



Scientia Agropecuaria

Web page: <http://revistas.unitru.edu.pe/index.php/scientiaagrop>

Facultad de Ciencias
Agropecuarias

Universidad Nacional de
Trujillo

REVIEW



Artificial intelligence in aquaculture: basis, applications, and future perspectives

Inteligencia artificial en acuicultura: fundamentos, aplicaciones y perspectivas futuras

Wilfredo Vásquez-Quispesivana^{1*} ; Marianela Inga² ; Indira Betalleluz-Pallardel² 

¹ Facultad de Pesquería, Universidad Nacional Agraria La Molina. Av. La Molina s/n, La Molina, Lima. Perú.

² Facultad de Industrias Alimentarias, Universidad Nacional Agraria La Molina. Av. La Molina s/n, La Molina, Lima. Perú.

* Corresponding author: wvasquez@lamolina.edu.pe (W. Vásquez-Quispesivana).

Received: 18 January 2022. Accepted: 17 March 2022. Published: 28 March 2022.

Abstract

Advances in data management technologies are being adapted to resolve difficulties and impacts that aquaculture manifests, some aspects that over the years have not been fully managed, are now more feasible to solve, such as the optimization of variables that intervene in the growth and increase of biomass, the prediction of water quality parameters to manage and make decisions during farming fish, the evaluation of the aquaculture environment and the impact generated by aquaculture, the diagnosis of diseases in aquaculture fish to determine more specific treatments, handling, management and closure of aquaculture farms. The objective of this article was to review within the last 20 years the various techniques, methodologies, models, algorithms, software, and devices that are used within artificial intelligence, machine learning and deep learning systems, to solve in a simpler way, quickly and precisely the difficulties and impacts that aquaculture manifests. In addition, the fundamentals of artificial intelligence, automatic learning and deep learning are explained, as well as the recommendations for future study on areas of interest in aquaculture, such as the reduction of production costs through the optimization of feeding based on good aquaculture practices and parameters of water quality, the identification of sex in fish that do not present sexual dimorphism, the determination of quality attributes such as the degree of pigmentation in salmon and trout.

Keywords: Aquaculture; artificial intelligence; neural networks; machine learning; deep learning; optimization.

Resumen

Los avances en las tecnologías de manejo de datos se están adecuando a resolver dificultades e impactos que la acuicultura manifiesta, algunos aspectos que a través de los años no se han podido manejar plenamente, ahora son más factibles de resolver, como la optimización de las variables que intervienen en el crecimiento e incremento de biomasa, la predicción de parámetros de calidad de agua para manejar y tomar decisiones durante el cultivo, la evaluación del medio ambiente acuícola y el impacto que genera la acuicultura, el diagnóstico de enfermedades de los peces para determinar tratamientos más puntuales, el manejo, gestión y cierre de granjas acuícolas. El objetivo del presente artículo fue revisar dentro de los últimos 20 años las diversas técnicas, metodologías, modelos, algoritmos, softwares y dispositivos que se utilizan dentro de los sistemas de inteligencia artificial, aprendizaje automático y aprendizaje profundo, para resolver de una manera más sencilla, rápida y precisa las dificultades e impactos que la acuicultura evidencia. Además, se explican los fundamentos de la inteligencia artificial, aprendizaje automático y aprendizaje profundo, así también las recomendaciones de estudio futuro sobre áreas de interés en acuicultura, como la reducción de los costos de producción mediante la optimización de la alimentación en función de las buenas prácticas de acuicultura y parámetros de calidad de agua, la identificación del sexo en peces que no presentan dimorfismo sexual, la determinación de atributos de calidad como el grado de pigmentación en salmones y truchas.

Palabras clave: Acuicultura; inteligencia artificial; redes neuronales; aprendizaje automático; aprendizaje profundo; optimización.

DOI: <https://dx.doi.org/10.17268/sci.agropecu.2022.008>

Cite this article:

Vásquez-Quispesivana, W., Inga, M., & Betalleluz-Pallardel, I. (2022). Inteligencia artificial en acuicultura: fundamentos, aplicaciones y perspectivas futuras. *Scientia Agropecuaria*, 13(1), 79-96.

1. Introducción

La acuicultura es una actividad productiva en continuo desarrollo y crecimiento de vital importancia para la seguridad alimentaria (Sabo-Attwood et al., 2021; Gao et al., 2019), en contraste con la pesca, que es una actividad cada vez más amenazada por la sobre explotación (Ahmed et al., 2019). El desarrollo de la acuicultura se sustenta en el control de las diferentes variables que se manejan durante el cultivo (Ren et al., 2020; Hu et al., 2020); como la calidad de agua, densidad de carga y alimentación entre otros. Con relación al agua, sus parámetros de calidad influyen en la morfología, características y comportamiento de los peces (Hu et al., 2020) y se miden utilizando instrumentos y sensores (Sabari et al., 2020). Se busca optimizar las interacciones y efectos de estas variables para lograr mayores rendimientos en cuanto a crecimiento de los animales se refiere. Diversidad de pruebas e investigaciones se realizan para obtener con mayor precisión los valores óptimos de las variables que intervienen en el proceso de cultivo, se utilizan para ello diseños experimentales y herramientas estadísticas. Considerando que son variables que intervienen en simultáneo, en los últimos años se está optando por utilizar herramientas más simples con mayor capacidad de procesar más número de datos y variables (Cevallos-Ampuero, 2004). El aprendizaje automático y el aprendizaje profundo son alternativas que se están aplicando dentro del marco de la inteligencia artificial, para optimizar y resolver nuevos problemas que la actividad acuícola presenta.

Los desarrollos de la automatización y la tecnología inteligente han llevado a cabo un desarrollo gradual de la acuicultura hacia una dirección intensiva e inteligente en todo el mundo (Zhao et al., 2021). Diversos artículos de investigación donde se aplica estas tecnologías en acuicultura se han publicado en los últimos 20 años, en la **Figura 1** se aprecia el liderazgo que tiene actualmente China, con 144 publicaciones en aplicación de inteligencia artificial, esto se correlaciona con la mayor producción en acuicultura que este país presenta, seguido de Estados Unidos con 41 publicaciones, Noruega un país acuícola

que destaca en la producción de salmones, participa con 24 publicaciones, Australia con 21 publicaciones y Corea del Sur con 20 publicaciones. Mientras que los demás países tienen aportes menores.

En la **Figura 2** se observa la evolución en los últimos 20 años de estas tecnologías aplicadas a la acuicultura.

La inteligencia artificial, el aprendizaje automático y el aprendizaje profundo son fascinantes dominios científicos interdisciplinarios donde las máquinas cuentan con una aproximación a la inteligencia humana. La conjetura es que las máquinas pueden aprender de ejemplos existentes y emplear este conocimiento acumulado para realizar tareas desafiantes como el análisis de regresión, la clasificación de patrones y la predicción (Mouloodi et al., 2021), la acuicultura inteligente se comprometerá a resolver los problemas en el desarrollo pesquero y la mejora de la productividad de la acuicultura (Zhao et al., 2021).

2. Fundamentos teóricos y conceptuales

La **Figura 3** muestra una síntesis de algunas de las principales técnicas y herramientas que se utilizan en los campos de la inteligencia artificial y que se describen a continuación.

2.1. Inteligencia artificial

La inteligencia artificial con su denominación en inglés "Artificial Intelligence" (AI) se puede definir como la emulación computacional del proceso de pensamiento humano (Atia et al., 2011a), siendo un campo de la informática que permite que las computadoras y las máquinas tomen decisiones como los seres humanos (Tian et al., 2020; Ng & Mahkeswaran, 2021). En el uso popular, la inteligencia artificial se refiere a la capacidad de una computadora o máquina para imitar la mente humana. Esto quiere decir aprender de ejemplos y experiencias, reconocer objetos, comprender y responder al lenguaje, tomar decisiones, resolver problemas, y combinar estas y otras capacidades para realizar funciones que un ser humano podría hacer, como entregar alimento balanceado a los peces cuando estos presentan movimientos o comportamientos que denoten necesitar alimento.

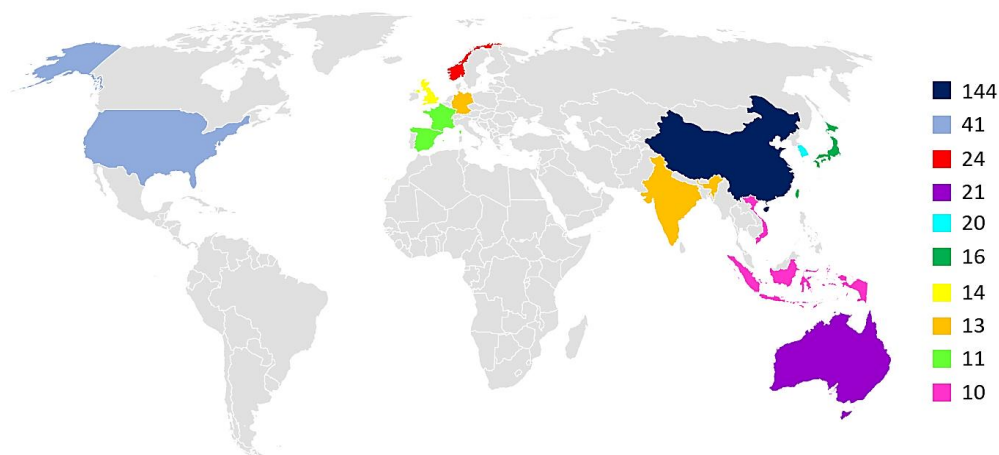


Figura 1. Aplicación de inteligencia artificial en acuicultura en el mundo durante los últimos 20 años, expresado en número de publicaciones por país. Información obtenida de la base de datos Scopus (Criterio de búsqueda: Título de artículo, resumen y palabras clave: "Acuicultura" & "Inteligencia artificial" en el periodo 2000-2021), en total 401 publicaciones y graficado en Excel con tecnología de Bing ©Australian Bureau of Statistics, GeoNames, Microsoft, Navinfo, TomTom.

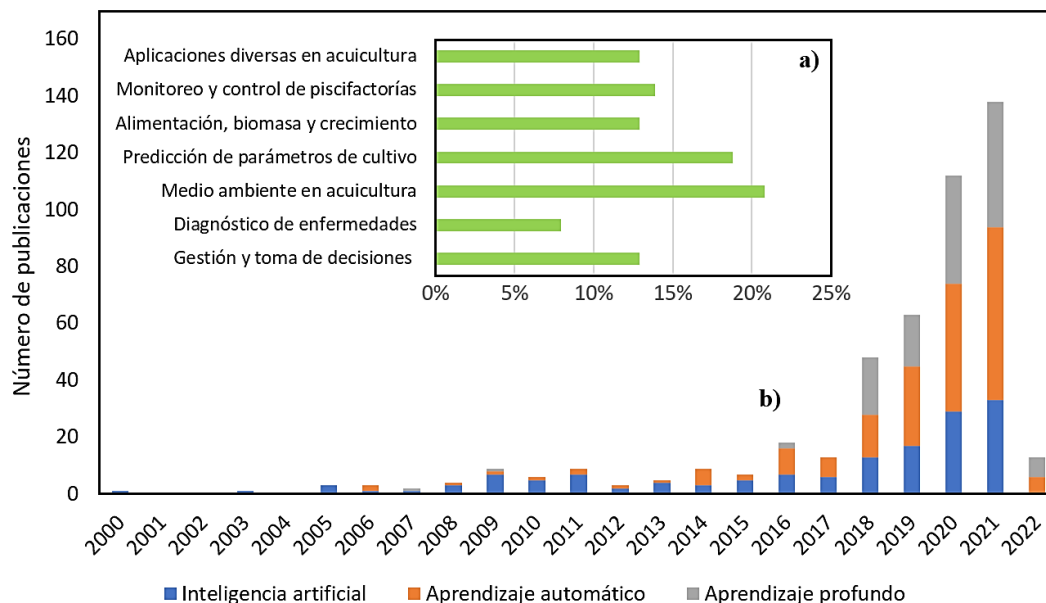


Figura 2. Evolución de la aplicación de Inteligencia artificial en acuicultura en el mundo en los últimos 20 años. (a) Aplicaciones de la Inteligencia artificial en acuicultura por temas de investigación. (b) Número de publicaciones de artículos científicos sobre Inteligencia artificial, aprendizaje automático y aprendizaje profundo en acuicultura obtenidos de la base de datos Scopus (Criterio de búsqueda: Título de artículo, resumen y palabras clave: "Aquaculture" & "Inteligencia Artificial"; "Aquaculture & Machine Learning" y "Aquaculture & Deep Learning" en el periodo 2000-2022). En total 467 publicaciones.

2.2. Aprendizaje automático

El aprendizaje automático, más conocido por su término en inglés Machine Learning (ML), se define como un campo científico que busca dar a las máquinas la capacidad de aprender sin ser estrictamente programado (Samuel, 2000a; Samuel, 2000b; Liakos et al., 2018; Yang et al., 2020). El aprendizaje automático es una disciplina que se centra en la resolución de dos problemas interrelacionados y, al aprender datos y algoritmos para generar modelos matemáticos, puede mejorar el rendimiento del sistema en los sistemas informáticos (Jordan & Mitchell, 2015). Al evolucionar a partir de la inteligencia artificial, los métodos de aprendizaje automático desarrollan modelos que son basados en características aprendidas de datos empíricos y puede inferir datos desconocidos problemas y descubrir patrones desconocidos (Sellars et al., 2013; Yang et al., 2019). Para tomar decisiones inteligentes de forma independiente, las computadoras y las máquinas deben aprender a usar algoritmos de aprendizaje automático (Sarker, 2021). En general, la efectividad y eficiencia del aprendizaje automático depende de la naturaleza y las características de los datos y del rendimiento de los algoritmos de aprendizaje.

En el área de algoritmos de aprendizaje automático, análisis de clasificación, regresión, agrupación de datos, ingeniería de características y reducción de dimensionalidad, aprendizaje de reglas de asociación o técnicas de aprendizaje por refuerzo, se construyen de manera efectiva sistemas basados en datos (Han et al., 2012; Witten et al., 2016), donde se ingresan datos de entrenamiento masivos para entrenar el modelo, de modo que el modelo pueda captar las leyes potenciales contenidas en los datos y luego lograr el propósito de clasificar o predecir con precisión los nuevos datos ingresados (Zhao et al., 2021).

2.2.1 Tipos de aprendizaje automático

Sobre la base del estilo de aprendizaje, el aprendizaje automático se puede dividir en cuatro tipos de aprendizaje: supervisado, no supervisado, semi-supervisado y reforzado (Zhao et al., 2021).

(a) Aprendizaje supervisado

Según Sarker (2021), el aprendizaje supervisado utiliza datos de entrenamiento etiquetados y una colección de ejemplos de entrenamiento para inferir una función. A través del aprendizaje y entrenamiento continuo con datos de muestras y resultados conocidos, el modelo puede obtener valores y relaciones propios, además de pronosticar los resultados (Kotsiantis, 2007).

Se usa comúnmente para separar datos "clasificación" y ajuste de datos "regresión" (Ghiassi & Lee, 2018; Sarker, 2021). Por ejemplo, mediante un modelo de aprendizaje supervisado se puede predecir el tiempo de crecimiento de los peces en función de la temperatura, pero antes se tendría que entrenar al modelo, con datos de temperatura y crecimiento, instruyendo que a mayor temperatura se acelera el crecimiento.

Clasificación

La clasificación es una técnica de aprendizaje automático considerada como una técnica predictiva del valor de algún atributo, llamado etiqueta, de un determinado conjunto de datos (Zhao et al., 2021). Además, la clasificación es una forma de aprendizaje supervisado, donde se utiliza un conjunto de entrenamiento para construir el modelo de aprendizaje. Asimismo, se utiliza un conjunto de datos de prueba para verificar la consistencia del modelo de aprendizaje desarrollado (Han et al., 2012; Sarker, 2021). Las tareas de clasificación pueden ser:

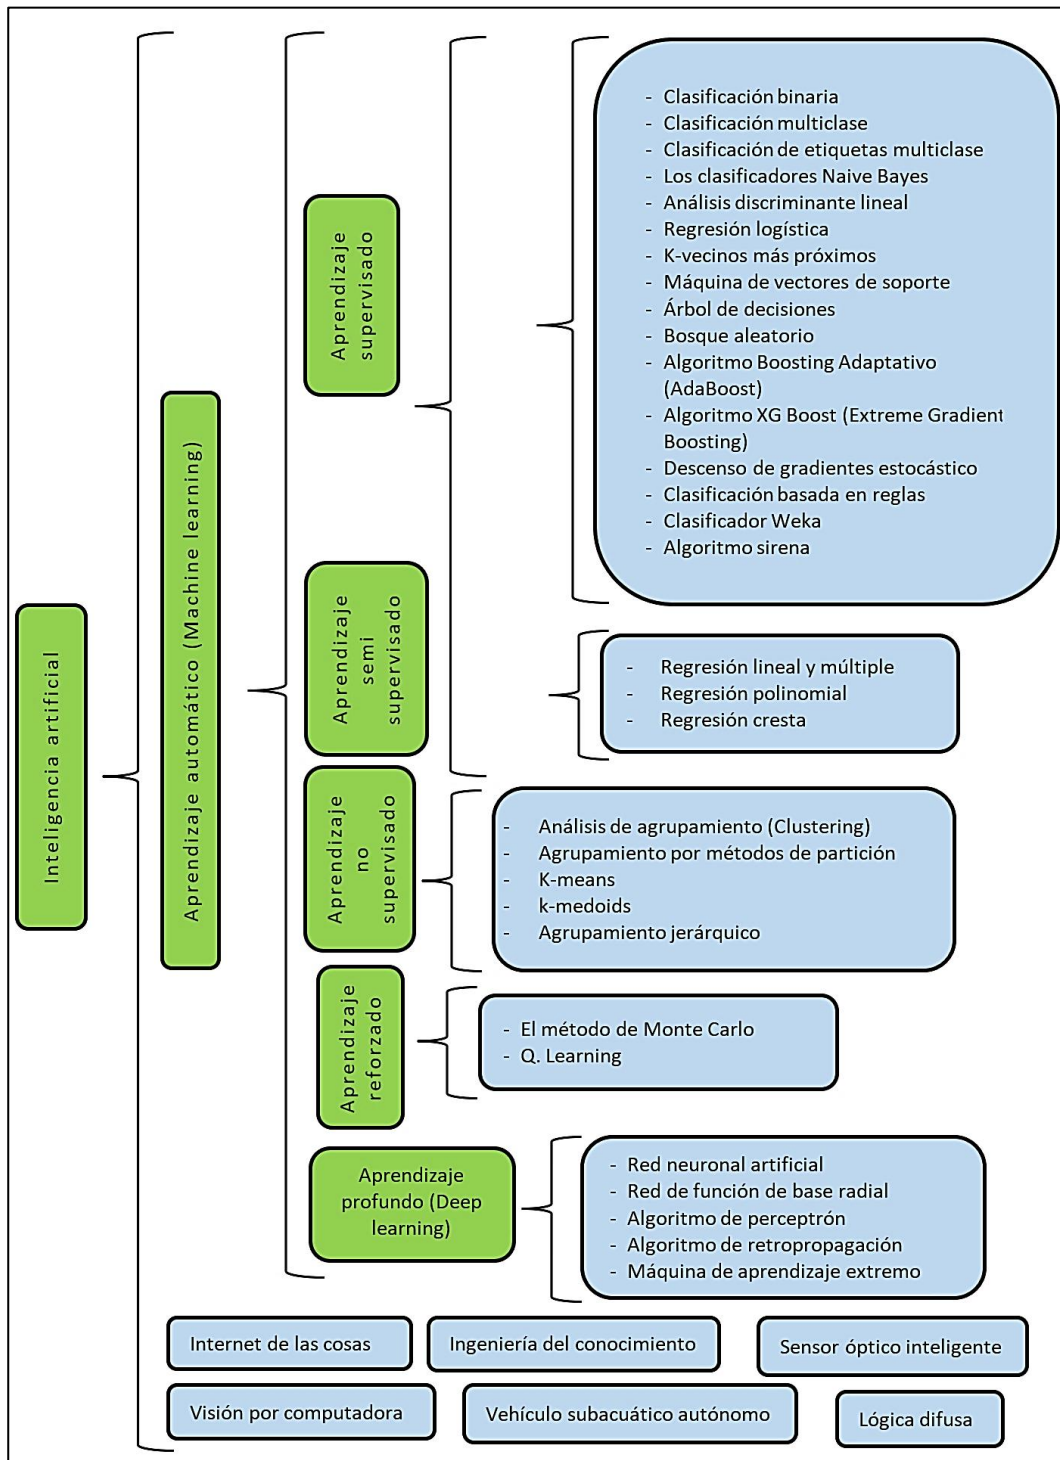


Figura 3. Campos de la Inteligencia artificial y principales técnicas y herramientas.

Clasificación binaria, que se refiere a tener dos etiquetas de clase como "verdadero y falso" o "sí" y "no" (Han et al., 2012).

Clasificación multiclase; dentro de un rango de clases especificadas los datos se clasifican como pertenecientes a una clase (Tavallaee et al., 2009).

Clasificación de etiquetas multiclase, es una generalización de la clasificación multiclase, donde las clases involucradas en el problema están jerárquicamente estructuradas, y cada dato puede simultáneamente pertenecer a más de una clase (Pedregosa et al., 2011). Algunos algoritmos de clasificación son:

Los clasificadores Naive Bayes (NBC) por su sigla en inglés, o también conocido como el ingenuo de Bayes; son algoritmos de aprendizaje automático simples pero potentes. Se basan en la probabilidad condicional y el teorema de Bayes (John & Langley, 1995). Los algoritmos Naives Bayes pueden ser interpretados cómo la suma de la información que se va obteniendo. Es decir, estos algoritmos van ganando información de cada uno de los atributos ya sea en favor o en contra de la clase dada (Hosmer et al., 2013).

Análisis discriminante lineal (LDA): Es un método de clasificación supervisado de variables cualitativas en el que dos o más grupos son conocidos *a priori* y nuevas observaciones se clasifican en uno de ellos en función de sus características. Haciendo uso del teorema de Bayes, LDA estima la probabilidad de que una observación, dado un determinado valor de los predictores, pertenezca a cada una de las clases de la variable cualitativa (Amat-Rodrigo, 2016).

Regresión logística, es un tipo de análisis de regresión utilizado para predecir el resultado de una variable categórica en función de las variables independientes o predictoras. Es útil para modelar la probabilidad de ocurrencia de un evento en función de otros factores (Hosmer et al., 2000). La regresión logística es el método de análisis adecuado cuando se necesita modelizar una variable respuesta binaria, por ejemplo, del tipo presencia o ausencia de enfermedad, y permite el uso conjunto de covariables de tipo categórico y continuo, proporcionando interpretación biológica a sus parámetros (Hosmer & Lemeshow, 1989; Boggio, 1997). El supuesto de linealidad entre las variables dependientes e independientes es considerado como un gran inconveniente de la regresión logística. Se puede utilizar tanto para problemas de clasificación como de regresión, pero se usa más comúnmente para clasificación (Sarker, 2021).

K-vecinos más próximos, conocido por su término en inglés como K-nearest neighbor. Puede usarse para clasificar nuevas muestras (valores discretos) o para predecir (regresión, valores continuos). Sirve para clasificar valores buscando los puntos de datos "más similares" aprendidos en la etapa de entrenamiento y haciendo conjeturas de nuevos puntos basados en esa clasificación (Mizianty et al., 2010).

Máquina de Vectores de Soporte, conocido por su término en inglés SVM (Support Vector Machine), es un conjunto de algoritmos que construye un hiperplano o conjunto de hiperplanos en un espacio de dimensionalidad muy alta (o incluso infinita) que puede ser utilizado en problemas de clasificación o regresión. Una buena separación entre las clases permitirá una clasificación correcta (Pedregosa et al., 2011).

Árbol de decisiones, es una de las principales herramientas predictivas que ayudan a seleccionar los atributos de mayor incidencia en una decisión de variable categórica (que usualmente pero no siempre, es dicotómica) basada en un árbol y generando una disyunción de conjunciones presentadas como un conjunto de reglas para tomar una decisión (Arias et al., 2013). Se trata de un método no paramétrico, robusto y fácil de interpretar. Funciona haciendo particiones

sucesivas en el espacio de variables buscando siempre la variable y el valor umbral de esta, que maximizan la homogeneidad de las particiones resultantes (Cánovas-García et al., 2016).

Bosque aleatorio, conocido por su término en inglés como Random forest, es una técnica que utiliza varios árboles de decisión (entre 500 y 2000), los resultados obtenidos se combinan a fin de obtener un modelo único más robusto en comparación con los resultados de cada árbol por separado (Breiman, 2001). Las ventajas del bosque aleatorio hacen que se convierta en una técnica ampliamente utilizada en muchos campos, por ejemplo, teledetección (para clasificación de imágenes), bancos (para detección de fraudes y clasificación de clientes para otorgamiento de crédito), medicina (para analizar históricos clínicos a fin de identificar enfermedades potenciales en los pacientes), finanzas (para pronosticar comportamientos futuros de los mercados financieros) y comercio electrónico (para pronosticar si un cliente comprará, o no, cierto producto), entre otros (Espinoza, 2010).

Algoritmo Boosting Adaptativo (AdaBoost), es un método que pretende mejorar el desempeño de cualquier algoritmo de aprendizaje supervisado mediante la combinación de los resultados de varios clasificadores débiles o de base para obtener un clasificador final robusto (Barbona & Beltrán, 2018). Crea un clasificador poderoso al combinar muchos clasificadores de bajo rendimiento para obtener un buen clasificador de alta precisión. En ese sentido, mejora significativamente la eficiencia del clasificador, pero en algunos casos, puede desencadenar sobreajustes, AdaBoost se utiliza mejor para impulsar el rendimiento de árboles de decisión (Pedregosa et al., 2011).

Algoritmo XG Boost (Extreme Gradient Boosting), es una técnica basada en árboles de decisión y que es considerada el estado del arte en la evolución de estos algoritmos (Espinoza, 2010). Consiste en un ensamblado secuencial de árboles de decisión (este ensamblado se conoce como CART, acrónimo de "Classification and Regression Trees"). Los árboles se agregan secuencialmente a fin de aprender del resultado de los árboles previos y corregir el error producido por los mismos, hasta que ya no se pueda corregir más dicho error, esto se conoce como "gradiente descendente" (Chen & Guestrin, 2016). La principal diferencia entre los algoritmos XGBoost y Random Forest es que en el primero el usuario define la extensión de los árboles mientras que en el segundo los árboles crecen hasta su máxima extensión (Espinoza, 2010).

Descenso de Gradientes Estocástico (SGD), es un método iterativo para optimizar una función objetivo con las propiedades de fluidez adecuada, donde la palabra "estocástico" se refiere a probabilidades aleatorias. Esto reduce la carga computacional, particularmente en problemas de optimización de alta dimensión, permitiendo iteraciones más rápidas a cambio de una menor tasa de convergencia. Siendo una gradiente la pendiente de una función que calcula el grado de cambio de una variable en respuesta a los cambios de otra variable (Han et al., 2012).

Clasificación basada en reglas, se puede utilizar para hacer referencia a cualquier esquema de clasificación que

hace uso de las reglas IF-THEN para la predicción de clases (Sarker, 2021). El árbol de decisión es uno de los algoritmos de clasificaciones basadas en reglas más comunes entre estas técnicas, porque tiene varias ventajas, como ser más fácil de interpretar; capacidad para manejar datos de alta dimensión; sencillez y velocidad; buena precisión y la capacidad de producir reglas para una clasificación clara y comprensible (Wu et al., 2016).

Análisis de regresión

El análisis de regresión incluye varios métodos de aprendizaje automático que permite predecir una variable de resultado continua (y) basado en el valor de una o más (x) variables predictoras (Han et al., 2012). La distinción más significativa entre clasificación y la regresión es que la clasificación predice distintas clases de etiquetas, mientras que la regresión facilita la predicción de una cantidad continua (Sarker, 2021).

Regresión lineal y múltiple, la regresión es una de las técnicas más populares de modelado del aprendizaje automático. En esta técnica, la variable dependiente es continua, la variable o variables independientes pueden ser continuas o discretas, y la forma de la recta de regresión es lineal (Sarker, 2021). Se conoce como regresión simple el cálculo de la ecuación correspondiente a la línea que mejor describe la relación entre la respuesta y la variable que la explica, mientras que la regresión múltiple es la extensión del modelo de regresión simple a k variables explicativas (Carrasquilla-Batista et al., 2016).

Regresión polinomial, es una forma del análisis de regresión en el que la relación entre la variable independiente X y la variable dependiente Y no es lineal, pero es del grado polinómico del n -ésimo en X (Pedregosa et al., 2011).

Regresión cresta, cuando en un modelo de regresión lineal existe una fuerte relación entre sus variables independientes se dice que hay multicolinealidad aproximada, en esta situación, el estimador de mínimos cuadrados ordinarios ofrece resultados inestables, por lo que una alternativa es el estimador cresta cuando se presenta multicolinealidad (García et al., 2017).

(b) Aprendizaje no supervisado

El aprendizaje no supervisado analiza un conjunto de datos no etiquetados, sin la necesidad de interferencia humana. Se usa ampliamente para extraer características generativas, identificar tendencias y estructuras significativas, agrupando los resultados (Sarker, 2021). Analiza grupos de datos similares entre sí (Bakshi et al., 2014). El aprendizaje no supervisado al no necesitar supervisión aprende de los mismos datos, descubriendo grupos de datos similares entre sí o patrones, por ejemplo; de un conjunto de datos obtenidos de la biometría de peces ligados a datos de calidad de agua, el modelo puede agrupar grupos de peces con tendencias a un rápido crecimiento. Las técnicas más utilizadas son:

Análisis de agrupamiento, también conocido como análisis de conglomerado y en su término en inglés como clustering, es una técnica de aprendizaje automático no supervisado, para identificar y agrupar puntos de datos relacionados en grandes conjuntos de datos sin preocuparse por el resultado específico. Lo hace

agrupando una colección de objetos de tal manera que los objetos de la misma categoría, denominados clúster, son en cierto sentido más similares entre sí que objetos de otros grupos (Han et al., 2012). Son varios los tipos de métodos de agrupación.

Agrupamiento por métodos de partición, basados en las características y similitudes en los datos, este enfoque de agrupamiento categoriza los datos en varios grupos o clústeres (Sarker, 2021). La versión más simple y fundamental de los métodos de segmentación son los métodos de partición, estos organizan los objetos de un conjunto en varios grupos exclusivos o clústers. Normalmente el número de clústers tendrá la nomenclatura "k" (Han et al., 2012). Las técnicas más usadas dentro de los métodos de partición son:

K-means, basada en un centroide, es posiblemente la técnica más popular de segmentación, k-means agrupa n observaciones o registros en k agrupaciones en las que cada observación pertenece a la agrupación con el centro más cercano. La agrupación funciona para agrupar los registros juntos de acuerdo con un algoritmo o fórmula matemática que intenta encontrar centroides, o centros, en torno al cual gravitan registros similares (Cao et al., 2020).

k-Medoids, basada en un objeto representativo, es muy sensible a los valores atípicos, ya que estos pueden estar muy lejanos de la mayoría de los puntos; y, por tanto, distorsionar el valor medio del clúster. Se busca corregir esta desviación que puede generarse; y, propone en lugar de determinar un punto medio para calcular la distancia entre los puntos, tomar como punto medio uno de los datos dados, un objeto representativo, que actuará como centroide, y el resto de los datos es asociado al clúster en función de la distancia con el centroide (Han et al., 2012).

Agrupamiento jerárquico, se diferencia del agrupamiento basado en particiones en que se construye un árbol de fusión binario a partir de hojas que contienen elementos de datos hasta la raíz que contiene el conjunto de datos completo. La representación gráfica de ese árbol que incrusta los nodos en el plano se llama dendrograma (Nielsen, 2016). Es un método de análisis de grupos puntuales, el cual busca construir una jerarquía de grupos mediante estrategias aglomerativas (acercamiento ascendente: cada observación comienza en su propio grupo, y los pares de grupos son mezclados mientras uno sube en la jerarquía) y divisivas (este es un acercamiento descendente: todas las observaciones comienzan en un grupo, y se realizan divisiones mientras uno baja en la jerarquía) (Sarker, 2021).

(c) Aprendizaje semi supervisado

El aprendizaje semi supervisado es un método que combina el aprendizaje supervisado con el aprendizaje no supervisado. Este método puede realizar la combinación de clasificación, regresión y agrupamiento (Zhao et al., 2021). Opera tanto en datos etiquetados como no etiquetados (Han et al., 2012; Sarker et al., 2020). Algunas áreas de aplicación donde el aprendizaje semi-supervisado se utiliza incluyen traducción automática, detección de fraudes, etiquetado, clasificación de datos y texto (Sarker, 2021).

Tabla 1
Investigaciones realizadas en gestión y toma de decisiones en acuicultura

Método	Tema de investigación	Técnica / Herramienta	Referencias
Aprendizaje profundo	Modelado de redes neuronales para los efectos del oxígeno disuelto en cultivos extensos	Red neuronal backpropagation.	Carbajal-Hernández & Sánchez-Fernández (2017)
Aprendizaje profundo	Un sistema de gestión inteligente para acuaponía, para estimar los parámetros de crecimiento a partir de imágenes ópticas.	Algoritmo ingenuo de Bayes / Red neuronal Long-Term-Short-Memory / Distancia de Mahalanobis.	Karimanzira & Rauschenbach (2021)
Aprendizaje profundo	Sistema de apoyo a la toma de decisiones para realizar predicciones en acuicultura	Lógica difusa y Red neuronal Backpropagation.	Wang et al. (2009)
Aprendizaje profundo	Aplicación de análisis de árbol de fallas y Red neuronal difusa para el diagnóstico de fallas en el Internet de las cosas para la acuicultura.	Análisis del árbol de fallas, Red neuronal difusa e Internet de las cosas.	Chen et al. (2017)
Aprendizaje automático	Desarrollo de un sistema de almacenamiento de peces ornamentales basado en grandes datos de video.	Máquina de vectores de soporte.	Chen et al. (2018)
Aprendizaje automático	Sirena: Un nuevo algoritmo informático aplicado a la clasificación de las zonas de cultivo.	Algoritmo Sirena.	Conte & Ahmadi (2016)
Aprendizaje automático	Métodos de agregación de conjuntos para predecir cierre de granjas.	Clasificador Weka.	D'Este et al. (2014)
Aprendizaje automático	Sistema electrónico inteligente para la gestión de estanques en la acuicultura de agua dulce.	Sistema de soporte de decisiones predictivo.	Kamiseti et al. (2012)
Aprendizaje automático	Apoyo dinámico a la toma de decisiones basado en datos para el cierre de granjas acuícolas.	Predicción basada en clasificación de series de tiempo.	Shahriar & McCulluch (2014)
Aprendizaje automático	Análisis de características de dispersión posterior de acuicultura de balsa flotante basado en imágenes ISAR.	Radar de apertura sintética, Radar de apertura sintética inversa y Función de dispersión hacia atrás.	Wang et al. (2019)
Aprendizaje profundo	Identificación de áreas de acuicultura por imágenes satelitales.	Radar polarimétrico de apertura sintética GF3 (POLRSAR) y Red neuronal convolucional.	Fan et al. (2019)
Aprendizaje profundo	Identificación de áreas de acuicultura por imágenes satelitales.	Red neuronal convolucional y Máquina de vectores de soporte.	Fu et al. (2019)
Aprendizaje profundo	Tecnología de visión por computadora en el desarrollo de un repelente ultrasónico.	Tecnología de visión por computadora.	Petrov & Popov (2021)

Fuente: Información obtenida de la base de datos Scopus (Criterio de búsqueda: Título de artículo, resumen y palabras clave: "Aquaculture" & "Inteligencia Artificial"; "Aquaculture & Machine Learning" y "Aquaculture & Deep Learning" en el periodo 2000-2022).

(d) Aprendizaje de refuerzo

El aprendizaje de refuerzo donde la máquina aprende por sí sola el comportamiento a seguir en base a recompensas y penalizaciones. Es un tipo de algoritmo de aprendizaje automático que habilita agentes de software y máquinas para evaluar automáticamente el óptimo comportamiento en un contexto o entorno particular para mejorar su eficiencia (Kaelbling et al., 1996; Sarker, 2021). Es un método de aprendizaje automático más complejo que enfatiza la interacción constante entre el sistema y el mundo exterior. Este método está dirigido principalmente a escenarios donde el razonamiento es requerido constantemente en el proceso, como la neurociencia (Mnih et al., 2015), robots que realizan cirugías (Faust et al., 2017) y sistema de piloto automático (Zhu et al., 2018). El método de Monte Carlo, son una amplia categoría de algoritmos computacionales que se basan en un muestreo aleatorio repetido para obtener resultados numéricos (Kaelbling et al., 1996). Utiliza la aleatoriedad para resolver problemas deterministas; optimización, integración numérica y hacer dibujos a partir de la distribución de probabilidad (Sarker, 2021).

Q.Learning, es un método de aprendizaje por refuerzo que permite resolver problemas de decisión secuencial en los cuales la utilidad de una acción depende de una secuencia de decisiones y donde además existe incertidumbre en cuanto a las dinámicas del ambiente en que está

situado el agente (Watkins & Dayan, 1996; Printista et al., 2000).

2.2.2 Aprendizaje profundo

El aprendizaje profundo más conocido por su término en inglés Deep Learning (DL), está ganando notoriedad en los últimos años ya que están mostrando un mejor desempeño al abordar muchos problemas de interés en la comunidad de aprendizaje automático (Abadi et al., 2016; Fernandes et al., 2020). Es una rama del aprendizaje automático y es de tipo del algoritmo de aprendizaje de representación basado en una red neuronal (Deng & Yu, 2013; Yang et al., 2021). Las redes neuronales artificiales (ANN) son programas de computadora que están diseñados para simular las funciones del cerebro humano utilizando diferentes algoritmos de aprendizaje, que pueden aprender de la experiencia (Gowrishankar et al., 2017). Un modelo de red neuronal típico generalmente consta de tres capas (Wang et al., 2009) independientes: de entrada, oculta y salida. Cada capa se compone de varios procesos neuronales (Chen et al., 2003). Las ANN tienen las características de procesamiento de información notables de un cerebro humano, como no linealidad, alto paralelismo, robustez, tolerancia a fallas y fallas, capacidad de aprendizaje para manejar información imprecisa y difusa y su capacidad para generalizar. Por lo tanto, las ANN se puede utilizar para resolver problemas complicados de la vida real, como clasificación de patrones, agrupamiento,

aproximación y optimización de funciones. Hay muchos tipos de modelos de ANN que se han desarrollado para numerosas aplicaciones diferentes. Basado en el algoritmo de aprendizaje (entrenamiento), el entrenamiento del modelo de ANN podría ser supervisado o no supervisado. Para entrenamiento supervisado, el modelo de ANN se presenta con conjuntos de datos de entrada-salida, mientras que, el entrenamiento no supervisado, el modelo de ANN se presenta solo con datos de entrada, y el modelo aprende a reconocer patrones en los datos (Gowrishankar et al., 2017).

El método de la red neuronal implica esencialmente el mapeo de un patrón de entrada complejo en otro complejo patrón de salida, utilizando una estructura de procesamiento de datos formada por neuronas ampliamente interconectadas. Porque el método deriva de la comprensión de los sistemas neurobiológicos, La red neuronal utiliza el concepto de aprender de las entradas para resultados, similar a la forma en que el cerebro humano aprende de la experiencia (Miao, 2010).

3. Aplicaciones de la inteligencia artificial en acuicultura

En diversas investigaciones se aplicaron la inteligencia artificial, aprendizaje automático y aprendizaje profundo, para caracterizar los sistemas inteligentes en toma de decisiones, en diseños para determinar pronósticos y la digitalización de imágenes. A continuación, se describe los principales campos de acuicultura, donde la inteligencia artificial interviene.

3.1 Gestión y toma de decisiones en acuicultura

El aprendizaje automático y aprendizaje profundo son los métodos más utilizados en investigaciones realizadas en temas de gestión inteligente de granjas acuícolas, apoyo más dinámico para toma de decisiones en acuicultura e identificación de áreas de acuicultura. En la **Tabla 1** se muestra la información de las principales técnicas aplicadas como las redes neuronales, lógica difusa, análisis de árbol de fallas, algoritmo sirena y algoritmo ingenuo de Bayes, máquina de vectores de soporte, además de

herramientas como las imágenes satelitales, visión por computadora y el internet de las cosas.

3.2 Diagnóstico de enfermedades en peces

La importancia de diagnosticar a tiempo una enfermedad en los peces permite aplicar las acciones y tratamientos para prevenir pérdidas en la producción. El comportamiento de los peces y algunos signos externos son los principales datos de entrenamiento para que la inteligencia artificial pueda diagnosticar enfermedades en los peces y así evitar su propagación (Ahmed et al., 2021). En la **Tabla 2** se muestra las investigaciones desarrolladas en diagnóstico de enfermedades en peces.

3.3 Medio ambiente en acuicultura

La acuicultura hace uso de insumos como alimentos balanceados, medicamentos y otros químicos que después de ser utilizados se acumulan en el medio acuático, ocasionando el deterioro de la calidad y su restricción para los cultivos. Medir y predecir el impacto de la acuicultura en el medio ambiente es cada vez más rápido y factible con la aplicación de la inteligencia artificial y los diferentes métodos de aprendizaje. Cobra mayor importancia desde que sus resultados se aplican para hacer seguimiento, controlar y regular leyes relacionadas al impacto de la acuicultura en el medio ambiente. En la **Tabla 3** se detalla algunas investigaciones técnicas y herramientas para medir el impacto ambiental de la acuicultura.

3.4 Predicción de parámetros de cultivo en acuicultura

Considerando los diversos parámetros que se manejan en acuicultura, es una necesidad optimizar estas para alcanzar un máximo rendimiento en cuanto a producción.

En los últimos años, la tecnología de aprendizaje automático se ha vuelto más profunda y amplia, y los modelos de aprendizaje se han aplicado en cada vez más campos, siendo la acuicultura uno de ellos (Zhao et al., 2021). Por ello la importancia de evaluar y relacionar los parámetros que son importantes en el mantenimiento de un entorno óptimo o ideal para la acuicultura (Gustilo & Dadios, 2011).

Tabla 2

Investigaciones con aplicación en diagnóstico de enfermedades en peces

Método	Tema de investigación	Técnica / Herramienta	Referencias
Aprendizaje automático	Detección de enfermedades de peces basada en imágenes	Máquinas de vectores de soporte	Ahmed et al. (2021)
Aprendizaje automático	Clasificación de algoritmos para datos de química sanguínea para peces.	Árbol de decisiones.	Coz-Rakovac et al. (2009)
Aprendizaje profundo	Detección de la enfermedad de la mancha blanca.	Algoritmo híbrido de redes neuronales y lógica difusa.	Fabregas et al. (2018)
Inteligencia artificial	Diagnóstico de enfermedades en peces, comparando imágenes con lo real.	Ingeniería del conocimiento.	Feijoo et al. (1989)
Inteligencia artificial	Desarrollo de un sistema de telediagnóstico de enfermedades de los peces.	Lógica difusa.	Li et al. (2006)
Inteligencia artificial	Exploración de tendencias emergentes en la salud de los animales acuáticos.	Aplicación de inteligencia de bioseguridad acuática de código abierto AquaticHealth.net.	Lyon et al. (2013)
Aprendizaje automático	La predicción de la resistencia a las enfermedades.	Árbol de decisiones, Máquinas de vectores de soporte, Bosque aleatorio, Impulso adaptativo (Adaboost) y el aumento de gradiente extremo	Palaikostas (2021)
Aprendizaje automático	Sistema inteligente de apoyo a la toma de decisiones para la gestión de enfermedades / salud de los peces.	Máquina de vectores de soporte	Xiaoshuan et al. (2009)

Fuente: Información obtenida de la base de datos Scopus (Criterio de búsqueda: Título de artículo, resumen y palabras clave: "Aquaculture" & "Inteligencia Artificial"; "Aquaculture & Machine Learning" y "Aquaculture & Deep Learning" en el periodo 2000-2022).

Tabla 3
Investigaciones con aplicación en medio ambiente

Método	Tema de investigación	Técnica / Herramienta	Referencias
Aprendizaje profundo	Clasificación de la calidad de agua de acuicultura mediante red neuronal BP basada en MapReduce.	Red neuronal backpropagation BP	Wen et al. (2020)
Inteligencia artificial	Un método óptico inteligente de medición de oxígeno disuelto basado en un mecanismo de extinción fluorescente.	Sensor óptico inteligente.	Li et al. (2015)
Aprendizaje profundo	Desarrollo de un conjunto de datos de imágenes microscópicas, en apoyo de la detección inteligente de fitoplancton mediante el aprendizaje profundo.	Algoritmo de detección en imágenes microscópicas.	Li et al. (2020)
Aprendizaje automático	Evaluación del efecto de la acuicultura utilizando tecnología basada en sensores con algoritmo de aprendizaje automático.	Internet de las cosas y algoritmo de aprendizaje automático de decisión mejorada.	Manoharan et al. (2020)
Aprendizaje automático	Análisis de aprendizaje automático de frecuencias oligonucleótidas bacterial para evaluar el impacto bentónico de la acuicultura.	Algoritmo de Bosques aleatorios.	Armstrong & Verhoeven (2020)
Inteligencia artificial	Clasificación para la calidad del hábitat artificial en acuicultura.	Sistema de inferencia difusa.	Carbajal & Sánchez (2008)
Aprendizaje profundo	Evaluación del potencial de recuperación de aguas residuales en acuicultura	Red neuronal recurrente parcial.	Chen et al. (2003)
Aprendizaje automático	Modelo de regulación inteligente para mantener un entorno de agua limpia y estable en acuicultura.	Máquinas de vectores de soporte.	Chen et al. (2021)
Aprendizaje automático	Predicción del estado de calidad ecológica mediante el aprendizaje automático supervisado.	Modelos predictivos.	Cordier et al. (2017)
Aprendizaje automático	Desarrollo de un sistema sostenible de apoyo a la toma de decisiones para una acuicultura en jaulas	Proceso de jerarquía analítica.	Halide et al. (2009)
Aprendizaje automático	Sistema de apoyo para la toma de decisiones como tecnología ambiental sostenible.	Sistema de soporte a las decisiones.	Hermawan (2018)
Inteligencia artificial	Evaluación del hábitat artificial en acuicultura utilizando la clasificación de patrones ambientales.	Sistema de inferencia difusa.	Hernández et al. (2010)
Aprendizaje profundo	Aplicación de redes neuronales artificiales para estimar la contaminación regional en aguas subterráneas	Red neuronal backpropagation	Kao & Chang (2011)
Aprendizaje automático	Incorporación de efectos acumulativos en evaluaciones ambientales de acuicultura.	Sistema de soporte a las decisiones.	King & Pushchak (2008)
Inteligencia artificial	Control del medio ambiente de la acuicultura.	Lógica difusa.	Lea et al. (1998)
Inteligencia artificial	Desarrollo de un sistema de evaluación de la idoneidad de las áreas de acuicultura basado en tecnología enchufable.	Sistemas de Información Geográfica ArcGIS, Modelo de extensión materia-elemento.	Li et al. (2020)
Aprendizaje automático	ClimeGreAq, software para la adaptación al cambio climático de la acuicultura griega.	Sistema de soporte a las decisiones.	Stavrakidis-Zachou et al. (2021)
Aprendizaje profundo	Análisis del sistema de toma de decisiones para la calidad del agua en acuicultura basado en el aprendizaje profundo.	Red neuronal Long-Term-Short-Memory.	Su et al. (2019)
Aprendizaje automático	Un sistema de apoyo a la toma de decisiones para evaluar el riesgo de seguridad de la calidad del agua contaminada en estanques	Máquina de vectores de soporte.	Tian et al. (2009)
Aprendizaje automático	Inteligencia artificial para detectar la mala calidad del agua con sensores remotos.	Teledetección óptica.	Uz et al. (2020)
Aprendizaje profundo	Nuevos modelos de evaluación de eutrofización para áreas de agua de acuicultura.	Red neuronal artificial, Red neuronal de regresión y Red neuronal multicapa de avance.	Yang et al. (2015)

Fuente: Información obtenida de la base de datos Scopus (Criterio de búsqueda: Título de artículo, resumen y palabras clave: "Aquaculture" & "Inteligencia Artificial"; "Aquaculture & Machine Learning" y "Aquaculture & Deep Learning" en el periodo 2000-2022).

Las redes neuronales artificiales están logrando tener relevancia en el estudio de procesos y resultados que consideren muchas variables de manera simultánea (Cevallos-Ampuero, 2004). En los últimos años se han desarrollado rápidamente redes neuronales que permiten optimizar procesos (Ta & Wei, 2018). La **Tabla 4** examina ciertas aplicaciones de inteligencia artificial en predicción de parámetros de cultivo.

3.5 Alimentación, biomasa y crecimiento

La tendencia que existe entre el crecimiento de los peces en función del tiempo debe ser optimizada en acuicultura,

así como la combinación de tratamientos que optimizan el crecimiento a través del tiempo. Según **Chen et al. (2019)** en la acuicultura, la predicción precisa de la ingesta de alimento para los peces del grupo se considera crucial a cualquier sistema de alimentación. Por otro lado, la sostenibilidad de la acuicultura depende también del aspecto económico, siendo el costo de alimentación el que influye de manera significativa y en mayor proporción que determina cuan rentable es la actividad para mantenerse activo. Según **Sun et al. (2016)** el nivel de alimentación está directamente relacionado con la eficiencia de producción y costo de reproducción.

En la **Tabla 5** se puntualiza las herramientas y técnicas aplicadas para la investigación en alimentación, biomasa y crecimiento en peces.

3.6 Monitoreo y control de piscifactorías

El propósito para aplicar la tecnología de control de procesos en la acuicultura abarca muchos factores socioeconómicos (Atia et al., 2011a), medio ambientales y productivos. Las diferentes herramientas y técnicas que abarca el concepto de internet de las cosas son las más utilizadas para el monitoreo y control de la eficiencia y

mejor comprensión de los procesos en acuicultura. En la **Tabla 6** se nombran las diferentes técnicas y herramientas utilizadas para temas de investigación en monitoreo y control de piscifactorías.

3.7 Aplicaciones diversas en acuicultura

En la **Tabla 7** se listan diversas técnicas y herramientas utilizadas para investigaciones y aplicaciones diversas en acuicultura, algunas se complementan con otras tecnologías y áreas de estudio como la genética y biología.

Tabla 4

Investigaciones en predicción de parámetros y variables de cultivo

Método	Tema de investigación	Técnica / Herramienta	Referencias
Aprendizaje profundo	Sistema de predicción a corto plazo de la temperatura del agua en la acuicultura de estanques.	Red neuronal backpropagation optimizado por algoritmo genético.	Chen et al. (2018)
Aprendizaje profundo	Modelo de predicción de la ingesta de alimento para peces en acuicultura intensiva.	Red neuronal backpropagation y Algoritmo evolutivo.	Chen et al. (2020)
Aprendizaje profundo	Segmentación de imágenes de aprendizaje para la extracción de medidas corporales de peces y la predicción del peso corporal y las características de la canal en la tilapia del Nilo.	Red neuronal convolucional.	Fernandes et al. (2020)
Aprendizaje profundo	Modelización de la concentración de oxígeno y materia orgánica en el sistema de cría intensivo de trucha arco iris (<i>Oncorhynchus mykiss</i>).	Red neuronal de base radial y Red neuronal perceptrón multicapa.	Galezan et al. (2020)
Aprendizaje automático	Pronóstico y mantención de la calidad del agua en las piscifactorías de agua dulce.	Algoritmo del factor atípico local, Internet de las cosas y Árbol de decisiones modelo M5.	Gao et al. (2019)
Aprendizaje profundo	Predicción de la calidad de agua en función a la salinidad, temperatura, oxígeno disuelto, pH y densidad de carga.	Red neuronal artificial.	Gustilo & Dadios (2011)
Inteligencia artificial	Evaluación y predicción de la calidad del agua en acuicultura utilizando técnicas de procesamiento de señales.	Lógica difusa.	Hernández et al. (2011)
Aprendizaje profundo	Predicción de oxígeno disuelto en agua de acuicultura basada en agrupación de K-medias y red neuronal de aprendizaje extremo.	Red neuronal de clasificación K.means y Red neuronal de aprendizaje extremo.	Huan & Liu (2016)
Aprendizaje profundo	Predicción de oxígeno disuelto en estanques de acuicultura de <i>Apostichopus japonicus</i> .	Red neuronal backpropagation y Red neuronal autoregresivo.	Li et al. (2010)
Aprendizaje profundo	Predicción del contenido de oxígeno disuelto en Acuicultura de <i>Hyriopsis Cumingii</i> .	Red neuronal de Elman.	Liu et al. (2012)
Aprendizaje profundo	Modelo capaz de predecir el oxígeno disuelto con precisión en estanques	Algoritmo de entrenamiento Levenberg-Marquardt y Algoritmo genético.	Miao et al. (2010)
Aprendizaje profundo	Pronóstico de las cosechas de <i>Litopenaeus vannamei</i> y <i>Penaeus monodon</i> .	Red neuronal backpropagation.	Pamungkas et al. (2020)
Aprendizaje profundo	Predicción inteligente de la calidad del agua basada en Internet de las cosas para la acuicultura de biofloc.	Internet de las cosas / Redes neuronales.	Rashid et al. (2021)
Aprendizaje profundo	Estudio sobre la predicción de la temperatura del agua en la acuicultura industrial.	Red neuronal de aprendizaje extremo optimizado por algoritmo genético.	Shi et al. (2018a)
Aprendizaje profundo	Predicción de la temperatura del agua en estanques de acuicultura.	Red neuronal de base radial.	Shi et al. (2018b)
Aprendizaje profundo	Método de predicción de oxígeno disuelto para recirculación del sistema de acuicultura, basado en una matriz de atenuación de tiempo y una red neuronal convolucional.	Red neuronal full backpropagation.	Ta & Wei (2018)
Aprendizaje profundo	Método de predicción de oxígeno disuelto para recirculación del sistema de acuicultura.	Red neuronal convolucional.	Ta et al. (2019)
Aprendizaje profundo	Modelo de predicción optimizado en tiempo real para oxígeno disuelto en estanques de acuicultura.	Red neuronal backpropagation.	Yang et al. (2014)
Aprendizaje profundo	Predicción de oxígeno disuelto en acuicultura.	Red neuronal convolucional tridimensional (3D), Red neuronal Convolucional Long-Term-Short-Memory.	Zha et al. (2021)

Fuente: Información obtenida de la base de datos Scopus (Criterio de búsqueda: Título de artículo, resumen y palabras clave: "Aquaculture" & "Inteligencia Artificial"; "Aquaculture & Machine Learning" y "Aquaculture & Deep Learning" en el periodo 2000-2022).

Tabla 5

Temas de investigación en alimentación, biomasa y crecimiento en peces

Método	Tema de investigación	Técnica / Herramienta	Referencias
Aprendizaje profundo	Incorporación de inteligencia en el sistema de alimentación de peces, para dispensar alimento basado según la intensidad de alimentación de los peces.	Red neuronal y análisis de vibraciones del comportamiento de los peces.	Adegboye et al. (2020)
Aprendizaje profundo	Un marco de segmentación de cardúmenes de peces de alta densidad para estadísticas de biomasa en una jaula de aguas profundas.	Modelo de fondo gaussiano adaptativo de múltiples escalas, Modelo de fondo basado en bloques de múltiples escalas y Núcleo de convolución ponderado direccional.	Liu et al. (2021)
Aprendizaje profundo	Evaluación de la intensidad de la alimentación de los peces en la acuicultura.	Red neuronal convolucional y visión artificial.	Zhou et al. (2019)
Aprendizaje profundo	Uso de algoritmos de aprendizaje automático para analizar la estructura del escudo y la identificación del sexo de <i>Acipenser ruthenus</i> .	Algoritmo de Boruta / Algoritmo del bosque aleatorio / Método de construcción de árbol binario / Análisis discriminante binario con algoritmo DA / Redes neuronales.	Barulin N. (2019)
Aprendizaje automático	Sistema de acuicultura inteligente: Un sistema de alimentación remota con teléfonos inteligentes.	Internet de las cosas.	Imai et al. (2019)
Aprendizaje automático	Investigación sobre el método de estimación de la masa corporal de los reproductores de Koi, basados en la tecnología de reconocimiento de imágenes del estado de alimentación.	Código OpenCV.	Ma et al. (2020)
Aprendizaje profundo	Evaluación de la intensidad de la alimentación de los peces en la acuicultura con redes neuronales convolucionales.	Red neuronal convolucional, Máquina de vectores de soporte y Red neuronal backpropagation.	Ubina et al. (2021)
Inteligencia artificial	Controlador de alimentación inteligente basado en visión artificial y comportamiento de alimentación para peces en acuicultura.	Tecnología de visión por computadora.	Zhou et al. (2019)
Inteligencia artificial	Aplicación de técnicas de inteligencia artificial para implementar un sistema práctico de gestión de acuicultura en jaulas inteligentes.	Internet de las cosas.	Chang et al. (2021)
Inteligencia artificial	Inteligencia artificial impulsada por ontología y sistemas de control de acceso para pesquerías inteligentes.	Control de acceso basado en atributos.	Chukkapalli et al. (2021)
Aprendizaje profundo	Análisis de imágenes de atún para datos biométricos.	Red neuronal artificial.	Costa et al. (2009)
Aprendizaje profundo	Parámetros de calidad de agua y su relación con el crecimiento de los peces.	Sistema de red neuronal artificial experto.	Deng et al. (2010)
Aprendizaje automático	Estimación automatizada de la masa de peces dentro del tanque utilizando un sistema de reflexión infrarroja.	Algoritmo de bosque aleatorio y Máquina de vectores de soporte.	Saberioon & Císař (2018)

Fuente: Información obtenida de la base de datos Scopus (Criterio de búsqueda: Título de artículo, resumen y palabras clave: "Aquaculture" & "Inteligencia Artificial"; "Aquaculture & Machine Learning" y "Aquaculture & Deep Learning" en el periodo 2000-2022)

4. Perspectivas de la inteligencia artificial en acuicultura

A medida que la tecnología avanza y lo permita, se tiene la posibilidad de optimizar más áreas en acuicultura:

4.1 Optimizar la cantidad de alimento y selección de peces

La cantidad de alimento a entregar a los peces es un factor crítico (Adegboye et al., 2017) está en función de la temperatura del agua, la biomasa de la unidad productiva (Saberioon & Císař, 2018) (estanque, jaula flotante), el peso promedio de los peces y una tasa de alimentación característica de cada tipo de alimento. La estimación de la biomasa es una de las prácticas más comunes e importantes en acuicultura (Li et al., 2020; Ma et al., 2020). Una vez que se determina la cantidad de alimento se debe de dar la ración correspondiente, sin embargo, no siempre los peces consumen todo lo que se les entrega y para evitar las pérdidas del alimento se debe entregar la cantidad de alimento exacta sin sobrepasar lo calculado

(Cho et al., 1994; Zhou et al., 2019), es decir, se puede optimizar la entrega del alimento aplicando la inteligencia artificial.

Un "sistema de alimentación automático" debe controlar la cantidad y el momento de la alimentación. Incluyendo cuatro procesos: "entrada de imagen", "reconocimiento de imagen", "control del alimentador" y "acción de alimentación" (Kuroki et al., 2020). Los avances en la visión por computadora son muy prometedores para aumentar el rendimiento de la resta de fondo y detección de primer plano y aumentando significativamente la cantidad de información que se puede extraer de datos de video (por ejemplo, identidad animal, tamaño, forma, color, tasa de movimiento, interacciones conductuales) (Weinstein, 2018). La Figura 4 representa una unidad productiva de acuicultura en jaulas flotantes, y se bosqueja la aplicación de la inteligencia artificial y sus diversos métodos, técnicas y herramientas para optimizar la cantidad de alimento y selección de peces.

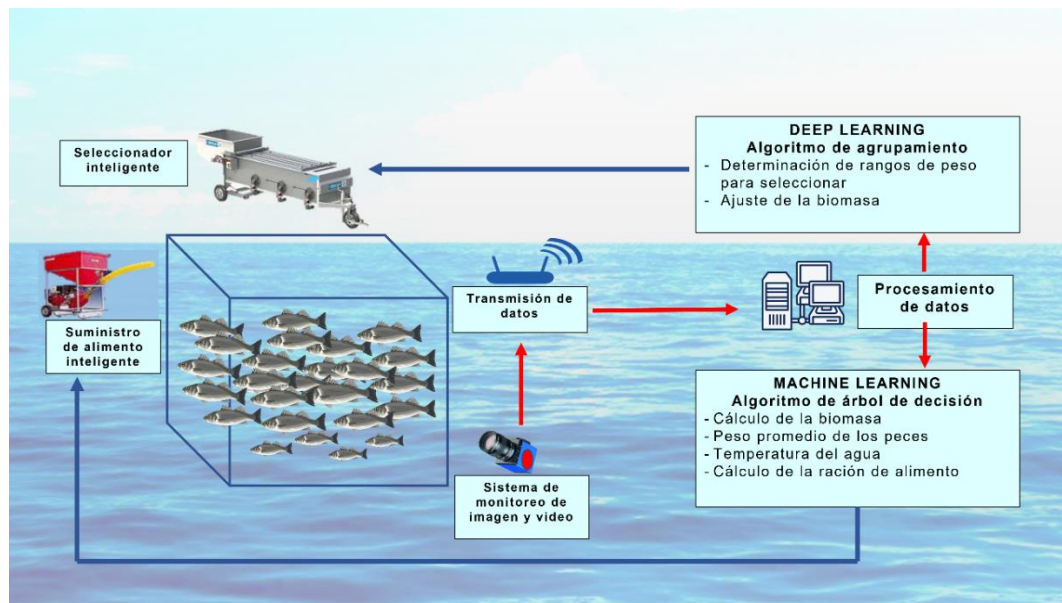


Figura 4. Aplicación de aprendizaje automático y aprendizaje profundo en la optimización de la cantidad de alimento y selección de peces en acuicultura.

Tabla 6

Temas de investigación monitoreo y control de piscifactorías

Método	Tema de investigación	Técnica / Herramienta	Referencias
Aprendizaje profundo	Técnicas de inteligencia artificial basadas en el control del sistema de calentamiento termosolar de agua de la acuicultura.	Control de lógica difusa adaptativa, redes neuronales.	Atia et al. (2011b)
Aprendizaje profundo	Control del flujo de agua caliente para mantener la temperatura del agua usando técnicas de inteligencia artificial	Red neuronal artificial.	Atia et al. (2011a)
Aprendizaje profundo	Optimización de la alimentación en función de la temperatura y oxígeno disuelto.	Algoritmo de entrenamiento Levenberg-Marquardt y Red neuronal artificial.	Gowrishankar et al. (2017)
Aprendizaje automático	El sistema de monitoreo de la calidad del agua basado en WSN.	Internet de las cosas.	He & Zhang (2012)
Inteligencia artificial	Estudio modificado del algoritmo de entrenamiento basado en el algoritmo de la colonia de hormigas ACO, para una red de sensores inalámbricos en acuicultura intensiva WSN.	Algoritmo de la colonia de hormigas.	Hua et al. (2013)
Inteligencia artificial	Prototipo de un sistema inteligente de vigilancia.	Tecnología de visión por computadora.	Huang et al. (2019)
Aprendizaje profundo	Diseño de arquitectura de monitoreo y control de sistema de acuaponía basado en internet de las cosas alimentado por energía solar.	Internet de las cosas.	Khaoula et al. (2021)
Aprendizaje automático	Desarrollo de simulador de acuicultura eficiente de <i>Sillago japonica</i> mediante aprendizaje reforzado.	Algoritmo de detección de objetos YOLOv3 / algoritmo Mask RCNN / Algoritmo de optimización de políticas.	Kuroki et al. (2020)
Inteligencia artificial	Digitalización de peces que nadan libremente basada en visión estéreo binocular.	Algoritmo de agregación de costos no local para la coincidencia estéreo.	Lin et al. (2016)
Inteligencia artificial	PelagiCam: Sistema de imágenes subacuáticas con visión por computadora, para el monitoreo semiautomático de la fauna acuícola.	Tecnología de visión por computadora.	Sheehan et al. (2020)
Aprendizaje automático	Equipo autoadaptativo de drones acuáticos con red de comunicación para Acuicultura.	Internet de las cosas.	Sousa et al. (2019)
Aprendizaje profundo	Detección de puntos claves de peces para monitoreo ecológico basado en inteligencia visual subacuática.	Red neuronal convolucional Faster - Faster.	Suo et al. (2020)
Aprendizaje automático	Avances actuales y desafíos futuros de las aplicaciones de inteligencia artificial en el monitoreo y control de materia particulada.	Internet de las cosas y Monitoreo de partículas en suspensión.	Yang et al. (2021)
Aprendizaje profundo	Propuesta de una estrategia de control PID basada en redes neuronales para regular la temperatura.	Red neuronal basado en algoritmo de control.	Yu et al. (2015)

Fuente: Información obtenida de la base de datos Scopus (Criterio de búsqueda: Título de artículo, resumen y palabras clave: "Acuaculture" & "Inteligencia Artificial"; "Aquaculture & Machine Learning" y "Aquaculture & Deep Learning" en el periodo 2000-2022)

Tabla 7

Aplicaciones diversas en acuicultura

Método	Tema de investigación	Técnica / Herramienta	Referencias
Aprendizaje profundo	Detección de peces, sistema de visión artificial para el seguimiento de peces por imágenes.	Red neuronal artificial y visión artificial.	Almero et al. (2019)
Aprendizaje profundo	Aprendizaje de transferencia sobre detección para sistema de visión subacuática.	Red neuronal convolucional.	Isa et al. (2020)
Aprendizaje automático	Uso del patrón binario local como herramienta para la extracción de características del género <i>scylla</i> .	Análisis Discriminante Lineal / Máquinas de vectores de soporte / K-vecino más próximo y Patrones binarios locales.	Ali & Fauzi (2019)
Aprendizaje automático	Inteligencia artificial: Control remoto móvil basado en 5G.	Internet de las cosas.	Angani et al. (2019)
Aprendizaje automático	Inteligencia artificial: Control de flujo basado en internet de las cosas utilizando MQTT.	Internet de las cosas.	Angani et al. (2019)
Aprendizaje automático	Modelo de evaluación del proyecto de investigación de tecnología de robots de acuicultura basado en aprendizaje automático.	Tecnología robótica.	Cheng (2020)
Inteligencia artificial	Inteligencia de enjambres en la gestión óptima de las granjas acuícolas.	Algoritmo de optimización basado en enjambres de partículas.	Cobo et al. (2015)
Aprendizaje automático	Integración de datos ambientales locales e información de ciencia ciudadana no impulsada.	Modelo aditivo generalizado.	Gutiérrez-Estrada et al. (2021)
Inteligencia artificial	Diseño de vehículos subacuáticos autónomos para las jaulas de acuicultura.	Vehículo subacuático autónomo.	Lee et al. (2007)
Aprendizaje profundo	Transcriptómica del ARNm y la calidad del huevo en peces de piscifactoría: algunos desarrollos recientes y direcciones futuras.	Red neuronal artificial.	Sullivan et al. (2015)
Aprendizaje profundo	Bioimagen: ajuste de umbral automático y segmentación a través de redes neuronales.	Red neuronal y segmentación por umbral.	Urbanová et al. (2017)
Aprendizaje automático	Selección genómica en acuicultura:	Máquina de vectores de soporte.	Zenger et al. (2019)
Aprendizaje automático	Manejo de reflejos de agua para visión artificial en acuicultura.	Máquina de vectores de soporte.	Zhou et al. (2018)

Fuente: Información obtenida de la base de datos Scopus (Criterio de búsqueda: Título de artículo, resumen y palabras clave: "Aquaculture" & "Inteligencia Artificial"; "Aquaculture & Machine Learning" y "Aquaculture & Deep Learning" en el periodo 2000-2022)

4.2. Para la identificación del sexo de los peces

El sexo biológico en los peces es un rasgo complejo y muestra un alto nivel evolutivo (Martínez et al., 2014; Mei & Gui, 2015; Lu & Luo, 2020). La identificación del sexo en los peces y su separación en espacios diferentes es una actividad importante que asegura la sostenibilidad de semilla para la acuicultura, mantener un plantel de reproductores machos y hembras es prioridad para proyectar la producción de semilla. Según Barulin (2019), la perfecta determinación temprana del sexo se considera imposible.

En algunas especies como salmónidos y truchas donde existe dimorfismo sexual la tarea no es complicada, sin embargo, en especies como el *Arapaima gigas*, una especie amazónica de gran importancia, que no manifiesta dimorfismo sexual, aún se presenta el inconveniente para la identificación del sexo. La mayoría de los métodos conocidos son difíciles de usar, causan estrés al pez o se usan a una edad relativamente tardía, se recurre a prueba bioquímicas para analizar en la sangre del pez la presencia de hormonas como la vitelogenina para determinar el sexo del pez, esto conlleva a un estrés adicional del pez. Se podría aplicar inteligencia artificial mediante visión artificial (Zhou et al., 2018) para correlacionar los datos de comportamiento del pez (Yongqiang et al., 2019), movimientos y dimensiones del cuerpo con el sexo del pez.

4.3 Grado de pigmentación del músculo de salmón y trucha

Los salmones y truchas tienen como atributo de calidad el grado de pigmentación del músculo. Para alcanzar el grado de pigmentación proyectado se añade al alimento, el pigmento artificial astaxantina, durante un tiempo definido se alimenta con este tipo de alimento denominado pigmentante. El control que se realiza para confirmar el grado de pigmentación alcanzado es mediante el sacrificio del pez. Sin embargo, se podría aplicar inteligencia artificial para optimizar el tiempo de pigmentación en función a variables como la temperatura del agua, cantidad de alimento entregado y talla del pez (Lin et al., 2016).

5. Conclusiones

Durante los últimos 20 años, la inteligencia artificial, y los campos que abarca; aprendizaje automático, aprendizaje profundo, así como las diversas técnicas y herramientas que utilizan, se han venido usando de manera más intensa en la acuicultura.

En comparación con las herramientas estadísticas convencionales, el desarrollo de la inteligencia artificial, el aprendizaje automático y la red neuronal ha ampliado el alcance de la aplicación inteligente en la acuicultura y ha mejorado la optimización de las principales variables como es el oxígeno disuelto y temperatura.

Sin embargo, las tecnologías estudiadas aún tienen el reto de resolver problemas como optimizar la cantidad de alimento y alimentación en granjas acuícolas, la identificación del sexo de los peces y la determinación del grado de pigmentación del músculo de salmones y trucha.

ORCID

W. Vasquez-Quispesivana  <https://orcid.org/0000-0003-1345-6261>

M. Inga  <https://orcid.org/0000-0002-9677-5446>

I. Betalueluz-Pallardel  <https://orcid.org/0000-0002-9286-7191>

Referencias bibliográficas

- Abadi, M., McMahan, H. B., Chu, A., Mironov, I., Zhang, L., Goodfellow, I., & Talwar, K. (2016). Deep learning with differential privacy. *Proceedings of the ACM Conference on Computer and Communications Security*, 24-28-October-2016, 308-318.
- Adegboye, M. A., Aibinu, A. M., Kolo, J. G., Aliyu, I., Folorunso, T. A., & Lee, S. (2020). Incorporating intelligence in fish feeding system for dispensing feed based on fish feeding intensity. *IEEE Access*, 8(9093055) 91948-91960.
- Ahmed, M. S., Aurpa, T. T., & Azad, M. A. K. (2021). Fish disease detection using image-based machine learning technique in aquaculture. *Journal of King Saud University - Computer and Information Sciences*. 1-13.
- Ahmed, N., Thompson, S., & Glaser, M. (2019). Global aquaculture productivity, environmental sustainability, and climate change adaptability. *Environmental Management*, 63(2), 159-172.
- Ali, R., & Fauzi, M. S. M. (2019). The use of local binary pattern (LBP) feature extraction members of the mud crab genus *Scylla*. *Pervasive Health: Pervasive Computing Technologies for Healthcare*, 202-206.
- Almero, V. J., Concepcion, R., Rosales, M., Vicerra, R. R., Bandala, A., & Dadios, E. (2019). An aquaculture-based binary classifier for fish detection using multilayer artificial neural network. *2019 IEEE 11th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment, and Management, HNICEM 2019*.
- Amat-Rodrigo, J. (2016). Análisis discriminante lineal (LDA) y análisis discriminante cuadrático (QDA). Available under a Attribution 4.0 International (CC BY 4.0).
- Angani, A., Lee, C., Lee, S., & Shin, K. J. (2019). Realization of eel fish farm with artificial intelligence part 3: 5G based mobile remote control. Paper presented at the *2019 IEEE International Conference on Architecture, Construction, Environment and Hydraulics, ICACEH 2019*, 101-104.
- Angani, A., Oh, S. M., Kim, E. S., & Shin, K. J. (2019). Realization of eel fish farm with artificial intelligence Part2: IoT based flow control using MQTT. *2019 IEEE International Conference on Architecture, Construction, Environment and Hydraulics, ICACEH 2019*, 97-100.
- Arias, R., Santa, J. J., & Vellozo, J. D. J. (2013). Aplicación del aprendizaje automático con árboles de decisión en el diagnóstico médico. *Cultura Del Cuidado*, 10(1), 63-72.
- Armstrong, G., & Verhoeven, T. P. (2020). Machine learning analyses of bacterial oligonucleotide frequencies to assess the benthic impact of aquaculture. *Aquaculture Environment Interactions*, 12, 131-137.
- Atia, A. D. M., Fahmy, F. H., Ahmed, N. M., & Dorrah, H. T. (2011a). Solar thermal aquaculture system controller based on artificial neural network. *World Academy of Science, Engineering and Technology*, 73, 378-384.
- Atia, D. M., Fahmy, F. H., Ahmed, N. M., & Dorrah, H. T. (2011b). Artificial intelligence techniques based on aquaculture solar thermal water heating system control. *Renewable Energy and Power Quality Journal*, 1(9), 1027-1034.
- Bakshi, S., Jagadev, A. K., Dehuri, S., & Wang, G. (2014). Enhancing scalability and accuracy of recommendation systems using unsupervised learning and particle swarm optimization. *Applied Soft Computing Journal*, 15, 21-29.
- Barbona, I., & Beltrán, C. (2018). Aplicación del algoritmo Boosting Adaptativo (ADABOOST) a un problema de clasificación automática de textos. *Revista de Epistemología y Ciencias Humanas. Facultad de Ciencias Agrarias, Universidad Nacional de Rosario, Argentina*.
- Barulin, N. V. (2019). Using machine learning algorithms to analyse the scute structure and sex identification of sterlet *Acipenser ruthenus* (Acipenseridae). *Aquaculture Research*, 50(10), 2810-2825.
- Boggio, G. (1997). Modelo de regresión logística aplicado a un estudio sobre enfermedad de Chagas. *Cadernos de Saúde Publica*. Brasil.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5-32.
- Cánovas-García, F., Alonso-Sarría, F., & Gomariz-Castillo, F. (2016). Modificación del algoritmo Random Forest para su empleo en clasificación de imágenes de teledetección. *Aplicaciones de las Tecnologías de la Información Geográfica (TIG) para el desarrollo económico sostenible XVII Congreso Nacional de Tecnologías de Información Geográfica*, Málaga.
- Cao, X., Liu, Y., Wang, J., Liu, C., & Duan, Q. (2020). Prediction of dissolved oxygen in pond culture water based on K-means clustering and gated recurrent unit neural network. *Aquacultural Engineering*, 91, 102122.
- Carbajal, J. J., & Sánchez, L. P. (2008). Classification based on fuzzy inference systems for artificial habitat quality in shrimp farming. *7th Mexican International Conference on Artificial Intelligence - Proceedings of the Special Session, MICAI 2008*, 388-392.
- Carbajal-Hernández, J. J., & Sánchez-Fernández, L. P. (2017). Neural network modelling for dissolved oxygen effects in extensive *Litopenaeus vannamei* culture. 15th Mexican International Conference on Artificial Intelligence, MICAI 2016, Cancun 23-28 October 2016. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 10062(LNAI), 132-140.
- Carrasquilla-Batista, A., Chacón-Rodríguez, A., Núñez-Montero, K., Gómez-Espinoza, O., Valverde, J., & Guerrero-Barrantes, M. (2016). Regresión lineal simple y múltiple: aplicación en la predicción de variables naturales relacionadas con el crecimiento microalgal. *Tecnología en Marcha. Encuentro de Investigación y Extensión 2016*. Pág 33-45.
- Cevallos-Ampuero, J. (2004). Aplicación de redes neuronales para optimizar problemas multiobjetivo en mejora de la calidad. *Revista de la Facultad de Ingeniería Industrial*, 2(7), 31-34.
- Chang, C., Wang, J., Wu, J., Hsieh, Y., Wu, T., Cheng, S., & Lin, C. (2021). Applying artificial intelligence (AI) techniques to implement a practical smart cage aquaculture management system. *Journal of Medical and Biological Engineering*, 41(5), 652-658.
- Chen, C., Chang, C., Chen, C., Chang, T., Zeng, X., Liu, J., & Lu, W. (2018). Developing an ornamental fish warehousing system based on big video data. *International Journal of Automation and Smart Technology*, 8(2), 79-83.
- Chen, F., Du, Y., Qiu, T., Xu, Z., Zhou, L., Xu, J., & Sun, J. (2021). Design of an intelligent variable-flow recirculating aquaculture system based on machine learning methods. *Applied Sciences (Switzerland)*, 11(14).
- Chen, J. C., Chang, N. B., & Shieh, W. K. (2003). Assessing wastewater reclamation potential by neural network model. *Engineering Applications of Artificial Intelligence*, 16(2 SPEC.), 149-157.
- Chen, L., Yang, X., Sun, C., Wang, Y., Xu, D., & Zhou, C. (2020). Feed intake prediction model for group fish using the MEA-BP neural network in intensive aquaculture. *Information Processing in Agriculture*, 7(2), 261-271.

- Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. Paper presented at the Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 13-17-August-2016 785-794.
- Chen, Y., Cheng, Q., Cheng, Y., Yu, H., & Zhang, C. (2017). Short-term prediction system of water temperature in pond aquaculture based on GA-BP neural network. *Nongye Jixie Xuebao/Transactions of the Chinese Society for Agricultural Machinery*, 48(8), 172-178.
- Chen, Y., Zhen, Z., Yu, H., & Xu, J. (2017). Application of fault tree analysis and fuzzy neural networks to fault diagnosis in the internet of things (IoT) for aquaculture. *Sensors (Switzerland)*, 17(1).
- Cho, C. Y., Hynes, J. D., Wood, K. R., & Yoshida, H. K. (1994). Development of high-nutrient-dense, low-pollution diets and prediction of aquaculture wastes using biological approaches. *Aquaculture*, 124(1-4), 293-305.
- Chukkappalli, S. S. L., Aziz, S. B., Alotaibi, N., Mittal, S., Gupta, M., & Abdelsalam, M. (2021). Ontology driven AI and access control systems for smart fisheries. Paper presented at the SAT-CPS 2021 - Proceedings of the 2021 ACM Workshop on Secure and Trustworthy Cyber-Physical Systems, 59-68.
- Cobo, A., Llorente, I., & Luna, L. (2015). Swarm intelligence in optimal management of aquaculture farms. *International Series in Operations Research and Management Science* 224, 221-239.
- Conte, F. S., & Ahmadi, A. (2016). Mermaid: A new computer algorithm applied to the classification of shellfish growing areas of Virginia, USA. Paper presented at the 21st Century Watershed Technology Conference and Workshop 2016: Improving Quality of Water Resources at Local, Basin and Regional Scales, 2016-January 1-9.
- Cordier, T., Esling, P., Lejzerowicz, F., Visco, J., Ouadahi, A., Martins, C., & Pawlowski, J. (2017). Predicting the ecological quality status of marine environments from eDNA metabarcoding data using supervised machine learning. *Environmental Science and Technology*, 51(16), 9118-9126.
- Costa, C., Scardi, M., Vitalini, V., & Cataudella, S. (2009). A dual camera system for counting and sizing northern bluefin tuna (*Thunnus thynnus*; *linnaeus*, 1758) stock, during transfer to aquaculture cages, with a semi-automatic artificial neural network tool. *Aquaculture*, 291(3-4), 161-167.
- Coz-Rakovac, R., Topic Popovic, N., Smuc, T., Strunjak-Perovic, I., & Jadan, M. (2009). Classification accuracy of algorithms for blood chemistry data for three aquaculture-affected marine fish species. *Fish Physiology and Biochemistry*, 35(4), 641-647.
- Deng, C., Gao, Y., Gu, J., Miao, X., & Li, S. (2010). Research on the growth model of aquaculture organisms based on neural network expert system. Paper presented at the Proceedings - 2010 6th International Conference on Natural Computation, ICNC 2010, 4 1812-1815.
- Deng, L., & Yu, D. (2013). Deep learning: Methods and applications. *Foundations and Trends in Signal Processing*, 7(3-4), 197-387.
- D'Este, C., Timms, G., Turnbull, A., & Rahman, A. (2014). Ensemble aggregation methods for relocating models of rare events. *Engineering Applications of Artificial Intelligence*, 34, 58-65.
- Espinoza, J. (2010). Aplicación de algoritmos Random Forest y XGBoost en una base de solicitudes de tarjetas de crédito. *Ingeniería Investigación y Tecnología volumen XXI* (3).
- Fabregas, A. C., Cruz, D., & Marmeto, M. D. (2018). SUGPO: A white spot disease detection in shrimps using hybrid neural networks with fuzzy logic algorithm. *ACM International Conference Proceeding Series*, 199-203.
- Fan, J., Zhao, J., An, W., & Hu, Y. (2019). Marine floating raft aquaculture detection of GF-3 PolSAR images based on collective multikernel fuzzy clustering. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12(8), 2741-2754.
- Faust, A., Palunko, I., Cruz, P., Fierro, R., & Tapia, L. (2017). Automated aerial suspended cargo delivery through reinforcement learning. *Artificial Intelligence*, 247, 381-398.
- Feijoo, S., Pintos, J., & Hernandez, C. (1989). Knowledge engineering for diagnosis of piscine diseases. *Proceedings of the IEEE International Conference on Systems, Man and Cybernetics*, 1, 313-314.
- Fernandes, A. F. A., Turra, E. M., de Alvarenga, É. R., Passafaro, T. L., Lopes, F. B., Alves, G. F. O., & Rosa, G. J. M. (2020). Deep learning image segmentation for extraction of fish body measurements and prediction of body weight and carcass traits in Nile tilapia. *Computers and Electronics in Agriculture*, 170.
- Fu, Y., Ye, Z., Deng, J., Zheng, X., Huang, Y., Yang, W., & Wang, K. (2019). Finer resolution mapping of marine aquaculture areas using world view-2 imagery and a hierarchical cascade convolutional neural network. *Remote Sensing*, 11(14).
- Galezan, F. H., Bayati, M. R., Safari, O., & Rohani, A. (2020). Modeling oxygen and organic matter concentration in the intensive Rainbow trout (*Oncorhynchus mykiss*) rearing system. *Environmental Monitoring and Assessment*, 192(4), 223.
- Gao, G., Xiao, K., & Chen, M. (2019). An intelligent IoT-based control and traceability system to forecast and maintain water quality in freshwater fish farms. *Computers and Electronics in Agriculture*, 166.
- García, C., Salemerón, R., Rodríguez, A. & García, J. (2017). Regresión cresta, algunos inconvenientes. Conference: XXXI Reunión Internacional de Economía Aplicada. ASEPELT XXXI. At: Lisboa Volume: Annales of Applied Economic ASEPELT.
- Ghiassi, M., & Lee, S. (2018). A domain transferable lexicon set for twitter sentiment analysis using a supervised machine learning approach. *Expert Systems with Applications*, 106, 197-216.
- Gowrishankar, K., Nithiyananthan, K., Mani, P. R., & Venkatesan, G. (2017). Neural network based mathematical model for feed management technique in aquaculture. *Journal of Advanced Research in Dynamical and Control Systems*, 18, 1142-1161.
- Gustilo, R. C., & Dadios, E. (2011). Optimal control of prawn aquaculture water quality index using artificial neural networks. *Proceedings of the 2011 IEEE 5th International Conference on Cybernetics and Intelligent Systems, CIS 2011*, 266-271.
- Gutiérrez-Estrada, J. C., Pulido-Calvo, I., Peregrín, A., García-Gálvez, A., Báez, J. C., Bellido, J. J., & López, J. A. (2021). Integrating local environmental data and information from non-driven citizen science to estimate jellyfish abundance in Costa del Sol (Southern Spain). *Estuarine, Coastal and Shelf Science*, 249, 107112.
- Halide, H., Stigebrandt, A., Rehbein, M., & McKinnon, A. D. (2009). Developing a decision support system for sustainable cage aquaculture. *Environmental Modelling and Software*, 24(6), 694-702.
- Han, J., Kamber, M., & Pei, J. (2012). Data mining: Concepts and techniques. 703 p.
- He, D., & Zhang, L. (2012). The water quality monitoring system based on WSN. *2012 2nd International Conference on Consumer Electronics, Communications and Networks, CEC Net 2012 - Proceedings*, 3661-3664.
- Hermawan, S. (2018). The benefit of decision support system as sustainable environment technology to utilize coastal abundant resources in Indonesia. *MATEC Web of Conferences*, 164.
- Hernández, J. J. C., Fernández, L. P. S., & Ibarra, M. A. M. (2010). Assessment of the artificial habitat in shrimp aquaculture using environmental pattern classification. *Lecture Notes in Computer Science (including subseries in Artificial Intelligence and Lecture Notes in Bioinformatics)* 6134 (LNCS), 113-121.

- Hernández, J. J. C., Fernández, L. P. S., & Pogrebnyak, O. (2011). Assessment and prediction of water quality in shrimp culture using signal processing techniques. *Aquaculture International*, 19(6), 1083-1104.
- Hosmer, D. W., Lemeshow, S., & Sturdivant, R. X. (2013) Applied Logistic Regression. Vol. 398, John Wiley & Sons.
- Hosmer, D. W., & Lemeshow, S. (1989). Applied Logistic Regression New York: John Wiley & Sons.
- Hosmer, D. W., Lemeshow, S., & Sturdivant, R. (2000). Applied Logistic Regression, 2nd ed. New York; Chichester, Wiley.
- Hu, Z., Li, R., Xia, X., Yu, C., Fan, X., & Zhao, Y. (2020). A method overview in smart aquaculture. *Environmental Monitoring and Assessment*, 192(8).
- Hua, X., Tian, Y., Chen, C., & Xing, K. (2013). Modified study of routing algorithm based on ACO for intensive aquaculture WSN. *Applied Mechanics and Materials*, 278-280, 974-977
- Huan, J., & Liu, X. (2016). Dissolved oxygen prediction in water based on K-means clustering and ELM neural network for aquaculture. *Nongye Gongcheng Xuebao/Transactions of the Chinese Society of Agricultural Engineering*, 32(17), 174-181.
- Huang, I., Hung, C., Kuang, S., Chang, Y., Huang, K., Tsai, C., & Feng, K. (2019). The prototype of a smart underwater surveillance system for shrimp farming. *Proceedings of the 2018 IEEE International Conference on Advanced Manufacturing*, ICAM 2018, 177-180.
- Imai, T., Arai, K., & Kobayashi, T. (2019). Smart aquaculture system: A remote feeding system with smartphones. *2019 IEEE 23rd International Symposium on Consumer Technologies*, ISCT 2019, 93-96.
- Isa, I. S., Norzrin, N. N., Sulaiman, S. N., Hamzaid, N. A., & Maruzuki, M. I. F. (2020). CNN transfer learning of shrimp detection for underwater vision system. *Proceeding - 1st International Conference on Information Technology, Advanced Mechanical and Electrical Engineering*, ICITAMEE 2020, 226-231.
- John, G. H., & Langley, P. (1995) Estimating Continuous Distributions in Bayesian Classifiers. *Proceedings of the Eleventh conference on Uncertainty in Artificial Intelligence*, Morgan Kaufmann Publishers Inc., 338-345.
- Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245), 255-260.
- Kaelbling, L. P., Littman, M. L., & Moore, A. W. (1996). Reinforcement learning: A survey. *Journal of Artificial Intelligence Research*, 4, 237-285.
- Kamisetti, S. N. R., Arvind Dattatreya Shaligram, & Sadistap, S. S. (2012). Smart electronic system for pond management in freshwater aquaculture. *ISIA 2012 - 2012 IEEE Symposium on Industrial Electronics and Applications*, 173-175.
- Kao, L., & Chang, F. (2011). Applying ANNs for estimating the regional arsenic pollution in groundwater. *Journal of Taiwan Agricultural Engineering*, 57(3), 88-102.
- Karimanzira, D., & Rauschenbach, T. (2021). An intelligent management system for aquaponics. [Ein intelligentes Managementsystem für die Aquaponik]. *At-Automatisierungstechnik*, 69(4), 345-350.
- Khaoula, T., Abdelouahid, R. A., Ezzahoui, I., & Marzak, A. (2021). Architecture design of monitoring and controlling of IoT-based aquaponics system powered by solar energy. *Procedia Computer Science*, 191, 493-498.
- King, S. C., & Pushchak, R. (2008). Incorporating cumulative effects into environmental assessments of mariculture: Limitations and failures of current siting methods. *Environmental Impact Assessment Review*, 28(8), 572-586.
- Kotsiantis, S. B. (2007). Supervised machine learning: A review of classification techniques. *Informatica (Ljubljana)*, 31(3), 249-268.
- Kuroki, H., Ikeoka, H., & Isawa, K. (2020). Development of simulator for efficient aquaculture of *Sillago japonica* using reinforcement learning. *Proceedings of International Conference on Image Processing and Robotics*, ICIPRoB 2020.
- Lea, R., Dohmann, E., Prebilsky, W., Lee, P., Turk, P., & Ying, H. (1998). A fuzzy logic application to aquaculture environment control. *Annual Conference of the North American Fuzzy Information Processing Society - NAFIPS*, 29-33.
- Lee, J., Roh, M., Kim, K., & Lee, D. (2007). Design of autonomous underwater vehicles for cage aquafarms. *IEEE Intelligent Vehicles Symposium, Proceedings*, 938-943.
- Li, B., Huang, X., Song, N., Wang, Q., Zhang, G., & Nie, L. (2020). Development of an aquaculture suitability assessment system of sea areas based on plug-in technology. *Proceedings - 2020 International Conference on Big Data, Artificial Intelligence and Internet of Things Engineering*, ICBAIE 2020, 250-254.
- Li, D., Hao, Y., & Duan, Y. (2020). Noninvasive methods for biomass estimation in aquaculture with emphasis on fish: A review. *Reviews in Aquaculture*, 12(3), 1390-1411.
- Li, D., Zhu, W., Duan, Y., & Fu, Z. (2006). Toward developing a tele-diagnosis system on fish disease. *IFIP International Federation for Information Processing*, 217, 445 - 454.
- Li, F., Du, M., Gao, Y., Jiang, W., Li, W., Dong, S., & Jiang, Z. (2020). Temporal and spatial distribution variation of picoplankton and environmental impact factors in Sanggou Bay. *Journal of Fisheries of China*, 44(7), 1100-1111.
- Li, F., Li, D., Wei, Y., Daokun, M., & Ding, Q. (2010). Dissolved oxygen prediction in *Apostichopus japonicus* aquaculture ponds by BP neural network and AR model. *Sensor Letters*, 8(1), 95-101.
- Li, F., Wei, Y., Chen, Y., Li, D., & Zhang, X. (2015). An intelligent optical dissolved oxygen measurement method based on a fluorescent quenching mechanism. *Sensors (Switzerland)*, 15(12), 30913-30926.
- Liakos, K. G., Busato, P., Moshou, D., Pearson, S., & Bochtis, D. (2018). Machine learning in agriculture: A review. *Sensors (Switzerland)*, 18(8), 2674.
- Lin, C., Xu, L., & Liu, Z. (2016). Digitization of free-swimming fish based on binocular stereo vision. *Proceedings - 2015 8th International Symposium on Computational Intelligence and Design*, ISCID 2015, 2, 363-368.
- Liu, H., Liu, T., Gu, Y., Li, P., Zhai, F., Huang, H., & He, S. (2021). A high-density fish school segmentation framework for biomass statistics in a deep-sea cage. *Ecological Informatics*, 64.
- Liu, S., Yan, M., Tai, H., Xu, L., & Li, D. (2012). Prediction of dissolved oxygen content in aquaculture of *Hyriopsis cumingii* using Elman neural network. *IFIP Advances in Information and Communication Technology*, 370(AICT), 508 - 518
- Lu, G., & Luo, M. (2020). Genomes of major fishes in world fisheries and aquaculture: Status, application and perspective. *Aquaculture and Fisheries*, 5(4), 163-173.
- Lyon, A., Mooney, A., & Grossel, G. (2013). Using aquatichealth.net to detect emerging trends in aquatic animal health. *Agriculture (Switzerland)*, 3(2), 299-309.
- Ma, Y., Wei, W., & Zhou, C. (2020). Research on body mass estimation method of Koi broodstock based on feeding state image recognition technology. *Journal of Physics: Conference Series*, 1637(1).
- Manoharan, H., Teekaraman, Y., Kshirsagar, P. R., Sundaramurthy, S., & Manoharan, A. (2020). Examining the effect of aquaculture using sensor-based technology with machine learning algorithm. *Aquaculture Research*, 51(11), 4748-4758.
- Martínez, P., Viñas, A. M., Sánchez, L., Díaz, N., Ribas, L., & Piferrer, F. (2014). Genetic architecture of sex determination in fish: Applications to sex ratio control in aquaculture. *Frontiers in Genetics*, 5(SEP).
- Mei, J., & Gui, J. (2015). Genetic basis and biotechnological manipulation of sexual dimorphism and sex determination in fish. *Science China Life Sciences*, 58(2), 124-136.
- Miao, X., Deng, C., Li, X., Gao, Y. & He, D. (2010). A hybrid neural network and genetic algorithm model for predicting dissolved oxygen in an aquaculture pond. *Proceedings - 2010 International Conference on Web Information Systems and Mining*, WISM 2010, 1 415-419.

- Mizianty, M., Kurgan, L., & Ogiela, M. (2010). Discretization as the enabling technique for the Naïve Bayes and semi-Naïve Bayes-based classification. *The Knowledge Engineering Review*, 25(4), 421-449.
- Mnih, V., Kavukcuoglu, K., Silver, D., Rusu, A. A., Veness, J., Bellemare, M. G. & Hassabis, D. (2015). Human-level control through deep reinforcement learning. *Nature*, 518(7540), 529-533.
- Mouloodi, S., Rahmanpanah, H., Gohari, S., Burvill, C., Ming, K., & Davies, H. (2021). What can artificial intelligence and machine learning tell us? A review of applications to equine biomechanical research. *Journal of the Mechanical Behavior of Biomedical Materials*, 123, 104728.
- Ng, A. K., & Mahkeswaran, R. (2021). Emerging and disruptive technologies for urban farming: A review and assessment. *Journal of Physics: Conference Series*, 2003(1), 012008.
- Nielsen, F. (2016). Hierarchical Clustering. In: Introduction to HPC with MPI for Data Science. *Undergraduate Topics in Computer Science*. Springer, Cham.
- Palaiokostas, C. (2021). Predicting for disease resistance in aquaculture species using machine learning models. *Aquaculture Reports*, 20.
- Pamungkas, A., Zulkarnain, R., Adiyana, K., Waryanto, Nugroho, H., & Saragih, A. S. (2020). Application of artificial neural networks to forecast *Litopenaeus vannamei* and *Penaeus monodon* harvests in Indramayu regency, Indonesia. Paper presented at the IOP Conference Series: *Earth and Environmental Science*, 521(1), 012018.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., & Duchesnay, É. (2011). Scikit-learn: Machine learning in python. *Journal of Machine Learning Research*, 12, 2825-2830.
- Petrov, A., & Popov, A. (2021). Computer vision technology in the development of an ultrasonic repeller. *Lecture Notes in Civil Engineering*, 130 (LNCE), 447-458.
- Printista, A., Errecalde, M. & Montoya, C. (2000). Una implementación paralela del algoritmo de Q-Learning basada en un esquema de comunicación con caché. Proyecto UNSL N° 3384031 *Departamento de Informática Universidad Nacional de San Luis*. Argentina.
- Rashid, M. M., Nayan, A., Rahman, M. O., Simi, S. A., Saha, J., & Kibria, M. G. (2021). IoT based smart water quality prediction for biofloc aquaculture. *International Journal of Advanced Computer Science and Applications*, 12(6), 56-62.
- Ren, Q., Wang, X., Li, W., Wei, Y., & An, D. (2020). Research of dissolved oxygen prediction in recirculating aquaculture systems based on deep belief network. *Aquacultural Engineering*, 90, 102085.
- Sabari, M., Aswinth, P., Karthik, T., & Bharath Kumar, C. (2020). Water quality monitoring system based on IoT. ICDCS 2020 - 2020 5th International Conference on Devices, Circuits and Systems, 279-282.
- Saberioon, M., & Cisař, P. (2018). Automated within tank fish mass estimation using infrared reflection system. *Computers and Electronics in Agriculture*, 150, 484-492.
- Sabo-Attwood, T., Apul, O. G., Bisesi, J. H., Kane, A. S., & Saleh, N. B. (2021). Nano-scale applications in aquaculture: Opportunities for improved production and disease control. *Journal of Fish Diseases*, 44(4), 359-370.
- Samuel, A. L. (2000). Some studies in machine learning using the game of checkers. *IBM Journal of Research and Development*, 44(1-2), 207-219.
- Sarker, I. H., Kayes, A. S. M., Badsha, S., Alqahtani, H., Watters, P., & Ng, A. (2020). Cybersecurity data science: An overview from machine learning perspective. *Journal of Big Data*, 7(1), 1-29.
- Sarker, I. H. (2021). Machine Learning: Algorithms, Real-World Applications and Research Directions. *SN Computer Science*, 2, 160.
- Sellars, S., Nguyen, P., Chu, W., Gao, X., Hsu, K., & Sorooshian, S. (2013). Computational earth science: Big data transformed into insight. *Eos (United States)*, 94(32), 277-278.
- Shahriar, M. S., & McCulluch, J. (2014). A dynamic data-driven decision support for aquaculture farm closure. *Procedia Computer Science*, 29, 1236-1245.
- Sheehan, E. V., Bridger, D., Nancollas, S. J., & Pittman, S. J. (2020). PelagiCam: A novel underwater imaging system with computer vision for semi-automated monitoring of mobile marine fauna at offshore structures. *Environmental Monitoring and Assessment*, 192(1), 11.
- Shi, P., Yuan, Y., Kuang, L., Li, G., & Zhang, H. (2018a). Water temperature prediction in pond aquaculture based on EMD-IGA-SELM neural network. *Chinese Society for Agricultural Machinery*, 49(11), 312-319.
- Shi, P., Yuan, Y., Kuang, L., Zhang, H., & Li, G. (2018b). Study on water temperature prediction in industrial aquaculture based on GA-SELM neural network. *Chinese Journal of Sensors and Actuators*, 31(10), 1592-1597.
- Sousa, D., Sargento, S., Pereira, A., & Luis, M. (2019). Self-adaptive team of aquatic drones with a communication network for aquaculture. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics) 11805(LNAI)*, 569-580
- Stavrakidis-Zachou, O., Sturm, A., Lika, K., Wätzold, F., & Papandroulakis, N. (2021). ClimeGreAq: A software based DSS for the climate change adaptation of Greek aquaculture. *Environmental Modelling and Software*, 143, 105121.
- Su, J., Chen, J., Wen, J., Xie, W., & Lin, M. (2020). Analysis decision-making system for aquaculture water quality based on deep learning. *Journal of Physics: Conference Series*, 1544(1), 012028.
- Sullivan, C. V., Chapman, R. W., Reading, B. J., & Anderson, P. E. (2015). Transcriptomics of mRNA and egg quality in farmed fish: Some recent developments and future directions. *General and Comparative Endocrinology*, 221, 23-30.
- Sun, M., Hassan, S. G., & Li, D. (2016). Models for estimating feed intake in aquaculture: A review. *Computers and Electronics in Agriculture*, 127, 425-438.
- Suo, F., Huang, K., Ling, G., Li, Y., & Xiang, J. (2020). Fish keypoints detection for ecology monitoring based on underwater visual intelligence. *16th IEEE International Conference on Control, Automation, Robotics and Vision, ICARCV 2020*, 542-547.
- Ta, X., & Wei, Y. (2018). Research on a dissolved oxygen prediction method for recirculating aquaculture systems based on a convolution neural network. *Computers and Electronics in Agriculture*, 145, 302-310.
- Ta, X., & Wei, Y. (2018). Research on a dissolved oxygen prediction method for recirculating aquaculture systems based on a convolution neural network. *Computers and Electronics in Agriculture*, 145, 302-310.
- Ta, X., An, D., & Wei, Y. (2019). Dissolved oxygen prediction method for recirculating aquaculture system, based on a timing attenuation matrix and a convolutional neural network. *Aquaculture*, 503, 26-33.
- Tavallaee, M., Bagheri, E., Lu, W., & Ghorbani, A. A. (2009). A detailed analysis of the KDD CUP 99 data set. *IEEE Symposium on Computational Intelligence for Security and Defense Applications, CISDA 2009*,
- Tian, D., Li, N., Huang, H., Fu, Z., & Zhang, X. (2009). A decision support system for evaluating quality safety risk contaminated by water pollution in aquaculture pond. *IFIP Advances in Information and Communication Technology*, 293, 643 - 652
- Tian, H., Wang, T., Liu, Y., Qiao, X., & Li, Y. (2020). Computer vision technology in agricultural automation. A review. *Information Processing in Agriculture*, 7(1), 1-19.
- Ubina, N., Cheng, S., Chang, C., & Chen, H. (2021). Evaluating fish feeding intensity in aquaculture with convolutional neural networks. *Aquacultural Engineering*, 94.

- Urbanová, P., Vaněk, J., Souček, P., Šys, D., Císař, P., & Železný, M. (2017). Bioimaging – autothresholding and segmentation via neural networks. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)* 10208(LNCS), 358–368.
- Uz, S. S., Ames, T. J., Memarsadeghi, N., McDonnell, S. M., Blough, N. V., Mehta, A. V., & McKay, J. R. (2020). Supporting aquaculture in the Chesapeake Bay using artificial intelligence to detect poor water quality with remote sensing. *International Geoscience and Remote Sensing Symposium (IGARSS)*, 3629-3632.
- Wang, D., Fan, J., Han, M., Guo, P., & Lu, Y. (2019). Marine floating raft aquaculture back scattering feature analysis based on ISAR imagery. *Proceedings of the 2018 IEEE Symposium Series on Computational Intelligence, SSCI 2018*, 1902-1905.
- Wang, R., Liu, Q., He, Y., & Fu, Z. (2009). A decision support system for DO prediction based on fuzzy model and neural network. *IFIP Advances in Information and Communication Technology*, 293, 689–699.
- Watkins, C. J. C. H. & Dayan, P. (1992) Q-Learning. *Machine Learning*, 8, 279-292.
- Weinstein, B. G. (2018). A computer vision for animal ecology. *Journal of Animal Ecology*, 87(3), 533-545.
- Wen, Y., Li, M., & Ye, Y. (2020). MapReduce-based BP neural network classification of aquaculture water quality. *Proceedings - 2020 International Conference on Computer Information and Big Data Applications, CIBDA 2020*, 132-135.
- Witten, I. H., Frank, E., Hall, M. A., & Pal, C. J. (2016). Data mining: Practical machine learning tools and techniques. (pp. 1-621).
- Wu, C., Chen, Y., Liu, Y., & Yang, X. (2016). Decision tree induction with a constrained number of leaf nodes. *Applied Intelligence*, 45(3), 673-685.
- Xiaoshuan, Z., Zetian, F., Wengui, C., Dong, T., & Jian, Z. (2009). Applying evolutionary prototyping model in developing FIDSS: An intelligent decision support system for fish disease/health management. *Expert Systems with Applications*, 36(2 PART 2), 3901-3913.
- Yang, C., Chen, H., Chang, E., Kristiani, E., Nguyen, K. L. P., & Chang, J. (2021). Current advances and future challenges of AloT applications in particulate matters (PM) monitoring and control. *Journal of Hazardous Materials*, 419.
- Yang, C., Yu, M., Li, Y., Hu, F., Jiang, Y., Liu, Q., & Gu, J. (2019). Big earth data analytics: A survey. *Big Earth Data*, 3(2), 83-107.
- Yang, D., Chen, F., & Zhou, Y. (2015). A novel eutrophication assessment models for aquaculture water area via artificial neural networks. *Journal of Computational and Theoretical Nanoscience*, 12(9), 2909-2912.
- Yang, X., Zhang, S., Liu, J., Gao, Q., Dong, S., & Zhou, C. (2021). Deep learning for smart fish farming: Applications, opportunities and challenges. *Reviews in Aquaculture*, 13(1), 66-90.
- Yang, Y., Tai, H., & Li, D. (2014). Real-time optimized prediction model for dissolved oxygen in crab aquaculture ponds using back propagation neural network. *Sensor Letters*, 12(3-5), 723-729.
- Yongqiang, C., Shaofang, L. I., Hongmei, L., Pin, T., & Yilin, C. (2019). Application of intelligent technology in animal husbandry and aquaculture industry. Paper presented at the *14th International Conference on Computer Science and Education, ICCSE 2019*, 335-339.
- Yu, H., Zheng, R., Wang, Z., & Bu, W. (2015). Application of neural network based PID method for temperature control of aquaculture greenhouse. *American Society of Agricultural and Biological Engineers Annual International Meeting 2015*, 3. 1881-1891.
- Zenger, K. R., Khatkar, M. S., Jones, D. B., Khalilisamani, N., Jerry, D. R., & Raadsma, H. W. (2019). Genomic selection in aquaculture: Application, limitations and opportunities with special reference to marine shrimp and pearl oysters. *Frontiers in Genetics*, 9, 00693.
- Zha, Y., Zhang, Q., Zhao, Y., & Hang, B. (2021). Prediction of dissolved oxygen in aquaculture based on 3D convolution and CLSTM neural network. *Yingyong Kexue Xuebao/Journal of Applied Sciences*, 39(4), 615-626.
- Zhao, S., Zhang, S., Liu, J., Wang, H., Zhu, J., Li, D., & Zhao, R. (2021). Application of machine learning in intelligent fish aquaculture: A review. *Aquaculture*, 540.
- Zhou, C., Lin, K., Xu, D., Sun, C., Chen, L., Zhang, S., & Guo, Q. (2019). Computer vision and feeding behavior based intelligent feeding controller for fish in aquaculture. *IFIP Advances in Information and Communication Technology*, 545, 98-107.
- Zhou, C., Sun, C. H., Lin, K., Xu, D. M., Guo, Q., Chen, L., & Yang, X. T. (2018). Handling water reflections for computer vision in aquaculture. *Transactions of the ASABE*, 61(2), 469-479.
- Zhou, C., Xu, D., Chen, L., Zhang, S., Sun, C., Yang, X., & Wang, Y. (2019). Evaluation of fish feeding intensity in aquaculture using a convolutional neural network and machine vision. *Aquaculture*, 507, 457-465.
- Zhu, M., Wang, X., & Wang, Y. (2018). Human-like autonomous car-following model with deep reinforcement learning. *Transportation Research Part C: Emerging Technologies*, 97, 348-368.