



UNIVERSIDAD ESTATAL DE MILAGRO

VICERRECTORADO DE INVESTIGACIÓN Y POSGRADO

PROYECTO PREVIO A LA OBTENCIÓN DEL TÍTULO DE

MAGISTER EN CIENCIAS MATEMÁTICAS

TÍTULO DEL PROYECTO

Modelo basado en redes neuronales artificiales para la evaluación de la calidad del agua en sistemas de cultivo extensivo de camarón

AUTOR

Ing. Franklin Elias Amboya Mishqui

TUTOR

PhD. Fabricio Guevara Viejo

MILAGRO, 05 noviembre del 2022

ECUADOR

ACEPTACIÓN DEL TUTOR

Por la presente hago constar que he analizado el proyecto de grado por el **Ing. Franklin Elias Amboya Mishqui**, con el tema ***“Modelo basado en redes neuronales artificiales para la evaluación de la calidad del agua en sistema de cultivo de camarón”***, para optar el título de Magíster en **MATEMÁTICA CON MENCIÓN EN MODELACIÓN MATEMÁTICA EN MODALIDAD PRESENCIAL**, y que acepto tutorial al estudiante, durante la etapa del desarrollo del trabajo hasta su presentación, evaluación y sustentación.

Milagro, a los 13 días del mes de octubre del 2022



Firmado electrónicamente por:
**JORGE
FABRICIO
GUEVARA VIEJO**

.....
Firma del tutor
PhD. Jorge Fabricio Guevara Viejo
C.I. 0917882961

DECLARACIÓN DE AUTORÍA DE LA INVESTIGACIÓN

El autor de esta investigación declara ante el Consejo Directivo de la Facultad de Ciencias de la Ingeniería de la Universidad Estatal de Milagro, que el trabajo presentado es de mi propia autoría, no contiene material escrito por otra persona, salvo el que está referenciado debidamente en el texto; parte del presente documento o en su totalidad no ha sido aceptado para el otorgamiento de cualquier otro Título o Grado de una institución nacional o extranjera.

Milagro, a los 22 días del mes de noviembre del 2022



Firmado electrónicamente por:
**FRANKLIN ELIAS
AMBOYA MISHQUI**

Ing. Franklin Elias Amboya

C.I.0923609127

VICERRECTORADO DE INVESTIGACIÓN Y POSGRADO
DIRECCIÓN DE POSGRADO
CERTIFICACIÓN DE LA DEFENSA

El TRIBUNAL CALIFICADOR previo a la obtención del título de **MAGÍSTER EN MATEMÁTICA CON MENCIÓN MODELACIÓN MATEMÁTICA CON MENCIÓN EN MODELACIÓN MATEMÁTICA**, presentado por **ING. AMBOYA MISHQUI FRANKLIN ELIAS**, otorga al presente proyecto de investigación denominado **"MODELO MATEMÁTICO BASADO EN REDES NEURONALES ARTIFICIALES PARA LA EVALUACIÓN DE LA CALIDAD DEL AGUA EN SISTEMAS DE CULTIVO EXTENSIVO DE CAMARÓN DE LA EMPRESA EXPOSYNERGY."**, las siguientes calificaciones:

TRABAJO DE TITULACION	58.33
DEFENSA ORAL	38.33
PROMEDIO	96.67
EQUIVALENTE	Excelente



Firmado digitalmente por:
**RAFAEL
SELEYMAN LAZO
SULCA**

Msc Bio V LAZO SULCA RAFAEL SELEYMAN
PRESIDENTE/A DEL TRIBUNAL



Firmado digitalmente por:
**BYRON RAMIRO
ROMERO ROMERO**

Msc. ROMERO ROMERO BYRON RAMIRO
VOCAL



Firmado digitalmente por:
**JUAN DIEGO
VALENZUELA
COBOS**

Ph.D. VALENZUELA COBOS JUAN DIEGO
SECRETARIO/A DEL TRIBUNAL

CESIÓN DE DERECHOS DE AUTOR

Señor Doctor

PhD. Fabricio Guevara Viejó

Rector de la Universidad Estatal de Milagro Presente.

Ciudad. -

Mediante el presente documento, libre y voluntariamente procedo a hacer entrega de la Cesión de Derecho del Autor del Trabajo realizado como requisito previo para la obtención de mi Título de Cuarto Nivel, cuyo tema fue **“Modelo basado en redes neuronales artificiales para la evaluación de la calidad del agua en sistemas de cultivo extensivo de camarón”** y que corresponde al Instituto de Posgrado y Educación Continua

Milagro, a los 22 días del mes de noviembre del 2022



Firmado electrónicamente por:
FRANKLIN ELIAS
AMBOYA MISHQUI

Ing. Franklin Elias Amboya Mishqui

C.I. 0923609127

DEDICATORIA

El presente trabajo de grado va dedicado a Dios, quien como guía estuvo presente en el caminar de mi vida, bendiciéndome y dándome fuerzas para continuar con mis metas trazadas sin desfallecer. A mi esposa Gloria por el apoyo incondicional para poder lograr culminar mi carrera profesional.

Ing. Franklin Amboya

AGRADECIMIENTO

Mi más sincero agradecimiento a Dios mi creador por darme fuerza en todo momento para la realización de esta tesis. A mi esposa que gracias a su apoyo moral me permitieron permanecer con empeño, dedicación y cariño, y a todos quienes contribuyeron con un granito de arena para culminar con éxito la meta propuesta.

Ing. Franklin Amboya

RESUMEN

El cultivo de especies acuícolas es una práctica común en todo el mundo. En Ecuador, la camaronicultura es una de las principales fuentes de ingresos del sector acuícola. La calidad del agua es un factor relevante en el éxito de las granjas camaroneras, por lo que su monitoreo es fundamental. Este estudio presenta un nuevo modelo computacional para evaluar la calidad del agua en granjas extensivas de *Litopenaeus vannamei*. Mediante el uso de una red neuronal artificial se creó un indicador de calidad del agua que permite establecer una relación entre la dinámica de los parámetros del ecosistema y los diferentes estados (excelente, bueno, normal y malo) de cultivo de las especies. Se eligieron cuatro parámetros ambientales porque son importantes en el hábitat: temperatura del agua, pH, oxígeno disuelto y salinidad. Los resultados obtenidos demuestran un buen desempeño y eficiencia del sistema propuesto en comparación con otros modelos de evaluación utilizados para este RNA. Las evaluaciones se muestran como una buena opción para evaluar y detectar condiciones óptimas o no deseadas para una buena gestión del agua en este tipo de cultivos.

Palabras Claves:

Modelo matemático, Pronósticos, Redes neuronales artificiales, Proceso, Productividad.

ABSTRACT

The farming of aquaculture species is an activity commonly practiced around the world. In Ecuador, shrimp farming is one of the main sources of income in the area of aquaculture. Water quality is a relevant factor in the success of cultivation in shrimp farms, so its monitoring is of vital importance. This study presents a new computational model for the evaluation of water quality in extensive culture farms for shrimp *Litopenaeus vannamei*. Through the use of artificial neural networks, an indicator of water quality was created, which allows establishing a relationship between the dynamics of the ecosystem parameters and different states for the cultivation of the species (excellent, good, fair and poor). . Four environmental parameters were selected due to their importance in the habitat: water temperature, pH, dissolved oxygen and salinity. The results obtained show a good performance and efficiency of the proposed system, when compared to other evaluation models used for this RNA. The evaluations show as a good option for the evaluation and detection of optimal or undesired states for good water management in this type of crops.

Keywords:

Mathematical model, Forecasting, Artificial neural networks, Process, Productivity.

INTRODUCCIÓN.....	1
1.1 Planteamiento Del Problema	2
1.2 Delimitación del problema	2
1.3 Formulación del problema	3
1.4 Sistematización del problema	3
1.5 Objetivos	3
1.5.1 Objetivo General.....	3
1.5.2 Objetivos Específicos	3
1.6 Justificación.....	3
1.6.1 Justificación Teórica	4
1.6.3 Justificación práctica	4
1.7 Hipótesis	5
1.7.1 Hipótesis General	5
1.7.2 Hipótesis Particular	5
1.7.3 Conceptualización y operacionalización de variables	5
CAPÍTULO II	5
2.1 Marco Teórico.....	6
2.1.1 Modelo matemático	6
2.1.2 Pronóstico de calidad de agua.....	7
2.1.3 Redes Neuronales Artificiales.....	10
2.1.3.1. Neurona Artificial	12
2.1.3.2. Arquitectura de una red neuronal artificial	13
2.1.4. Aprendizaje y entrenamiento de la RNA	15
2.2 Plataforma utilizada para la RNA.....	17
2.2.1 Herramienta NN - TOOLBOX.....	17
2.3 Datos ingreso para la RNA.....	19
2.4 Marco Conceptual	19
2.5 Marco referencial	21
CAPÍTULO III	24
MARCO METODOLÓGICO	24
3.1 Tipo de Investigación.....	24
3.2 Diseño De La Investigación.....	24
3.3 Población y Muestra.....	25

3.4 Método, Técnica y Uso de Software de Tratamiento y Análisis de Datos	25
CAPITULO IV	30
PROPUESTA.....	30
4.1. Selección de la Variable.....	30
4.2. Recolección de Datos	30
4.3. Preprocesamiento de Datos	31
4.4. Definición de Conjunto de Entrenamiento, Validación y Prueba.....	33
4.4.1. Asociación	33
4.4.2. Conjunto de entrenamiento.....	33
4.4.3. Reprocesamiento	34
4.4.4. Estructura y composición de una RNA	35
4.4.5. Construcción del modelo de evaluación de la calidad del agua	37
4.5. Entrenamiento de la Red Neuronal.....	38
4.6. Validación y resultado de la red con conjunto de prueba.....	41
CONCLUSIONES	47
RECOMENDACIONES	47
BIBLIOGRAFÍA.....	48

ÍNDICE DE TABLAS

Tabla 1. Parámetros físico-

Tabla 2. Parámetros de calidad del
en el cultivo de camarón.....

Tabla 3. Concentraciones y evaluaciones de la calidad
un día de supervisión. Se sombreadon las mediciones que se
límite permitido

ÍNDICE DE GRÁFICOS

Figura 1. Metodología propuesta para la evaluación de la calidad del agua en camaronicultura empleando un modelo neuronal. La RNA responde reconociendo los diferentes estados del estanque: (e) excelente, (b) bueno, (r) regular y (d) deficiente. Posteriormente, mediante un proceso de agregación, se conjuntan los estados de la calidad del agua evaluados proporcionando un indicador global (1W4I).....	8
Figura 2. Modelo de neurona artificial de McCulloch y Pitts	11
Figura 3. Funciones de activación más usuales	12
Figura 4. Disposición de las distintas capas de nodos en una red neuronal de ejemplo	13
Figura 5. Metodología utilizada para el entrenamiento de aprendizaje en la RNA. La adquisición de muestras, generación de bases de datos y clasificación de situaciones no deseadas son de gran importancia para el buen desempeño de la RNA.....	24
Figura 6. Modelo de una neurona, en donde x_i es iésima entrada, W es el peso multiplicador, b es el sesgo y z es la salida	28
Figura 7. Arquitectura de la red neuronal para clasificar la calidad del agua.....	30
Figura 8. Metodología utilizada para la evaluación de la calidad del agua empleando a la RNA. El proceso de agregación integra las salidas de la RNA y las convierte en un indicador con rango $[0, 1]$	31
Figura 9. Funciones difusas empleadas para integrar los resultados de las neuronas de salida de la RNA.	32
Figura 10. Proceso de agregación de las salidas de la red neuronal para obtener un el indicador de calidad del agua empleando el centro de gravedad	33
Figura 11. Resultado de evaluación de comportamiento de la temperatura.....	34
Figura 12. comportamiento de la salinidad.....	34
Figura 13. Comportamiento del oxígeno disuelto	34
Figura 14. Historial del PH.....	35
Figura 15. Comparación entre índices de la calidad el agua. Se puede observar cómo el comportamiento oscilante entre la temperatura y el oxígeno disuelto influencia el resultado final.	35

INTRODUCCIÓN

Durante años, las pequeñas empresas han utilizado métodos ineficientes o imprecisos para predecir cuánto producirán al final de un período determinado, lo que ha provocado que las pequeñas empresas incurran en pérdidas financieras debido a diferentes factores.

Por tanto, es necesario generar un modelo más cercano a la realidad de cada pequeña empresa, que debe tener en cuenta el máximo número de incógnitas independientes que aportan al modelo y representar de la mejor manera el máximo número de variables independientes y variables del proceso de fabricación. como sea posible.

El propósito de este estudio es analizar una técnica específica que utiliza redes neuronales artificiales para comprender la influencia de las variables independientes, proporcionar una descripción del proceso de producción de las microempresas y comprender la relación causal entre las variables independientes y dependientes.

Las piscinas de camarón es una importante actividad económica que actualmente se lleva a cabo en muchos países alrededor del mundo. Ecuador es uno de los principales productores de camarón y la mayoría de las granjas están ubicadas a lo largo de la costa. Hay muchos estilos diferentes de cultivo de camarones. Este último es el centro de este trabajo.

CAPÍTULO I

1.1 Planteamiento Del Problema

Los parámetros adecuados en la condición del agua en las piscinas de camarón es una de las principales preocupaciones de los productores. Los parámetros ambientales relacionados con el ecosistema son medidos y monitoreados continuamente para evitar situaciones estresantes en el organismo.

Las organizaciones gubernamentales ponen mucho esfuerzo en el análisis de la acuicultura, desarrollando criterios y estándares para las concentraciones permitidas de actividades acuícolas.

Considerando el problema, se plantea la siguiente pregunta: ¿Cómo se puede determinar la evaluación de la calidad del agua en piscinas de camarón?

1.2 Delimitación del problema

Espacio

El actual análisis se gestiona en la Región Costera, Provincia del Guayas, ciudad de Guayaquil, en la isla Puna.

Tiempo

Los datos obtenidos están dentro del estándar de un estudio recopilado en cuanto a los parámetros del agua durante los 10 últimos años

Universo

El análisis se refleja en un modelo matemático para la evaluación de la calidad del agua en piscinas de camarón

1.3 Formulación del problema

¿De qué forma la práctica de las redes neuronales artificiales ayudara en el desarrollo de un modelo para analizar la calidad del agua en piscinas de camarón?

1.4 Sistematización del problema

- ✓ ¿Mediante el análisis de los componentes de un modelo matemático se podrá identificar los factores de la calidad del agua en piscinas de camarón?
- ✓ ¿Será posible realizar un análisis de la variabilidad de cada uno de los factores que inciden en la evaluación de la calidad del agua en piscinas de camarón?
- ✓ ¿Será posible entrenar una RNA que permita acoplar adecuadamente las variables independientes que intervienen en la calidad del agua en piscinas de camarón?

1.5 Objetivos

1.5.1 Objetivo General

Proponer un modelo matemático apropiado para la evaluación de la calidad del agua en piscinas de camarón, mediante la utilización de una RNA.

1.5.2 Objetivos Específicos

- Diagnosticar la situación actual del agua de las piscinas de camarón para su cuantificación en el modelo.
- Analizar las variables obtenidas para el desarrollo del modelo aplicando Red Neuronal Artificial RNA.
- Entrenar una RNA para acoplar adecuadamente las variables independientes que inciden en el proceso de evaluación de la calidad del agua en piscinas de camarón.

1.6 Justificación

1.6.1 Justificación Teórica

El cultivo de camarones se ha vuelto muy competitivo en estos días, por lo que es importante contar con una herramienta que pueda evaluar la calidad del agua en piscinas de camarón a gran escala. La calidad del agua se puede analizar utilizando parámetros ambientales en varias concentraciones..

La relación entre ellos y su comportamiento establece el estándar de qué tan bien se gestionan los recursos hídricos en los sistemas agrícolas. El control preciso de los parámetros es una cuestión compleja en los sistemas de cultivo extensivo, por lo que la creación de un índice de calidad del agua ayudará a comprender el comportamiento general de los estanques.

1.6.2 Justificación metodológica

El presente trabajo de investigación se basa en un análisis metodológico de diversos factores que inciden en la predicción del rendimiento, tales como: Se estudian todos los parámetros más importantes (temperatura, oxígeno disuelto, pH y salinidad) ya que su comportamiento puede ser óptimo o desfavorable para las especies.

Estudio de concentraciones nocivas, combinaciones indeseables y efectos tóxicos de las especies a analizar y clasificar. A través de RNA, se establecieron respuestas para cada una de estas clasificaciones, lo que permitió vincular un conjunto de concentraciones al estado de calidad del agua, creando un índice universal de excelente, bueno, normal y malo. Asimismo, las relaciones intrínsecas y dependencias de los valores ingresados son procesados por la RNA, haciendo más precisas las evaluaciones

Cuando se trabaja con redes neuronales, es importante poder determinar el tipo de red neuronal artificial a utilizar, es decir, el número de capas ocultas, el número de neuronas en las capas ocultas, la función de activación o función de transferencia, además de definir el número de épocas de la red.

1.6.3 Justificación práctica

Se espera que proporcione una evaluación de la calidad del agua en una amplia gama de sistemas de cultivo de camarones.

Se estima que el modelo matemático es preciso para la producción de la industria camaronera y se puede utilizar en cualquier tipo de sistema de cultivo de camarón.

1.7 Hipótesis

1.7.1 Hipótesis General

Es posible entrenar una RNA para que permita acoplar adecuadamente las variables independientes que inciden en el proceso de evaluación de la calidad del agua en piscinas de camarón.

1.7.2 Hipótesis Particular

Es posible poder identificar los factores que inciden en la calidad del agua en piscinas de camarón.

Es posible poder discriminar que factores influyen en la variabilidad de un modelo de pronósticos para la evaluación de la calidad del agua en piscinas de camarón.

Es posible entrenar una RNA que permita pronosticar de manera ágil la producción aplicándolo en la evaluación de la calidad del agua en piscinas de camarón.

1.7.3 Conceptualización y operacionalización de variables

Variable independiente: Redes Neuronales Artificiales

Variable dependiente: analizar la calidad del agua

CAPÍTULO II

2.1 Marco Teórico

2.1.1 Modelo matemático

El desarrollo de un modelo matemático es una técnica aritmética para estudiar y analizar problemas de diferentes áreas del conocimiento; El propósito del prototipo matemático es poder interpretar y predecir diferentes patrones de conocimiento. (Montesinos-López & Hernández-Suárez, 2007, pág. 32)

Un principio fundamental del modelado matemático es aportar a la comprensión de los fenómenos del mundo que nos rodea, sin embargo, al comenzar a modelar, es necesario saber seleccionar y definir de manera sistemática las variables. En efecto, debido a que los fenómenos reales en cuestión son tan complejos, su estudio requiere diferentes enfoques y ha dado lugar a diferentes ciencias que han evolucionado a lo largo de los años y siglos hasta alcanzar la cúspide de la expresión actual. El modelado matemático o modelado matemático es el proceso lógico de crear modelos matemáticos para representar fenómenos de la humanidad. (Cervantes Gómez, 2015, pág. 2)

Un modelo matemático se define como un modelo simplificado de un escenario real. Para poder estudiarlo, la modelización matemática comienza por identificar los puntos primitivos o deterministas del sistema y caracterizarlos con expresiones matemáticas. (Bocco, 2010, pág. 34)

Para observar el sistema, el modelo matemático comienza identificando los puntos primitivos o deterministas del sistema y describiéndolos mediante expresiones matemáticas. La iniciativa en acción es descubrir un equilibrio entre la simplicidad y la reproducción del comportamiento que permita comprender, probar, predecir y ajustar el costo de los cambios que describe y la respuesta del sistema en su grupo. (Bocco, 2010, pág. 11).

Es importante señalar que el modelo matemático se define de hecho ale tu relación entre ellos. Estas relaciones son independientes de los datos ingresados en modelos matemáticos porque pueden usar modelos matemáticos para diferentes situaciones y en diferentes contextos. . (Aravena, Caamaño, & Giménez, 2008, pág. 22)

Las matemáticas permiten el desarrollo de modelos que permitan una mejor comprensión, simulación y predicción del fenómeno en estudio. Los modelos se pueden construir en términos generales, tales como: expresiones o fórmulas numéricas, gráficas o representaciones geométricas, ecuaciones algebraicas, tablas, programas de computadora y más. Por otro lado, una vez que se propone un modelo, es el resultado de estimaciones realizadas para tener una mejor comprensión del fenómeno, sin embargo, dichas estimaciones no corresponden a la realidad para siempre. (Salett Biembegut & Hein, 1999, pág. 15)

2.1.2 Pronóstico de calidad de agua.

La calidad del agua se puede evaluar en función de diferentes concentraciones de parámetros ambientales. La relación entre ellos y su comportamiento establece los criterios para una buena o mala gestión del agua en los sistemas agrícolas. En las piscinas de camarón, el control en cuanto a las condiciones del agua es un asunto complejo, por lo que la creación de un índice de calidad del agua será de gran ayuda para comprender el comportamiento general del estanque. Las redes neuronales artificiales tienen la capacidad de aprender algunas características sean favorables o desfavorables entre parámetros, si se si se propone un análisis adaptativo. (Beltrame, 2017)

En la Figura 1 se observa el método de operación del algoritmo que se va implantar, el cual permite obtener análisis de la calidad del agua, mediciones de parámetros ambientales y tiene un rango $[0, 1]$ sobre el estado del sistema. Por lo cual se seleccionaron cuatro características para las entradas en el modelo: temperatura del agua, pH, oxígeno disuelto y salinidad. La justificación de su selección se describe a continuación. (Belt, 2018)




Figura 1. RNA para la evaluación de la calidad en las piscinas de camarón I

Actualmente, se han llevado a cabo una serie de encuestas para analizar la calidad del agua en el sector de la camaronicultura, desarrollando diferentes modelos y relacionando otros parámetros de calidad del agua, como las medidas sugeridas por (Carvajal, 2019), existen diferentes trabajos que complementan este estudio, contienen información relevante sobre el comportamiento de los parámetros de calidad del agua en diferentes sistemas acuícolas y han sido propuestos por (Song, 2019).

El ecosistema camaronero está conformado por un conjunto de parámetros físico-químicos que deben ser monitoreados y controlados siempre dentro de rangos aceptables, creando una calidad de agua óptima para el cultivo de estas especies. A menudo hay situaciones de mala calidad del agua en los sistemas agrícolas a gran escala porque los parámetros suelen cambiar repentinamente o hay reacciones químicas que conducen a niveles inaceptables de toxicidad en el ecosistema. (Bower, 2017)

Es muy importante conocer las características que tiene el agua y cada cuánto tiempo monitorearlos para poder analizar mejor su comportamiento dentro del tanque de cultivo. En el ecosistema camaronero existen parámetros de mayor impacto, los cuales deben ser monitoreados con mayor frecuencia, ya que son más propensos a desestabilizar el ecosistema que otros, este conjunto es el más importante para evaluar la calidad del agua (Semarnap, 2018).

La Tabla 1 y 2 presenta la clasificación de parámetros relacionados con la calidad del agua por su frecuencia de monitoreo. En este trabajo se eligió el grupo de

monitoreo diario por su importancia primordial en el agroecosistema.

Tabla 1. Parámetros físico-químicos involucrados en el hábitat del camarón

	Monitoreo		
	Diario	Semanal	Por requerimiento
Temperatura		Amonio total	Alcalinidad
Salinidad		Nitratos	Fósforo
Oxígeno disuelto		Amonio no ionizado	Sulfato de hidrógeno no ionizado
pH		Turbidez	Sulfato de hidrógeno
			Dióxido de carbono
			Silicatos
			Clorofila A
			Nitrógeno total inorgánico
			Sólidos suspendidos
			Potencial Redox
			Conteo <i>Vibrio</i>
			Coliformes fecales

Tabla 2. Niveles de condición del agua en cultivo de camarón

	Parámetros	Importancia en camaronicultura
Monitoreo diario	Temperatura (Temp)	La temperatura tiene un efecto en los procesos químicos y biológicos en un estanque de cultivo; un aumento de 10 °C causa un aumento al doble o triple en las tasas de reacciones químicas y biológicas (Boyd, 1992; Fontenot, Bonvillain, Kilgen, & Boopathy, 2007). La temperatura controla la solubilidad de los gases en el agua, la velocidad de reacción química y la toxicidad del amonio. El rango ideal para la temperatura se considera entre 25 y 32 °C (Chien, 1992; Boyd, 1989)
	Oxígeno disuelto (DO)	La concentración mínima de oxígeno para mantener una tasa aceptable de sobrevivencia varía con el tiempo de exposición (Páez, 2001; Boyd, 1992). En concentraciones bajas de oxígeno disuelto, los camarones son más susceptibles a enfermedades. Cuando el porcentaje de saturación permanece por debajo de 5 ppm, los camarones presentan bajas tasas de alimentación y crecimiento. La fluctuación diaria de oxígeno disuelto en un estanque aparentemente tiene poco efecto sobre la alimentación y el crecimiento para algunas especies, siempre y cuando la concentración no caiga por debajo de 2 ppm en la mañana (Li, Li, & Wang, 2006). Los valores mínimos recomendados por expertos oscilan entre 4 y 5 ppm (Chien, 1992; Boyd, 1989)
	Salinidad (Sal)	Los organismos que viven en el agua deben mantener sus líquidos vitales a cierta concentración iónica (salinidad). Cuando la salinidad del medio es diferente, los organismos necesitan llevar a cabo ciertas estrategias para poder mantenerla en los niveles propicios, lo cual implica un gasto energético que puede verse reflejado en una menor tasa de crecimiento (Bower & Bidwell, 1978; Fontenot <i>et al.</i> , 2007). Altas concentraciones de salinidad reducen los niveles de oxígeno disuelto en el agua del estanque. Las concentraciones óptimas de salinidad se presentan en los rangos de 15 a 23 ppt (Páez, 2001; Boyd, 1992)
	pH	Cuando el pH tiene valores bajos o elevados causa estrés en los organismos bajo cultivo. Las aguas que presentan un intervalo de pH entre 6.5 y 9.0 son las más apropiadas para la producción acuícola. La reproducción disminuye en valores inferiores a 6.5 o mayores a 9.0. Por debajo de 4.0 hay muerte ácida y por encima de 11.0, muerte alcalina. Aunque los organismos pueden sobrevivir, el rendimiento es pobre en estanques que presentan valores de pH en la mañana de 4 a 6, o de 9 a 10. En muchos sistemas de cultivo, el pH puede aumentar hasta valores de 9 o 10 por periodos cortos sin ocasionar un efecto adverso a los organismos (Martínez, 1994; Arredondo & Ponce, 1998). Concentraciones extremadamente bajas y altas de pH pueden generar un caparazón duro y baja sobrevivencia (Chien, 1992; Boyd, 2001)

Es importante definir el mínimo y máximo permitido para cada uno de los

parámetros evaluados. Los lineamientos ambientales se clasifican en diferentes rangos; cada uno de ellos representa un lineamiento diferente.

2.1.3 Redes Neuronales Artificiales.

Una red neuronal imita ciertos rasgos humanos, como la capacidad de recordar y asociar hechos. Si miramos detenidamente los problemas que no pueden ser expresados por un algoritmo, veremos que todos tienen una cosa en común: la experiencia. Las personas pueden lidiar con estas situaciones utilizando la experiencia acumulada. Así que, claramente, una forma de abordar el problema es construir sistemas capaces de replicar este espíritu humano. (Matich, 2001, pág. 15)

Una red neuronal no es un modelo artificial y similar al cerebro humano, la relación más perfecta que tenemos de un sistema capaz de recibir información a través de la interacción. La red es “un nuevo sistema de procesamiento de información cuya unidad básica de procesamiento está inspirada en las células básicas del sistema nervioso humano: la neurona”. (Matich, 2001, pág. 13)

Todo el análisis del cuerpo humano está sistematizado de una forma u otra con ejecución de las neuronas. Son partes del cuerpo humano, pero cuando miles de ellos están interconectados, se vuelven muy poderosos. Lo básico que sucede en una neurona biológica es esto: la neurona es excitada o estimulada por sus inputs (entradas). (Matich, 2001, pág. 7)

Investigaciones posteriores llevaron al descubrimiento que el pensamiento tiene lugar en el cerebro, el cerebro está formado por miles de millones de neuronas interconectadas. Entonces, el secreto de la "inteligencia" radica en estas neuronas interconectadas y sus interacciones. Además, es conocido que los seres humanos tienen la capacidad de aprender, de ahí la red neuronal. (Matich, 2001, pág. 16)

La clasificación de RNA se puede realizar considerando varios criterios, como el número de capas, la dirección del flujo de información, el tipo de entrenamiento y la función de transferencia como se muestra en figura. Las redes neuronales artificiales se clasifican de acuerdo al número de capas y el tipo de entrenamiento.

Tabla 3. Clasificación de la RNA

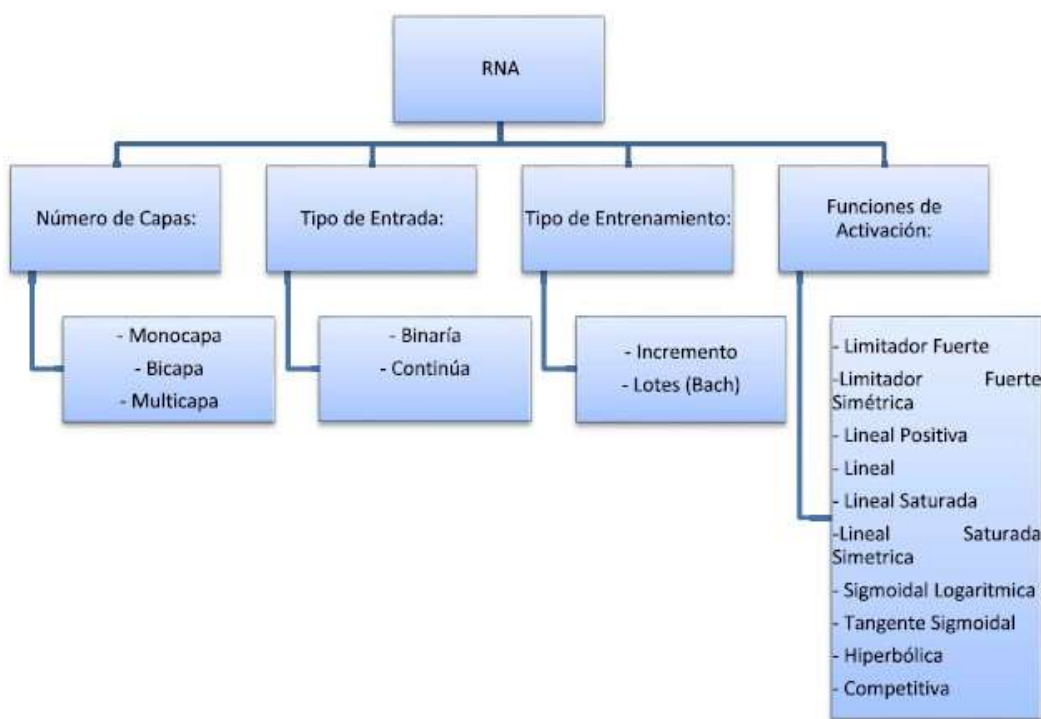


Tabla 4. Clasificación de una RNA por las entradas



2.1.3.1. Neurona Artificial

McCulloch y Pitts en el año de 1943 realizaron observaciones biológicas, presentando el primer modelo de una neurona artificial. Según Freeman (Freeman Castro & Skapura González, 1993), Estos elementos computacionales individuales que componen la mayoría de los modelos RNA a menudo no se denominan neuronas artificiales, lo más frecuente es darles el nombre de nodos, unidades o elemento de procesamiento o PE por sus siglas en inglés.




Figura 2. Modelo de neurona artificial de McCulloch y Pitts

Autor: La imagen representa el modelo básico de una neurona artificial, los valores de entradas, sus pesos y su interacción. Tomado de *Las Redes Neuronales Artificiales – Fundamentos teóricos y aplicaciones prácticas*, Flores y Fernández, 2008, Netbiblo

Como se puede observar en la figura 2, una red neuronal artificial posee cantidad finita de conexiones de ingreso -n para este caso llamado n- que corresponden a las dendritas para el modelo biológico, por las cuales ingresa cada una de las n componentes de información o vector de entrada. Cada conexión de entrada tiene una magnitud asociada, denominada peso o fuerza (eficiencia sináptica), definida por los componentes del vector de peso. Estos pesos de conexión w_i pueden ser positivos-excitadores- o negativos-inhíbidores.

Por lo general, agregamos un parámetro adicional θ_i llamado umbral al conjunto de pesos de las neuronas sustraídos del potencial postsináptico, por lo que los parámetros de la función de activación se convierten en

$$\sum_j w_{ij} x_j - \theta_i$$

De forma proporcional, cambiamos los índices i y j empiecen por 0 y analizando $w_{ij} = \theta_i$ y $x_0 = -1$ (constante) podemos obtener el comportamiento de la neurona a través de:

$$y_j(t) = f_i \left(\sum_{j=0}^n w_{ij} * x_j \right)$$

Hay que determinar que la función de activación la neurona la cual tiene funciones son las mostradas en la tabla de la figura 3.


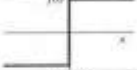
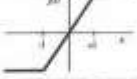
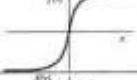

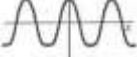
	Función	Rango	Gráfica
Identidad	$y = x$	$[-\infty, +\infty]$	
Escalón	$y = \text{sign}(x)$ $y = H(x)$	$\{-1, +1\}$ $\{0, +1\}$	
Línea a tramos	$y = \begin{cases} -1, & \text{si } x < -l \\ x, & \text{si } -l \leq x \leq +l \\ +1, & \text{si } x > +l \end{cases}$	$[-1, +1]$	
Sigmoidea	$y = \frac{1}{1+e^{-x}}$ $y = \text{tgh}(x)$	$[0, +1]$ $[-1, +1]$	
Gaussiana	$y = Ae^{-2x^2}$	$[0, +1]$	
Simusoidal	$y = A \text{sen}(ax + \phi)$	$[-1, +1]$	

Figura 3. Funciones de activación más usuales

Autor: La imagen representa las Funciones de activación más usuales. Tomado de *Redes Neuronales: Guía Sencilla de Redes Neuronales Artificiales*, Rudolph Russell, 2018, CreateSpace Independent Publishing Platform

2.1.3.2. Arquitectura de una red neuronal artificial

La estructura de la red feedforward es similar a la que se muestra en la Figura 4. Como se observa, este gráfico está subdividido en diferentes capas. Un grupo de nodos que están en el mismo nivel según la conectividad.

Al crear una arquitectura RNA, es necesario partir del número de capas oculto, la versión 2011 de NN-Toolbox no tiene limitaciones en determine el número de capas ocultas. Otra característica arquitectónica la red neuronal es la cantidad de neuronas en capas ocultas, este elemento es muy útil importancia para obtener la mejor arquitectura de aprendizaje en red, para el ejercicio se recomienda empezar a entrenar con 10 neuronas por capas seleccionado oculto. Del mismo modo, esta herramienta no tiene límites número de neuronas en la capa oculta.

NN-Toolbox presenta diferentes tipos de funciones transferencia para cada clase de ARN. Función de transferencia lineal (purelina), sigmoide (logsig) y tangente hiperbólica (tansig) son más comunes cuando hora de configurar la arquitectura de la red neuronal.




Figura 4. Simetría de las capas en una red neuronal

Autor: La imagen representa la disposición de las distintas capas y nodos en una red neurona artificial, se observa los enlaces entre neuronas de distintas capas.

Tomado de *Introducción a la inteligencia artificial: sistemas expertos, redes neuronales artificiales y computación evolutiva*, Pino Díez, Gómez Gómez, Abajo Martínez, 2001, Universidad de Oviedo

- Capa de entrada: Está estructurada por neuronas que contienen datos o señales del entorno.
- Capa de salida: una capa de neuronas que proporciona retroalimentación a la red neuronal.
- Capa oculta: La capa que no tiene contacto directo con el medio ambiente.

Que las conexiones entre neuronas sean excitatorias o inhibitorias depende del

signo de los pesos sinápticos asociados con la conexión. Dicho peso sináptico es contrario, en ese caso tienes una conexión inhibitoria, pero si es positiva estás ante una conexión excitatoria. Esta distinción no suele usarse demasiado, ya que los pesos y sus magnitudes vendrán determinados por el algoritmo de entrenamiento en cada momento (Awwa, 2017).

Las conexiones también se pueden clasificar en conexiones de capas internas y conexiones entre capas. El primero corresponde a conexiones entre neuronas relacionadas en una misma capa, y el segundo corresponde a conexiones desarrolladas entre las neuronas de diferentes capas. (Luliano, 2019)

Cuando hablamos de modo de acción, nos referimos a cómo la red neuronal posee estímulos de la parte exterior y efectúa una respuesta emergente. Se puede considerar que las redes neuronales pertenecen al siguiente análisis:

- **Redes estáticas:** En esta clase de red, una vez determinado el valor de los ingresos, las salidas tienen un valor fijo sin tener relación con las entradas se mantienen siempre por debajo de un determinado nivel.

Esta clase de redes se caracterizan de forma estructuralmente por la ausencia de datos de retroalimentación. Por su modo de operación, estas redes poseen un límite para realizar sus funciones de forma indeterminada con respecto al tiempo en a semejanza con otras redes.

2.1.4. Aprendizaje y entrenamiento de la RNA

El objetivo de la formación de RNA es obtener una aplicación dada, dado un conjunto de entradas, para producir el conjunto mínimo deseado o consistente de salidas. El proceso de aprendizaje implica aplicación de diferentes sistemas o vectores de entrada para que el peso de la asociación se ajuste de acuerdo al procedimiento especificado. Durante el entrenamiento, el peso se acumula gradualmente según el principio de que cada entrada produce el vector de salida requerido. (Shan, 2015)

Los algoritmos de adiestramiento pueden pertenecer a dos grupos: Supervisado y No Supervisado.

La NN-Toolbox se utiliza para realizar la fase de aprendizaje de RNA la tabla 3 muestra los diferentes algoritmos de aprendizaje:

Tabla 5. Algoritmo de Entrenamiento

FUNCIÓN	DESCRIPCIÓN
trainlm	Levenberg-Marquardt
trainbr	Bayesian Regularization
trainbfg	BFGS Quasi-Newton
trainrp	Resilient Backpropagation
trainscg	Scaled Conjugate Gradient
traincgb	Conjugate Gradient with Powell/Beale Restarts
traincgf	Fletcher-Powell Conjugate Gradient
traincgp	Polak-Ribière Conjugate Gradient
trainoss	One Step Secant
traingdx	Variable Learning Rate Gradient Descent
traingdm	Gradient Descent with Momentum
traingd	Gradient Descent

El algoritmo de aprendizaje más rápido es trainlm, por lo que aparece en plataforma predeterminada. El algoritmo trainbfg también es rápido. Pero estos métodos son menos eficientes en redes largas con miles de pesos sinápticos. Algoritmo trainlm está mejor desarrollado para problemas de ajuste funcional (regresión no lineal).

Después de elegir un algoritmo de entrenamiento, el siguiente paso es elegir un criterio de entrenamiento de redes neuronales, estos criterios son utilizados para determinar el entrenamiento de la neurona como se muestra la siguiente tabla:

Tabla 6. Parámetros de parada de entrenamiento de la RNA

PARAMETROS	CRITERIOS DE PARADA
min_grad	Magnitud mínima de gradiente
max_fail	Número máximo de incremento de validación
time	Tiempo máximo de entrenamiento
goal	Valor mínimo de rendimiento
epochs	Número máximo de iteraciones de entrenamiento

2.2 Plataforma utilizada para la RNA

Este capítulo proporciona una breve introducción al emulador NN - Toolbox que se usa para simular RNA. El NN - Toolbox es una herramienta que forma parte del programa Matlab que facilita la resolución de problemas en diferentes dominios mediante el proceso de diseño de una red neuronal, como las relaciones B. P-E, da una oportunidad.

2.2.1 Herramienta NN - TOOLBOX

RNA ha sido entrenada para resolver dar solución a problemas complejos en diferentes campos y difíciles de desarrollar por métodos analíticos. El fenómeno P-E es un El problema se puede simular aplicando RNA, que tiene diversos tipos de emuladores que difieren según la topología de la red, según la cantidad de neuronas, por la cantidad de capas ocultas, por tipos de algoritmos de aprendizaje, etc.

NN-Toolbox Emulador le permite resolver varios problemas aplicando RNA administrado por emulador, una plataforma flexible y fácil de configurar alcambiar las propiedades de la red neuronal y hay varias formas para comprobarel error mostrado por los datos de salida contra los datos deseados.

Presentación gráfica de arquitectura y resultados y errores creados con cada función de entrenamiento muy útil para el análisis y comentarios sobre los productos creados con la herramienta. Resultados fáciles importar para usarlos en otras plataformas para crear nuevas aplicaciones o resultados de analisis.

NN-Toolbox proporciona cuatro formas de usarlo para resolver problemas basados en RNA. La primera forma de usar la herramienta es a través de interfaz gráfica de usuario para un acceso rápido una poderosa herramienta para tales tareas:

- Función de Ajuste (Function Fitting)
- Reconocimiento de patrones (Patterns Recognition)

- Agrupamiento de datos (Data Clustering)
- Análisis de series de tiempos (Time series)

La tarea de coincidencia de características crea una red de reenvío de dos capas con una función sigmoidea aplicada a la capa oculta y una función lineal a la capa de salida.

La tarea de identificación de patrones es la actividad de entrenar una red neuronal para ajustar la clase deseada correcta a un conjunto de patrones de entrada. La red consta de dos capas, utilizando una función lineal en la capa oculta y una función exponencial normalizada en la capa de salida.

La tarea de agrupamiento es el proceso de entrenar la red neuronal en patrones, por lo que la red aparece con su propio clasificador de patrones similares y relativamente ordenados. Además, este tipo de red se tiene en cuenta como representante de la auto organización, incluida una clase competitiva, puede clasificar conjuntos de datos con cualquier número de dimensiones capas como las que tienen neuronas. Las neuronas están dispuestas en una topología bidimensional

El problema del análisis de series de tiempo es un proceso de aprendizaje que resuelve problema con series temporales no lineales con red neuronal dinámica. Red, las neuronas dinámicas se utilizan para el filtrado no lineal y la predicción de valores futuro basado en valores pasados de la serie temporal red neuronal la dinámica puede resolver problemas no lineales, problemas de autorregresión no lineal y problema de autorregresión no lineal con entradas externas.

La segunda forma de utilizar la herramienta es realizar operaciones básicas línea de comando. Funciones de línea de comando usando listas de argumentos simple gracias a la configuración de parámetros de función predeterminada inteligente. La tercera aplicación son las herramientas de ajuste. esta oportunidad avanzado, sin embargo, le permite crear su propia red neuronal mantenga el acceso a todas las funciones del dispositivo.

La cuarta aplicación de la herramienta es la capacidad de modificar cualquier archivo código contenido en NN-Toolbox cada ingrediente computacional está escrito en código MATLAB y es totalmente accesible.

El procedimiento para utilizar la herramienta se describe brevemente a continuación NN - Toolbox para ARN. Los pasos comunes son: Entrada de entrada y Comienzo; crear una arquitectura de red neuronal; formación y validación RNA

2.3 Datos ingreso para la RNA

Los usuarios de NN-Toolbox pueden seleccionar variables de entrada y/o salida INS. Se puede seleccionar el número de entradas o salidas libertad, sin restricciones a la hora de entrenar RNA. Las entradas y salidas se pueden utilizar como valores o valores reales valor normalizado/normalizado, el usuario definió cuál de los dos la entrada variable es mejor para usted en la fase de aprendizaje.

A los fines del entrenamiento de RNA, puede dividir los datos en tres Subconjunto. El primer subconjunto es el entrenamiento que se utiliza para calcular Gradiente y actualice los pesos sinápticos y de sesgo. Segundo subconjunto calibración, donde los errores se controlan durante el entrenamiento y cuando se recibe el error más pequeño, la fase de aprendizaje se detendrá y se cargará synaptic y bias ya tienen la distribución adecuada para la red. El tercer día un subconjunto llamado prueba se utiliza para comparar la pero no se requiere su uso en la etapa de entrenamiento de la red.

Cuando se usa el subconjunto de prueba y el error de prueba es mínimo cuando el número de iteraciones es significativamente diferente del error de validación corregido, esto puede mostrar una distribución porcentual incorrecta subconjuntos en una serie de datos.

2.4 Marco Conceptual

Los siguientes conceptos son tomados del libro “Funciones elementales para construir modelos matemáticos” (Bocco, 2010) y “Redes Neuronales: Conceptos Básicos y Aplicaciones (Matich, 2001):

- **Algoritmo:** Es un conjunto de reglas específicas que permiten resolver un problema, de cierta manera, mediante operaciones sistemáticas (no necesariamente ordenadas) y finitas. Estas instrucciones, específicas y ordenadas con datos, resuelven el problema o tarea.
- **Aprendizaje supervisado:** es un método en un conjunto de datos para su respectivo de entrenamiento. Los datos de entrenamiento están compuestos de pares de objetos: los datos de entrada y el otro, los datos de salida o resultados.
- **BackPropagation:** Es una red de aprendizaje que tiene un ciclo de adaptación de propagación de dos fases. Cuando se aplica un patrón como estímulo a la entrada de la red, se propaga desde la primera capa a través de las capas superiores de la red hasta que se produce la salida.
- **Capa de entrada:** Está formada por diferentes neuronas que recopilan datos o señales del entorno.
- **Capa de salida:** una capa de neuronas que proporciona retroalimentación a la red neuronal.
- **Capa oculta:** La capa que no tiene contacto directo con el medio ambiente.
- **Función de activación:** Es la función de transmitir información resultante de la combinación lineal de pesos y entradas, es decir, es un medio de transmisión de información a través de enlaces de salida.
- **Modelo matemático:** algoritmo que utiliza funciones que tiene un modelo de ecuaciones el cual está relacionado algunas variables
- **Neurona excitada:** la excitabilidad, el impulso o la neurogénesis es la capacidad de las neuronas para cambiar sus potenciales eléctricos y transmitir este cambio a través de sus axones.
- **Neurona:** Son la unidad básica del sistema nervioso, especialmente del cerebro. Cada neurona es una unidad de procesamiento simple que recibe y recoge señales de otras neuronas y otras neuronas.

- **Peso sináptico:** determina la fuerza de la conexión sináptica entre dos neuronas, la primera neurona presináptica y la neurona postsináptica. Los pesos sinápticos pueden tomar valores positivos, negativos o cero.
- **Pronóstico de producción:** incluye la previsión de eventos futuros relacionados con nuestros productos o servicios.
- **Pronóstico:** el pronóstico es una estimación del comportamiento de variables estadísticas en eventos futuros.
- **Red neuronal:** es un algoritmo simple que simula cómo el cerebro humano en la recopilación y análisis de información.
- **Redes neuronales artificiales:** Redes paralelas interconectadas de elementos simples y organizados jerárquicamente que intentan interactuar con objetos del mundo real de manera similar al sistema del mundo real, la neurociencia biológica.

2.5 Marco referencial

Este tipo de investigación es una característica de la investigación actual porque cubre temas de investigación y hace contribuciones valiosas tanto al proceso como a la investigación.

Llumitasig (2021) en su estudio “Simulación de pronósticos de ventas en la empresa IMPACTEX mediante redes neuronales”, ejecución de una simulación de previsión de ventas utilizando una red neuronal artificial. Para ello utiliza el programa gratuito Python, así como datos históricos de ventas de los años 2008-2019. Se realizaron un análisis ABC para determinar qué productos tienen más demanda. (Llumitasig Galarza, 2021, p. 32).

Vidaurre (2012) en su trabajo de investigación “Aplicación de las redes neuronales artificiales para el pronóstico de la demanda de agua potable en la empresa EPSEL S.A. de la ciudad de Lambayeque” Demostrar que el uso de sistemas informáticos basados en la inteligencia humana, como las redes neuronales, reduce los niveles de error y predice los antojos de agua. Predecir cuánta agua doméstica se necesita hoy en día es muy importante para las empresas de servicios de limpieza (Vidaurre Siadén, 2012, pág. 45)

Zapata (2019) en su proyecto de investigación denominado “Aplicación de las redes neuronales para determinar los pronósticos mensuales de la inflación para el año 2018” Se muestra que el propósito principal de usar el sistema es crear una red neuronal para determinar el pronóstico de crecimiento mensual para 2018 utilizando la información de enero de 2008 a diciembre de 2017. Está desarrollado para crear un modelo o red neuronal utilizando un sistema matemático. MATLAB con SPSS y software matemático EVIEWS; Los siguientes se utilizan para el procesamiento de datos, incluido el análisis de la no linealidad del sistema y su varianza en el sistema final; Esencial para acelerar la convergencia de algoritmos de aprendizaje en red. En este caso, las redes neuronales inspiradas en sistemas biológicos parecen resolver algunos problemas, especialmente aquellos que el sistema tradicional genera ciertas dificultades, como, por ejemplo: sistemas no rígidos. Uno de los problemas que presentan estos dispositivos de alto rendimiento es la monitorización del rendimiento, especialmente para la previsión. (Zapata Laureano, 2019, pág. 15)

Bajaña (2019) en su trabajo de investigación “Pronóstico de producción hidroeléctrica del Ecuador usando redes neuronales” validación de la producción hidroeléctrica 2015 en Ecuador mediante una red neuronal artificial. Para este pronóstico, compara datos históricos para el período de 2000 a 2015, utilizando los siguientes datos para varios análisis de pronóstico, analizados en ARIMA y métricas de rendimiento de tiempo. comparar. La normalización de los máximos y la reducción de datos se utilizan para impulsar el entrenamiento y las pruebas en las neuronas, y las neuronas controladas para los neurotransmisores con una función excitatoria se utilizan para las curvas de aprendizaje sigmoideas y detenidas. (Bajaña Martínez, 2019, p. 27)

(Render & Heizer, 2007, pág. 12) en su trabajo de investigación “Aplicación de redes neuronales artificiales para predicción de variables en ingeniería del riego: evapotranspiración de referencia y pérdidas de carga localizadas en emisores integrados” mostró que la aplicación del ligamento cruzado anterior (ANN) demostró dos cambios importantes en los sistemas de riego: la medición de la

evapotranspiración y la pérdida de peso de transmisión. Del mismo modo, no se ha desarrollado un modelo ANN para la caída de presión debido a la inserción del implante en el tubo de irrigación local, que aún no se ha logrado utilizando la red neuronal. A diferencia del modelo estadístico actual, el tipo de ANN propuesto para predicciones locales de la tasa de mortalidad final contiene un indicador de rendimiento que indica el orden de las pruebas independientes, lo que permite la prueba de potenciales totales. Estas innovaciones incluyen pruebas de baja humedad, así como el uso de datos meteorológicos de una segunda estación auxiliar con la misma calificación continental que la estación de prueba (Martí Perez, 2009, pág. 35)

CAPÍTULO III

MARCO METODOLÓGICO

3.1 Tipo de Investigación

Investigación Aplicada.

Este trabajo siguió algunos parámetros de la investigación la cual es documental, exploratoria, descriptiva, comparativa y por secciones. En el desarrollo del trabajo de campo se utilizaron métodos empíricos para recolectar datos de fuentes primarias. Esto incluyó herramientas como informes de observación científica, encuestas y entrevistas enfocadas.

Para la recolección de datos de las fuentes secundarias, se utilizaron instrumentos como fichas bibliográficas, el internet y bibliotecas virtuales. En la tabulación y posterior procesamiento de datos se emplearon métodos electrónicos y computacionales, y durante la revisión de los resultados se utilizaron las metodologías inductiva- deductiva y analítica-sintética.

Investigación Cuantitativa.

El estudio es de carácter cuantitativo debido a que se recopilan y analizan datos digitales, es decir, datos de producción mensuales. Con este método, se identifican tendencias y calidad del agua para que se puedan hacer predicciones, se verifiquen las relaciones y se puedan obtener resultados generales. Se espera que ayude a aumentar los niveles de calidad, permitiendo así que las pequeñas empresas tomen mejores decisiones.

3.2 Diseño De La Investigación

El diseño aplicado para este estudio es experimental, evaluando muestras de agua

diarias durante el cultivo de camarón *L. vannamei* en las diferentes piscinas. A los cuales se les analizara por medio de parámetros de calidad del agua, también recomendamos realizar un análisis completo al principio y al final de cada inspección de los cultivos de camarones. Para realizar la comparativa de los parámetros de agua con los niveles de aceptación en cuanto a la calidad apropiada.

3.3 Población y Muestra

Se tomaron muestras diariamente para los parámetros temperatura, NH_4 , pH, salinidad y O_2 . Se realizó un alisado general del agua del tanque al inicio del cultivo para obtener evidencia de los valores existentes y poder ajustar los valores para el bienestar de los camarones. Al final de la cosecha, se tomaron nuevamente muestras de agua y se analizaron para comparar y validar los valores de los parámetros probados.

3.4 Método, Técnica y Uso de Software de Tratamiento y Análisis de Datos

Para analizar más a fondo el modelo de evaluación, se propuso estudiar los estanques de acuicultura mediante el control de un conjunto de parámetros comunes como el pH, el oxígeno disuelto, la temperatura y la salinidad. El amoníaco no ionizado es un parámetro altamente tóxico para los organismos vivos, pero no se ha medido porque puede controlarse mediante el pH y la temperatura. (Chien, 2018)

Al automatizar los estándares, se pueden minimizar los errores de monitoreo, como los retrasos en las mediciones, la ubicación incorrecta del sensor y las mediciones faltantes. Algunos dispositivos encontraron errores al monitorear los parámetros y descartaron dichas mediciones del conjunto de datos para producir un registro más confiable.

Los estanques de cultivo son alimentados con agua marina proveniente del río Guayas. Para la recolección de muestras se utilizó un estanque de 5 ha, con dimensiones de 100 m de ancho por 500 m de largo por estanque, con pendiente

transversal de 0.1% y 0.1% en sentido longitudinal. El estanque requiere de un recambio de entre 5 y 15% diario de agua; no se tomó en cuenta los procedimientos de aeración en la muestra. La frecuencia de medición es aproximadamente de 15 minutos entre lecturas (4 mediciones/hora), debido a que esta frecuencia es suficiente para observar a detalle las fluctuaciones de cada parámetro.

En definitiva, para utilizar una red neuronal artificial, el primer paso es entrenarla. Presentar un conjunto de entradas y salidas conocidas, que se propagan a través de la red hasta que se obtienen ciertas salidas (feedforward), luego se cambian los pesos y sesgos para que la salida.

Haga coincidir el deseado (propagación hacia atrás). En el segundo paso, se intenta validar la red con un conjunto conocido de entradas y salidas, también hacia adelante, pero no es necesaria la retropropagación, ya que la red ya está debidamente entrenada en principio.

Si el resultado de la fase de verificación es el esperado, la red neuronal se puede utilizar para la aplicación deseada. Entre ellos, habrá algunas entradas que se propagan mediante un acarreo para producir salidas que coincidan correctamente con las entradas.

3.5.1 Técnica

Para que la red funcione como se acaba de describir, se deben alcanzar los valores de pesos y sesgos que lo permitan. Este proceso es entrenamiento en red. Esta entrada de red es conocida (modo de entrada), por lo que puede esperar algunas exportaciones.

De esta manera, el peso cambia porque el modo de entrada se entrega a la red, por lo que las exportaciones se acercan cada vez más. En una red de señales de radar, se proporcionará como muestra una señal que se sabe que se genera por la presencia de un automóvil, una persona o un entorno.

Una vez que se entrena la red, se debe probar su comportamiento correcto

utilizando un conjunto de entradas y salidas en lugar del conjunto de entrenamiento (llamado conjunto de prueba). Una vez que se valida el conjunto de prueba, la red neuronal se puede utilizar en la aplicación entrenada.

Centrándonos en la fase de entrenamiento, cuando el patrón de entrada se presenta a la red, este se propaga a través de la red como se explicó en la sección anterior hasta obtener la salida (feedforward).

A continuación, se produce el aprendizaje a medida que se modifican los pesos de la red para hacer coincidir la salida esperada del usuario con la salida lograda por la red. Una forma es utilizar el algoritmo de retropropagación, que se detalla en la siguiente sección:




Figura 5. Etapas y algoritmos asociados en el desarrollo de una red neuronal artificial

Autor: Elaboración propia

- Análisis del agua al ingresar los camarones.
- Registros de los diversos parámetros físicos y químicos del agua durante el proceso.
- RNA (Redes Neuronales artificiales)

3.5.3 Herramienta

Matlab es una herramienta de software matemático que proporciona un entorno de desarrollo integrado. Gran parte de su funcionalidad está contenida en cajas de herramientas, una clase de extensiones especialmente diseñadas que amplían las capacidades de Matlab. HDL Verifier es un conjunto de herramientas. Su función principal es diseñar con lenguaje de descripción de hardware (HDL) usando cosimulación o simulación FPGA-in-the-loop.

Matlab versión 2019, la cual usara funcionamiento (feedforward) que es un tipo de arquitectura de redes neuronales. En esta sección se utilizara una red de perceptrones multicapa ya que es la más utilizada y es esta red la que se utilizará en los experimentos de este trabajo.

Este tipo de red puede actuar como un aproximador de función universal. Puede aproximar cualquier tipo de función continua o la relación entre un grupo de variables de entrada y salida. Esta propiedad hace que las redes de perceptrones multicapa sean herramientas flexibles, flexibles y no lineales.

La red constan de una capa de entrada, una capa de salida y una o más capas ocultas. Cada una de las entradas llega a conectarse con la neurona de la primera capa. Las salidas de las neuronas de la capa uno se envía a todas las neuronas de la capa dos. Repita este proceso hasta llegar a la capa de salida que obtiene el valor final. Por lo tanto, la conexión siempre es directa, no hay conexión lateral ni conexión inversa.

3.5.4 Fuente

Los datos utilizados provienen de una empresa que cuenta con hectáreas de piscinas de camarón, la cual brindan un repositorio de datos reales en cuanto a las condiciones de la calidad del agua.

3.6 Metodología

Esta metodología está compuesta por 8 pasos

1. Selección de la variable
2. Recolección de datos
3. Preprocesamiento de datos
4. Definición de conjunto de entrenamiento, validación y prueba
 - 4.1 Conjunto de entrenamiento.
 - 4.2 Conjunto de validación
 - 4.3 Conjunto de prueba
5. Selección de la arquitectura
 - 5.1 Número de neuronas de entradas
 - 5.2 Número de capas ocultas
 - 5.3 cantidad de neuronas en la capa de salida
 - 5.4 Función de transferencia
6. Criterio de evaluación
7. Aprendizaje de la red neuronal
8. Implementación del modelo de redes neuronales artificiales

CAPITULO IV

PROPUESTA

4.1. Selección de la Variable

Establecer cuáles son las variables de entrada que resultan importantes para el pronóstico es un vital para el modelo. En este proceso, el interés de hacer predicciones es utilizar datos técnicos como entrada en lugar de datos fundamentales debido a la naturaleza del estudio en sí.

- Variable a Predecir: Calidad del agua en piscinas de camarón
- Tipo de Variable: Cuantitativa.

4.2. Recolección de Datos

El muestreo se realizó diariamente utilizando un refractómetro para evaluar la salinidad del agua de cada piscina. Se debe tener en cuenta que inicialmente esto ocurrió en un solo tanque en el que se alojaron todas las larvas de camarón. Allí, redujimos la salinidad del agua para acomodar el ambiente de salinidad del tanque entre 1 y 0.

Una vez los camarones alcanzaron la etapa juvenil se los distribuyo en sus piscinas correspondientes donde se efectuó periódicamente la toma de datos tanto de temperatura. Oxígeno disuelto, pH salinidad, NH₄.

La toma de temperatura se la realizaba in situ por medio de un termómetro el cual se sumergía en las piscinas por alrededor de 3 minutos, esto se solía realizar e 3 a 4 veces al día tomando en cuenta la hora de medio día y tarde con lo cual según el nivel de temperatura se planteaba incrementar el nivel de oxigenación en el agua.

El O₂ se lo realizaba con un oxigeno metro electrónico el cual arrojaba datos de oxígeno en agua en porcentaje y según los datos que se registraban se aumentaba

o se disminuía la oxigenación de las piscinas. Esta toma de datos se solía realizar tres veces al día una por la mañana, una por el medio día o tarde y una por la noche.

El pH se lo tomaba por medio de un medidor de pH digital y por soluciones reactivas. Esto se realizaba una vez al día principalmente al medio día y en relación a los niveles de pH tomados ya sean altos o bajos se tomaban medidas correctivas para asegurar el bienestar de los camarones.

El NH_4 se lo realizaba cada 7 días por medio de reactivos de pigmentación el cual definían de acuerdo a rangos de colores los niveles de NH_4 en el agua estos valores no se realizaban diariamente debido a que los niveles de NH_4 no cambian al inicio por lo cual se procedió cada 7 días para tener una constante de estos, y si llegaban a mostrar valores que podrían afectar al camarón se realizaban medidas correctivas para evitar esto.

Al inicio de la investigación antes del ingreso de los camarones se realizó una toma de muestra de agua del reservorio en donde se plantea realizar el tratamiento del agua para acondicionarlo al bienestar de estos. Al finalizar la producción se realizó otro muestreo para visualizar los valores arrojados después de la producción.

4.3. Preprocesamiento de Datos

El modelo neuronal consta de dos etapas: aprendizaje y retroalimentación durante la operación. El proceso de diseño de RNA requiere una serie de pasos para completarse. Este método de aprendizaje se puede ver en la Figura 5, donde los valores de los parámetros de calidad del agua se miden, luego se clasifican y almacenan en la base de datos.

Posteriormente son analizados y clasificados según el tipo de daño o condición de la calidad del agua, generando patrones. Por último, los patrones más representativos se utilizan para entrenar a la RNA, según la respuesta que el experto desea obtener




Figura 6. Modelo de aprendizaje para el entrenamiento de aprendizaje en la RNA.

Como se mencionó anteriormente, la calidad del agua se puede clasificar en función de las diferentes situaciones que crean los parámetros en un sistema de cultivo. Cada estado corresponde a una combinación de parámetros óptimos o peligrosos para el organismo. Estas combinaciones se clasifican según su importancia para la acuicultura. Esto se explica a continuación:

- Excelente: todos los parámetros medioambientales están dentro del rango establecido. La calidad del agua es de vital importancia para el cultivo del camarón.
- Bueno: algún parámetro físico-químico están asignados en niveles fuera del parámetro establecido; sin embargo, no tiene una consecuencia bilateral para el cultivo.
- Regular: Algunos parámetros pueden tener concentraciones perjudiciales para los sistemas acuícolas. Las situaciones no deseadas deben ser corregidas. Por ejemplo, las altas temperaturas y los niveles de pH provocan altas concentraciones de amoníaco no ionizado
- Deficiente: la calidad el agua no es aceptable para el cultivo de la especie. Los valores de los parámetros medioambientales son pçeligrosos para el organismo, como situación de hipoxia debido a muy bajas concentraciones de oxígeno disuelto.

4.4. Definición de Conjunto de Entrenamiento, Validación y Prueba

4.4.1. Asociación

Los datos obtenidos se almacenan en un vector que se puede muestra como:

$$y = x^{temp}, x^{sal}, x^{DO}, x^{pH}$$

Cada vector está seleccionando a una categoría determinada por el estado de la calidad del agua según el nivel permitido, su efecto en el estanque y su importancia para la reproducción de la especie (Excelente, Buena, Regular y Mala). Tal asociación se puede señalar de la siguiente manera:

$$\{(y, c) | i = 1, 2, \dots, n\}$$

Donde c_i corresponde a la clase asignada. Cada vector clase se caracteriza por ser un vector orto-normal, el cual presenta un valor unitario en una localidad, dependiendo de la calidad del agua a detectar; es decir, la clasificación que se desea asignar se representará por un 1, mientras que el resto por un "0".

$$c_i = [c_i^e, c_i^b, c_i^r, c_i^d]$$

Donde $c_i^e \in A$, tal que $A = \{0, 1\}$.

4.4.2. Conjunto de entrenamiento

Se ha creado un paquete de capacitación para el proceso de aprendizaje de RNA. Hay un total de 28.335 mediciones en este conjunto, relacionadas con cuatro parámetros de calidad de la piscina.

En circunstancias normales, es difícil obtener una gran cantidad de mediciones que cubran todos los escenarios posibles, por lo que los modelos de medición y los simuladores se combinan para crear conjuntos de datos para "diagnosticar la calidad del agua". Por lo tanto, el conjunto de modelos de entrenamiento basado en mediciones es representativo del actual estado de la calidad del agua.

Este proyecto se enfoca en desarrollar un modelo para analizar la calidad del agua en sistemas de cultivo de camarones a gran escala. El principal objetivo de este modelo es evaluar con precisión los parámetros más importantes e intentar analizar la relación entre los posibles niveles y los parámetros dañinos para los cultivos.

Por esta razón, es necesario comparar los resultados con otros modelos propuestos en la literatura utilizando un conjunto de datos extraídos directamente del sistema de la planta. Los registros de parámetros de temperatura, oxígeno disuelto, salinidad y pH fueron analizados durante el período de medición de julio a agosto, como se menciona en la sección “Área de estudio y recolección de datos”.

Se creó una base de datos para analizar los modelos propuestos y compararlos con los descritos en protocolos para aplicaciones similares. Se tomaron muestras cada cuatro mediciones por hora, evitando una falla del sensor por día, y se recibieron un total de 4.800 muestras para análisis.

El proceso de puntuación requiere reprocesar cada conjunto de datos de cuatro muestras antes de introducirlos en la RNA a través de los pasos de estandarización y normalización. Después de eso, RNA muestra el estado de calidad del agua del estanque de acuerdo con los valores de cada parámetro medido.

Es importante señalar que el análisis de diferentes sistemas de gestión requerirá mediciones del propio hábitat, ya que los valores utilizados en el análisis pretenden mostrar la eficiencia del modelo computacional. Para diferentes condiciones tratadas individualmente.

4.4.3. Reprocesamiento

Las RNA son software de clasificación muy eficiente en la actualidad y se utilizan ampliamente en la similitud de patrones. Sin embargo, dicha eficiencia puede verse obstaculizada por una mala gestión de patrones durante la fase de entrenamiento.

Por lo tanto, es muy importante reprocesar la información obtenida para mejorar la tasa de clasificación.

El primer paso consiste en hacer un proceso de estandarización a los datos de entrenamiento, mismos que permitirán tener una media cero y unificar la desviación estándar con el uso de la siguiente ecuación:

$$x^k = \frac{x_i - \bar{x}}{\sigma}, \forall i = 1, 2, \dots, n;$$

donde k es el parámetro de la calidad del agua; \bar{x} , la media; σ , la desviación estándar; σ , la cantidad de mediciones realizadas, y x^k es el vector de mediciones estandarizadas.

Debido a la naturaleza de los parámetros de calidad del agua, algunos de ellos presentan escalas mucho más grandes que otros; dentro de una RNA, este comportamiento genera una tendencia de decisión hacia los parámetros de mayor escala. Esto se puede minimizar o evitar normalizando el conjunto de datos de entrada estandarizados mediante la siguiente ecuación:

$$x^\infty = \frac{x_i^k - \min(x^k)}{\max(x^k) - \min(x^k)}, \forall i = 1, 2, \dots, n;$$

donde x^∞ es el conjunto de mediciones normalizados.

4.4.4. Estructura y composición de una RNA

Las redes neuronales artificiales poseen conexiones entre patrones de entrada y salida. Esta propiedad permite su uso para correlacionar patrones característicos entre parámetros y condiciones desfavorables de calidad del agua. En otras palabras, las ANN proporcionan una relación no lineal entre los parámetros ambientales (conjunto de entrada) y el estado de calidad del agua (respuesta deseada). Las redes neuronales están formadas por elementos de procesamiento (PE) llamados neuronas, interconectados por pesos y sesgos (Figura 6).




Figura 7. Modelo de una red donde tiene entradas y salidas

Las neuronas están dispuestas en una arquitectura de capas. La primera capa de la red se denomina capa de entrada y es donde se recibe toda la información sobre los parámetros ambientales. La capa final se denomina capa de salida y procesan las clasificaciones deseadas que conducen a los estados de calidad del agua.

A las capas utilizadas entre la capa de entrada y la de salida se les denomina capas ocultas y realizan todo el procesamiento de la información de la RNA. Gran parte del trabajo consiste en determinar la topología adecuada que permita el correcto funcionamiento de la RNA.

El comportamiento de una neurona puede ser expresada con la siguiente ecuación:

$$s_i = \sum_{j=1}^n y_j w_{ij} + b_i$$

Donde w_{ij} son los pesos que interconectan a las diferentes neuronas j de la capa anterior con la neurona actual i ; b , el sesgo de cada neurona; y , la salida de la neurona de la capa anterior, y s_i es la nueva salida de la RNA. El resultado de una neurona es procesado por una nueva función, llamada función de transferencia, la cual se define como:

$$z_i = \frac{1}{1 + e^{-s_j}}$$

Donde z_i es la nueva salida de la i -ésima neurona actual y corresponde a una clase determinada.

4.4.5. Construcción del modelo de evaluación de la calidad del agua

Se construye un modelo de diagnóstico de la calidad del agua utilizando una red neuronal de retropropagación. Dado que el patrón (y_i) contiene 4 parámetros de entrada, los usamos para alimentar una red neuronal y obtener diferentes clases definidas como estados de calidad del agua (c_i) como salidas. Una serie de neuronas en la capa intermedia se encargan de la parte de procesamiento de la información para garantizar el correcto funcionamiento del RNA.

En realidad, no existe regla alguna que permita identificar la cantidad de capas y neuronas en cada una de capa; sin embargo, en este trabajo, una RNA con topología de 4, 20, 4 capas fue la que mejor resultados generó (figura 7). La topología de la red neuronal se determinó probando diferentes arquitecturas (capas y neuronas).

Sin embargo, esta fue la que presentó mejor tiempo de procesamiento y respuesta de clasificación. Del mismo modo, las arquitecturas con un bajo nivel de capas no están bien clasificadas.

Dentro de las diferentes arquitecturas se determinó que no existían diferencias significantes con redes de número mayor de neuronas en las capas ocultas ni con mayor número de capas.




Figura 8. Estructura de la red neuronal para clasificar las variables del agua para el uso en las piscinas de camarón

4.5. Entrenamiento de la Red Neuronal

El entrenamiento se realizó utilizando el software Matlab a través de Neural Network Toolbox. El algoritmo de aprendizaje fue Levenberg-Marquardt debido a la eficiencia del proceso de aprendizaje en RNA. La capa de entrada recibe un conjunto de medidas clasificadas (concentraciones de parámetros fisicoquímicos).

La capa de salida recibe un conjunto de vectores de clasificación de los estados de degradación del estanque (muy bueno, bueno, regular o malo). Se requirieron cerca de 500 iteraciones durante el proceso de entrenamiento y el error de aprendizaje MSE obtenido fue 0.005%.

Una vez finalizada la formación RNA, los resultados se integran en los indicadores que componen el modelo de puntuación. En este caso, el conjunto de medidas debe pasar por los mismos pasos de reprocesamiento del proceso de aprendizaje, teniendo en cuenta los parámetros obtenidos. Promedio, Desviación, Máximo, Mínimo. Posteriormente son marcados por RNA.

Un modelo neuronal captura y evalúa el estado de calidad del agua de un hábitat. Dichos resultados pueden detectar diferentes estados y deben combinarse en una métrica final integrando los resultados con el proceso de agregación. Este proceso reúne todos los resultados de RNA y los convierte en un único índice de calidad

del agua (NWQI). La Figura 8 se observa el método de evaluación.




Figura 9. Análisis de la calidad del agua utilizando la RNA. El proceso de agregación integra las salidas de la RNA y las convierte en un indicador con rango [0, 1]

El vector de salida de la red neuronal posee cuatro variantes de estado de calidad del agua. Por tanto, las neuronas de salida están conectadas a una etapa de agregación que utiliza un sistema difuso para integrar correctamente los resultados.

En esta etapa, usamos una serie de funciones difusas (+) diseñadas en el rango [0, 1], como se muestra en la Figura 8. No hay reglas definidas para elegir el tipo de función difusa. Sin embargo, una función lineal (trapezoidal en este trabajo) facilita el proceso de agregación. Estas funciones difusas se pueden representar mediante las siguientes funciones:

$$\mu(x, a, b, c, d) = \max \left\{ \min \left\{ \frac{x - a}{b - a}, 1, \frac{d - x}{d - c} \right\}, 0 \right\}$$

Cada función de salida corresponde a la neurona designada a la misma clasificación y el valor de + es determinado por el valor de la neurona. La figura 8 muestra este proceso. El siguiente paso es la integración de las funciones de salida para el cálculo final del índice. Esto se realiza mediante el cálculo del centro de gravedad (centroide) de la función de agregación (figura 9). La función centroide (CF) ha demostrado físicamente ser la más eficiente para transformar una función difusa a un valor real, al regresar el centro del área bajo la curva formada por la

agregación de dichas funciones.

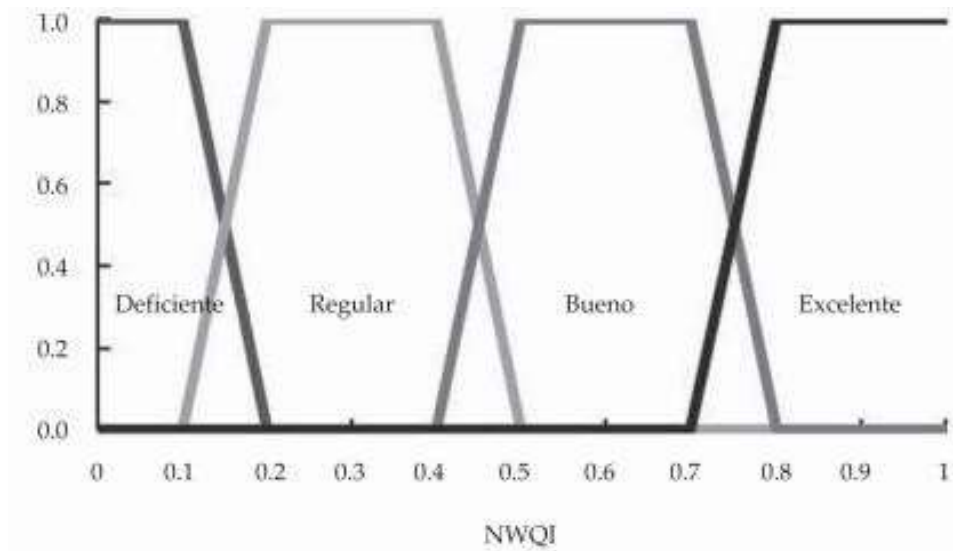


Figura 10. Funciones implementadas para agrupar los resultados de salida de la RNA.

Cada función de salida está seleccionada a una neurona asociada a la misma clasificación, y el valor + está aplicado para el valor de la neurona. La figura 10 se muestra este proceso. El siguiente análisis es la agrupación de las variables de salida para el proceso final del aprendizaje de la RNA.

Para ello se calcula el centroide (centroid) de la función agregada (Figura 10). La función centroide (CF) se encuentra físicamente como la forma más eficiente de transformar una función difusa en un valor real devolviendo el centro del área bajo la curva formada por el conjunto de estas funciones. La función centroide se calcula usando la siguiente fórmula:

$$CF = \frac{\int x \mu_{out}(x) dx}{\int \mu_{out}(x) dx}$$




Figura 11. Proceso asignar salidas de redes neuronales para obtener índices de calidad del agua usando centroides

Dado que el método del centroide calcula el centroide de las características, el resultado final de CF está limitado desde el centro de la característica mala (0,078) al centro de la característica buena (0,87), por lo que el valor final de CF debe normalizarse. Restablecer al rango [0, 1]. Para hacer esta conversión, utilice la siguiente fórmula:

$$NWQI = \frac{CF - \min(CF)}{\max(CF) - \min(CF)}$$

Donde NWQI es el valor normalizado.

4.6. Validación y resultado de la red con conjunto de prueba

El análisis preliminar de cada elemento de calidad del agua es registrado en la base de datos de la piscina de prueba revela muchas características esenciales que afectan directamente el estado de la calidad del agua.

Una red de retransmisión (feedforward) multicapa consta de al menos una capas ocultas. Se utilizan para muchas tareas tales como: patrones de clasificación, identificación de sistemas, control de procesos, robótica, etcétera.

La Figura 1.9 muestra la red de transición (configuración directa) con varios

niveles: Capa de entrada con señal N , dos capas de neuronas ocultas. En las neuronas, respectivamente, N_1 y N_2 y ciertamente una capa de neuronas. La salida compleja de las neuronas M , que representan los valores de salida apropiados.

Las principales redes que utilizan redes directas (feedforward) multicapa incluyen el porcentaje multicapa (MLP) y la función de base radial (FBR), cuyos algoritmos de aprendizaje se utilizan en sus procesos en función de las reglas delta, correspondiente.

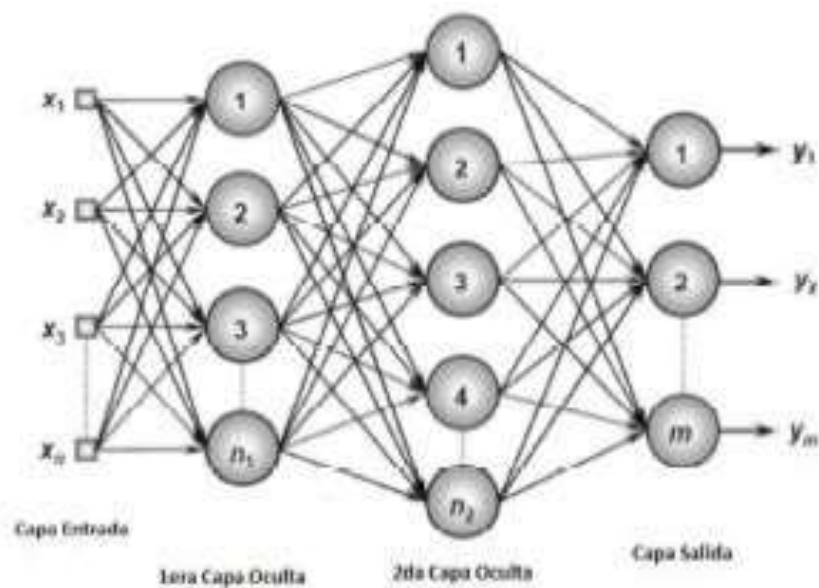


Figura 12. Redes directas (feedforward) multicapa

Autor: Elaboración propia

Para evaluar la calidad del agua ingresamos al programa de matlab, para ingresar los datos y evaluar a través de la red neuronal si esta tiene una calidad óptima. La cual a través de un software nos permitirá tener una percepción clara.




Figura 11. Software de matlab para la evaluación de la calidad del agua

La figura 12 muestra el comportamiento de la temperatura a medida que fluctúa a lo largo del día con los cambios en la intensidad solar. El rango óptimo tiene un límite superior e inferior, con tendencia a superar ligeramente el límite superior (30 °C), lo que produce una puntuación negativa en el NWQI.




Figura 12. Resultado de evaluación de comportamiento de la temperatura

La figura 13 muestra el comportamiento de la salinidad, mostrando inicialmente concentraciones por encima del límite permisible (25 mg/l), corregidas por reducción de salinidad por cambios de agua. Se espera que las altas concentraciones al comienzo del período de medición influyan en los resultados del NWQI y que puedan obtener un conjunto de evaluaciones negativas.




Figura 13. comportamiento de la salinidad

En la Figura 13, el oxígeno disuelto exhibe un comportamiento oscilatorio debido principalmente a la actividad del micro algas. Los micros algas liberan altas concentraciones de oxígeno durante el pico de intensidad solar y lo agotan por la noche. Sin embargo, los niveles de oxígeno disuelto rara vez muestran valores muy bajos (por debajo de 2 mg/l). El valor de NWQI se ve afectado por este parámetro. Esto se debe a que los valores bajos se presentan debido a que este comportamiento fue destacado como indeseable en el proceso de entrenamiento.




Figura 13. Comportamiento del oxígeno disuelto

La Figura 14 muestra el curso del valor de pH. Este se encuentra en un nivel óptimo y estable y no debería plantear ningún problema para el estanque y, por lo tanto, para el análisis de NWQI.




Figura 14. Historial del PH

La Figura 15 muestra la evaluación de las tres métricas durante el período de prueba. Los resultados de RNA incluyen una detección más sólida de condiciones adversas en el análisis de la calidad del agua en comparación con los índices CCME y (HI)c. Esto se explica por el proceso de formación RNA. En este proceso, RNA clasificó y aprendió concentraciones que representan condiciones potencialmente dañinas para la calidad del agua. Como resultado, la puntuación de penalización aumenta cada vez que se mide una concentración problemática.




Figura 15. Análisis entre factores de la calidad el agua.

El RNA se puede utilizar para correlacionar concentraciones suficientes o desfavorables en ecosistemas con condiciones de calidad del agua. Por tanto, una buena selección de patrones en el entrenamiento de una RNA mejorará su rendimiento en la evaluación. Esto se puede observar cuando los valores de oxígeno disuelto disminuyen significativamente.

De manera similar, evaluar las condiciones óptimas para el crecimiento de las especies presupone que se han clasificado las concentraciones apropiadas en los ecosistemas. La principal ventaja de usar ANN es su capacidad de generalización. Esto significa que puede clasificar patrones que no están en el conjunto de entrenamiento.

El comportamiento oscilatorio de temperatura y oxígeno disuelto fue un factor preponderante en el resultado final, pues en conjunto influenciaron de forma considerable la evaluación proporcionada por los indicadores.

Parámetros					Resultados		
Tabla 7. Concentraciones y evaluaciones de los parámetros de la calidad del agua							
00:00	27.5	5.85	23.47	8.4	0.58527044	0.799	0.855
01:00	27.3	5.32	23.46	8.4	0.54061635	0.784	0.824
02:00	27	4.99	23.48	8.4	0.46559748	0.774	0.803
03:00	26.9	4.86	23.5	8.4	0.43612579	0.77	0.794
04:00	26.7	5.18	23.55	8.4	0.50042767	0.78	0.816
05:00	26.5	4.66	23.55	8.4	0.37986164	0.763	0.78
06:00	26.4	4.43	23.55	8.4	0.33163522	0.755	0.763
07:00	26.3	4.5	23.58	8.4	0.32895597	0.757	0.768
08:00	26.4	4.94	23.58	8.4	0.44416352	0.772	0.8
09:00	26.6	5.44	23.57	8.4	0.56205031	0.788	0.832
10:00	27	6.22	23.59	8.4	0.5772327	0.809	0.876
11:00	28.3	7.88	23.48	8.4	0.58437736	0.845	0.913
12:00	29.2	8.43	23.38	8.4	0.56562264	0.855	0.913
13:00	30.2	8.62	23.39	8.4	0.45577358	0.858	0.913
14:00	31	8.45	23.46	8.4	0.34056604	0.852	0.913
15:00	30.7	8.63	23.51	8.5	0.37986164	0.856	0.899
16:00	30.9	8.33	23.54	8.5	0.34771069	0.85	0.899
17:00	30.5	7.98	23.54	8.5	0.40754717	0.845	0.899
18:00	29.9	7.58	23.56	8.5	0.47006289	0.839	0.899
19:00	29.3	6.95	23.56	8.5	0.53972327	0.826	0.897
20:00	29	6.39	23.63	8.5	0.57455346	0.813	0.871
21:00	29	6.28	23.68	8.4	0.57008805	0.81	0.879
22:00	28.6	5.81	23.73	8.4	0.56651572	0.797	0.855
23:00	28.4	5.55	23.72	8.4	0.56740881	0.79	0.839

La Tabla 3 muestra un conjunto de mediciones como ejemplo de las evaluaciones realizadas con las métricas propuestas. En este caso, se pueden observar fluctuaciones en el oxígeno disuelto y temperatura cercanas a los límites aceptables, condiciones que afectan la evaluación final del NWQI.

CONCLUSIONES

Actualmente, existen varios modelos de diagnóstico de la calidad del agua. Sin embargo, se han desarrollado y aplicado a diferentes tipos de ecosistemas y no son compatibles con los hábitats de los camarones. Como se vio en la sección anterior, se realizaron una serie de análisis de la calidad del agua en estanques grandes utilizando dos indicadores que servían para el mismo propósito.

En este estudio, se desarrolló un modelo informático para evaluar la calidad del agua en la acuicultura del camarón blanco *Litopenaeus vannamei*. Este modelo se construye usando técnicas computacionales tales como: RNA desarrollada

Los resultados que se muestran en la Figura 15 muestran una mayor caída en el rendimiento utilizando NWQI a medida que se identificaron estas situaciones problemáticas y se capacitó a la ANN en estos criterios, que se reflejaron durante la evaluación. Cabe señalar que este trabajo ofrece avances en el diagnóstico de la calidad del agua en este tipo de sistemas acuícolas.

RECOMENDACIONES

Se necesita más investigación para obtener un modelo más completo y preciso del ecosistema en cuestión. La correlación entre parámetros y comportamiento en la gestión del agua es un tema propuesto a futuro, ya que la misma red neuronal puede detectar estas anomalías y establecer la relación. De manera similar, se han propuesto modelos para explorar correlaciones entre otros parámetros importantes y aspectos biológicos de la contaminación y/o los organismos.

BIBLIOGRAFÍA

- ARAVENA, M., CAAMANO, C., & GIMENEZ, J. (2008). Modelos matemáticos a través de proyectos. *Revista latinoamericana de investigación en matemática educativa*, 11(1), 49-92.
- Aravena, M., Caamaño, C., & Giménez, J. (2008). Modelos matemáticos a través de proyectos. *Revista latinoamericana de investigación en matemática educativa*, 11(1).
- Awwa. (2017). *Standard methods for the examination of water and water*.
- Bajaña Martínez, E. A. (2019). *Pronóstico de producción hidroeléctrica del Ecuador usando redes neuronales*. Universidad de Guayaquil.
- Banco Central del Ecuador. (2017). *Cuentas Nacionales*. Quito: Banco Central del Ecuador.
- Basogain Olabe, X. (2019). *Redes neuronales Artificiales y sus Aplicaciones*. España: Escuela Superior de Ingeniería de Bilbao.
- Belt. (2018). *Principals of shrimp culture chemotherapy*. Squaculture Societ.
- Beltrame. (2017). *Pre-selection of areas for shrimp culture in a subtropical Brazilian Lagoon based on multicriteria hydrological evaluation*. Coastal Research.
- Berkowitz, D. E. (1998). INDUSTRIA ALIMENTARIA. En *ENCICLOPEDIA DE SALUD Y SEGURIDAD EN EL TRABAJO* (págs. 67 - 67.35). Madrid: Chantal Dufresne, BA.
- Bocco, M. (2010). *Funciones elementales para construir modelos matemáticos* (Primera ed.). Buenos Aires: Instituto Nacional de Educación Tecnológica.
- Bower. (2017). *Ionization of ammonia in seawater: Effects of temperature, pH and salinity*. Journal of the Fisheries Research of Canada.
- Carvajal. (2019). Assessment and prediction of the water quality in shrimp culture using signal processing techniques.
- Cervantes Gómez, L. (2015). *Modelización matemática: Principios y Aplicaciones* (Primera ed.). México: Benemerita Universidad Autónoma de Puebla.
- Chien. (2018). *Water quality requirements and management for marine shrimp culture*. FLORIDA: Squaculture Society.
- Del Carpio Gallegos, J. (2005). Las redes neuronales artificiales en las finanzas. *Industrial Data*, 8(2).
- EscobarGómez, E. N., Díaz-Núñez, J. J., & Taracena-Sanz, L. F. (2010). Modelo para el ajuste de pronósticos agregados utilizando lógica difusa. *Ingeniería. Investigación y Tecnología*, 11(3), 289-302.

- FAO. (07 de Octubre de 2021). *FAO. (Situación Alimentaria Mundial)* Recuperado el 08 de Octubre de 2021, de <http://www.fao.org/worldfoodsituation/csdb/es/>
- FAO y CEPAL. (2020). *Sistemas alimentarios y COVID-19 en América Latina y el Caribe*. Santiago de Chile: FAO.
- Freeman Castro, J. A., & Skapura González, D. M. (1993). *Redes neuronales; algoritmos, aplicaciones y técnicas de programación*. España: Addison-Wesley.
- Kaastra, L., & Boyd, M. (1996). Designing a neural network for forecasting financial and economic time series. *Neurocomputing*, 10(3), 215-236.
- Llunitasig Galarza, M. C. (2021). *Simulación de pronósticos de ventas en la empresa IMPACTEX mediante redes neuronales*. Universidad Técnica de Ambato.
- López Rodríguez, S. M., & Zapata Zuluaga, T. (2018). *Técnicas de pronósticos en revisión sistémica de literatura para empresas de confecciones*. Bogotá: Universidad Cooperativa de Colombia.
- Luliano. (2019). *Neural and adaptative systems Fundamentals through simulations*.
- Martí Perez, P. (2009). *Aplicación de redes neuronales artificiales para predicción de variables en ingeniería del riego: evapotranspiración de referencia y pérdidas de carga localizadas en emisores integrados*. Valencia: Universidad Politécnica de Valencia.
- Matich, D. J. (2001). *Redes Neuronales: Conceptos Básicos y Aplicaciones*. Rosario: Universidad Tecnológica Nacional.
- Méndez Giraldü, G. A., & Lopez Santana, E. R. (2014). Metodología para el pronóstico de la demanda en ambientes multiproducto y de alta variabilidad. *Tecnura: Tecnología y Cultura Afirmando el Conocimiento*, 18(40), 89-102.
- Montes Albarracin, A. I. (2016). *Uso de redes neuronales artificiales para el pronóstico de demanda de hielo industrial en Hielos Santa Lucía S.R.L*. Tacna: Escuela Profesional de Ingeniería en Informática y Sistemas.
- Montesinos-López, O. A., & Hernández-Suárez, C. M. (2007). Modelos matemáticos para enfermedades infecciosas. *Salud Pública de México*, 49(3), 218-226.
- Morales Tabares , Z. E., Cabrera Campos , A., Vázquez Silva , E., & Caballero Mota , Y. (3 de julio de 2016). MPREDSTOCK : Modelo multivariado de predicción del stock de piezas de repuesto para equipos médicos. *Revista Cubana de Ciencias Informáticas*, 10(3), 143-159 .
- Nations, O. a. (2020). *OCDE-FAO Perspectivas Agrícolas*. OCDE-FAO.
- Perez, R. A., Mosquera Sanchez, S. A., & Bravo, J. J. (2012). Aplicación de modelos de pronósticos en productos de consumo masivo. *Biotecnología en el Sector Agropecuario y Agroindustrial: BSAA*, 10(2), 117-125.

- Ramos, A., Sánchez, P., Ferrer, J. M., Barquín, J., & Linares, P. (2010). *Modelos matemáticos de optimización*. Madrid: Universidad Pontificia Comillas.
- Render, B., & Heizer, J. (2007). *Administración de la producción*. México: PEARSON EDUCACIÓN.
- Rodríguez Velázquez, J. A., & Steegmann Pascual, C. (Agosto de 2012). *Modelos Matemáticos*. Obtenido de https://recursos.salonesvirtuales.com/wp-content/uploads/bloques/2012/08/Modelos_matematicos.pdf
- Rodríguez Velázquez, J. A., & Steegmann Pascual, C. (24 de Junio de 2013). *Modelos Matemáticos*. Recuperado el 8 de Octubre de 2021, de https://recursos.salonesvirtuales.com/wp-content/uploads/bloques/2012/08/Modelos_matematicos.pdf
- Ruiz Pozo, R. G., Soria Torres, L. O., & Vidarte Ureta, A. T. (2020). *Optimización de la producción de petróleo en el Campo Limoncocha mediante el análisis de pruebas de restauración de presión*. Quito: Universidad Central del Ecuador.
- Salett Biembegut, M., & Hein, N. (1999). Modelación matemática: Estrategia para enseñar y aprenderr matemáticas. *Educación Matemática*, 11(1), 119-134.
- Sánchez López, E., Barreras Serrano, A., Pérez Linares, C., Figueroa Saavedra, F., & Olivas Valdez, J. A. (2013). Aplicacion de un modelo arima para pronosticar la producción de leche de bovino en Baja California, México. *Tropical and Subtropical Agroecosystems*, 16(3), 315-324.
- Sánchez Sánchez, D. A. (2018). *Modelo ARIMA para el pronóstico de la produccion de cacao en el Prú 2012 - 2018*. Facultad de Ciencias Físicas y Matemáticas. Trujillo: Universidad Nacional de Trujillo.
- Saucedo Castillo, O., Pérez, L. V., Herrera Isla, L., & Fernández Pérez, L. (2010). Sistema de pronóstico climático del tizón tardío (phytophthora infestans) en el cultivo de la papa en la provincia de Villa Clara. *REDVET. Revista Electrónica de Veterinaria*, 11(3B), 1-12.
- Semarnap. (2018). Secretaría de Medio Ambiente, Recursos Naturales y Pesca.
- Shan. (2015). *Development of an artificial neural network-based software for prediction*.
- Song. (2019). Artificial neural network modeling of the water quality in intensive.
- Superintendencia de Compañías, Valores y Seguros. (2018). *Panorama de las MIPYMES y Grandes Empresas en el Ecuador 2013-2017*. Quito: Superintendencia de Compañías, Valores y Seguros.
- Vidaurre Siadén, Y. (2012). *Aplicación de las redes neuronales artificiales para el pronóstico de la demanda de agua potable en la empresa EPSEL S.A. de la ciudad de Lambayeque*. Chiclayo: Universidad Católica Santo Toribio de Mogrovejo.

- Villada, F., Muñoz, N., & García, E. (2012). Aplicación de las Redes Neuronales al Pronóstico de Precios en el Mercado de Valores. *Información tecnológica*, 23(4), 11 - 20.
- Villada, F., Muñoz, N., & García-Quintero, E. (2016). Redes Neuronales Artificiales aplicadas a la Predicción del Precio del Oro. *Información tecnológica*, 27(5).
- Zafra Mejía, C. A., & Gutiérrez Gil, V. H. (2015). Análisis de la producción de lixiviado y biogás bajo condiciones de extracción activa. *Ingenium Revista De La Facultad De ingeniería*, 16(31), 9-23.
- Zapata Laureano, J. (2019). *Aplicación de las redes neuronales para determinar los pronósticos mensuales de la inflación para el año 2018*. Piura: Universidad Nacional de Piura.