

2. **Ejecución de Pruebas Integradas en Escenarios Simulados:** Se realizarán pruebas de extremo a extremo, simulando ciclos de cultivo completos con variaciones en los parámetros para evaluar la interacción entre la captura de datos, las alertas y el módulo analítico.
3. **Evaluación de la Funcionalidad de Cada Módulo (Captura, Alertas, Predicción):** Se ejecutarán pruebas específicas para cada componente, asegurando que el formulario de captura funcione sin errores, que las alertas se disparen en el momento y con el mensaje correcto, y que las predicciones y recomendaciones sean coherentes y precisas.
4. **Análisis de Retroalimentación por Parte del Usuario (Productores):** Se implementarán encuestas, entrevistas y grupos focales con la muestra de usuarios (definida en la sección 3) para recopilar su percepción, identificar puntos de mejora y evaluar el impacto potencial de la herramienta en su toma de decisiones.
5. **Ajuste Final de la Plataforma antes del Despliegue como Prototipo Demostrativo:** Basado en los resultados de las pruebas y la retroalimentación de los usuarios, se realizarán los ajustes finales al software. Se generará un prototipo funcional listo para demostraciones y una posible implementación piloto en campo. Se incluirá la documentación técnica completa del diseño, implementación y validación.

3.4 Técnicas e instrumentos de recolección de datos

La captura de datos para el sistema AquaNutri AI Móvil se realizará en tiempo real mediante digitación manual por parte de los productores en la interfaz móvil diseñada para este fin. Es importante destacar que, si bien la entrada de datos en la aplicación será manual, la información provendrá de las mediciones realizadas por los productores utilizando sus propios procedimientos e instrumentos físicos de medición de parámetros fisicoquímicos (ejemplo:

medidores de oxígeno disuelto, pH, temperatura, turbidez, kits de amonio/nitrito/nitrato, etc.) y de registros zootécnicos (ejemplo: pesajes de biomasa, conteo de mortalidad, registro de consumo de alimento) ya existentes en sus unidades productivas. Estos datos serán automáticamente almacenados en una base de datos alojada en la nube (Google Drive u otro servicio en la nube según se determine en el proyecto), la cual servirá como insumo principal para los modelos predictivos y correlacionales desarrollados en las fases subsiguientes.

La recolección de datos no se realizará mediante sensores IoT, sino mediante captura manual por parte del productor, utilizando sus instrumentos tradicionales de medición. Esta información será digitada directamente en la aplicación móvil, la cual notificará y almacenará automáticamente los datos en la nube para su posterior análisis.

3.5 Procesamiento y análisis de datos

El procesamiento y análisis de los datos recolectados se ejecutará como parte de la Fase 3 del desarrollo del sistema. Este proceso incluirá el análisis exploratorio (EDA), la normalización, segmentación y validación de la calidad de los datos, tanto los históricos como los capturados manualmente. Se aplicarán técnicas estadísticas correlacionales (ejemplo: coeficiente de correlación de Pearson, regresión múltiple) para identificar relaciones entre parámetros, y algoritmos predictivos avanzados (ejemplo: redes neuronales, modelos ensamblados) para anticipar condiciones críticas. El objetivo final es la generación de indicadores de calidad, recomendaciones específicas para el manejo del cultivo y la activación de alertas automáticas.

3.6 Validación del sistema

La validación integral del sistema AquaNutri AI Móvil se llevará a cabo como la Fase 4 del proyecto. Este proceso incluirá simulaciones para medir la precisión y efectividad de los modelos predictivos y correlacionales desarrollados. Adicionalmente, se realizarán pruebas de

funcionalidad y se evaluará la oportunidad de respuesta del sistema de alertas automáticas, así como la evaluación práctica de la pertinencia y utilidad de las recomendaciones generadas para los productores.

3.7 Hipótesis

H1: La implementación de la plataforma inteligente AquaNutri AI Móvil, con su interfaz de captura de datos, sistema de alertas automáticas y módulos de análisis correlacional y predictivo, optimizará significativamente la gestión de la calidad del agua en sistemas acuícolas Biofloc y RAS en Colombia, lo que se traducirá en una mejora de la productividad, la sostenibilidad ambiental y la eficiencia operativa de las unidades productivas.

3.8 Variables del estudio

Las variables del estudio, que serán capturadas y analizadas por el sistema AquaNutri AI Móvil, se clasifican en:

- **Variables Físicoquímicas:** Incluyen parámetros críticos para la calidad del agua en sistemas acuícolas intensivos como Biofloc y RAS, tales como el oxígeno disuelto (DO), temperatura, pH, turbidez, amonio total (TAN, que comprende $\text{NH}_3/\text{NH}_4^+$), nitrito (NO_2^- -N), nitrato (NO_3^- -N), alcalinidad, dióxido de carbono (CO_2), dureza total/calcio, fósforo (P), sólidos sedimentables/suspendidos y salinidad. Estos parámetros son fundamentales para la salud de los organismos cultivados y la estabilidad del sistema.
- **Variables Zootécnicas:** Son indicadores de rendimiento productivo y bienestar animal que serán registrados por el productor a través de la interfaz móvil, basándose en mediciones periódicas (ejemplo: muestreos de peso, mortalidad, entre otros) y registros

de eventos. Incluyen el crecimiento (peso promedio, ganancia de peso), la mortalidad y el Factor de Conversión Alimenticia (FCR).

3.9 Validación Experimental de la Hipótesis

Para verificar la hipótesis, se diseñará un protocolo experimental que permita evaluar el impacto real de la plataforma en entornos productivos reales. Es validación será de tipo cuasiexperimental con pretest y posttest (Anexo A y B), mediante comparación antes y después de la implementación del sistema.

3.9.1 Diseño Experimental de Validación

El diseño experimental de validación planteado se divide en cinco fases (tabla No. 3).

Tabla 3

Diseño Experimental de Validación

Fase	Descripción
Fase 1	Selección de al menos dos unidades productivas piloto (una en Biofloc, otra en RAS).
Fase 2	Aplicación de un diagnóstico inicial (pretest): medición de parámetros y rendimiento actual.
Fase 3	Implementación de la plataforma AquaNutri AI Móvil durante un ciclo productivo completo.
Fase 4	Registro manual de datos por el productor a través de la app móvil.
Fase 5	Evaluación final (postest): análisis de los resultados productivos, ambientales y energéticos.

Nota. Elaborado por el autor.

3.9.2 Indicadores de Validación

La validación se basará en la comparación de los siguientes indicadores clave antes y después del uso de AquaNutri AI Móvil:

Tabla 4

Indicadores de Validación

Indicador	Unidad/Métrica	Fuente esperada
Eficiencia de conversión alimenticia (FCR)	Kg alimento / Kg biomasa	Registro zootécnico
Mortalidad	Porcentaje (%) acumulado durante el ciclo	Bitácora del productor
Consumo energético de aireadores	kWh / ciclo	Medidor de consumo de energía
Eventos críticos de calidad de agua	Número de alertas críticas generadas	Módulo de alertas de la aplicación AquaNutri AI
Cumplimiento de rangos óptimos	Porcentaje (%) del tiempo en parámetros óptimos	Análisis de base de datos de obtenido de la aplicación
Nivel de respuesta del productor	Porcentaje (%) de alertas respondidas	Logs de la aplicación
Percepción del usuario	Escala Likert 1-5	Encuesta semiestructurada

Nota. Elaborado por el autor.

3.9.3 Herramientas de Análisis

Se aplicarán pruebas estadísticas de comparación de medias (t-student para muestras relacionadas) para determinar mejoras significativas en los indicadores cuantitativos.

Se usarán gráficos de evolución temporal por parámetros, con línea base y seguimiento.

El análisis cualitativo se complementará con entrevistas cortas al productor sobre la experiencia de uso de la plataforma.

3.9.4 Criterios de Aceptación de la Hipótesis

Se tendrán en cuenta que la hipótesis de valida si:

- Se reduce el FCR en al menos un 10% en comparación con el ciclo previo.
- El porcentaje de tiempo con parámetros fuera de rango se reduce en mínimo 20%.

- La plataforma genera al menos 5 alertas útiles durante el ciclo.
- El productor reporta una percepción positiva mayor o igual ($\geq$) 4/5 de la encuesta de satisfacción.

4. Cronograma de Actividades del Proyecto

El desarrollo del proyecto AquaNutri AI Móvil se ha estructurado en cuatro fases principales, cada una con actividades específicas que responden a los objetivos del proyecto. A continuación, se presenta el cronograma general de actividades del proyecto en la Tabla No. 3, el cual incluye la fase correspondiente, las actividades detalladas, su duración estimada y el mes en que se ejecutarán.

Tabla 5

Cronograma de Actividades

Fase	Actividad	Duración estimada	Mes de ejecución
Fase 1: Desarrollo e Implementación de la Interfaz Móvil	Diseño de la estructura visual y funcional de la interfaz	5 días	Mes 1
Fase 1: Desarrollo e Implementación de la Interfaz Móvil	Programación del formulario de captura de datos	5 días	Mes 1
Fase 1: Desarrollo e Implementación de la Interfaz Móvil	Implementación de almacenamiento en la nube	4 días	Mes 1
Fase 1: Desarrollo e Implementación de la Interfaz Móvil	Pruebas de funcionalidad con datos simulados	4 días	Mes 1
Fase 1: Desarrollo e Implementación de la Interfaz Móvil	Validación con usuarios reales (productores) para verificar usabilidad	5 días	Mes 1
Fase 2: Implementación del Sistema de Alertas Automáticas	Definición de rangos óptimos de parámetros	5 días	Mes 2
Fase 2: Implementación del Sistema de Alertas Automáticas	Programación de condiciones de activación de alertas	4 días	Mes 2

Fase	Actividad	Duración estimada	Mes de ejecución
Fase 2: Implementación del Sistema de Alertas Automáticas	Integración del sistema de notificaciones	4 días	Mes 2
Fase 2: Implementación del Sistema de Alertas Automáticas	Simulación de condiciones críticas para prueba de alertas	3 días	Mes2
Fase 2: Implementación del Sistema de Alertas Automáticas	Ajuste umbrales y validación de oportunidades de respuesta	5 días	Mes 2
Fase 3: Desarrollo del Módulo de Análisis Correlacional y Predictivo	Construcción de la base de datos históricas y en tiempo ral	6 días	Mes 3
Fase 3: Desarrollo del Módulo de Análisis Correlacional y Predictivo	Análisis exploratorio de datos (EDA) y limpieza de registros	5 días	Mes 3
Fase 3: Desarrollo del Módulo de Análisis Correlacional y Predictivo	Aplicación de análisis correlacional	5 días	Mes 3
Fase 3: Desarrollo del Módulo de Análisis Correlacional y Predictivo	Entrenamiento de modelos predictivos (Machine Learning (ML))	6 días	Mes 3
Fase 3: Desarrollo del Módulo de Análisis Correlacional y Predictivo	Generación de indicadores e interpretación de resultados para recomendaciones	5 días	Mes 3
Fase 4: Validación integral del Sistema	Definición de métricas de evaluación	3 días	Mes 4
Fase 4: Validación integral del Sistema	Ejecución de pruebas integradas en escenarios simulados	5 días	Mes 4
Fase 4: Validación integral del Sistema	Evaluación de funcionalidad de cada módulo	4 días	Mes 4
Fase 4: Validación integral del Sistema	Análisis de retroalimentación por parte de usuario (productores)	4 días	Mes 4
Fase 4: Validación integral del Sistema	Ajuste final del sistema y preparación del prototipo demostrativo	6 días	Mes 4

Nota. Elaborado por el autor.

Total duración estimada del proyecto: 5 meses.

5. Presupuesto Estimado del Proyecto

A continuación, se presenta una estimación de costos para el desarrollo completo del anteproyecto AquaNutri AI Móvil, considerando recursos técnicos, licencias, infraestructura digital y tiempo académico invertido. Todos los valores están expresados en pesos colombianos (COP).

Tabla 6

Presupuesto Estimado del Proyecto AquaNutri AI Móvil

Item	Descripción	Valor estimado (\$COP)
1. Valoración de Tiempo del Investigador/Estudiante	Dedicación estimada de 240 horas a \$100.000/ hora	\$24.000.000
2. Acceso a base de datos científicos	Licencias y descargas de artículos indexados	\$500.000
3. Infraestructura computacional (cloud)	Uso de servidores cloud y energía para procesamiento intensivo	\$2.500.000
4. Software y herramientas analíticas	Licencias opcionales (como MATLAB, herramientas de visualización avanzada) dando prioridad a código abierto.	\$1.000.000
5. Diseño y desarrollo de aplicación móvil (UI/UX)	Herramientas de prototipado, testing y documentación técnica, el costo del diseño UI/UX de personal está incluido en Personal Técnico Investigador.	\$1.200.000
6. Consultoría especializada (Estadística y ML)	Costos de consultoría esporádica en control inteligente y validación estadística de modelos de IA	\$4.000.000
7. Publicación y divulgación académica	Traducción, edición y publicación en revista especializada	\$2.200.000
Subtotal		\$35.400.000
8. Imprevistos	Variaciones menores de presupuesto	\$3.540.000
Total estimado del proyecto		\$38.940.000

Nota. Elaborado por el autor.

El presupuesto estimado para el desarrollo de este trabajo de grado, enfocado en el anteproyecto AquaNutri AI Móvil, asciende a \$38.940.000 COP. Esta estimación se ha elaborado para reflejar de manera integral los recursos necesarios para la consecución de los objetivos

propuestos, considerando tanto los costos directos de implementación como la valoración del esfuerzo intelectual y técnico invertido por el investigador.

El primer rubro, y el más significativo, corresponde a la Valoración del Tiempo del Investigador/Estudiante, estimado en \$24.000.000 COP. Aunque en el contexto de un trabajo de grado el tiempo del estudiante no representa una erogación directa, este valor se calcula con base en una dedicación de 240 horas distribuidas a lo largo de los cuatro meses del proyecto, aplicando una tarifa de \$100.000 COP por hora. Este ítem busca cuantificar el costo de oportunidad o el valor de mercado del trabajo especializado que un profesional con las competencias necesarias (zootecnia, desarrollo de software, inteligencia artificial, gerencia agropecuaria) dedicaría a un proyecto de esta envergadura. Es una forma de visibilizar la inversión de capital humano y conocimiento que el estudiante aporta al proyecto.

Para el Acceso a base de datos científicos, se ha destinado un valor de \$500.000 COP. Este monto permitirá la adquisición de licencias o el acceso a artículos científicos específicos que puedan no estar cubiertos por las suscripciones institucionales, asegurando la fundamentación teórica y técnica del proyecto.

El ítem de Infraestructura computacional (cloud) se ha estimado en \$2.500.000 COP. Este valor es crucial para cubrir los costos de uso de servidores en la nube, los cuales son indispensables para el almacenamiento de la base de datos del proyecto y, fundamentalmente, para el procesamiento y entrenamiento intensivo de los algoritmos de Machine Learning (ML) y las simulaciones requeridas durante las fases de desarrollo y validación del sistema.

En cuanto al Software y herramientas analíticas, se ha considerado un valor de \$1.000.000 COP para licencias opcionales de herramientas especializadas de visualización avanzada o análisis

que puedan complementar las soluciones de código abierto, las cuales serán priorizadas en todo momento para optimizar los costos.

El rubro de Diseño y herramientas UI/UX, por un valor de \$1.200.000 COP, contempla específicamente las herramientas de prototipado y testing, así como los recursos para la documentación técnica. El trabajo de diseño de interfaz y experiencia de usuario realizado por el investigador principal está incluido en la "Valoración del Tiempo del Investigador/Estudiante".

Para la Consultoría especializada (Estadística y ML), se ha asignado un monto de \$4.000.000 COP. Este presupuesto está destinado a cubrir la posible necesidad de apoyo puntual de expertos externos en estadística avanzada o en la optimización de algoritmos de ML, garantizando la rigurosidad metodológica y la calidad técnica del análisis de datos.

Finalmente, para la Publicación y divulgación académica, se ha presupuestado \$2.200.000 COP. Este valor está destinado a cubrir los posibles costos de traducción y edición profesional del manuscrito, así como los honorarios por procesamiento de artículos (APC) en revistas especializadas, lo que permitirá la difusión de los hallazgos del trabajo de grado en la comunidad científica.

Se ha incluido un ítem de Imprevistos por un valor de \$3.540.000 COP, que representa el 10% del subtotal de los costos estimados. Este porcentaje es una provisión estándar para cubrir cualquier variación menor o necesidad no anticipada que pueda surgir durante el desarrollo y la fase final del proyecto.

Este presupuesto consolidado, ajustado al contexto de un trabajo de grado, refleja un enfoque realista y una asignación de recursos adecuada para el alcance y la ambición del anteproyecto AquaNutri AI Móvil, buscando maximizar su viabilidad técnica, su aporte académico y su potencial impacto en el sector acuícola colombiano.

6. Resultados Esperados

Al finalizar el proyecto AquaNutri AI Móvil, se espera disponer de una plataforma móvil completamente funcional que permita al productor acuícola ingresar manualmente los parámetros fisicoquímicos y zootécnicos de sus cultivos. Esta información se almacenará automáticamente en una base de datos en la nube, asegurando la disponibilidad y trazabilidad de los datos para posteriores análisis.

Asimismo, se contará con un sistema de alertas automáticas integrado en la plataforma, el cual advertirá al productor cuando algún parámetro se encuentre fuera de los rangos óptimos definidos. Estas alertas se validarán en función de su precisión, velocidad de respuesta y utilidad práctica para la toma de decisiones inmediatas.

Como resultado técnico fundamental, se desarrollará un módulo de análisis basado en algoritmos de aprendizaje automático, el cual permitirá establecer correlaciones significativas entre variables críticas, y predecir condiciones potencialmente riesgosas en la calidad del agua. Este módulo proporcionará recomendaciones personalizadas e indicadores interpretables por el productor.

También se consolidará una base de datos estructurada, que integrará datos históricos y los capturados por los usuarios en tiempo real. Esta base de datos servirá como insumo para los modelos predictivos, fortaleciendo el componente analítico del sistema.

El sistema será validado mediante pruebas funcionales y retroalimentación de usuarios reales, lo que permitirá obtener un prototipo demostrativo ajustado a las condiciones operativas de sistemas acuícolas colombianos.

Finalmente, se producirá documentación técnica completa sobre el diseño, implementación y validación de la plataforma, además de un informe final con resultados y, eventualmente, un artículo académico que permitirá la difusión del conocimiento generado.

Entre los indicadores que permitirán evaluar estos resultados se encuentran: el porcentaje de funcionalidad validada del sistema, la oportunidad de las alertas automáticas, la precisión de los modelos predictivos, el nivel de satisfacción del usuario y el volumen de datos registrados mensualmente.

6.1 Modelo de Negocio Propuesto

El modelo de negocio de AquaNutri AI Móvil se fundamenta en el enfoque B2B (Business-to-Business) y B2F (Business-to-Farmer), orientado a ofrecer una solución digital escalable y asequible para pequeños, medianos y grandes acuicultores en Colombia que utilicen sistemas Biofloc o RAS.

Este modelo busca monetizar el uso de la plataforma mediante dos vías:

a. Suscripción Freemium (App + Plataforma Cloud)

- **Versión gratuita:** funcionalidades básicas como captura de datos manual, visualización de parámetros e historial.
- Versión premium: incluye sistema de alertas automáticas, análisis predictivo, correlación multivariable, soporte técnico y acceso compartido en línea.

b. Licenciamiento Institucional

Para asociaciones de productores, universidades, centros de investigación o entidades territoriales interesadas en usar la plataforma de forma masiva.

6.2 Propuesta de Valor

La propuesta de valor que se busca alcanzar es (tabla 7):

Tabla 7

Propuesta de Valor

Componente	Valor Propuesto
Productividad	Mejorar del FCR, menor mortalidad, optimización del manejo
Sostenibilidad	Menor uso de energía por control de aireación, reducción de desperdicios
Toma de decisiones	Predicción anticipada de escenarios críticos con base en datos históricos
Adopción tecnológica	Interfaz sencilla, adaptable a bajos niveles de alfabetización digital
Escalabilidad	Plataforma flexible y modular, con posibilidad de expansión futura

Nota. Elaborado por el autor.

6.3 Presupuesto del Modelo de Negocio (MVP funcional)

Este presupuesto se enfoca en la construcción y validación de un prototipo mínimo viable (MVP) con funcionalidad operativa, orientada a su futura escalabilidad comercial en el sector acuícola.

Tabla 8

Presupuesto Estimado para Desarrollo de MVP AquaNutri AI Móvil

Rubro	Descripción	Valor estimado (\$COP)
Desarrollo de App móvil funcional (Flutter + Firebase)	Captura de datos, visualización, alertas	\$2.500.000
Backend y base de datos cloud	Estructura inicial en Firebase o Google Sheets	\$400.000
Inferfaz web opcional para escritorio	Panel de monitoreo web simple	\$800.000
Asesoría técnica en IA y modelos predictivos	Validación inicial de lógica de análisis	\$1.200.000
Validación en campo	Encuestas, pruebas con productores, logística	\$600.000
Hosting y servicios en la nube (6 meses)	API REST, autenticación, almacenamiento	\$600.000
Material de capacitación	Manual digital, videotutoriales	\$200.000
Total estimado MVP funcional		\$6.000.000

Nota. Elaborado por el autor, este presupuesto corresponde al componente técnico-productivo y será utilizado para pruebas funcionales con usuarios reales.

6.4 Esquema de Ingresos Proyectado (Escalamiento)

Una vez validado el MVP, se propone el siguiente modelo de ingresos para su escalamiento en el sector productivo acuícola:

Tabla 9

Esquema de Ingresos Esperados

Modalidad	Frecuencia	Valor Estimado (\$COP)
Suscripción Premium individual	Mensual	\$25.000 - \$35.000
Licencia Institucional (asociaciones, entes públicos)	Anual	\$3.000.000 - \$6.000.000
Venta como solución llave en mano personalizada	Única / Anual	Según requerimiento del cliente

Nota. Elaborado por el autor

El anterior esquema permite combinar accesibilidad para pequeños productores (vía suscripción) y sostenibilidad financiera mediante licencias más robustas para instituciones, ONG o entes gubernamentales.

6.5 Estrategia de Financiación del Proyecto en Colombia

La financiación se abordará desde cuatro fuentes principales:

1. Fondos de Investigación Nacional

Dirigidos a cubrir el componente académico y científico del proyecto.

- Recursos propios.
- MinCiencias – Convocatorias de proyectos de investigación aplicada
 - Modalidad: Jóvenes Investigadores, Innovación en el sector agropecuario, AgroSENA.
 - Apoyo: hasta \$100 millones COP en especie o efectivo.

- Universidad Santo Tomás
 - Fondos internos para trabajos de grado de impacto tecnológico.
 - Vinculación a grupos de investigación institucionales.

Nota: Aplicarían para cubrir las fases de modelado, validación, publicación y tesis.

2. Programas de Emprendimiento Tecnológico

Dirigido a convertir el MVP en un producto real con enfoque comercial y escalable.

- Apps.co (MinTIC)
 - Acompañamiento y financiación para el desarrollo de productos digitales.
- iNNpula Colombia – Programa ALDEA, CEmprende, retos de innovación
 - Fondos de capital semilla + mentorías para startups agrotech.
- SENA Fondo Emprender
 - Hasta \$80 millones COP para ideas innovadoras con componente productivo.

Nota: Aplica para escalar la App, construir un piloto comercial y validar modelo de negocio.

3. Alianzas con Cooperativas o Clústeres Acuícolas

- ACUICOOP, AUNAP, piscicultores del Meta, Huila, Tolima y Amazonas.

Posibilidad de cofinanciar pruebas de campo, licencias de uso y adopción tecnológica.

Nota: Aplica para la validación en campo adopción y análisis de impacto en usuarios reales.

4. Cooperación Internacional y ONGs

- FAO, FONTAGRO, CIAT, BID Lab

Enfocados en desarrollo sostenible, acuicultura, seguridad alimentaria y tecnología.

Nota: Aplica para fases posteriores de internacionalización, investigación avanzada o expansión.

Tabla 10

Resumen de la Estrategia de Financiación

Fuente	Tipo	Aplicación	Etapa
Recursos Propios	Privada	Investigación, desarrollo del MVP	Académica
MinCiencias	Pública (investigación)	Modelado, IA, validación científica	Académica
Fondo Emprender – SENA	Pública (emprendimiento)	Desarrollo MVP y comercialización	Técnica
iNNpulsa – Cemprende	Pública (aceleración)	Escalamiento de plataforma	Comercial
Alianzas cooperativas (AUNAP, piscicultores del Meta, Tolima, Huila y Amazonas)	Mixta	Validación y adopción en campo	Implementación
FAO / FONTAGRO	Cooperación internacional	Tecnología y sostenibilidad	Internacionalización

Nota. Elaborado por el autor.

7. Impacto del Proyecto AquaNutri AI Móvil

El proyecto *AquaNutri AI Móvil* está diseñado para generar un impacto positivo multidimensional en el ámbito técnico, económico, ambiental, social y científico, alineado con los objetivos de sostenibilidad e innovación del sector agropecuario colombiano.

7.1 Impacto técnico y tecnológico

El proyecto AquaNutri AI Móvil introducirá una solución tecnológica accesible y eficiente para la gestión de la calidad del agua en sistemas acuícolas intensivos. La implementación de una plataforma móvil con funcionalidades de captura de datos, alertas automatizadas y análisis predictivo representa un avance significativo respecto a los métodos manuales y desconectados que predominan actualmente en el sector. Esta solución integrará tecnologías digitales y analíticas con aplicaciones directas en campo, facilitando la transición hacia la acuicultura inteligente.

7.2 Impacto económico

Desde una perspectiva económica, la plataforma contribuirá a la reducción de pérdidas productivas y costos operativos derivados de malas decisiones en la gestión de parámetros fisicoquímicos. Al facilitar el monitoreo y control oportuno del oxígeno disuelto, temperatura, pH y otros indicadores relevantes, el sistema permitirá optimizar el uso de recursos como el alimento, energía y agua, incrementando la eficiencia y rentabilidad del cultivo.

7.3 Impacto ambiental

El monitoreo y control eficiente de parámetros fisicoquímicos mediante una herramienta predictiva reducirá el riesgo de contaminación por acumulación de residuos nitrogenados y el uso excesivo de insumos. Esto se traduce en una acuicultura más limpia y sustentable, con menor emisión de desechos y menor impacto sobre los ecosistemas circundantes. Además, la prevención de eventos críticos disminuirá la necesidad de recambios de agua y otras intervenciones ambientales correctivas.

7.4 Impacto social

El proyecto fomentará la apropiación tecnológica por parte de pequeños y medianos acuicultores, fortaleciendo su capacidad de gestión y toma de decisiones basada en datos. Esto generará mayores oportunidades de competitividad, sostenibilidad y bienestar económico para familias rurales que dependen de esta actividad productiva, además de promover el uso responsable de la tecnología en zonas de vocación acuícola.

7.5 Impacto académico y científico

Desde el ámbito académico, el desarrollo del sistema permitirá fortalecer líneas de investigación interdisciplinaria que integran zootecnia, ingeniería, ciencia de datos y sostenibilidad. El proyecto servirá como caso de estudio para nuevas investigaciones sobre IA

aplicada a la acuicultura y contribuirá con publicaciones y disseminación de conocimiento en eventos científicos nacionales e internacionales.

7.6 Impacto institucional y normativo

El proyecto está alineado con el Plan Nacional para el Desarrollo de la Acuicultura Sostenible (PlaNDAS) y la Política Nacional de Inteligencia Artificial (CONPES 4144 de 2025). Su ejecución respalda la modernización tecnológica del sector acuícola en Colombia, promoviendo buenas prácticas productivas y ofreciendo una herramienta adaptable a programas de fomento rural. La plataforma puede convertirse en insumo para futuras políticas públicas relacionadas con la trazabilidad, sostenibilidad y digitalización del sector agropecuario.

En conjunto, estos impactos posicionan a *AquaNutri AI Móvil* como una solución integral que contribuye al desarrollo sostenible, competitivo e inteligente de los sistemas acuícolas colombianos.

7.7 Estrategia de Adopción y Capacitación del Sistema AquaNutri AI Móvil

El éxito de la implementación de AquaNutri AI Móvil no solo depende del desarrollo tecnológico, sino también de su aceptación y uso efectivo por parte de los productores acuícolas. Por ello, se propone una estrategia integral de adopción y capacitación basada en cinco pilares fundamentales.

Enfoque Participativo desde el Diseño

Desde las fases iniciales del proyecto, se ha contemplado la participación directa de acuicultores para validar las necesidades reales que tienen, capacidades técnicas y modos habituales de registro de datos. Esta participación permite garantizar que la interfaz móvil sea comprensible, accesible y útil para el usuario final, favoreciendo la apropiación temprana de la herramienta.

Capacitación Inicial Personalizada

Se diseñará un módulo de capacitación presencial o virtual, según las condiciones del productor, que incluirá:

- Manual de uso ilustrado (modo paso a paso)
- Video tutorial corto (3-5 minutos) sobre el uso básico de la app.
- Guía práctica para la digitalización de datos.
- Taller básico de interpretación de alertas y recomendaciones

Este módulo será aplicado durante el proceso de implementación piloto, donde se espera capacitar inicialmente entre 5 y 10 productores seleccionados.

Soporte Técnico Acompañado (Modelo A+P)

Se aplicará un modelo de Asistencia + Práctica, que combinará:

- Línea directa de WhatsApp y/o correo técnico para resolución de dudas.
- Seguimientos técnico semanal en la primera fase de implementación.
- Retroalimentación individual sobre la calidad de los datos ingresados.

Este acompañamiento busca minimizar el abandono del sistema durante la curva de aprendizaje inicial.

Mejoras Iterativas con Base en el Usuario

Durante la fase de validación, se habilitará un formulario *in-app* para recibir sugerencias del usuario, errores reportados o solicitudes de mejora. Esta retroalimentación será sistematizada e incorporada en versiones posteriores del sistema, generando una relación de co-creación tecnológica con los usuarios.

Estrategia de Incentivos para la Adopción

Se plantea vincular incentivos para fomentar el uso continuo del sistema, tales como.

- Certificados de participación y adopción tecnológica
- Priorización para ser incluido en futuras fases de IoT o subsidios
- Visibilidad en medios institucionales como casos de éxito

Resultados esperados

- Al menos el 80% de los productores capacitados completan exitosamente su primer ciclo de registro de datos.
- Mejora en la comprensión y toma de decisiones basada en alertas inteligentes generadas por el sistema.
- Disminución del rechazo tecnológico gracias a una estrategia centrada en el usuario.

Figura 1

Estrategia de Adopción y Capacitación – AquaNutri AI Móvil



Nota. Elaborado por el autor.

Generación de Comunidades Piloto

Con el fin de validar y ajustar la plataforma AquaNutri AI Móvil en condiciones reales de operación, se propone la creación de comunidades piloto conformadas por productores acuícolas de pequeña y mediana escala en al menos dos regiones representativas del país, como el Meta (Llanos Orientales) y el Huila (Zona Andina), donde la producción acuícola con sistemas Biofloc y RAS presenta potencial de crecimiento.

Estas comunidades piloto permitirán:

- Realizar pruebas controladas de la interfaz y sus funcionalidades (alertas, captura de datos, recomendaciones).
- Recopilar retroalimentación cualitativa y cuantitativa directamente de los usuarios finales.
- Validar los rangos de parámetros fisicoquímicos y sus umbrales de alerta en condiciones regionales específicas.
- Construir confianza y apropiación tecnológica entre los productores.

Cada comunidad piloto contará con acompañamiento técnico y una fase de seguimiento de al menos tres (3) meses, lo cual permitirá recoger información importante para las fases de mejora continua y adaptación tecnológica.

Inclusión de Jóvenes Rurales como Embajadores Tecnológicos

Para garantizar la apropiación del sistema y fortalecer las capacidades locales, se implementará una estrategia de formación de jóvenes rurales como embajadores tecnológicos AquaNutri. Estos jóvenes cumplirán funciones clave como:

- Soporte técnico de primera línea en las comunidades piloto
- Multiplicadores de conocimiento y cultura de datos

- Promotores de buenas prácticas en el uso de la aplicación móvil y la interpretación de los datos generados
- Enlace entre los equipos técnicos del proyecto y las necesidades reales de los productores.

Esta estrategia incluye:

- Selección participativa de jóvenes en cada comunidad piloto.
- Formación técnica intensiva (virtual o semipresencial) en uso de la app, conceptos de calidad de agua y manejo de datos.
- Acompañamiento con guías de campo, material gráfico y soporte digital.

Esto no solo mejora la adopción tecnológica, sino que también genera empleo rural calificado y contribuye a la retención del talento humano en el campo colombiano.

Escalabilidad del Sistema AquaNutri AI Móvil

La escalabilidad del sistema ha sido considerada desde su concepción bajo tres principios fundamentales:

- a) Modularidad tecnológico, el sistema ha sido diseñado de forma modular, lo que permitirá:
 - Integrar nuevos módulos de análisis, predicción u otras variables zootécnicas (como medida del animal o consumo de alimento).
 - Adaptar el sistema a otras especies y sistemas productivos, como tilapia, cachama, trucha o camarón.
- b) Adaptabilidad regional
 - Los rangos y alertas pueden ajustarse con base en datos locales y retroalimentación de usuario por región.

- La interfaz será configurable en distintos niveles de complejidad (básico, intermedio, técnico), permitiendo un uso flexible.

c) Infraestructura de bajo costo

- La solución no dependerá de sensores IoT ni hardware costoso, lo cual la hace viable para productores en zonas con baja conectividad o con recursos limitados.
- El sistema puede operar offline con sincronización posterior en la nube, facilitando su adopción en entornos rurales.

La visión a largo plazo contempla la expansión del sistema a nivel nacional mediante alianzas con instituciones públicas (SENA, UMATAS, ICA), gremios (FEDEACUA, ACUICOLOMBIA, entre otros), y programas de transformación digital rural.

8. Limitaciones y Delimitaciones Tecnológicas del Proyecto

Una de las delimitaciones tecnológicas del presente proyecto es la no incorporación de sensores IoT en la captura de datos. Esta decisión responde a tres factores principales: a) la baja disponibilidad de infraestructura IoT en pequeñas y medianas unidades acuícolas en Colombia, b) la necesidad de validar primero el modelo predictivo con datos manuales antes de automatizar, y c) la optimización de recursos en el desarrollo del MVP. La integración de sensores podrá ser contemplada en futuras versiones del sistema para procesos de automatización avanzada.

Tabla 11

Comparativo IoT Vs Sistema propuesto


Aspecto	Sistema con IoT	Sistema sin IoT (propuesto)
Captura de datos	Automática mediante sensores	Manual, digitada por el productor
Fuente de información	Sensores conectados (DO, pH, Temperatura, etc.)	Instrumentos tradicionales del productor

Aspecto	Sistema con IoT	Sistema sin IoT (propuesto)
Necesidad de conectividad	Alta (Wi-Fi, LoRa, etc.)	Baja (se tomas los datos directamente del instrumento)
Costo estimado inicial	\$10 millones - \$25 millones COP adicionales	Incluido en presupuesto actual (\$38,9 millones COP)
Tiempo de implementación	Medio – Alto	Bajo – Medio
Nivel de adopción por el productor	Bajo – Medio (curva de aprendizaje)	Alta (basado en prácticas actuales)
Escalabilidad técnica	Alta	Media (dependiente de adopción)
Mantenimiento requerido	Alto (calibración, energía, reemplazos)	Bajo
Viabilidad en zonas rurales	Limitada por conectividad y costos	Alta
Dependencia de hardware	Alta	Baja

Nota. Elaborado por el autor.

Figura 2

Comparativo Técnico Operativo: Sistema con vs sin IoT



Nota. Elaborado por el autor, con base a la información analizada sobre el uso de IoT o no uso en el proyecto.

La figura 1, compara cinco aspectos importantes del desarrollo del sistema con y sin el uso de tecnología IoT, evaluados en una escala subjetiva de 1 a 5, donde un valor más alto representa mayor complejidad, costo o requisito técnico.

Observamos, que el sistema con IoT presenta mayores niveles de exigencia en términos de captura de datos (automática), requerimientos de conectividad, costos iniciales, y mantenimiento. En cambio, la solución sin IoT, propuesta por AquaNutriAI Móvil, mantiene una menor complejidad operativa y económica, facilitando así su adopción por pequeños y medianos acuicultores en Colombia. Este análisis respalda la decisión técnica de omitir sensores IoT en la fase actual del proyecto.

9. Conclusiones y Recomendaciones

El anteproyecto "AquaNutri AI Móvil" se ha fundamentado en la necesidad crítica de transformar la gestión de la calidad del agua en la acuicultura intensiva colombiana, especialmente en sistemas Biofloc y RAS. La falta de herramientas tecnológicas accesibles para el monitoreo en tiempo real y el análisis predictivo limita la capacidad de respuesta de los productores, afectando directamente la sostenibilidad técnica y económica de sus unidades productivas. En respuesta a esta problemática, se ha propuesto el desarrollo de una plataforma inteligente que, mediante la digitalización manual de datos y la aplicación de inteligencia artificial, apoye la toma de decisiones informadas por parte de los acuicultores.

9.1 Conclusiones

A partir del análisis y diseño planteado en este anteproyecto, se pueden extraer las siguientes conclusiones fundamentales respecto a la viabilidad y pertinencia del proyecto AquaNutri AI Móvil:

Validación de la Hipótesis Central

La formulación de la hipótesis que plantea que la implementación de AquaNutri AI Móvil optimizará significativamente la gestión de la calidad del agua y mejorará la productividad, sostenibilidad y eficiencia operativa, se valida teóricamente a través de la revisión del Marco Teórico y el Estado del Arte. La literatura respalda que la integración de monitoreo de parámetros, alertas y análisis predictivos es crucial para sistemas acuícolas intensivos. Este anteproyecto establece las bases metodológicas para demostrar empíricamente esta hipótesis en la fase de desarrollo y validación.

Coherencia con los Objetivos Propuestos

Los objetivos específicos del proyecto —implementar una interfaz móvil para la captura y almacenamiento de datos, diseñar un sistema de alertas automáticas, y desarrollar módulos de análisis correlacional y predictivo — son totalmente coherentes con la solución planteada. Cada fase de desarrollo metodológico ha sido detallada para asegurar la consecución de estos objetivos, desde el diseño centrado en el usuario hasta el entrenamiento de modelos de Machine Learning.

Pertinencia para la Gestión Agropecuaria

El proyecto AquaNutri AI Móvil se alinea estratégicamente con los principios de gerencia de empresas agropecuarias. Al ofrecer herramientas para la gestión de parámetros fisicoquímicos y zootécnicos, la plataforma permite a los productores pasar de un manejo reactivo a uno proactivo y basado en datos. Esto es clave para la optimización de recursos como alimento, energía y agua, lo que se traduce directamente en una mejora de la rentabilidad y la eficiencia operativa de la unidad productiva acuícola. La herramienta fomenta la toma de decisiones informada, un pilar de la gerencia moderna.

Enfoque Práctico y Accesible

A diferencia de otras soluciones que requieren una automatización total con hardware especializado, AquaNutri AI Móvil se enfoca en la digitalización manual de datos. Esta aproximación reduce significativamente los costos de implementación inicial para el productor y facilita la adopción tecnológica en pequeños y medianos acuicultores en Colombia, lo cual es fundamental para la transferencia tecnológica y el desarrollo sectorial.

Rigurosidad Metodológica para el Desarrollo de Software con IA

Se ha definido una metodología cuantitativa, aplicada y experimental, que incluye fases detalladas de desarrollo, procesamiento de datos con algoritmos avanzados de Machine Learning (EDA, correlación, predicción, imputación de datos faltantes), y una validación integral del sistema. Esto asegura la construcción de un prototipo funcional y robusto, capaz de generar indicadores y recomendaciones precisas.

Impacto Multidimensional y Sostenible

El proyecto tiene el potencial de generar un impacto positivo técnico-tecnológico, económico, ambiental y social en la acuicultura colombiana, además de contribuir al ámbito académico-científico e institucional. La alineación con el Plan Nacional para el Desarrollo de la Acuicultura Sostenible (PlaNDAS) y la Política Nacional de Inteligencia Artificial (CONPES 4144 de 2025) refuerza su pertinencia estratégica a nivel nacional.

Estas conclusiones reafirman la solidez del anteproyecto y las recomendaciones trazan una hoja de ruta clara para su exitosa implementación y su potencial evolución, consolidando su aporte al sector acuícola colombiano desde una perspectiva de gestión empresarial innovadora.

9.2 Recomendaciones

Para la fase de desarrollo e implementación del proyecto AquaNutri AI Móvil, así como para futuras líneas de investigación, se formulan las siguientes recomendaciones:

Priorizar la Interfaz de Usuario (UI/UX)

Dado que la plataforma depende de la digitación manual de datos por parte del productor, es crucial que la Fase 1 del desarrollo de la interfaz móvil ponga un énfasis significativo en la simplicidad, la intuición y la retroalimentación visual amigable. Se recomienda realizar pruebas de usabilidad continuas e iterativas con usuarios reales para garantizar una experiencia fluida y minimizar la barrera tecnológica.

Optimización y Robustez de los Modelos de IA

En la Fase 3, dedicada al desarrollo del módulo de análisis, se recomienda explorar y comparar diferentes arquitecturas de modelos de *Machine Learning* y *Deep Learning* (ejemplo: Ensemble Shuffling-CNN, redes neuronales recurrentes) para la predicción de parámetros clave. Es fundamental optimizar su robustez frente a la variabilidad y posibles datos incompletos, así como investigar técnicas de transferencia de aprendizaje para adaptar los modelos a las particularidades de diferentes granjas colombianas.

Estrategia de Recopilación de Datos en Fase de Validación

Para la Fase 4 de validación, se recomienda establecer un protocolo riguroso para la recolección de datos en campo por parte de los productores. Esto incluye la estandarización de los instrumentos de medición que utilizarán los productores, la frecuencia de las mediciones y la capacitación adecuada para asegurar la calidad y consistencia de los datos ingresados manualmente, que serán cruciales para la fiabilidad de las predicciones.

Desarrollo de un Módulo de Costos y Rentabilidad

Complementando el enfoque en gerencia de empresas agropecuarias, se recomienda considerar el desarrollo futuro de un módulo adicional que correlacione los parámetros de calidad del agua y los indicadores zootécnicos con los costos de producción (ejemplo: consumo de energía, uso de insumos, pérdidas por mortalidad). Esto permitiría a los productores visualizar directamente el impacto económico de las recomendaciones de la IA y calcular la rentabilidad mejorada.

Exploración de Integración Híbrida (Manual + Sensores)

Si bien el enfoque inicial es la digitalización manual, se recomienda explorar en el futuro la posibilidad de una integración híbrida donde el sistema pueda, progresivamente, conectarse a sensores IoT básicos y accesibles para aquellos productores que deseen avanzar en la automatización del monitoreo, combinando la entrada manual con la lectura automática para enriquecer la base de datos y la precisión de los modelos.

Validación a Mayor Escala y Diversidad de Sistemas

Una vez que el prototipo demostrativo esté consolidado, se recomienda planificar una fase de validación en campo con un mayor número de productores y en diversas condiciones geográficas y tipos de sistemas Biofloc/RAS en Colombia. Esto permitirá evaluar la generalización del sistema y su impacto real en distintas escalas de producción.

Desarrollo de Contenido Educativo Integrado

Para potenciar la apropiación tecnológica, se recomienda integrar en la plataforma o desarrollar material educativo complementario que explique los principios básicos de los parámetros de calidad del agua, la tecnología Biofloc/RAS y cómo interpretar y actuar sobre las alertas y recomendaciones de la IA.

Referencias

- Abid, M. A., Amjad, M., Munir, K., Siddique, H. U., & Jurcut, A. D. (2024). IoT-Based Smart Biofloc Monitoring System for Fish Farming Using Machine Learning. *IEEE Access*, 12, 86333-86345. <https://doi.org/10.1109/ACCESS.2024.3384263>
- Autoridad Nacional de Acuicultura y Pesca - AUNAP, & Ministerio de Agricultura y Desarrollo Rural. (2022). *Plan Nacional para el Desarrollo de la Acuicultura Sostenible en Colombia (PlaNDAS)*. Fedeacua.org: <https://fedecua.org/files/plan-nacional-para-el-desarrollo-de-la-acuicultura-sostenible-colombia.pdf>
- Baena-Navarro, R., Carriazo-Regino, Y., Torres-Hoyos, F., & Pinedo-López, J. (2025). Intelligent Prediction and Continuous Monitoring of Water Quality in Aquaculture: Integration of Machine Learning and Internet of Things for Sustainable Management. *Water*, 17(1), 82. <https://doi.org/10.3390/w17010082>
- BIOAQUAFLOC (b). (17 de julio de 2025). *BioAquaflor*. Influencia de factores químicos en la tecnología biofloc: <https://www.bioaquafloc.com/influencia-de-factores-quimicos-en-la-tecnologia-biofloc/>
- BIOAQUAFLOC. (7 de 2025). *BioAquaflor*. ¿Cómo acaba el Biofloc con el amonio, los nitritos y los nitratos del agua?: <https://www.bioaquafloc.com/como-acaba-el-biofloc-con-el-amonio-los-nitritos-y-los-nitratos-del-agua/>
- Boyd, C. E. (9 de noviembre de 2020). *Global Seafood Alliance*. Efectos del tiempo y el clima en la acuicultura: <https://www.globalseafood.org/advocate/efectos-del-tiempo-y-el-clima-en-la-acuicultura/>
- Capetillo-Contreras, O., Pérez-Reynoso, F. D., Zamora-Antuñano, M. A., Álvarez-Alvarado, J. M., & Rodríguez-Reséndiz, J. (2024). Artificial Intelligence-Based Aquaculture System

- for Optimizing the Quality of Water: A Systematic Analysis. *Journal of Marine Science and Engineering (MDPI)*, 12(1), 161. <https://doi.org/10.3390/jmse12010161>
- Cardozo Ramírez, L. E., Calle Viles, E., Fuentes Telleria, R., Ramos Silvestre, E. R., & Tavera Gutiérrez, D. F. (2024). Monitoreo de la Calidad del Agua en Criaderos de Tilapias Mediante Tecnologías Lpwan y VPS. *Ciencia Latina Revista Científica Multidisciplinar*, 8(2), 5609-5629. https://doi.org/10.37811/cl_rcm.v8i2.10975
- Chen, F., Qiu, T., Xu, J., Zhang, J., Du, Y., Duan, Y., . . . Sun, M. (2024). Rapid real-time prediction techniques for ammonia and nitrite in high-density shrimp farming in recirculating aquaculture systems. *Fishes*, 9, 386. <https://doi.org/10.3390/fishes9100386>
- Chiu, M.-C., Yan, W.-M., Bhat, S. A., & Huang, N.-F. (2022). Development of smart aquaculture farm management system using IoT and AI-based surrogate models. *Journal of Agriculture and Food Research*, 9, 100357. <https://doi.org/10.1016/j.jafr.2022.100357>
- Congreso de Colombia (b). (2012). Ley 1581 de 2012: Por la cual se dictan disposiciones generales para la protección de datos personales. *Diario Oficial No. 48587*. <https://www.suin-juriscol.gov.co/viewDocument.asp?ruta=Leyes/1684507>
- Congreso de Colombia. (1982). Ley 23 de 1982: Sobre derechos de autor. *Diario Oficial No. 35949*. <https://www.suin-juriscol.gov.co/viewDocument.asp?ruta=Leyes/30035790>
- Congreso de la República de Colombia. (12 de julio de 2018). *Ley 1915 de 2018, Por la cual se modifica la ley 23 de 1982 y se establecen otras disposiciones en materia de derecho de autor y derechos conexos*. Departamento de la Función Pública: <https://www.funcionpublica.gov.co/eva/gestornormativo/norma.php?i=87419>

Departamento Nacional de Planeación - República de Colombia. (2025). Política nacional para el desarrollo y adopción de la inteligencia artificial en Colombia (CONPES 4144).

<https://colaboracion.dnp.gov.co/CDT/Conpes/Econ%C3%B3micos/4144.pdf>

Gálvez-Cantero, L., Julián-Ricardo, M. C., & Ramos-Sánchez, L. B. (2022). EL BIOFLOC EN LA ACUICULTURA. *Centro Azucar*, 49(2), 136-146.

http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S2223-48612022000200136&lng=es&tlng=es

Granda Jaramillo, H. E. (2022). *Repositorio Universidad Nacional Abierta y a Distancia*.

Comparación de los parámetros de producción obtenidos en 8 estanques de producción de tilapia roja (*Oreochromis mossambicus*) en una explotación piscícola con sistema de recirculación en el municipio de rio negro, Santander [Trabajo de grado]:

<https://repository.unad.edu.co/bitstream/handle/10596/51355/hegrandaj.pdf>

Hernández Mancipe, L. E., Londoño Velez, J. I., Hernández García, K. A., & Torres Hernández,

L. C. (2019). Los sistemas biofloc: una estrategia eficiente en la producción acuícola. *CES Medicina Veterinaria y Zootecnia*, 14(1), 70-99. <https://doi.org/10.21615/cesmvz.14.1.6>

Hernández, N. (2020). *Repositorio Universidad Nacional Abierta y a Distancia (UNAD)*.

Vigilancia tecnológica e inteligencia competitiva de un cultivo de alevinos de tilapia roja (*Oreochromis* sp) en sistema de biofloc :

<https://repository.unad.edu.co/bitstream/handle/10596/35213/nhernandezlop.pdf>

Kaur, G., Braveen, M., Krishnapriya, S., Wawale, S. G., Castillo-Picon, J., Malhotra, D., & Osei-

Owusu, J. (2023). Machine Learning Integrated Multivariate Water Quality Control Framework for Prawn Harvesting from Fresh Water Ponds. *Hindawi Journal of Food Quality*, Article ID 3841882, 9. <https://doi.org/10.1155/2023/3841882>

López Jaime, J. A. (2019). *Cultivo Acuapónico Guía Especializada (Aquapinic Culture - Tool kit)*.

Aula del Mar. <https://cifalmalaga.org/wp-content/uploads/2020/04/2019.11.07-LIBRO-ACUAPONIA.pdf>

Majid, M. R., & Setiawan, K. E. (2024). Ensemble Shuffling-CNN, Attention-Alternative Model of Water Quality Parameters Prediction in Small Fishponds for Urban Aquaculture. *ICIC Express Letters*, 18(7), 669-676. <https://doi.org/10.24507/icicel.18.07.669>

Manan, H., Kasan, N. A., Ikhwanuddin, M., Kamaruzzan, A. S., Jalilah, M., Fauzan, F., . . . Amin-Safwan, A. (2024). Biofloc technology in improving shellfish aquaculture production – a review. *Annals of Animal Science*, 24(4), 983-993. <https://doi.org/10.2478/aoas-2023-0093>

Oviedo P., M., Brú C., S., Atencio G., V., & Pardo C., S. (2013). Potencialidad de la región costera de Córdoba -Colombia- para el cultivo de tilapia nilótica. *Revista MVZ Córdoba*, 18(3), 3781-3789. <http://www.scielo.org.co/pdf/mvz/v18n3/v18n3a06.pdf>

Presidencia de la República de Colombia. (2021). Decreto 1835 de 2021: Por medio del cual se modifican disposiciones del Decreto 1071 de 2015 sobre pesca y acuicultura. *Diario Oficial* No. 51898. <https://www.funcionpublica.gov.co/eva/gestornormativo/norma.php?i=175148>

Presidencia de la República de Colombia. (20 de julio de 2025). *Decreto 1835 de 2021, Por medio del cual se modifican, adicionan y derogan algunas disposiciones de la Parte 16 del Libro 2, del Decreto 1071 de 2015, Decreto Único Reglamentario del Sector Administrativo Agropecuario, Pesquero y de Desarrollo Rural ...* Departamento de la Función Pública: <https://www.funcionpublica.gov.co/eva/gestornormativo/norma.php?i=175148>

Quintero Sánchez, Y. D., Sánchez Portillo, S., Bracho Colina, E., Salazar Sánchez, M. D., Pereira Flórez, L. F., & Hernández Martínez, I. (2024). Evaluación de la producción de tilapia roja

- (oreochromis sp) criados con tecnologia biofloc. *Revista EIA*, 21(42).
<https://doi.org/10.24050/reia.v21i42.1761>
- Rajan, R., Sharrer, K., Tsukuda, S., & Good, C. (2023). Effects of image data quality on a convolutional neural network trained in-tank fish detection model for recirculating aquaculture systems. *Computers and Electronics in Agriculture*(205), 107644.
<https://doi.org/10.1016/j.compag.2023.107644>
- Rashid, M. M., Nayan, A.-A., Afrin Simi, S., Saha, J., Rahman, M. O., & Kibria, M. G. (2021). IoT based Smart Water Quality Prediction for Biofloc Aquaculture. *International Journal of Advanced Computer Science and Applications(IJACSA)*, 12(6).
<https://doi.org/10.14569/IJACSA.2021.0120608>
- República de Colombia - Departamento Nacional de Planeación. (29 de julio de 2025). *Documento CONPES 4144*. Departamento Nacional de Planeación:
<https://colaboracion.dnp.gov.co/CDT/Conpes/Económicos/4144.pdf>
- República de Colombia - SIC. (21 de agosto de 2024). *Circular Externa No. 002 de 2024 , Lineamientos sobre el Tratamiento de Datos personales en Sistemas de Inteligencia Artificial*". Superintendencia de Industria y Comercio:
<https://sedeelectronica.sic.gov.co/sites/default/files/normativa/Circular%20Externa%20No.%20002%20del%2021%20de%20agosto%20de%202024.pdf>
- Rivas Salazar, D., Silva-Acuña, R., Barrios Maestre, R., & Noriega Salazar, A. (2021). Recambio de agua, su efecto sobre características físico-químicas y crecimiento en juveniles de tilapia roja. *Revista ESPAMCIENCIA*, 12(1), 8-16.
https://doi.org/10.51260/revista_espamciencia.v12i1.260

Saavedra Martínez, M. A. (4 de agosto de 2006). *The University of Rhode Island*. Manejo del Cultivo de Tilapia [Manual]: <https://www.crc.uri.edu/download/MANEJO-DEL-CULTIVO-DE-TILAPIA-CIDEA.pdf>

Shin, H., Park, T., Jo, S.-K., & Jung, J. Y. (2025). Enhancing flow-through aquaculture system monitoring: A comparative study of machine learning algorithms for missing-data imputation. *Aquaculture*, 601, 742303. <https://doi.org/10.1016/j.aquaculture.2025.742303>

Soto Castro, A. (febrero de 2015). *Biblioteca Virtual Universidad Michoacana de San Nicolás de Hidalgo*. Estudio de un Reactor de Lecho Móvil, Acoplado a un Sistema Acuícola con Recirculación [Tesis de Maestría]: http://bibliotecavirtual.dgb.umich.mx:8083/xmlui/bitstream/handle/DGB_UMICH/4709/FIQ-M-2015-0448.pdf

Apéndices

Apéndice A. Formato de Diagnóstico Inicial (Pretest)

Nombre del productor: _____

Nombre de la unidad productiva: _____

Fecha de aplicación: ____ / ____ / ____

Sistema utilizado: ____ Biofloc ____ RAS

Duración típica del ciclo productivo: _____ días.

1. Información General del Sistema Productivo

Ítem	Valor / Descripción
Especie cultivada	_____
Etapas productivas actuales	__ Alevinos __ Juveniles __ Engorde
Área total del cultivo (m ²)	_____
Número de Estanques	_____
Volumen total de agua (m ³) por estanque	_____
Tipo de aireación utilizada	_____
Consumo energético mensual promedio (kWh)	_____
Tipo de alimentación	__ Manuel __ Automática
Registro de alimentación (kg/día)	_____
Utiliza sensores o pruebas manuales de toma de parámetros	_____
¿Qué sensor electrónico utiliza?	_____

2. Parámetros Fisicoquímicos Medidos (Últimos 7 días)

Parámetros	Valor Promedio	Rango Observado	Frecuencia de Medición	Instrumento Utilidad
Temperatura (oC)	_____	_____	_____	_____
Oxígeno Disuelto (mg/L)	_____	_____	_____	_____

Parámetros	Valor Promedio	Rango Observado	Frecuencia de Medición	Instrumento Utilidad
pH				
Amonio (NH ₃ -N) (mg/L)				
Nitrito (NO ₂ -N) (mg/L)				
Nitrato (mg/L)				
Alcalinidad (CaCO ₃) (mg/L)				
Sólidos Suspendidos (mg/L)				
CO ₂ disuelto (mg/L)				
Relación Carbono – Nitrógeno (C:N)				

3. Indicadores Productivos y Ambientales

Indicador	Valor aproximado (último ciclo)
Tasa de supervivencia (%)	
Conversión alimenticia (FCR)	
Biomasa total cosechada (kg)	
Mortalidad acumulada (kg o número)	
Eventos de mortalidad súbita reportados	___ Si ___ No ___ No aplica
Consumo energético mensual promedio (aireadores)	

4. Observaciones Generales del Productor

a) ¿Qué dificultades principales ha tenido para mantener la calidad del agua?

b) ¿Ha tenido eventos críticos por falta de oxígeno o exceso de amonio/nitrito?

___ Si ___ No Si respondió Si, describa:

c) ¿Tiene procedimientos de registro o control sistematizados?

___ Si ___ No ___ Parcialmente

d) ¿Utiliza alguna herramienta digital actualmente? ¿Cuál?

e) ¿Qué espera mejorar al implementar el sistema AguaNutri AI Móvil?

Apéndice B. Encuesta de Evaluación para Productores Piloto

Nombre del productor: _____

Fecha de aplicación: ____ / ____ / ____

Sistema utilizado: ____ Biofloc ____ RAS

Duración del ciclo de prueba: _____

Tamaño del cultivo (m2): _____

Número de Estanques: _____

Metros cúbicos por estanque: _____

Densidad de siembra: _____

Sección 1. Usabilidad de la Aplicación Móvil

Por favor, marque una X de acuerdo con el grado de satisfacción con las siguientes afirmaciones, utilizando una escala del 1 al 5, donde uno es totalmente de desacuerdo y 5 totalmente de acuerdo.

Ítem	1	2	3	4	5
La app fue fácil de aprender a usar.					
El ingreso de los datos fue claro y rápido.					
Las alertas automáticas fueron entendibles.					
La interfaz es clara y organizada					
En general, me sentí cómodo usando la aplicación					

Sección 2. Percepción del Impacto en la Producción

Indique si ha notado mejoras en su sistema de cultivo gracias al uso de AquaNutri AI Móvil:

Pregunta	Si	No	No sabe / No aplica
¿Disminuyó la mortalidad de los peces/camarones?			

Pregunta	Si	No	No sabe / No aplica
¿Mejóro el crecimiento o engorde de los animales?			
¿Pudo reaccionar a tiempo ante cambios de calidad del agua gracias a las alertas?			
¿Notó una reducción en el uso de aireadores o consumo de energía?			
¿Confía en los análisis o recomendaciones que entrega la aplicación?			

Sección 3. Retroalimentación Abierta

1. ¿Qué fue lo que más le gustó de la plataforma AquaNutri AI Móvil?

2. ¿Qué aspectos considera que se deben mejorar?

3. ¿Estaría dispuesto a seguir utilizando esta herramienta en su producción acuícola?

___ Si ___ No ___ Depende de mejoras

¿Por qué?: _____
