

UNIVERSIDAD AUTÓNOMA DE ZACATECAS “FRANCISCO GARCÍA SALINAS”
UNIDAD ACADÉMICA DE INGENIERÍA ELÉCTRICA
DOCTORADO EN CIENCIAS DE LA INGENIERÍA



**ILUMINACIÓN LED PARA MEJORAR LA PRODUCCIÓN EN CULTIVOS
INTENSIVOS DE TILAPIA Y MONITOREAR SÓLIDOS SUSPENDIDOS EN
SISTEMAS ACUÍCOLAS CON TECNOLOGÍA BIOFLOC**

TESIS DE DOCTORADO

COMO REQUISITO PARCIAL PARA OBTENER EL GRADO DE:

DOCTOR EN CIENCIAS DE LA INGENIERÍA

ORIENTACIÓN: PROCESAMIENTO DE SEÑALES E INSTRUMENTACIÓN ELECTRÓNICA

PRESENTA:

DANIELA PAOLA LÓPEZ BETANCUR

DIRECTORES DE TESIS:

DR. CARLOS ALBERTO OLVERA OLVERA, Y DR. IVÁN MORENO HERNÁNDEZ

ZACATECAS, ZAC., 13 DE FEBRERO DE 2020.

ABREVIATURAS

AI	<i>En inglés:</i> Artificial Intelligent
ANN	<i>En inglés:</i> Artificial Neural Network
C	Carbono
CNN	<i>En inglés:</i> Convolutional Neural Network
CO₂	Dióxido de carbono
C/N	Relación Carbono/Nitrógeno
FAO	<i>En inglés:</i> Food and Agriculture Organization of the United Nations
LED	<i>En inglés:</i> Light Emitting Diode.
N	Nitrógeno
TAN	<i>En inglés:</i> Total ammonia nitrogen
NH₄⁺	Amonio
NH₃	Amoníaco
DO	<i>En inglés:</i> Dissolved Oxygen
SRA	Sistema de recirculación acuícola
TSS	<i>En inglés:</i> Total Suspended Solids
SSV	Solidos suspendidos volátiles
TBF	<i>En inglés:</i> Biofloc technology

Resumen

El uso de nuevas tecnologías como la iluminación LED (*Light Emitting Diode*) y la tecnología biofloc (BFT) permiten mejorar la eficiencia y la sostenibilidad en la producción acuícola. Los sistemas acuícolas con BFT no requieren intercambio de agua, por lo cual, los residuos orgánicos se acumulan y degradan en el estanque, lo que genera condiciones ideales para la formación de comunidades microbianas, llamadas bioflocs. Los bioflocs, son conglomerados de microbios, algas, protozoos, detritus y partículas orgánicas, que al ser alimentados con carbohidratos (azúcar, almidón, melaza, harina de yuca, etc.) se ven forzados a tomar el nitrógeno inorgánico presente en el agua del tanque para poder producir la proteína requerida para su crecimiento y multiplicación celular, lo que a su vez mejora la calidad del agua. Posteriormente, estos bioflocs, si se mantienen en suspensión en el agua, sirven como alimento para los peces, complementando así la alimentación y reduciendo a su vez la compra de alimentos comerciales. Además, con el desarrollo de nuevas tecnologías como la iluminación LED se puede mejorar la producción en sistemas acuícolas. Los LEDs son fuentes de luz de alta eficiencia en la conversión de energía, vida de larga duración, baja emisión de calor, bajo consumo eléctrico, intensidad de luz ajustable, robustos, y resistentes al medio ambiente. A su vez, las lámparas LED de colores permiten obtener iluminaciones con longitudes de ondas específicas.

Es por esto, que en esta investigación se propone la implementación de sistemas de iluminación LED en sistemas intensivos de tilapia con BFT con el propósito de mejorar la producción, el crecimiento y la composición nutricional de las tilapias, y de los bioflocs como fuente de alimento para las tilapias. Además, con el propósito de monitorear la concentración de biofloc, en esta tesis también se propone un nuevo método para monitorear la turbidez y los sólidos suspendidos totales (TSS). Por esta razón, la tesis se divide en dos fases: la primera fase evalúa el efecto de la longitud de onda (color) en el crecimiento y la composición nutricional de la tilapia, y también el efecto de la luz de color en los bioflocs como fuente de alimento para los peces. Esta etapa fue realizada a través de un experimento piloto con alevines de tilapia de 0.242g. La experimentación duró 73 días, y en esta, tres tanques fueron iluminados con luz natural (luz proveniente del sol) y lámparas LED cuyas longitudes de onda (λ) fueron 627.27 nm para luz roja, 513.33 nm para luz verde, y 451.67 nm para la luz azul. La intensidad de luz utilizada en las tres lámparas fue de 0.832 mW/cm^2 , y el régimen de luz utilizado (fotoperiodo)

fue de 18 horas de luz y 6 horas de oscuridad. También, un cuarto tanque fue utilizado como tanque de control o tanque testigo, y estuvo solo iluminado con luz proveniente del sol (luz natural). Los resultados obtenidos en esta fase mostraron un efecto significativo de la longitud de onda sobre el crecimiento de las tilapias, y la composición nutricional de las tilapias y los bioflocs.

Por su parte, la segunda fase de esta investigación se centró en monitorear la concentración de biofloc en el agua. En específico, se desarrolló una nueva técnica de medición de sólidos suspendidos y turbidez, a través de un sistema de iluminación LED, un teléfono celular, y el uso de redes neuronales convolucionales. En esta fase, se implementó una red convolucional con arquitectura AlexNet (modelo pre-entrenado) y una regresión lineal múltiple (MLR) para estimar valores de TSS y turbidez, basándose en las partículas suspendidas de una muestra líquida. Para esto, la muestra fue iluminada con luz LED blanca, roja, verde y azul, con el fin de evaluar con que color de luz la red neuronal obtenía una mayor precisión para estimar el número total de partículas suspendidas. Los resultados obtenidos en esta fase muestran un método de medición de alta precisión, y en el cual se reduce la intervención humana y los costos para realizar mediciones de TSS y turbidez. Este sistema fue diseñado para monitorear en un futuro la concentración de biofloc en la acuicultura, y probado mediante el monitoreo de la concentración de alimento para peces en el agua. Sin embargo, con adaptaciones adecuadas, el método podría ser utilizado en otras áreas donde se requiera evaluar la calidad del agua potable, la calidad del agua utilizada para el consumo humano, la evaluación de aguas con residuos industriales, etc.

Palabras claves: Luz, Color, LEDs, acuicultura, redes neuronales convolucionales, sólidos suspendidos totales (TSS), turbidez.

Abstract

The use of new technologies such as LED (Light Emitting Diode) lighting, and biofloc technology (BFT) allow improving efficiency and sustainability in aquaculture production. Aquaculture systems with BFT do not require water exchange, therefore, organic waste accumulates and degrades in the pond, which creates ideal conditions for the formation of microbial communities, called bioflocs. Bioflocs are conglomerates of microbes, algae, protozoa, detritus and dead organic particles, that when fed with carbohydrates (sugar, starch, molasses, cassava flour, etc.) are forced to take the inorganic nitrogen present in the water of the tank to be able to produce the protein required for their growth and cell multiplication, which in turn improves water quality. Subsequently, these bioflocs, if they remain in suspension in the water, serve as food for the fish, thus complementing the diet, and reducing the purchase of commercial food. In addition, LED lighting systems are high efficiency light sources in energy conversion, long life, low heat emission, low power consumption, adjustable light intensity, robust, and environmentally resistant. In turn, colored LED lamps allow to obtain illuminations with specific wavelengths.

It is for these reasons that in this research, the implementation of LED lighting systems in intensive systems of tilapia with BFT is proposed in order to improve the production, growth and nutritional composition of tilapia, and bioflocs as a food source for tilapia. In addition, in order to monitor the concentration of biofloc, this thesis also proposes a new method to monitor turbidity and total suspended solids (TSS). For this reason, the thesis is divided into two phases: the first phase assesses the effect of wavelength (color) on the growth and nutritional composition of tilapia, and also the effect of color light on bioflocs as food source for fish. This stage was carried out through a pilot experiment with tilapia fry of 0.242g. The experimentation lasted 73 days, and in this, three tanks were illuminated in addition to natural sunlight with colored light using RGB light emitting diodes (LEDs) with peak wavelengths (λ) of 627.27 nm for red, 513.33 nm for green, and 451.67 nm for blue light. The light intensity used in the three lamps was 0.832 mW/cm^2 , and had an 18-h photoperiod of light per day throughout the study. Also, a fourth tank was used as a control tank or witness tank, and was only illuminated with sunlight. The results obtained in this phase showed a significant effect of colored light on tilapia growth, and nutritional composition of tilapia and bioflocs.

For its part, the second phase of this investigation focused on monitoring the concentration of biofloc in water. Specifically, a new technique for measuring suspended solids and turbidity was developed, through an LED lighting system, a cell phone, and the use of convolutional neural networks. In this phase, a convolutional network with AlexNet architecture (pre-trained model) and a multiple linear regression (MLR) were implemented to estimate TSS and turbidity values, based on the suspended particles of a liquid sample. For this, the sample was illuminated with white, red, green and blue LED light, in order to evaluate with what color of light the neural network obtained greater precision to estimate the total number of suspended particles. The results obtained in this phase show a high-precision measurement method. This method reduces human intervention and the cost of making TSS and turbidity measurements. The system was designed and tested to monitor physical-chemical parameters in aquaculture applications, however, this could be used in other areas, where it is required to evaluate the quality of drinking water, the quality of water used for human consumption, and water evaluation of industrial waste, among others.

Keywords: Light, Color, LEDs, aquaculture, convolution neural network, total suspended solids (TSS), turbidity.

Agradecimientos

Al Dr. Carlos Alberto Olvera Olvera por compartir conmigo sus conocimientos, su gran amistad, su apoyo y por abrirme las puertas tanto en México como en la Universidad Autónoma de Zacatecas.

Al Dr. Iván Moreno Hernández por sus enseñanzas, amistad, sabios consejos e inestimable guía en cada momento y etapa de esta investigación. Usted jamás dejó de creer en mí y/o en esta investigación, lo cual le agradezco infinitamente, al igual que su disponibilidad y paciencia.

Al Dr. Efrén González Ramírez, al Dr. Tonatiuh Saucedo, y a la Dra. Ma. Auxiliadora Araiza Esquivel por contribuir en el desarrollo de esta investigación y participar como sinodales.

A la Maestra Ana Isabel Veyna Gómez por su ayuda con las muestras de turbidez.

A mis grandes amigos y compañeros en esta aventura Edith, Anuard y Claudia.

Al Dr. José Ismael De la Rosa Vargas y a todos los docentes del programa Doctorado en Ciencias de la Ingeniería,

A el Consejo Nacional de Ciencia y Tecnología de México (CONACYT), a la Organización de los Estados Americanos (OEA) y la Agencia Mexicana de Cooperación Internacional para el Desarrollo (AMEXCID) por su apoyo económico para la realización de mis estudios de Doctorado.

A mí familia.

Contenido

Capítulo 1. Introducción	13
1.1. Introducción	13
1.2 Antecedentes	16
1.2.1. Iluminación LED	16
1.2.2. Acuicultura	16
1.2.3. Redes neuronales convolucionales	18
1.2.4. Sólidos suspendidos y turbidez	18
1.3. Estado del arte y resumen histórico	19
1.3.1. Acuicultura e iluminación	19
1.3.2. Redes neuronales convolucionales	26
1.3.3. Sólidos suspendidos y turbidez	27
1.4. Planteamiento del problema y justificación	28
1.5. Hipótesis	29
1.6. Objetivos	30
1.6.1. Objetivo General	30
1.6.2. Objetivos Específicos	30
Capítulo 2. Marco teórico	31
2.1. Iluminación LED	31
2.2. Tecnología Biofloc	33
2.3. Tilapia del Nilo	35
2.3. Redes neuronales convolucionales (CNN)	36
Capítulo 3. Materiales y métodos	39
3.1. Fase I	39
3.1.1. Diseño experimental.....	39
3.1.2. Caracterización de las lámparas LED.....	42
3.1.3. Sistema biofloc	42
3.1.4. Calidad del agua	44
3.1.5. Métricas de evaluación del rendimiento del crecimiento de las tilapias	44
3.2. Fase II	48
3.2.1. CNN utilizada.....	48
3.2.2. MLR para predecir TSS y valores de turbidez	49

3.2.3. Activaciones de la CNN propuesta.....	50
3.2.4. Diseño experimental.....	52
3.2.5. Muestras líquidas utilizadas	54
3.2.6. Evaluación del desempeño de la técnica propuesta.....	55
Capítulo 4. Resultados y discusiones	59
4.1. Fase I.....	59
4.1.1. Calidad del agua	59
4.1.2. Tasa de crecimiento de las tilapias de Nilo	60
4.1.3. Composición nutricional de las tilapias y los bioflocs	63
4.2. Fase II.....	67
CONCLUSIONES.....	75
REFERENCIAS	77
ANEXOS	86

Índice de figuras

Figura 1. Evolución histórica del rendimiento en eficiencia luminosa del LED y el rendimiento proyectado en comparación con otras fuentes convencionales de luz.....	31
Figura 2. Esquema de un Diodo LED	32
Figura 3. Tres métodos para generar luz blanca a partir de LEDs: (a) LED rojo + verde + azul. (b) LED UV + fósforo RGB. (c) Pc-LED = LED azul + fósforo amarillo	33
Figura 4. Esquema del sistema de la tecnología biofloc	34
Figura 5. Esquema del cálculo esquemático de la cantidad diaria de carbohidratos añadidos que necesitan los bioflocs para eliminar el nitrógeno excretado en un estanque de acuicultura intensiva. .	35
Figura 6. Descripción general de un modelo CNN.	36
Figura 7. Representación del proceso TL y puesta a punto de la CNN.....	37
Figura 8. Diseño experimental utilizado.	40
Figura 9. Climatización de los alevines de tilapia.....	40
Figura 10. Siembra de los alevines de tilapia.	40
Figura 11. Períodos de luz recibidos por cada tanque durante esta investigación.....	41
Figura 12. Distribución espectral de las potencias de las lámparas LED RGB utilizadas en el estudio: (a) lámpara LED R, (b) lámpara LED G, y (c) lámpara LED B.	42
Figura 13. Experimento en día 20, ya con bioflocs formados.	43
Figura 14. Biometrías realizadas: a) Determinación de masa de las tilapias; b) Medición de la longitud corporal de los peces.	45
Figura 15. Almacenamiento de todos los peces, para prueba bromatológica.	46
Figura 16. Detalles de la estructura de la CNN entrenada para esta investigación..	48
Figura 17. Vectores Logits generados con una CNN para ajustar la MLR.	50
Figura 18. Visualización de los mapas de características extraídos de cada capa convolucional del modelo AlexNet pre-entrenado.	51
Figura 19. (a) Esquema de la configuración experimental; (b) Configuración experimental utilizada.	52
Figura 20. Muestras con una concentración de 0.1 g/l, iluminadas bajo diferentes colores de luz: (a) blanca; (b) rojo; (c) azul; (d) verde.	53
Figura 21. Distribuciones de potencia espectral de la lámpara LED RGB utilizada en este estudio: (a) color azul; (b) color verde; (c) color rojo, y (d) color blanco.....	53
Figura 22. Elementos de una matriz de confusión multiclase	56
Figura 23. Peso final obtenido de los peces.	62
Figura 24. Composición nutricional de las tilapias en los tratamientos con luz R-G-B y Natural.....	64
Figura 25. Composición nutricional de los bioflocs en los tratamientos con luz R-G-B y Natural.	65
Figura 26. Matriz de confusión alcanzada en los cuatro entrenamientos.	67
Figura 27. Curva ROC obtenida en la evaluación del desempeño de la CNN.	68
Figura 28. (a) Exactitud de entrenamiento del clasificador para cada conjunto de datos iluminado con diferentes colores, (b) Pérdida de entrenamiento del clasificador para cada conjunto de datos iluminado con diferentes colores.	69
Figura 29. Comparación entre los valores medidos utilizando el método propuesto y los valores reales de concentración de TSS de las muestras líquidas.	71

Índice de tablas

Tabla 1. Colores monocromáticos [28].	32
Tabla 2. Propiedades espectrales de la luz de las lámparas LED: rojo (R), verde (G), y azul (B).	42
Tabla 3. Composición de los alimentos suministrados.	44
Tabla 4. Estructura y parámetros de la CNN utilizados para clasificar muestras líquidas.	49
Tabla 5. Hiperparámetros utilizados en el proceso de entrenamiento de la red neuronal.	54
Tabla 6. Muestras líquidas utilizadas.	55
Tabla 7. Parámetros de la calidad del agua	59
Tabla 8. Métricas obtenidas de las tilapias del Nilo.	61
Tabla 9. Métricas de evaluación del rendimiento de la CNN como clasificador	69
Tabla 10. Métricas de rendimiento de la MLR para los diferentes conjuntos de datos bajo cada color de iluminación.	70
Tabla 11. Los valores de TSS estimados por la CNN y la MLR para cada conjunto de datos bajo diferente color de iluminación. Se muestran los valores promedio \pm desviación estándar en unidades de $gL - 1$.	70
Tabla 12. Métricas de evaluación del método propuesto para todas las clases de acuerdo con cada conjunto de datos de color.	72
Tabla 13. Mediciones de turbidez con un turbidímetro DR900. Se muestran los valores de turbidez en valor promedio \pm desviación estándar, correspondientes a los valores de referencia de TSS o clase.	73
Tabla 14. Valores de turbidez medidos con el método propuesto. Valores promedios \pm desviación estándar de la turbidez estimada por la CNN y la MLR para cada conjunto de datos bajo diferentes colores de iluminación.	73
Tabla 15. Error relativo entre la turbidez medida con el turbidímetro DR900 y el método propuesto para cada clase.	74

Capítulo 1. Introducción

1.1. Introducción

La acuicultura es una de las áreas de producción de alimentos de más rápido crecimiento, y constituye una de las fuentes más importantes de alimentos, nutrición, ingresos y medios de vida para cientos de millones de personas en todo el mundo [1]. Para 2030, se espera que la producción de especies de agua dulce como la carpa, el bagre y la tilapia represente alrededor del 60% de la producción acuícola total [2,3]. La acuicultura requiere del uso tierras, y aguas dulces, los cuales a escala mundial son cada vez más escasos y caros. Para el 2030, el mundo podría sufrir un déficit global de agua del 40% en el escenario habitual, y para el 2050, se espera que la demanda de agua aumente en un 55% en todos los sectores de producción [4]. Por lo tanto, un aumento en la producción acuícola debe planificarse cuidadosamente, para minimizar el impacto ambiental y optimizar el uso de los recursos naturales.

Hoy en día, existen sistemas sostenibles de acuicultura que logran producir más sin afectar el medio ambiente, como los que implementan la tecnología biofloc (BFT). En sistemas acuícolas con BFT, se logra cero o mínimo intercambio de agua, por lo cual existe una acumulación de materia orgánica, materia inorgánica, residuos de alimentos, microorganismos y nutrientes que promueven el desarrollo de comunidades microbianas llamada bioflocs [5]. Los bioflocs son conglomerados de fitoplancton, bacterias, zooplancton, herbívoros microbianos y partículas de materia orgánica, que son principalmente bacterias heterotróficas. Cuando estos conglomerados son alimentados con fuentes externas ricas en carbono (azúcar, almidón, melaza, harina de yuca, etc.), se estimula su crecimiento, y se ven forzados a tomar el nitrógeno inorgánico presente en el agua del tanque para poder producir su propia proteína microbiana, y gracias a esta asimilación del nitrógeno, se crean ciclos de reciclaje que no requieren que el tanque se someta a procesos de intercambio de agua, y que mejoran la calidad del agua [6,7]. A su vez, la proteína microbiana que la comunidad de bacterias heterotróficas crea para su crecimiento y multiplicación celular, sirve como fuente de alimento para los peces, y está disponible las 24 horas del día [8–11].

Como mencionábamos anteriormente en los sistemas con BFT, se da una acumulación de materia orgánica, materia inorgánica, residuos de alimentos, microorganismos y nutrientes.

Esta acumulación de materia es asociada con parámetros físico-químicos como los sólidos suspendidos totales (TSS) y la turbidez. Los cuales son también de gran importancia para determinar la calidad del agua, y permitir la visibilidad para que el pez se alimente. En el caso de los sistemas con BFT, el monitoreo de estos parámetros es importante, debido a que no cualquier especie de pez lo puede soportar, y los niveles de TSS y turbidez deben regularse para no evitar el estrés. Es por tal motivo, que los sistemas BFT, se utilizan principalmente para cultivar tilapia (*Oreochromis sp.*), y camarones blancos (*Litopenaeus vannamei*), porque ambas especies pueden comer bioflocs y vivir en ambientes con altos niveles de TSS y turbidez [12].

Además, el desarrollo de nuevas tecnologías y estudios científicos en acuicultura es esencial para mejorar la producción intensiva de peces. Una mejora prometedora en la acuicultura proviene de la iluminación LED. La luz es elemental para varios procesos vitales de los peces. En su alimentación, ellos necesitan una intensidad de luz mínima para comer y, por lo tanto, crecer y desarrollarse [13]. En el caso de las tilapias, ellas son diurnas para su alimentación y generalmente se alimentan en diferentes períodos de tiempo durante el día [14]. Se ha demostrado que la iluminación en la acuicultura puede influir en el desarrollo embrionario, mediante la liberación de hormonas reproductivas y aumentando el crecimiento de los peces [15–17]. Además, la intensidad y el espectro de la luz influyen en el desarrollo embrionario, y con la generación de ciertos fotoperiodos (intensidad, duración y periodicidad) se puede alterar y controlar el crecimiento de los peces [16]. A su vez, el fotoperiodo influye en la liberación de hormonas reproductivas; teniendo así un papel importante en la reproducción y el crecimiento de peces [18–22]. Además, bajo longitudes de onda corta como la luz azul, la melatonina (que es la hormona responsable del sueño) disminuye en el pez lubina, y cuanto más baja es la melatonina, más tiempo están los peces despiertos y más se alimentan.[23]. Por otro lado, el camarón *Penaeus merguensis* presenta un crecimiento más rápido como efecto de la intensidad de la iluminación. Lo interesante es que cuanto mayor fue la intensidad de la luz, menor fue la ingesta de alimentos, pero sin embargo estos crecieron más, posiblemente debido a una mayor eficiencia en la asimilación de los alimentos [24]. Y en el caso de los camarones con BFT, se observó que cuando se usaba baja intensidad de luz, la producción de camarones disminuía en un 48%, así como también disminuía en un 60%, 60% y 90% la densidad de las microalgas, zooplancton y rotíferos respectivamente [25]. Por otra parte, al usar lámparas de tubo fluorescente con un fotoperiodo de 18 horas de luz y 6 horas de oscuridad, y una iluminación de 2500 lux, fue posible producir más semillas, porcentaje del saco y sincronía de

desove en las tilapias Nilo en comparación con fotoperiodos cortos y de baja iluminación (2500lux/15h, 2500lux/12h, 500lux/18h, 500lux/15h, 500lux/12h) [17].

Hasta ahora, la nueva tecnología de iluminación LED se ha explorado e implementado muy poco en la acuicultura. La iluminación LED puede ser una herramienta muy útil, que permite controlar parámetros como la intensidad, el color y la periodicidad para obtener beneficios en la producción de la tilapia en sistemas BFT. El rápido desarrollo de la iluminación LED en los últimos años ha superado las características de las lámparas incandescentes y fluorescentes en eficiencia luminosa, alta eficiencia de conversión de energía, baja emisión de calor, robustez, resistencia al medio ambiente, durabilidad, intensidad de luz ajustable e especificidad de longitud de onda [26,27].

En esta investigación exploramos e implementamos por primera vez la iluminación LED en un cultivo de tilapia con tecnología biofloc. En específico, se investigó el efecto de la longitud de onda (color) en el crecimiento y la composición nutricional de la tilapia, y también el efecto de la luz de color en los bioflocs como fuente de alimento para los peces. También, para monitorear la concentración del alimento existente en los tanques con cultivos de tilapia, se desarrolló un método de monitoreo de sólidos suspendidos que aprovecha la iluminación LED y la inteligencia artificial. Es decir, se desarrolló una nueva técnica de medición de parámetros físico-químicos importantes para la acuicultura con sistemas BFT como lo son los TSS y la turbidez.

1.2 Antecedentes

1.2.1. Iluminación LED

Un LED (*Light-Emitting Diode*) es un diodo semiconductor que emite luz por emisión espontánea cuando la corriente eléctrica fluye a través de su unión *p-n* de materiales semiconductores, liberando energía en forma de fotones [28]. Los LEDs han marcado tendencia en comparación con otras fuentes de luz gracias a que poseen una mayor vida útil, son de pequeño volumen, baja emisión de calor, alta eficiencia de conversión de energía, robustos, resistentes al medio ambiente, con intensidad de luz ajustable, y lo más importante para nuestra investigación con especificidad de longitud de onda. Desde 1907 Henry Joseph Round (Marconi Co, Reino Unido) reportó el primer informe conocido sobre el efecto de la emisión de luz de un material semiconductor. La primera patente de LED se realizó en 1929 por un técnico de radio ruso Oleg Vladimirovich Losev. Sin una explicación clara, este descubrimiento fue rápidamente olvidado [29]. No fue hasta 1962 que Nick Holonyak y S.F. Bevacqua, consultores de General Electric, firmaron "el certificado oficial" del primer diodo rojo que emite luz. Desde entonces, las cosas han ganado ritmo rápidamente. En 1970, el primer LED comercializado (diodo emisor de luz) producía apenas 0,001 lm de luz roja [30]. Hoy en día, los LED blancos de alto brillo generan más de 100 lm y están disponibles comercialmente. Recientemente, se alcanzó un valor record de 1100 lm con dispositivos que combinan varias uniones LED en un chip [31].

1.2.2. Acuicultura

El término acuicultura proviene del latín (aqua = agua) y (cultvare = cultivar), es decir cultivar en el agua. La acuicultura puede ser definida como la explotación de organismos acuáticos, donde el término explotación implica la intervención en los procesos de cría con el fin de mejorar la producción. La acuicultura se remonta a tiempos antiguos. En el caso de la producción de peces en estanques, esta fue desarrollada por los primeros agricultores como uno de los muchos sistemas de producción primaria para asegurar el abastecimiento de alimentos.

En el caso de México, la piscicultura arranca a finales del siglo XIX, cuando en el año 1883 el Gobierno de México a través de la secretaria de Fomento y Alfredo B. Lamotte construyen el Vivero Nacional Chimalapan en Ocoyoacan Lerman, Estado de México [32].

Todo esto nace como una actividad complementaria de apoyo social a las comunidades rurales, con lo cual se pretendía incrementar el consumo de proteína animal y mejorar así los niveles nutricionales de la población [33]. De 1970 a 1987, la acuicultura registró un acelerado avance con el uso de las nuevas tecnologías innovadoras, observándose así la transición al uso de sistemas semintensivos e intensivos para el cultivo de especies de gran importancia social como la carpa y la tilapia, y posteriormente para el cultivo de especies de alto valor comercial como el bagre, la trucha, el langostino y el camarón [34].

A partir de 1986, el Gobierno de México inicia cambios mayores de política, diseñados para promover la acuicultura, principalmente en especies de alto valor comercial como el camarón y el ostión, que antes estaban restringidas a la explotación exclusiva por las sociedades cooperativas. Con estos primeros pasos se inician las acciones para abrir la industria de la acuicultura de estas especies a los inversionistas privados. En 1989, se hicieron cambios adicionales a la Ley Federal de Pesca y permitieron por primera vez que los inversionistas privados fueran propietarios. Los cuales, podrían operar sus propias granjas para el cultivo del camarón, y en 1992 se hicieron otros cambios legales, donde las tierras ejidales podrían ser utilizadas, incrementando así la participación de productores privados [35].

A nivel mundial, la producción anual acuícola se ha incrementado en un 8.9 % desde el año 1970, en comparación con el crecimiento anual del 1.2 % para la pesca de captura, y del 2.8 % para la producción de carne de res durante el mismo periodo de tiempo [6]. Este aumento en la producción acuícola tiene que ser planificado, teniendo en cuenta la necesidad de minimizar el impacto ambiental y optimizar el uso de los recursos naturales como el agua que cada día es más escaso. Es por esto, que desde la década de 1950 en Japón se desarrolla la tecnología de Sistemas de Recirculación Acuícola (SRA), donde su primer paso fue la creación y uso de biofiltros para la producción de carpa (*Cyprinus carpio*), con el fin de utilizar de una manera más productiva los recursos de agua limitados de la localidad [36]. En este tipo de sistemas de recirculación acuícola, el agua y los materiales sedimentados son eliminados de estanque de producción a una gran velocidad, para poder mantener las condiciones de agua limpia. No obstante, el agua “eliminada” no es liberada al ambiente, al contrario, es tratada y posteriormente reingresada al estanque de producción. Pero la gran desventaja de los sistemas RAS es que son caros, tanto en inversión como en mantenimiento. Por lo cual, desde mediados de los años 90 s, Chamberlain [37], Hopkins y colaboradores del Centro de Maricultura Waddell

[38], en Carolina del Sur y al mismo tiempo Avnimelech y colaboradores de Israel [39], desarrollan la tecnología biofloc, la cual es una forma de producción súper-intensiva en la acuicultura con cero o mínimo intercambio de agua.

Por lo cual, desde mediados de los años 90s, Chamberlain [37], Hopkins y colaboradores del Centro de Maricultura Waddell [38], en Carolina del Sur y al mismo tiempo Avnimelech y colaboradores de Israel [39], desarrollan la tecnología biofloc.

1.2.3. Redes neuronales convolucionales

El concepto de Inteligencia Artificial (IA) está relacionado con la creación de máquinas inteligentes que simulan cómo los seres humanos actúan y reaccionan a tareas simples. En específico tratan de imitar el funcionamiento de la corteza visual de los mamíferos utilizando operaciones avanzadas de bloques y varias capas de neuronas, llamadas redes neuronales convolucionales (CNN). Desde 1936, Alan Turing estudió el cerebro como una forma de ver el mundo de la computación [40]. Sin embargo, hasta 1957 se desarrolló el concepto de perceptrón. Esta es la red neuronal más antigua, la cual era capaz reconocer patrones que no se le hubiesen presentado anteriormente. Sin embargo, en 1969 se demostró que el perceptrón simple no podía resolver problemas con funciones no lineales. Una combinación de perceptrones si podría resolver problemas no lineales, sin embargo, aún no existía un mecanismo automático capaz de recalculer los pesos para cada capa, y fue hasta 1974, que se desarrolló el algoritmo de aprendizaje de propagación hacia atrás (backpropagation) que sería capaz de recalculer los pesos para cada capa. En 1980, se crea el modelo Neocognitron, capaz de realizar reconocimiento visual de patrones [41]. Este modelo fue más tarde mejorado al implementar el algoritmo de backpropagation en 1998 [42].

1.2.4. Sólidos suspendidos y turbidez

Los sólidos suspendidos totales (gL^{-1}) se pueden definir como la masa presente en una columna de agua [43]. Las partículas suspendidas se dispersan y absorben la luz, y esto provoca la pérdida de la transparencia del agua. El total de sólidos suspendidos (TSS) es un parámetro importante para determinar la calidad del agua [44]. En el caso de la acuicultura, un alto nivel de TSS reduce la visión y la capacidad de los peces para capturar su alimento [45]. Relacionado con los TSS existe la turbidez. La turbidez (NTU) es el grado de pérdida de transparencia del agua por sólidos en suspensión [46]. Por lo tanto, cuanto mayor sea el número de sólidos

suspendidos en el líquido, mayor será el grado de turbidez. El primer instrumento de medición del nivel de turbidez fue el disco Secchi creado en 1986. En los últimos años se ha creado más métodos de medición de la turbidez basados principalmente en la medición de la luz transmitida a través de una muestra. El método establecido para la medición de turbidez es el 180.1 desarrollado por la U.S EPA. En este método, se utiliza una lámpara de tungsteno, y la distancia entre la luz incidente y la luz dispersa dentro del recipiente de la muestra debe ser inferior a 10 cm. La fuente de luz se orienta a 90 ° del detector fotoeléctrico. El rango de medición está entre 0-40 NTU, para medir valores más altos, la muestra debe diluirse [47].

1.3. Estado del arte y resumen histórico

1.3.1. Acuicultura e iluminación

4000-3500 a. C. En China y Mesopotamia, se registra la cría de peces en estanques [5].

25-250 d. C. Se documenta la producción de arroz y peces en la China antigua, durante la dinastía de Han Oriental [48].

1883 El gobierno de México instituyó la piscicultura a través de la Secretaria de Fomento y A. Lamotte al construir el primer vivero de peces. Llamado el Vivero Nacional Chimalapan en Ocoyoacan Lerman, Estado de México. El cual comenzó con un lote de 500000 huevos de trucha arco iris [32].

1907 Henry Joseph Round (Marconi Co, Reino Unido) reportó el primer informe conocido sobre efecto de la emisión de luz de un material semiconductor [30].

1929 Se realiza la primera patente del LED, descubierto por el ruso Oleg Vladimirovich Losev [29].

1950 Se desarrolla la tecnología de SRA en Japón con la creación y uso de biofiltros para la producción de carpa (*Cyprinus carpio*) [36].

1962 Nick Holonyak y S.F. Bevacqua crean el primer diodo rojo que emite luz [30].

1965 G. Clarke y M. Kelly analizan el papel de la luz en las actividades de los microorganismos marinos, en donde los peces presentan un ciclo de 24 h de actividad que a menudo pueden ser una simple respuesta a la luz [49].

1970-1987 Se da la transición del uso de sistemas semintensivos a intensivos para el cultivo de carpas, tilapia, bagre, trucha, langostino y camarón. [34].

- 1974** N. Richardson, J. McCleave y E. Albert usan diferentes fotoperiodos en el salmón del atlántico, observando que las transiciones de luz-oscuridad son importantes en la sincronización de los ritmos de actividad locomotora [50,51].
- 1986** El gobierno de México realiza cambios en la política para promover la acuicultura de especies de alto valor que antes era exclusivas para las sociedades cooperativas. Con esto se abre la posibilidad a los inversionistas privados [35].
- 1988** J. Cole, S. Findlay y M. Pac analizan los sistemas cruzados, donde la producción bacteriana se da en ecosistemas de agua dulce y salada [52].
- 1989** Se realizaron cambios adicionales a la Ley Federal de Pesca, permitiendo por primera vez que los inversionistas privados fueran por primera vez propietarios [35].
- 1989** Y. Avnimelech modela como la materia orgánica se acumula en los sedimentos de un depósito de nueva construcción [53].
- 1989** J. Thorpe, C. Adams, M. Miles y D. Keay determinan que los peces se alimentan activamente durante el día, pero no por la noche, y a su vez estudian el crecimiento del salmón del atlántico a través de cambios en el fotoperiodo y la temperatura [54].
- 1989** N. Ounaïs identifica un umbral de intensidad mínimo de luz para permitir que las larvas de peces tengan un crecimiento y desarrollo normal, estimando un rango de intensidad entre 50 y 150 lux para el pez dorada (*Sparus aurata*) [55].
- 1992** Se dio otro cambio político en el cual las tierras ejidales pudieran ser utilizadas. Lo que incrementó la participación de productores privados [35].
- 1993** J. Hopkins, R. Hamilton, P. Sandier, C. Browdy y A. Stokes dan los primeros pasos del desarrollo de la tecnología biofloc con el estudio sobre los efectos de la tasa de intercambio de agua en la producción, la calidad del agua, las características del efluente y los balances de nitrógeno en los estanques intensivos de camarón [38].
- 1994** J. Huisman y F. Weissing desarrollan un modelo elemental de luz-crecimiento y competencia por la luz en ambientes acuáticos bien mezclados entre especies de fitoplancton [56].
- 1994** G. Chamberlain y J. Hopkins analizan la posibilidad de reducir el uso del agua y el costo del alimento en los estanques intensivos [37].
- 1994** Y. Avnimelech y colaboradores de Israel desarrollan la tecnología biofloc, con el desarrollo de sistemas de acuicultura intensivos. Los cuales se controlaban con un

limitado intercambio de agua y un ajuste en el carbono según las proporciones de nitrógeno en el estanque [39].

- 1999** G. Boeuf y P. Le Bail estudian la influencia que tiene la intensidad de la luz y el fotoperiodo en el crecimiento de los peces, siendo la intensidad de la luz importante para el desarrollo y crecimiento de los peces y larvas. Esto en relación con que la mayoría de las especies necesitan luz para localizar, capturar e ingerir presas [16].
- 1999** T. Bahadur, J. Urabe y M. Nakanishi determinaron que, bajo altas condiciones de luz, las bacterias heterótrofas mostraron una alta tasa de crecimiento siempre y cuando se suministre carbono y fósforo, y la tasa de crecimiento de las algas sea alta [57].
- 2002** M. Bayarri, J. Madrid, F. Sánchez-Vázquez observan que bajo longitudes de onda cortas como la azul, la melatonina decrece en el pez róbalo [23].
- 2002** M. Timmons, J. Ebeling, F. Wheaton, S. Summerfelt y B. Vinci presentan un libro de Sistemas de Recirculación Acuícola mostrándonos sistemas de oxigenación optimizados [58].
- 2002** S. Rier y R. Stevenson encontraron que la biomasa de las algas y de las bacterias heterótrofas es alta en condiciones con luz, sin embargo, en la oscuridad las bacterias heterótrofas no responden a la glucosa. Concluyendo con que existe una relación positiva entre el crecimiento de las algas y las bacterias heterótrofas, posiblemente esta relación se debe a que las bacterias utilizan a las algas y a una matriz de polisacáridos asociada como un sustrato para la colonización [59].
- 2003** T. Hoang, M. Barchiesi, S. Lee, C. Keenan y G. Marsden demuestran que los camarones *Penaeus merguensis* presentan un crecimiento más rápido como efecto a la intensidad de la luz. Lo interesante es que con mayor intensidad de luz los camarones consumieron menos alimentos, pero crecieron más rápido, posiblemente debido a una mejor eficiencia de asimilación [24].
- 2004** B. Hari, B. Madhusoodana Kurup, Johny T. Varghese, J.W. Schrama y M.C.J Verdegem examinan los efectos de añadir carbohidratos en la producción de sistemas extensivo de cultivo de camarón [60].
- 2006** B. Hari, B. Kurup, J. Varghese, J. Schrama y M. Verdegem estudian los efectos de añadir carbohidratos en la calidad del agua y en el balance del nitrógeno en sistemas extensivo de cultivo de camarón [61].

- 2006** M. Saavedra presenta un manual sobre el manejo de cultivo de tilapia, en el que se resalta que la luz influye en la reproducción, y en donde el aumento de la iluminación o disminución por 8 horas dificultan la reproducción en las tilapias [62].
- 2006** L. Alonso, J. Gasol, T. Lefort, J. Hofer y R. Sommaruga estudian el efecto de la luz en la actividad bacteriana, en la cual las bacterioplancton acuáticas demostraron ser sensibles a la radiación solar de longitudes de onda corta (290-400nm) [63].
- 2007** I. Moreno y U. Contreras presentan la distribución de color a partir de matrices LED multicolor. Concluyendo que para sistemas de iluminación LED, el color puede ser seleccionado sin la necesidad de añadir filtros [26].
- 2008** P. De Schryver, R. Crab, T. Defoirdt, N. Boon y W. Verstraete nos presenta los fundamentos de la tecnología biofloc, y el valor añadido que esta tiene en la acuicultura, para el caso de la tilapia. En este artículo se reportan las cantidades convencionales de alimentos añadidos si la tecnología biofloc es aplicada [64].
- 2009** Y. Avnimelech publica un libro de guía práctica sobre la tecnología biofloc, en el cual nos presenta los principios básicos de los sistemas biofloc, la alimentación con bioflocs, el manejo de estanques, el desarrollo sostenible de la acuicultura, etc. [65].
- 2010** H. Yoon, J. Hwang y S. Choi analizan el efecto de la intensidad de la luz en la primera alimentación de larvas de pez estornino (*Scomber japonicus*), generándose una incidencia alimentaria más alta cuando se tenía una intensidad de luz en el estanque [66].
- 2010** J. Tello y C. Martínez determinaron que la luz influye directa o indirectamente en el crecimiento de las larvas de pez blanco. En donde se encontró que periodos continuos de luz (24L:0D), permiten incrementar hasta un 43 % el peso y en un 12.87 % su longitud sin alterar los valores normales de supervivencia a los 90 días post-eclosión [67].
- 2010** R. Neal, S. Coyle, J. Tidwell y B. Boudreau observaron que la combinación de alta densidad y luz natural con una intensidad de 718 Lx en comparación con otro estanque con la misma densidad de camarones y una intensidad de Luz de 50 Lx aumenta la producción de camarones en un 48 %, como también aumento en un 58.44 %, 59.56 % y 89.48 % la densidad de las microalgas, zooplancton y rotíferos en sistemas de TBF [25].

- 2011** S. Coyle, L. Bright, D. Wood, R. Neal y J. Tidwell indican que bajos niveles de iluminación fluorescente y/o iluminación de halógenos metálicos son apropiados para la producción de camarón en sistemas Biofloc. Pero a su vez sugieren que el espectro y la intensidad de la luz tienen efectos en la estructura de los flóculos, que a su vez tiene efecto en la supervivencia y la producción de camarones [68].
- 2012** J. Arredondo, L. Núñez, P. Heredia y J. Ponce observaron que bajo fotoperiodos controlados se da una mayor producción de huevos y bajo condiciones de fotoperiodos naturales se dio un alto número de post-larvas y un mayor índice de supervivencia [69].
- 2013** M. Baloi, R. Arantes, R. Schweitzer, C. Magnotti y L. Vinatea demuestran que la producción de camarones en sistemas Biofloc es más alta en tratamientos con intensidades de luz de 10 000 lx [70].
- 2013** E. Olvera, D. Alaniz, R. Ivanov, J. Villa, C. Olvera, E. González, M. Araiza, V. Torres y V. Castaño implementan un sistema inteligente de luz LED para determinar el efecto de luz pulsada en el crecimiento y desarrollo de plantas [71].
- 2013** P. García, C. Olvera y E. González evalúan la composición de los bioflocs y determinan el comportamiento de la producción de proteína en relación con la turbidez [72].
- 2013** Y. Avnimelech y I. Bejerano estudian la infección por streptococcus en la tilapia, observándose que en taques de Biofloc se tiene infección y mortalidad baja (casi nula) [73].
- 2014** C. Teo, M. Atta, A. Bukhari, M. Taisir, A. Yusuf y A. Idris analizan el efecto de diferentes longitudes de onda en la tasa de crecimiento y producción de lípidos de las micro-algas marinas, en donde la mejor curva de crecimiento y producción se da bajo la longitud de onda azul [74].
- 2015** L. Collazos y J. Arias reportan la tecnología biofloc como una alternativa para piscicultura. En la cual, se muestra la diferencia metabólica entre la cachama blanca y la tilapia en términos del Nitrógeno Amónico Total (NAT) [75].
- 2015** W. Xu, T. Morris y T. Samocha muestran que al manipular la relación C/N se tiene gran influencia en el desarrollo y las características de los bioflocs, esto se representa en la dinámica del fósforo y del nitrógeno inorgánico que a su vez afecta el rendimiento y el uso del alimento. Otro dato destacable de esta investigación es que los Sólidos Suspendidos Volátiles (SSV) y la turbidez son parámetros superiores para la determinación cuantitativa de biofloc [76].

- 2015** C. Wang, L. Pan, K. Zhang, W. Xu, D. Zhao y L. Mei, resaltan los efectos que tiene añadir diferentes fuentes de carbono en la composición nutricional, en el rendimiento de crecimiento y en la actividad de enzimas extracelulares y digestivas en los camarones. En esta investigación se tiene que para una relación C/N de 16 y añadiendo como fuente de carbono una mezcla de 60 % de melaza, 20 % de harina de maíz y 20 % de salvado de trigo, se logra alcanzar una ganancia de peso del 81.5 % con una tasa de supervivencia superior al 88 % [77].
- 2015** S. Kumar, P. Shyne, D. De, A. Deo y compañeros plantean los efectos que tienen diferentes fuentes de carbono en la calidad del agua, rendimiento de crecimiento y respuestas inmunes en el camarón tigre negro (*Penaeus monodon*). Resaltando que la mezcla de harina de arroz y pellets de alimento de pez con 32 % de proteína, pueden remplazar pellets de alimentos de pez con un 40 % de proteína [78].
- 2015** J. Delabbio estudia las ventajas de los sistemas de iluminación LED en las larvas de piscicultura, en donde las crías de larvas responden con éxito a las tres características de la luz ambiental artificial (intensidad, fotoperiodo y longitud de onda). Resaltando que el tiempo requerido, la modulación de la intensidad y el espectro de longitud de onda varían según la especie [79,80].
- 2015** C. Ganesh y V. Mokashi demostraron que una inadecuada señal de iluminación puede conducir a la omisión del desove, sugiriendo que las perturbaciones de las condiciones ambientales causan alteraciones en la actividad androgénica y en los ovarios de la Tilapia del Mozambique [81].
- 2015** L. Long, J. Yang, Y. Li, C. Guan y F. Wu reportan que en estanques TBF el peso individual, la ganancia de peso y la tasa de eficiencia de proteína de los peces fue mayor que en el estanque con recirculación de agua en un 12.54 %, 9.46 % y 22.2 % respectivamente. Además, en el estanque TBF, la tasa de conversión fue menor en un 17.5 % y se mejoró las actividades de las enzimas digestivas y la respuesta inmune de la tilapia [82].
- 2015** N. Bakar, N. Nasir, F. Lananan, S. Hamid, S. Lam y A. Jusoh prueban con 5 diferentes relaciones de C/N (10, 15, 20, 25, 30), obteniendo con la relación C/N de 15 una eliminación de amonio en un 98.7 % [83].
- 2015** J. Ekasari, D. Rheza, A. Putri, E. Harris, M. Zairin, P. Bossier y P. De Schryver analizan el rendimiento de crecimiento en larvas de tilapia (*Oreochromis niloticus*), obteniendo

- que las larvas puestas en un estanque BFT tuvieron una ganancia mayor en peso y longitud con respecto a las puestas en un estanque tradicional del 13 % y el 5.49 % respectivamente [84].
- 2015** K. Edwards, M. Thomas, C. Klausmeier y E. Litchman caracterizan la tasa de crecimiento del fitoplancton marino en función de la irradiancia, a través del modelo dinámico de foto-inhibición de la fotosíntesis de Eilers y Peeters [85].
- 2016** F. Bantis, T. Ouzounis y K. Radoglou analizan el crecimiento de la albahaca bajo dos condiciones de iluminación artificial, LED y luz fluorescente, obteniéndose un mayor incremento de biomasa en los cultivos bajo iluminación LED [86].
- 2016** A. Sánchez, A. Miranda, M. Rivas, J. López, L. Martínez y A. Tejada desarrollan un modelo dinámico para simular el Nitrógeno Amoniacal Total (NAT) en sistemas con cero intercambios de agua [87].
- 2017** H. Aly, M. Abdel-Rahim, A. Lotfy, y B. Abdelaty informaron que, para la tilapia roja híbrida en agua salada, bajo luz azul, las tilapias presentaban el rendimiento de crecimiento más bajo y podían atribuirse a una visión reducida del pez bajo esta longitud de onda.
- 2017** A. Mansour y M. Esteban, analizan el efecto de diferentes tipos de fuente de carbón en el crecimiento de la tilapia en sistemas biofloc [88].
- 2018** E. Younis, A. Al-Quffail, N. Al-Asgah, A. Abdel-Warith, y Y. Al-Hafedh, analizan el efecto que tiene las algas rojas, *Gracilaria arcuata*, sobre el rendimiento de crecimiento y composición corporal de la tilapia del Nilo *Oreochromis niloticus* [89].
- 2019** Wenjing Ren, Li Li, Shuanglin Dong, Xiangli Tian y Yiming Xue, analizan el efecto de Relación C/N y luz sobre la absorción de nitrógeno amoniacal en tanques de cultivo de *Litopenaeus vannamei* [90].
- 2019** Daniela Lopez-Betancur, Carlos Olvera-Olvera, Ivan Moreno y Carlos Guerrero-Méndez reportan los primeros resultados sobre el efecto de las longitudes de onda RGB de la luz LED en las tasas de crecimiento de alevines de tilapia del Nilo en sistemas con tecnología Biofloc [91].
- 2020** Daniela Lopez-Betancur, Ivan Moreno, Carlos Guerrero-Mendez, Domingo Gómez-Meléndez, Manuel de J. Macias P., y Carlos Olvera-Olvera, analizan el efecto de la luz de color en el crecimiento y la composición nutricional de la tilapia, y la composición nutricional del biofloc como fuente de alimento para las tilapias [92].

1.3.2. Redes neuronales convolucionales

- 1943** Warren McCulloch y Walter Pitts proponen los primeros modelos matemáticos y eléctricos de redes neuronales artificiales. Basándose en el funcionamiento de las neuronas biológicas modelaron una red neuronal artificial simple utilizando circuitos eléctricos [93].
- 1949** Donald Hebb define conceptos que describen: El aprendizaje es realizado en la sinapsis (conexión entre neuronas). El aprendizaje y la ejecución de las redes neuronales se representa en el cerebro mediante un conjunto de neuronas activas o inactivas. Estos conceptos afirman que el aprendizaje de una red neuronal es efectuado mediante las actualizaciones de los pesos de la sinapsis en toda la red neuronal y como es que una neurona repercute en sus neuronas más avanzadas [94] .
- 1956** En el Dartmouth College, se llevó a cabo el primer grupo de charlas sobre Inteligencia Artificial, este lugar es considerado como el “lugar de nacimiento” de la AI. Donde se discutió la capacidad de las máquinas para simular el aprendizaje humano [95].
- 1958** Frank Rosenblatt dio a conocer el concepto de Perceptrón y expuso los modelos de activación de una red neuronal artificial [96].
- 1960** Bernard Widrow y Marcian Hoff exponen los algoritmos de clasificación de patrones adaptativos de maquina Adaline (Adaptative Linear Neuron) y Madaline (Múltiple Adaline). Estos algoritmos fueron utilizados en la clasificación de patrones originales y patrones con ruido [97].
- 1974** Paul Werbos describe el proceso de Backpropagation, que se refiere a la actualización de los pesos de los perceptores en una red neuronal durante el proceso de entrenamiento [98].
- 1986** Rina Dechter introduce el término de “Deep Learning” a la comunidad de machine learning [99].
- 2000** Igor Aizenberg y sus colaboradores implementan el concepto de Deep learning utilizando redes neuronales [100].
- 2010** Se publica la base de datos ImageNet con la cual se efectúa el “ImageNet Large Scale Visual Recognition Challenge (ILSVRC)” en donde compiten las arquitecturas de redes neuronales en tareas de clasificación y detección de objetos [101].

2012 Alex Krizhevsky diseña la estructura de red neuronal convolucional llamada AlexNet. Esta arquitectura de red compitió en el ILSVRC el 30 de septiembre del 2012, alcanzando un error del 15.3% [102].

1.3.3. Sólidos suspendidos y turbidez

1986 Preisendorfer propone el disco de Secchi como instrumento de medición de la penetración luminosa en una muestra líquida, y por ende asociarlo con el valor de turbidez y sólidos suspendidos en el agua [103].

2013 Timo Toivanen y sus colaboradores presentan el Secchi3300, que es un dispositivo que usa un teléfono celular para la comparación de valores de intensidad de luz basado en una actualización disco de Secchi [104].

2015 Mohd Taufiq Mohd Khairi y sus colaboradores presentan la aplicación de un sistema óptico termográfico basado en redes neuronales artificiales para predecir el valor de turbidez en una muestra de agua [105].

2016 Hussain, Ahamad y Nath proponen un medidor de turbidez con un teléfono inteligente y radiación infrarroja. Ellos consiguen mediciones de 0 a 400 NTU [106].

2017 Gaya y colaboradores presentan una comparación entre las de Hammertein Wiener y las redes neuronales para la estimación de turbidez en una planta tratadora. Con esta investigación se concluye que las redes neuronales superan a la técnica de Hammertein Wiener en la medición de turbidez [107].

2017 F. N. Hamidi, M. F. Zainuddin y Z. Abbas proponen el uso de imágenes de RGB para posteriormente crear una imagen en escala de grises con ciertas características usando procesamiento digital de imágenes. Ellos obtienen mediciones que van desde los 0 a 100 NTU [108].

2018 D. Mullins y sus colaboradores presentan un sistema estimador de turbidez en líquidos. Ellos toman imágenes de las muestras líquidas y las asocian con características de absorción de luz en función de la profundidad del fluido mediante la implementación de técnicas de procesamiento de imágenes [109].

1.4. Planteamiento del problema y justificación

A nivel mundial, la producción acuícola ha aumentado más de 40 veces durante los últimos 50 años y se espera que aumente 5 veces más en los próximos 50 años para poder mantener los niveles actuales de consumo de productos acuícolas [110]. Este aumento en la producción acuícola tiene que ser planificado, teniendo en cuenta la necesidad de minimizar el impacto ambiental y optimizar el uso de los recursos naturales. Es bien sabido por todos, que en la acuicultura se utilizan tierras y recursos de agua frescos y/o marinos, pero también se sabe que a escala mundial los recursos hídricos son cada vez más escasos y caros. Tan solo en la actualidad, aproximadamente el 41 % de la población mundial vive en cuencas fluviales escasas de agua, y se estima que para el 2050, el 70 % se enfrentará a problemas de escasez de agua [65]. El desarrollo de sistemas acuícolas ha estado acompañado por daños al medio ambiente. Estos procesos de producción generan grandes cantidades de efluentes contaminados con alimentos no consumidos, heces de peces y compuestos orgánicos e inorgánicos como el amonio, fósforo, carbono orgánico disuelto y materia orgánica que deterioran los cuerpos de agua receptores. Por lo cual, hoy en día se requiere de sistemas acuícolas sostenibles que proporcionen más peces sin aumentar significativamente el uso de recursos naturales básicos como el agua y la tierra. Estos sistemas deberán proporcionar una relación costo/beneficio razonable que apoye la sostenibilidad económica y social, por lo cual el reciclaje de los alimentos es otro factor importante [111]. Una solución a esta demanda son los sistemas de recirculación acuícola, los cuales son sistemas intensivos (de alta producción por unidad de volumen) que tratan los efluentes de agua y posteriormente los reingresan en el estanque de producción, pero desafortunadamente por requerimientos de inversión y mantenimiento son costosos. Ahora bien, uno de los sistemas de producción acuícola más novedosos que cumplen con todos los requisitos de uso eficiente de agua, tratamiento de los efluentes de agua, suelo, alta producción, bajo costo y reciclaje de alimentos es la tecnología biofloc. En los sistemas biofloc se da cero o mínimo intercambio de agua. Los residuos orgánicos acumulados en el estanque se degradan y el amonio generado es nitrificado o asimilado por una comunidad microbiana intensiva, creando así ciclos de reciclaje que no requieren de altos sistemas de intercambio de agua. En esencia, estos procesos microbianos en los estanques sirven como un tratamiento para la calidad del agua y por otra parte la proteína microbiana sirve como alimento para los peces [112]. Para forzar a los microorganismos a consumir el nitrógeno inorgánico, se debe agregar carbohidratos. A su vez, cabe resaltar que esta acumulación de materia (orgánica,

inorgánica, residuos de alimentos, microorganismos y nutrientes) debe ser controlada para garantizar la calidad del agua y garantizar que el pez tenga la suficiente visibilidad para alimentarse. En específico, en la tecnología biofloc se debe monitorear constantemente los niveles de acumulación de materia, debido a que no toda especie de peces puede soportar altos niveles. Estos niveles de acumulación se determinan a partir de parámetros como los sólidos suspendidos y la turbidez. Es por tal razón, que la tecnología biofloc es aplicada principal en cultivos de tilapia, y camarones, ya que pueden vivir en ambientes con altos niveles de TSS y turbidez. Por otra parte, la aplicación de sistemas de iluminación con lámparas fluorescentes e incandescentes han demostrado una mejora en el desarrollo embrionario, la reproducción y el crecimiento de peces, pero no se ha delimitado con que características de la luz, como por ejemplo con que longitudes de ondas es posible hacer más efectivos estos procesos. Por otra parte, no se tienen registros sobre la influencia que tendría la aplicación de sistemas de iluminación LED en composición nutricional de los bioflocs.

Es por tal motivo, que en esta investigación se utilizará un sistema de iluminación LED, el cual con determinados parámetros de iluminación (longitud de onda, fotoperiodo e intensidades) busca hacer más eficiente la tecnología biofloc. La iluminación LED tiene el potencial de mejorar la producción en cultivos de tilapias, mejorar la calidad nutricional de las tilapias y de los biofloc como fuente de alimento, y al mismo tiempo tiene el potencial de monitorear parámetros como los sólidos suspendidos y la turbidez. Lo que permitiría que los sistemas acuícolas fueran más eficientes, y sostenibles, ajustándose a su vez a las necesidades específicas de los consumidores, y en el futuro a la escasez de recursos alimentarios.

1.5. Hipótesis

Utilizando un sistema de iluminación LED con longitudes de onda e intensidad de luz controlados, es posible mejorar la producción, el crecimiento y la composición nutricional de las tilapias, y de los bioflocs como fuente de alimento para los peces. Por otro lado, como parte de la implementación de la iluminación LED en un sistema acuícola es posible monitorear parámetros como la turbidez y los sólidos suspendidos totales (TSS) mediante un sistema basado en redes neuronales convolucionales.

1.6. Objetivos

1.6.1. Objetivo General

- Diseñar, implementar, monitorear y estudiar un cultivo intensivo de tilapias con iluminación LED de colores y con tecnología biofloc.

1.6.2. Objetivos Específicos

- Analizar los efectos de la luz LED monocromática de diferentes longitudes de onda en el crecimiento de las tilapias.
- Determinar el efecto de diferentes longitudes de onda en la composición nutricional de las tilapias y los bioflocs.
- Determinar las características o parámetros de la iluminación LED con los que se mejore la producción, el crecimiento y la composición nutricional de los alevines de tilapia en cultivos intensivos con tecnología biofloc.
- Monitorear mediante la misma iluminación LED y mediante redes neuronales convolucionales parámetros de turbidez y TSS.

Capítulo 2. Marco teórico

2.1. Iluminación LED

Actualmente, los LEDs se han convertido en la fuente de iluminación más eficiente, utilizando hasta un 90% menos de energía que la iluminación incandescente y hasta un 60% menos que la iluminación fluorescente (Ver Fig. 1) [113].




Figura 1. Evolución histórica del rendimiento en eficiencia luminosa del LED y el rendimiento proyectado en comparación con otras fuentes convencionales de luz.

Un LED es un diodo de unión $p-n$, que emite luz cuando está activado. El LED es un diodo semiconductor que emite luz por emisión espontánea, cuando la corriente eléctrica fluye los electrones se recombinan con los huecos en la región de la unión $p-n$ de materiales semiconductores, liberando energía en forma de fotones (Ver Fig. 2). Este efecto es conocido como electroluminiscencia [28,114].

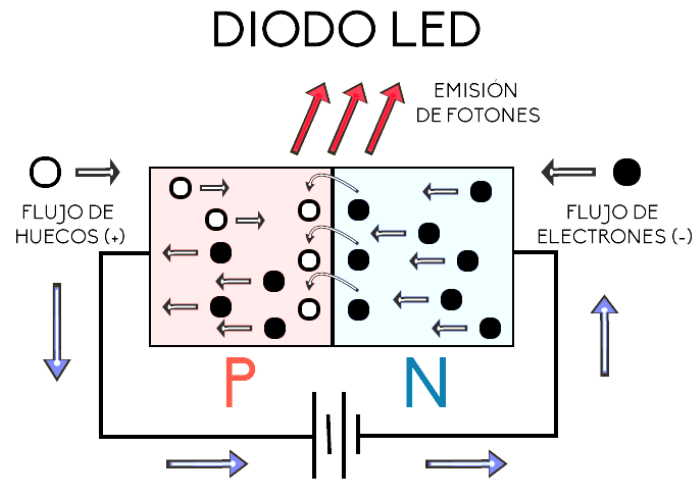


Figura 2. Esquema de un Diodo LED

Los LEDs emiten luz monocromática de manera intrínseca. Usualmente el color es asociado con una longitud de onda (λ) del espectro visible. Los colores que pueden ser producidos por la luz visible de un espectro estrecho de longitudes de onda (luz monocromática) se denominan colores espectrales. Los diversos rangos espectrales de cada color se indican en la Tabla 1.

Tabla 1. Colores monocromáticos [28].

Colores	Longitud de onda λ (nm)	Frecuencia (THz)
Violeta	~ 380-450	~ 659-789
Azul	~ 450-492	~ 609-659
Verde	~ 492-577	~ 520-609
Amarillo	~ 577-597	~502-520
Naranja	~ 597-622	~ 482-502
Rojo	~ 622-780	~ 384-482

En los LEDs, el color de la luz generada depende de la energía de los fotones emitidos. La energía de los fotones está determinada por la anchura de la banda prohibida del semiconductor, la cual depende del material semiconductor empleado en la construcción del diodo, pudiendo emitir luz desde el ultravioleta, pasando por el espectro de luz visible, hasta el infrarrojo. Mediante la selección de diferentes materiales semiconductores, se pueden hacer LEDs de un solo color que emitan luz en una banda estrecha de longitudes de onda desde el

infrarrojo cercano a través del espectro visible y hasta el rango ultravioleta. A medida que las longitudes de onda se acortan, el voltaje de operación del LED aumenta [115]. En caso del LED de luz blanca, hay dos formas de producirlo: La primera, es utilizar LEDs individuales que utilicen los colores primarios (rojo, verde y azul), posteriormente mezclarlos para formar la luz blanca (la luz blanca es la combinación de todos los colores del espectro de luz visible (~389-700 nm)). Y la segunda forma, es utilizar un material de fósforo para convertir la luz monocromática de un LED azul (también con un UV LED) en luz blanca de amplio espectro [116,117]. La Fig. 3 muestra los métodos para generar luz blanca mediante LEDs.

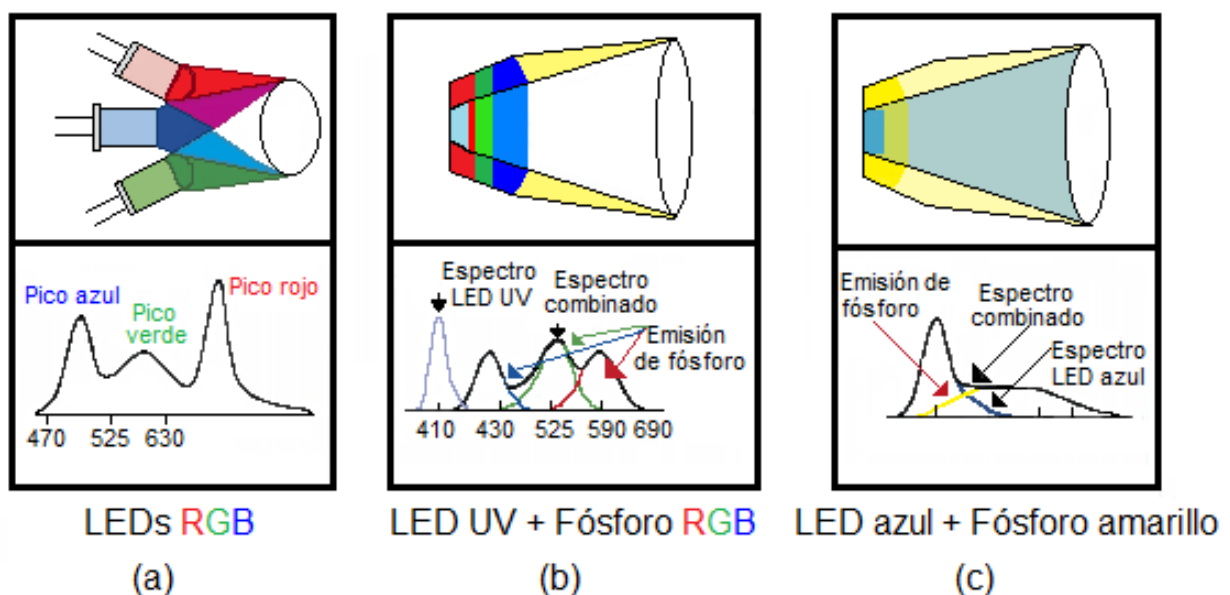


Figura 3. Tres métodos para generar luz blanca a partir de LEDs: (a) LED rojo + verde + azul. (b) LED UV + fósforo RGB. (c) Pc-LED = LED azul + fósforo amarillo

2.2. Tecnología Biofloc

La tecnología biofloc es una forma de producción súper-intensiva (producir más kg de peces en pocos metros cúbicos de agua) en la acuicultura con cero o mínimo intercambio de agua. En este sistema, existe una acumulación de materia orgánica, materia inorgánica, residuos de alimentos, microorganismos y nutrientes que promueven el desarrollo de comunidades microbianas llamada bioflocs [5]. Los bioflocs son conglomerados de fitoplancton, bacterias, zooplancton, herbívoros microbianos y materia orgánica, que son principalmente bacterias heterotróficas [8–11]. Cuando estos conglomerados son alimentados con fuentes externas ricas en carbono, como lo son los carbohidratos (azúcar, almidón, melaza, harina de yuca, etc.), se

estimula su crecimiento, y se ven forzados a tomar el nitrógeno inorgánico presente en el agua del tanque para poder producir su propia proteína microbiana, y gracias a esta asimilación del nitrógeno, se crean ciclos de reciclaje que no requieren que el tanque se someta a procesos de intercambio de agua, y que mejoran la calidad del agua (por ejemplo: una concentración de $10 \text{ mg de } NH_4^+$ (amonio) puede removerse después de 5h si se añade $100 \text{ mg de } C$, relación $C/N = 10$). A su vez, la proteína microbiana que la comunidad de bacterias heterotróficas crea para su crecimiento y multiplicación celular (por cada 1g que consumen de carbohidratos, las bacterias generan 0.4 g de peso seco), sirve como fuente de alimento para los peces, y está disponible las 24 horas del día (Ver Fig. 4) [7,65].




Figura 4. Esquema del sistema de la tecnología biofloc

La cantidad requerida de carbono se determina a través del proceso propuesto por Schryver [64], y un resumen general se muestra en la Fig. 5.

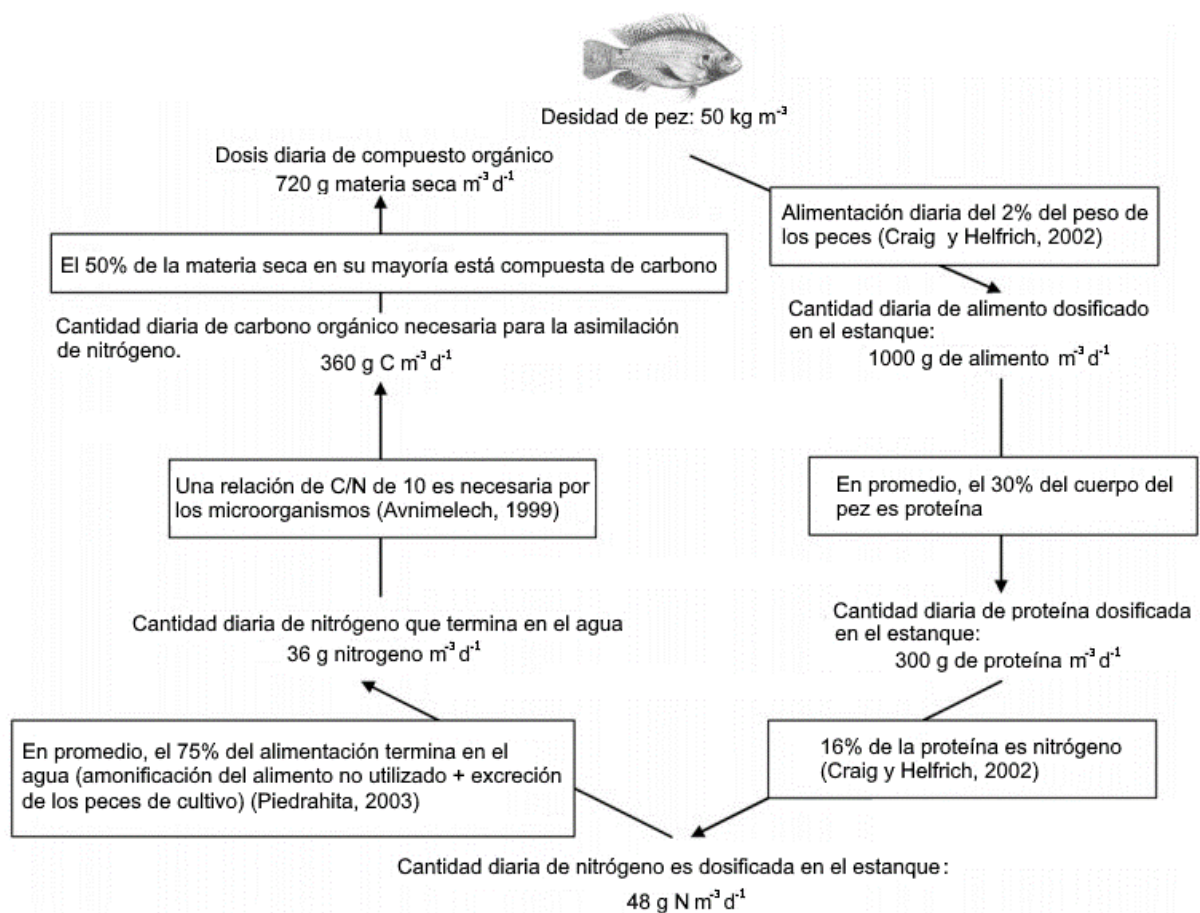


Figura 5. Esquema del cálculo esquemático de la cantidad diaria de carbohidratos añadidos que necesitan los bioflocs para eliminar el nitrógeno excretado en un estanque de acuicultura intensiva.

2.3. Tilapia del Nilo

La tilapia del Nilo (*Oreochromis niloticus*) es una especie tropical, que no soporta bajas temperaturas. Las temperaturas letales para la tilapia son: inferior $11-12 \text{ }^{\circ}\text{C}$ y superior $42 \text{ }^{\circ}\text{C}$. La tilapia se alimenta de fitoplancton, perifiton, plantas acuáticas, pequeños invertebrados, fauna béntica, desechos y capas bacterianas asociadas a los detritus. La tilapia filtra alimentos como partículas suspendidas, y tiene una gran tolerancia para vivir en medios acuáticos con grandes cantidades de sólidos suspendidos. Su resistencia a enfermedades, su fácil reproducción, su alta adaptabilidad a diferentes ambientes, alimentos y calidades de agua, la han hecho una de las especies más populares en la acuicultura. La tilapia del Nilo puede vivir más de 10 años y alcanzar un peso de 5 kg [118].

2.3. Redes neuronales convolucionales (CNN)

Hoy en día, las redes neuronales artificiales (ANNs) han aumentado la atención, debido a la capacidad que tienen de aproximar con precisión cualquier función continua [119]. Las ANNs se han aplicado con éxito a la clasificación de imágenes [120–122], en la detección de objetos [123–125], en el reconocimiento de voz [126–128], en el seguimiento de objetos [129–131], en el etiquetado y/o clasificación de imágenes [132–134], y en el procesamiento del lenguaje natural en diferentes áreas como la medicina, ingeniería, agricultura, construcción, producción industrial, etc [135].

El concepto de Inteligencia Artificial (IA) está relacionado con la creación de máquinas inteligentes que simulan cómo los seres humanos actúan y reaccionan a tareas simples, esto se logra mediante la unión de una gran cantidad de unidades simples de procesamiento de datos, llamadas neuronas, que trabajan juntos y crean una ANN para procesar información [136]. También Machine Learning (ML) y Deep Learning (DL) son dos nociones importantes originadas por el desarrollo de la IA. Los modelos de DL imitan el funcionamiento de la corteza visual de los mamíferos utilizando operaciones avanzadas de bloques y varias capas de neuronas, llamadas redes neuronales convolucionales (CNN). Las CNN están diseñadas especialmente para el uso de datos bidimensionales y aprenden estructuras complejas requeridas en tareas que involucran clasificación, reconocimiento, descripción y detección de patrones de imagen [119].

En las tareas de clasificación de imágenes, una CNN lleva a cabo como primer paso la extracción de características y, en un segundo paso, la clasificación de la imagen de entrada en un conjunto de categorías posibles, de acuerdo con las características extraídas de la imagen de entrada (ver Fig. 6).




Figura 6. Descripción general de un modelo CNN.

Otro concepto relevante y significativo en el DL, que se puede aplicar en los modelos CNN, es el Transfer Learning (TL). En TL, un modelo CNN que ha sido entrenado previamente para una tarea, se reutiliza y entrena nuevamente para aprender otra tarea nueva. Es decir, TL permite transferir conocimiento entre dominios y aplicar diferentes tareas en el nuevo dominio. Para aplicar TL en una CNN, el primer paso es modificar la última capa completamente conectada de acuerdo con el nuevo número de categorías de imágenes para clasificar en la nueva tarea. Posteriormente, el segundo paso consiste en descongelar las capas de la base convolucional, y permitir que los pesos y el sesgo se vuelvan a calcular (actualizando todos los parámetros del modelo) de acuerdo con el nuevo proceso de reentrenamiento, este proceso de TL se le conoce como ajuste fino (Fine-tuning), que, en esencia, reentrena todo el modelo. Para ajustar el modelo previamente entrenado, los pesos de cada neurona en la CNN deben inicializarse aleatoriamente. La Fig. 7 muestra el proceso de TL en una CNN, donde se cambia la tarea de clasificación, de clasificar animales a clasificar soluciones líquidas de acuerdo a sus sólidos suspendidos.

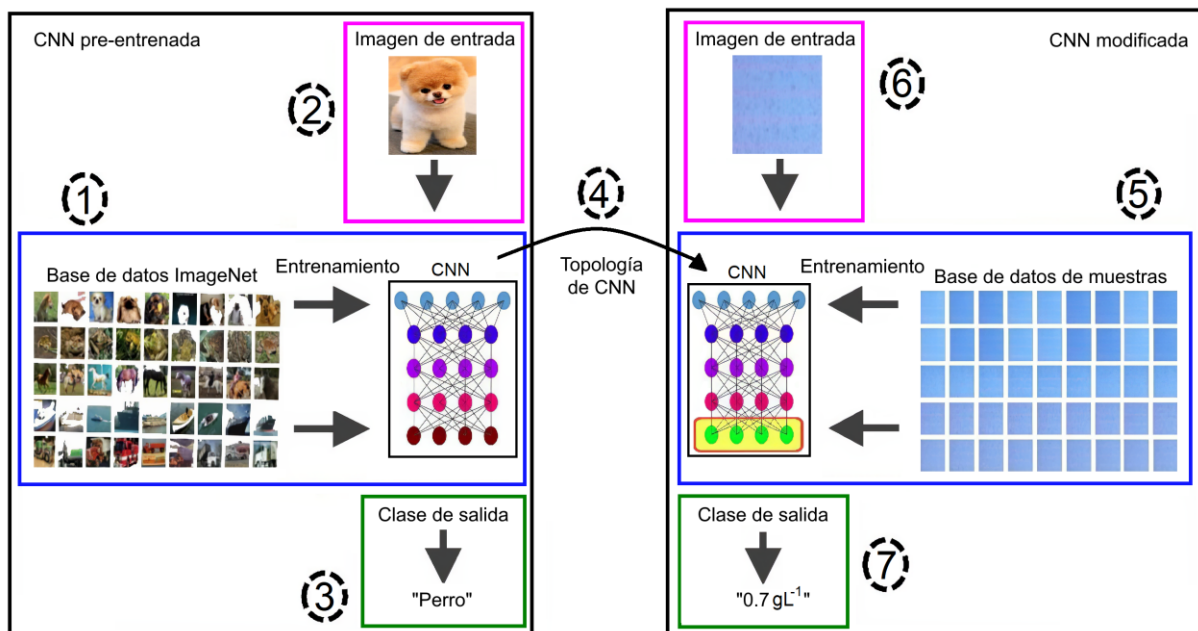


Figura 7. Representación del proceso TL y puesta a punto de la CNN. 1) Base de datos de entrenamiento (ImageNet), 2) entrada de imagen para clasificar, 3) resultado de la clasificación, 4) reutilización del modelo pre-entrenado a nueva tarea (Transfer learning), 5) nuevo conjunto de datos de entrenamiento (con imágenes de la nueva tarea), 6) nueva imagen de entrada para clasificar, 7) resultados de la nueva clasificación.

Durante el proceso de entrenamiento se conoce la clase correcta de cada imagen del conjunto de datos de entrenamiento (entrenamiento supervisado). Este proceso hace posible calcular los valores de peso de las neuronas utilizadas para la clasificación de salida. El modelo aprende ajustando los pesos de las neuronas, utilizadas para predecir una etiqueta de clase correcta, y calculando un término de error. El proceso de entrenamiento es un método iterativo, en cual se espera que el término de error sea menor cada vez, lo que significa que los valores de salida estarán cada vez más cerca del valor correcto. En otras palabras, el proceso de capacitación implica el uso de un conjunto de datos de entrenamiento, que actualiza los pesos del modelo para causar una respuesta correcta a las salidas.

Capítulo 3. Materiales y métodos

En esta investigación se propone la implementación de sistemas de iluminación LED en sistemas intensivos de tilapia con BFT, que mejoren la producción, el crecimiento y la composición nutricional de las tilapias, y de los bioflocs como fuente de alimento para las tilapias, y a su vez permita monitorear parámetros físico-químicos como la turbidez y los sólidos suspendidos totales (TSS). Esta investigación se planteó en dos fases: la primera fase evalúa el efecto de la longitud de onda (color) en el crecimiento y la composición nutricional de la tilapia, y también el efecto de la luz de color en los bioflocs como fuente de alimento para los peces; y la segunda fase se concentró en desarrollar una nueva técnica de medición de turbidez y sólidos suspendidos, mediante un sistema de iluminación LED, un teléfono celular, y el uso de redes neuronales convolucionales. Es por tal motivo, que los materiales y métodos utilizados en esta investigación serán descritas en dos fases.

3.1. Fase I

3.1.1. Diseño experimental

El experimento se llevó a cabo por 73 días en el laboratorio de prototipos de la Universidad Autónoma de Zacatecas. Un espacio de 1.7m x 2.5m x 2.7m se acondicionó para tener efecto invernadero, para lo cual se recubrió con plástico de invernadero y un calentador eléctrico fue utilizado para regular la temperatura. Antes de que el experimento comenzara, se adquirieron 489 alevines de tilapia de Nilo (*O. niloticus*) del criadero comercial AQUAMOL S.C. DE R.L., Jamay, Jal., México, y fueron llevadas al laboratorio, donde tuvieron un periodo de climatización de 2 semanas, en las cuales solo recibieron iluminación natural. Los alevines de tilapia tenían una masa promedio inicial de 0.242 ± 0.01 g. Aproximadamente se distribuyeron 123 peces por tanque, para tener de inicio 30 g de biomasa en cada tanque. La distribución fue aleatoria con una misma densidad de siembra de 0.2 kg/m^3 en tanques circulares (150 L volumen, 39 cm altura, 70 cm diámetro) bajo condiciones de luz natural. Cada tanque contaba con cabezas de poder (bombas) para la circulación y mezcla del agua, y discos difusores para la aireación. La aireación total para los tanques se suministró con un blower SinoAqua de $\frac{1}{2}$ hp. Ver Fig. 8 con el diseño experimental, y Fig. 9 y 10 con la climatización y siembra de los alevines respectivamente.




Figura 8. Diseño experimental utilizado.



Figura 9. Climatización de los alevines de tilapia.




Figura 10. Siembra de los alevines de tilapia.

El experimento fue diseñado para evaluar los efectos de la luz de color bajo condiciones de iluminación real. Es decir, este experimento puede ser transferido a condiciones reales de producción de tilapia, debido a que los cuatro tratamientos recibieron luz natural, como lo reciben normalmente las granjas acuícolas. Esta investigación implementó un cambio especial a esto, además de recibir luz natural, se iluminaron tres tratamientos con lámparas LED rojas, verdes y azules durante 18 h por día. La iluminación fue proporcionada por lámparas LED RGB (luz monocromática roja, verde y azul) con longitudes de onda pico (λ) de 627.27 nm para el tratamiento de luz roja (R), 513.33 nm para el tratamiento de luz verde (G), y 451.67 nm para el tratamiento de luz azul (B). Las lámparas LED fueron posicionadas a 25 cm por encima de la superficie del agua, con el propósito de que el ángulo de apertura de la lámpara (110°), se enfocara completamente en toda la superficie del agua de todo el diámetro del tanque. La intensidad de luz de todas las lámparas LED fue constante, con una irradiancia sobre la superficie del agua de 0.832 mW/cm^2 , y la luz natural proveniente del sol dentro del invernadero tuvo un máximo de irradiancia en la superficie del agua de 0.95 mW/cm^2 a las 2:00 pm. Al mismo tiempo, se utilizó un cuarto tratamiento que solo recibió luz natural, el cual es llamado tratamiento "Natural". Los cuatro tratamientos recibieron de luz del sol. El tratamiento Natural actuó como el tanque testigo y/o de control. Las condiciones de iluminación para los cuatro tratamientos se muestran en la Fig. 11.

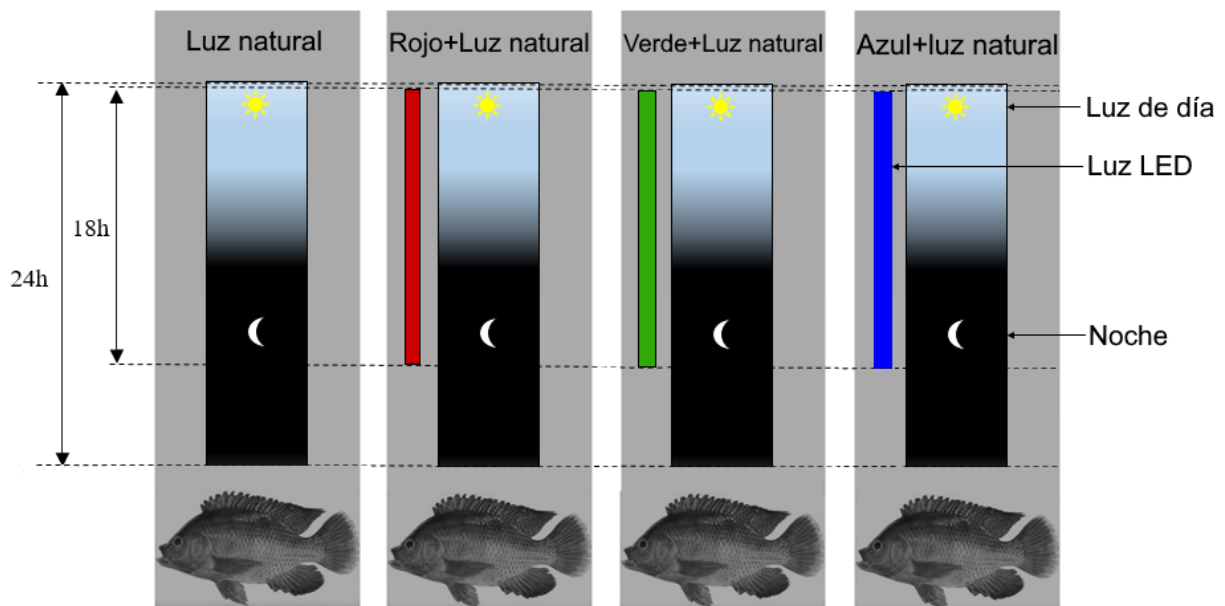


Figura 11. Períodos de luz recibidos por cada tanque durante esta investigación. Todos los tratamientos recibieron luz natural, pero tres de los tratamientos también se iluminaron con luz de color rojo, verde y azul, que fue proporcionada por una lámpara LED, con un fotoperiodo de 18 h por día.

3.1.2. Caracterización de las lámparas LED

Todas las lámparas LED se caracterizaron ópticamente a través de un espectrofotómetro (Ocean Optics USB2000) y un radiómetro calibrado NIST (ILT-1400). Tanto la longitud de onda pico (λ) como la anchura espectral ($\Delta\lambda$) se midieron con el espectrofotómetro. La irradiancia o la densidad de potencia radiante en la superficie del agua de cada tanque se midió con el radiómetro calibrado. Los parámetros medidos se muestran en la Tabla 2, donde la irradiancia promedio fue de 0.832 mW/cm^2 . Además, en la Fig. 12 se muestra la distribución de energía espectral de la luz emitida por cada lámpara LED de color utilizada en el experimento.

Tabla 2. Propiedades espectrales de la luz de las lámparas LED: rojo (R), verde (G), y azul (B).

Parámetros	Lámparas LED		
	R	G	B
λ (nm)	627.27	513.33	451.67
$\Delta\lambda$ (nm)	16.92	32.80	23.75
Irradiancia (mW/cm^2)	0.870	0.825	0.802




Figura 12. Distribución espectral de las potencias de las lámparas LED RGB utilizadas en el estudio: (a) lámpara LED R, (b) lámpara LED G, y (c) lámpara LED B.

3.1.3. Sistema biofloc

Todos tanques comenzaron con agua potable, y esta fue aireada previamente por dos semanas antes de la llegada de los alevines de tilapia para completar el proceso de desclorinación. A partir de esto, con la llegada de los peces y el comienzo de la alimentación de estos, ningún intercambio de agua se realizó y los bioflocs empezaron a formarse desde cero. Se comenzó a agregar el carbono orgánico que necesitan los bioflocs para eliminar el nitrógeno excretado en el tanque por los alevines. La cantidad de carbono agregado al sistema se calculó con el método descrito en De Schryver et al. [64]. Se utilizó azúcar mascabada como fuente de

carbono con una relación C/N de 20: 1 para controlar el nitrógeno inorgánico [137]. Esta relación se mantuvo durante todo el estudio. El estudio duró 73 días. Cada tanque se fijó a 29 ° C con un termostato sumergido en el agua (300 W, grupo de acuarios LOMAS) para evitar altas variaciones de temperatura. Ver Fig. 13 con bioflocs ya formados en el experimento.



Figura 13. Experimento en día 20, ya con bioflocs formados.

Los peces fueron alimentados dos veces al día con la dieta I durante el primer mes, y después del primer mes con la dieta II de acuerdo con los requisitos de su etapa de crecimiento. La composición de las dietas I, II y el azúcar proporcionados por el fabricante y calculados por el laboratorio a través de una prueba de bromatología se muestra en la Tabla 3. La cantidad diaria de alimento se ajustó cada semana según la biomasa de peces presente en cada tanque, y de acuerdo al registro de sobrevivencia para cada tanque. Durante el período experimental, los tanques se revisaron cada día, y si algún pez aparecía muerto, este se retiraba y se registraba.

Tabla 3. Composición de los alimentos suministrados.

Componente	Alimento					
	Dieta I (Fabricante)	Dieta I (Laboratorio)	Dieta II (Fabricante)	Dieta II (Laboratorio)	Azúcar (Fabricante)	Azúcar (Laboratorio)
Humedad (%)	12.0	7.9	12.0	8.1	0.0	1.8
Proteína (%)	53.0	43.0	32.0	40.9	0.0	0.3
Lípidos (%)	15.0	12.3	6.0	12.8	0.0	0.0
Fibra (%)	2.5	1.7	6.0	2.2	0.0	3.3
Cenizas (%)	12.0	7.8	15.0	10.0	0.0	0.1
E. L. N (%)	5.5	27.3	29.0	26.0	100.0	94.5

E. L. N= Extracto libre de nitrógeno.

3.1.4. Calidad del agua

La temperatura, el oxígeno disuelto y el pH se midieron dos veces al día en cada tanque a las 10:00 y las 20:00 horas. La temperatura y el oxígeno disuelto se midieron con el medidor de oxígeno disuelto YSI modelo 550A, y el pH mediante un medidor Hanna modelo HI 98127. Por su parte, el amoníaco nitrogenado NH₃-N se midió semanalmente con un medidor Hanna modelo HI715. Además, el TAN (Nitrógeno Amoniacal Total) se calculó a partir de amoníaco-nitrógeno usando la expresión matemática del equilibrio descrita en Boyd and Tucker (2012) en la Ecuación 1.

$$\text{TAN} = (\text{NH}_3 - \text{N}) * \left\{ 1 + \text{antilog} \left(0.09018 + \frac{2729.92}{273.15+T} \right) - \text{pH} \right\}, \quad (1)$$

donde TAN es el nitrógeno amoniacal total, (NH₃ - N) es el nitrógeno amoniacal, T es la temperatura del agua (°C) y pH es el pH del agua.

3.1.5. Métricas de evaluación del rendimiento del crecimiento de las tilapias

Al inicio y luego cada semana, se tomaron medidas biométricas (Ver Fig. 14). Al final del experimento, todos los peces en cada tanque fueron sacados, pesados, y medidos. Las métricas de evaluación del crecimiento de las tilapias se reportan como promedio ± desviación estándar.




Figura 14. Biometrías realizadas: a) Determinación de masa de las tilapias; b) Medición de la longitud corporal de los peces.

Las métricas para evaluar el crecimiento de los peces fueron: masa inicial (g/pez), masa final (g/pez), longitud corporal final (cm/pez), supervivencia (%), tasa de crecimiento específica (SGR), ganancia diaria de peso (DWG) y tasa de conversión de alimentación (FCR). Estas biometrías son descritas por Mansour y Esteban [88] y Nhi et al. [138], y se pueden resumir de la siguiente manera:

$$\text{Masa inicial (g/pez)} = (\text{biomasa inicial (g)}) / (\text{números de peces inicial}), \quad (2)$$

$$\text{Masa final (g/pez)} = (\text{biomasa final (g)}) / (\text{número de peces final}), \quad (3)$$

$$\text{Longitud corporal final (cm/pez)} = \frac{\sum_{i=0}^{\text{numero final de peces}} \text{longitud corporal final del pez (i)}}{\text{numero final de peces}}, \quad (4)$$

$$\text{Supervivencia (\%)} = (\text{número final de peces}) / (\text{número inicial de peces}) * 100\%, \quad (5)$$

$$\text{SGR (\%/día)} = \frac{\ln(\text{masa final (g)}) - \ln(\text{masa inicial (g)})}{\text{número de días}} * 100\%, \quad (6)$$

$$\text{DWG (g/día)} = (\text{masa final (g)} - \text{masa inicial (g)}) / (\text{número de días}), \quad (7)$$

$$\text{FCR} = (\text{total de alimento suministrado (g)}) / (\text{total de masa húmeda ganada por el pez (g)}), \quad (8)$$

donde la biomasa inicial es la masa de todos los peces en cada tanque al comienzo del experimento, y la biomasa final es la masa de todos los peces al final del experimento. Por su parte, el total de alimento suministrado es la cantidad de alimento suministrado a los peces

durante los 73 días de experimentación, y total de masa húmeda ganada por el pez es la diferencia entre la masa final y la masa inicial de toda la biomasa.

3.1.6. Composición nutricional de las tilapias y los bioflocs

La composición nutricional de la tilapia es información de gran valor para determinar el aporte nutricional que la carne de pez tendrá para un consumidor. Un estudio de composición nutricional de biofloc también proporciona información sobre si la dieta de los peces podría completarse correctamente utilizando el biofloc.

Al final de la experimentación, todos los peces de cada tanque fueron tomados para el análisis nutricional (Ver Fig. 15). A su vez, el agua de cada tanque se filtró con un tamiz # 200 para obtener la mayor cantidad de bioflocs. El análisis nutricional fue realizado en el laboratorio químico de estudios especiales de la UAZ. La composición nutricional de los peces y los bioflocs se determinó mediante la evaluación de lípidos, humedad, proteína cruda, fibra cruda, ceniza, extracto de éter y extracto libre de nitrógeno, según la metodología estándar de Norma Mexicana NMX [139,140]. La determinación de lípidos se llevó a cabo en un equipo de extracción Soxhlet y los otros parámetros mediante bromatología utilizando técnicas gravimétricas.



Figura 15. Almacenamiento de todos los peces, para prueba bromatológica.

3.1.7. Análisis estadístico

Todos los datos medidos, y las métricas calculadas en esta investigación fueron analizados con el fin de lograr una evaluación de rendimiento y una comparación amplia entre los cuatro tratamientos. El ANOVA es un análisis de varianza unidireccional, que compara la variación entre grupos con valores promedios. Los parámetros de calidad del agua no se analizaron utilizando el ANOVA debido a la ausencia de réplicas ($n=1$). Sin embargo, las tasas de crecimiento si fueron analizadas con el ANOVA unidireccional, seguido de la prueba Tukey, con un nivel de significancia del 5%. Antes de realizar la evaluación ANOVA unidireccional, se verificó la hipótesis de igualdad (homogeneidad) de las variaciones mediante la prueba de Levene [141]. Los datos mostrados sobre análisis de datos de la composición nutricional de las tilapias y los biofloc son el promedio resultante para tres muestras analizadas de cada tratamiento.

3.2. Fase II

3.2.1. CNN utilizada

Un modelo de CNN simple y elemental con una poderosa capacidad de modelado es AlexNet [142]. El modelo AlexNet ha sido entrenado usando más de un millón de imágenes de la base de datos ImageNet y puede clasificar una imagen en 1000 categorías de objetos. La arquitectura AlexNet es simple y fácil de entrenar y optimizar, y tiene una capacidad comprobada para clasificar y reconocer imágenes simples con baja complejidad visual, como la baja resolución [143]. El tamaño de entrada para AlexNet es de 224x224 imágenes RGB [144]. Es por tal motivo, que en esta investigación se utiliza una red convolucional con arquitectura AlexNet para extraer información implícita de múltiples imágenes de entrada, y luego, obtener un grupo de vectores de características de acuerdo a la información extraída. Estos vectores de características, son utilizados para ajustar un modelo de regresión lineal múltiple (MLR) alimentado de los datos de la CNN, se usará para estimar valores de TSS y turbidez en muestras líquidas.

La estructura de la arquitectura AlexNet después del proceso *transfer learning* (modificación de la última capa de acuerdo con el nuevo número de clases a clasificar) se muestra en la Fig. 16. Además, la estructura y los parámetros utilizados en la CNN se enumeran en la Tabla 4.

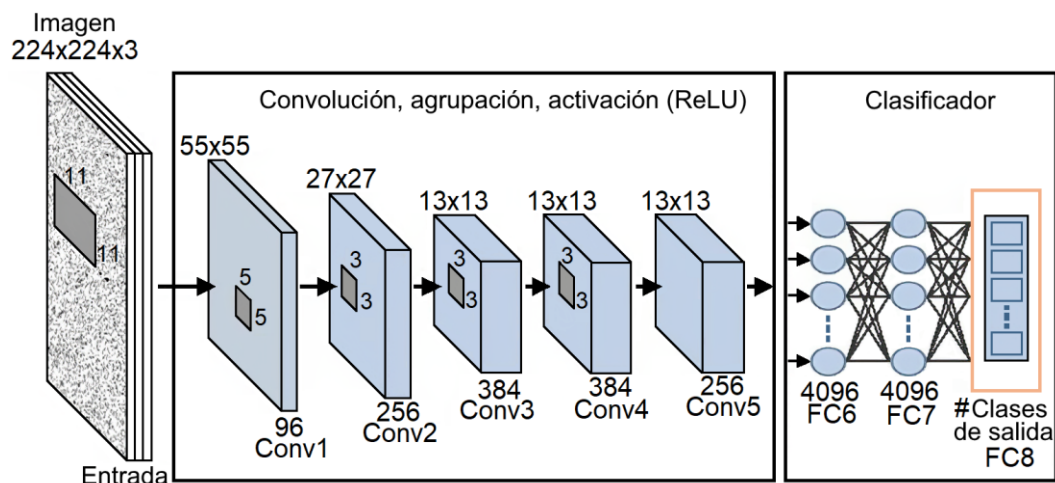


Figura 16. Detalles de la estructura de la CNN entrenada para esta investigación. La capa FC8 está marcada para indicar el cambio de tamaño de esta capa de acuerdo con el número de categorías de la nueva tarea (medición de TSS y turbidez).

Tabla 4. Estructura y parámetros de la CNN utilizados para clasificar muestras líquidas.

Función	Tamaño del núcleo (Kernel size)	Paso (Stride)	Relleno (Padding)	Activaciones
Data				224x224x3
Conv1	11,11	4,4	2,2	55x55x96
ReLU				55x55x96
MaxPool2d	3	2	0	27x27x96
Conv2	5,5	1,1	2,2	27x27x256
ReLU				27x27x256
MaxPool2d	3	2	0	13x13x256
Conv3	3,3	1,1	1,1	13x13x384
ReLU				13x13x384
Conv4	3,3	1,1	1,1	13x13x384
ReLU				13x13x384
Conv5	3,3	1,1	1,1	13x13x256
ReLU				13x13x256
MaxPool2d	3	2	0	6x6x256
Dropout				
Fully-connected				1x1x4096
ReLU				
Dropout				
Fully-connected				1x1x4096
ReLU				
Fully-connected				1x1x9

3.2.2. MLR para predecir TSS y valores de turbidez

La capa final de la CNN propuesta entrega los vectores logits para la predicción de la clasificación. Esta última capa, genera predicciones de valores de probabilidad no normalizados en un rango de $-\infty$, $+\infty$. En esta investigación, las probabilidades de clase se utilizan para predecir los valores de TSS y turbidez en una muestra líquida. Usamos el vector logits para ajustar la MLR, de tal manera que al ingresar un nuevo vector logits de una solución desconocida, esta pueda ser estimada.

La MLR modela la relación entre dos o más variables, y da una respuesta de acuerdo a la ecuación lineal del conjunto de datos de entrenamiento. Entonces, al ajustar la MLR con el vector logits obtenido de todo el conjunto de datos de entrenamiento, se puede estimar valores de sólidos suspendidos y turbidez a partir de una imagen. La figura 17 muestra cómo se ajusta el MLR usando el vector logits generado por una CNN.

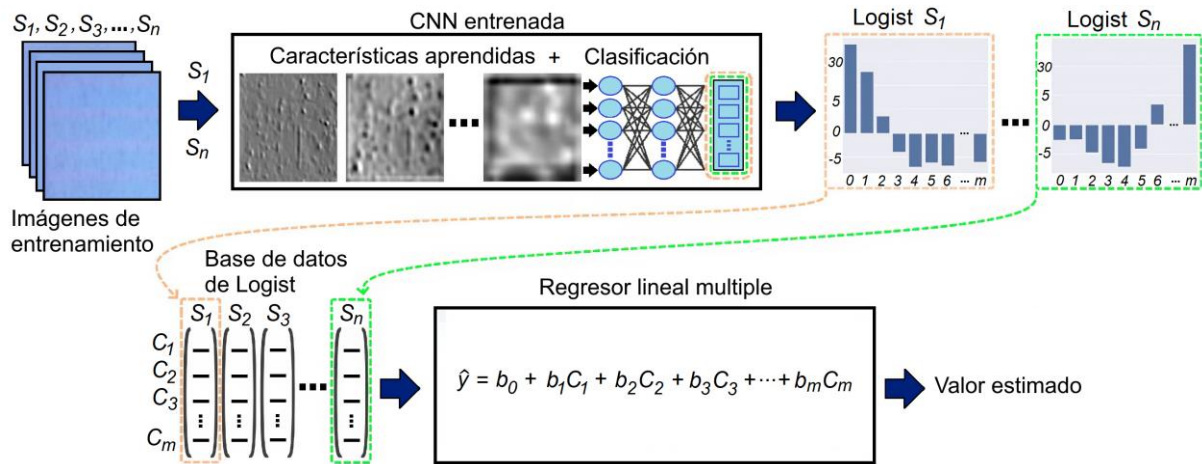


Figura 17. Vectores Logits generados con una CNN para ajustar la MLR. En la imagen $S_1, S_2, S_3, \dots, S_n$ representan las imágenes obtenidas de las muestras líquidas con diferentes valores de TSS, hasta un número n total de imágenes de muestras. Las dimensiones de los vectores Logits obtenidos estarán relacionadas con el número m de las clases C de las muestras líquidas implementadas para el entrenamiento de la CNN. El regresor línea múltiple ajustado está conformado por \hat{y} , que es la variable dependiente y contendrá el valor estimado de TSS cuando se introduzcan las clases C . Y b se refiere a los coeficientes de la recta que se utilizará para estimar el valor final.

3.2.3. Activaciones de la CNN propuesta

La principal ventaja de usar una CNN es que detecta automáticamente las características más relevantes de una imagen de entrada sin supervisión humana. Una CNN consiste en una agrupación de diferentes capas que transforman los datos de entrada en datos de salida. En la tarea de clasificación de imágenes, si ingresamos una imagen de entrada a una CNN, se obtiene el puntaje o la probabilidad de la clase para clasificar la imagen de entrada de acuerdo con el conjunto de datos de entrenamiento.

Naturalmente, cualquier CNN utiliza la operación matemática convolucional en al menos una de sus capas para fusionar dos grupos de información. En la capa convolucional de una CNN, un filtro se convoluciona a través del ancho y la altura de la imagen de entrada para producir un mapa de activación bidimensional o un mapa de características. Debido a que usamos un conjunto de filtros, apilamos los mapas de características de las capas convolucionales para crear un volumen de salida. Aunque la CNN tiene una topología definida para operar con datos bidimensionales utilizando filtros bidimensionales (Kernel), el proceso de capacitación de CNN puede ser a ciegas con respecto a cómo la CNN usa los datos extraídos de un gran volumen de datos de entrenamiento. Entonces, una herramienta importante para

inspeccionar y visualizar los tipos de características que el modelo detecta para una entrada dada, es el mapa de características. Este mapa proporciona información sobre si las características extraídas pueden ser útiles, relacionadas o apropiadas para describir los datos a clasificar.

Entonces, en este apartado, se analiza un conjunto de mapas de características para confirmar que la CNN detecta las partículas suspendidas en las muestras líquidas. Además, corrobora que la CNN aprenda a ser insensible a aberraciones ópticas o parámetros como la frecuencia de emisión de luz de la lámpara LED, variaciones de intensidad de luz, y otras cosas. La Fig. 18 muestra un conjunto de mapas de características, extraídos de los resultados apilados en cada capa convolucional de la arquitectura AlexNet. Se debe resaltar, que las áreas brillantes (activaciones) en la Fig. 18 corresponden a las partículas suspendidas de la muestra líquida de la imagen de entrada.

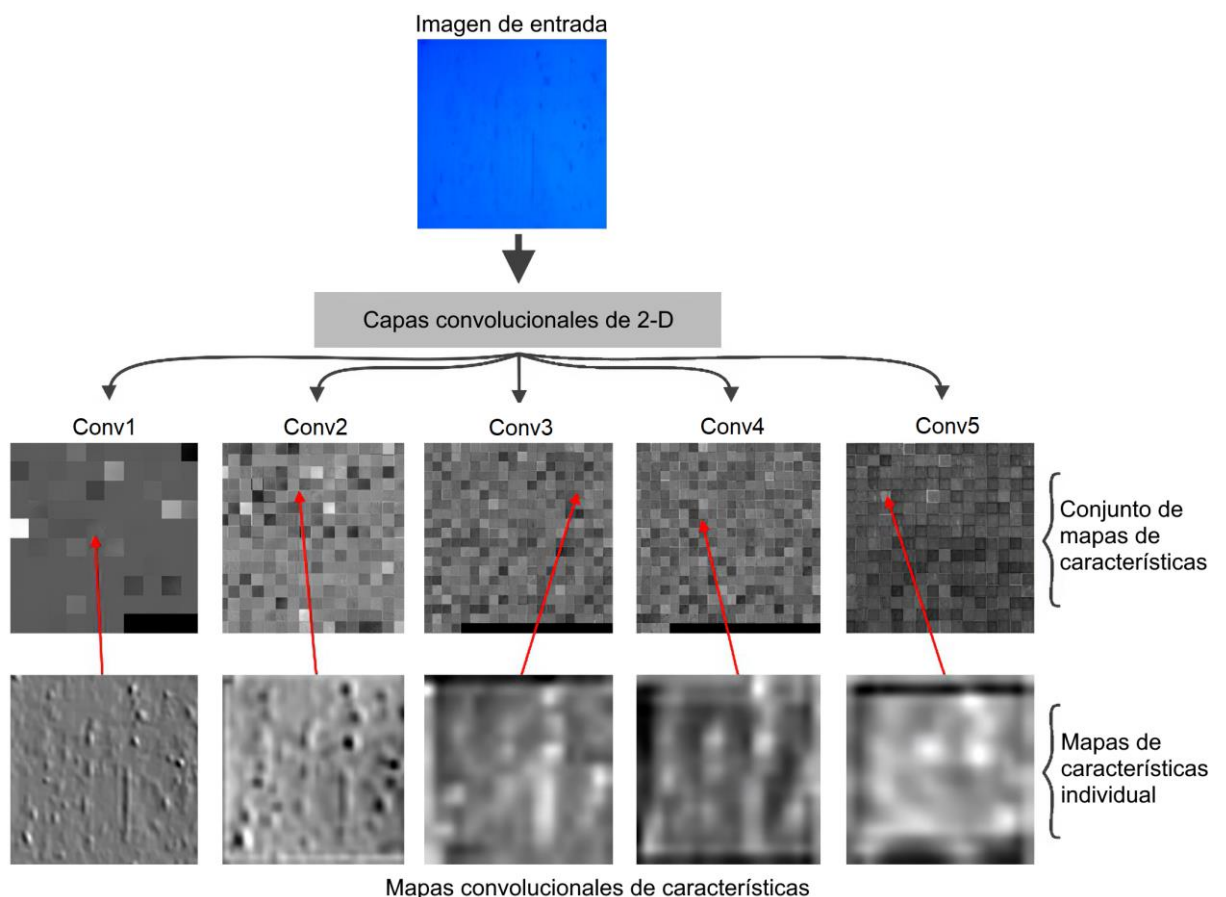


Figura 18. Visualización de los mapas de características extraídos de cada capa convolucional del modelo AlexNet pre-entrenado.

3.2.4. Diseño experimental

Este experimento fue diseñado para obtener una nueva técnica de medición de sólidos suspendidos y turbidez, a través del uso de redes neuronales convolucionales. Para esto, se utilizó un recipiente transparente cúbico de $5 \times 5 \times 5 \text{ cm}^3$, el cual fue llenado con agua destilada y ciertas cantidades de sólidos en suspensión. Para asegurar que los sólidos se mantuvieran en suspensión y a su vez la solución fuera homogénea, un agitador magnético fue utilizado durante el registro de las imágenes (imágenes de entrenamiento y validación). Es decir, las imágenes fueron tomadas en movimiento a una velocidad de mezcla de 60 rpm (revoluciones por minuto). A su vez, la muestra líquida fue iluminada con una lámpara LED RGB, y un teléfono celular fue utilizado para tomar las imágenes con diferentes niveles de concentración de sólidos suspendidos, y bajo los diferentes colores de iluminación (Ver Fig. 19 con la configuración experimental). Los colores de luz utilizados para iluminar la muestra líquida fueron: rojo, verde, azul y blanco (Ver Fig. 20). Los cuatro colores de luz se mantuvieron a una intensidad constante de 0.852 mW/cm^2 , y la distribución de potencia espectral de la lámpara para los cuatro colores de luz utilizados se muestra en la Fig. 21.




Figura 19. (a) Esquema de la configuración experimental; (b) Configuración experimental utilizada.




Figura 20. Muestras con una concentración de 0.1 g/l, iluminadas bajo diferentes colores de luz: (a) blanca; (b) rojo; (c) azul; (d) verde.




Figura 21. Distribuciones de potencia espectral de la lámpara LED RGB utilizada en este estudio: (a) color azul; (b) color verde; (c) color rojo, y (d) color blanco.

Para crear y grabar el conjunto de datos de las muestras líquidas, se utilizó la cámara principal del teléfono inteligente Huawei Mate 20 Lite. Se registraron un total de 39600 imágenes para 9 clases o 9 diferentes niveles de concentración de sólidos en suspensión. El tamaño de la imagen registrada por el teléfono celular fue de 2448×2448 píxeles, sin embargo, las imágenes se recortaron en el centro a 224×224 píxeles, de acuerdo con los requisitos de la capa de entrada de la CNN. La cámara del teléfono inteligente se utilizó en el modo manual. Las características de la cámara que se mantuvieron constantes durante el experimento fueron: la velocidad de captura o FPS (fotogramas por segundo), el nivel ISO y la opción de enfoque. De las 39600 imágenes registradas, 36000 imágenes fueron seleccionadas al azar para crear el conjunto de datos de imágenes de entrenamiento, y las 3600 imágenes restantes se usaron para construir el conjunto de datos de imágenes de validación.

El proceso de entrenamiento se desarrolló e implementó utilizando Google Colaboratory, el cual es un servicio gratuito en la nube para la educación de aprendizaje automático (machine learning). Google Colaboratory proporciona un entorno portátil que se ejecuta en una máquina virtual con una GPU Nvidia Tesla K80 con 2496 núcleos CUDA. Por su parte, AlexNet se extrajo del paquete Torchvision, que ofrece algunos modelos previamente entrenados y ofrece herramientas de procesamiento de imágenes. Para el entrenamiento de la CNN, el algoritmo ejecutó un total de 75 épocas de entrenamiento. Este número de épocas fue seleccionado de acuerdo a la pérdida de entrenamiento (loss of training). La red neuronal fue entrenada con el gradiente de descenso estocástico de 0,9 de impulso (momentum). El tamaño del lote (batch size) fue de 50, y el resto de los hiperparámetros utilizados en el experimento se especifican en la Tabla 5.

Tabla 5. Hiperparámetros utilizados en el proceso de entrenamiento de la red neuronal.



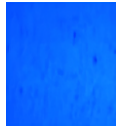




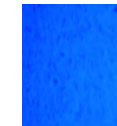
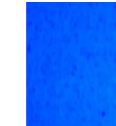
Hiperparámetros	Valores
Algoritmo optimizador	SGD
Tasa de aprendizaje (Learning rate)	0.0005
Impulso (Momentum)	0.9
Tamaño del lote (Batch size)	50
Número de épocas	75

3.2.5. Muestras líquidas utilizadas

Para crear las muestras líquidas, el alimento comercial para peces se utilizó como para los sólidos en suspensión. Esta elección se basó en que el alimento de peces es fácil de dosificar y es uno de los componentes que más se acumula en los sistemas de acuicultura intensiva [65]. Además, el alimento de peces para tilapia está diseñado para estar en suspensión [145,146]. El alimento para peces utilizado tiene un tamaño de partícula de <0.35 mm y está compuesto principalmente de humedad (7.90%), proteína cruda (43.00%), lípidos (12.30%), fibra cruda (1.70%), cenizas (7.80%) y extracto de nitrógeno (27.30%) [92]. Se prepararon un total de 9 muestras líquidas, para esto se mezcló un litro de agua destilada con cada cantidad de masa de alimento para peces que se muestra en la Tabla 6. Las cantidades de alimento para peces utilizadas se midieron en una balanza de alta resolución PI-214 de Denver Instruments, cuya resolución nos permite obtener valores con 4 cifras significativas. Las concentraciones de las

muestras líquidas creadas varían de 0 a 0.8 g/l, y de 0 a 263 NTU, debido a que es el rango operativo más común de los medidores comerciales disponibles de sólidos suspendidos y turbidímetros como el de HANNA instruments [147], y los de Hach [148,149]. Las mediciones de turbidez fueron realizadas con un turbidímetro DR900. En la Tabla 6 se muestran los valores de turbidez en valor promedio \pm desviación estándar. Las imágenes con las diferentes concentraciones de cada clase fueron tomadas aleatoriamente del conjunto de datos creados para esta investigación

Tabla 6. Muestras líquidas utilizadas.

Clases	0	1	2	3	4	5	6	7	8
Masa (g)	0.0000	0.1000	0.2000	0.3000	0.4000	0.5000	0.6000	0.7000	0.8000
TSS (gL^{-1})	0.0000	0.1000	0.2000	0.3000	0.4000	0.5000	0.6000	0.7000	0.8000
Turbidez (NTU)	0 \pm 0.55	38 \pm 2.61	77 \pm 7.06	95 \pm 13.62	132 \pm 12.37	168 \pm 12.68	189 \pm 22.66	245 \pm 21.65	263 \pm 23.73
Imágenes									

3.2.6. Evaluación del desempeño de la técnica propuesta

La evaluación del rendimiento del experimento debe evaluarse en dos etapas. En la primera etapa se debe evaluar la capacidad de la CNN para clasificar las muestras líquidas. Una clasificación correcta significa obtener los mejores valores del vector de características. En la segunda etapa, necesitamos evaluar la MLR para confirmar y obtener la relación correcta entre el vector de características (extraído de la CNN) y el valor estimado de TSS y turbidez.

3.2.6.1. Métricas para la evaluación del clasificador

Para evaluar el rendimiento de clasificación de una red neuronal se utiliza la matriz de confusión [150–152]. Existen cuatro términos importantes que conforman una matriz de confusión (ver Fig. 22), los cuales son: TP (True Positive), TN (True Negative), FP (False Positive) y FN (False Negative). El TP agrupa los casos en que el número de elementos de clase se predijo como elementos que le pertenecen, y son de esta clase. El TN tiene los casos en que el número de elementos de clase se predijo como elementos que no le pertenecen, y que no son

de esta clase. El FP agrupa los casos en que el número de elementos de clase se predijo como elementos que le pertenecen, y no son de esta clase. Por último, el FN es para los casos en que el número de elementos de clase se predijo como elementos que no le pertenecen a él, y son de esta clase.

		Clase predecida		
		$C_0 \dots C_{k-1}$	C_k	$C_{k+1} \dots C_n$
Clase real	$C_{k+1} \dots C_n$	TN	FP	TN
	C_k	FN	TP	FN
	$C_0 \dots C_{k-1}$	TN	FP	TN

Figura 22. Elementos de una matriz de confusión multiclase

Mediante la matriz de confusión se calculan algunas figuras de mérito para evaluar el clasificador. La primera es la exactitud, que evalúa el número total de predicciones que se clasificaron correctamente y se calcula como:

$$Exactitud = (TP + FN)/N, \quad (9)$$

donde N es el número total de elementos para clasificar.

Por su parte, la precisión es la capacidad del clasificador para predecir una muestra de acuerdo con lo que realmente es, y se define como:

$$Precisión = TP/(TP + FP). \quad (10)$$

También sensibilidad (Recall) es la capacidad del clasificador para encontrar todas las muestras positivas. En otras palabras, cuántos ejemplos de casos positivos se etiquetaron correctamente como positivos, y se expresa como:

$$Sensibilidad = TP/(TP + FN). \quad (11)$$

De manera similar a la sensibilidad, se tiene la especificidad la cual es la capacidad del clasificador para encontrar todas las muestras negativas, y se define como:

$$\text{Especificidad} = TN / (TN + FP). \quad (12)$$

A su vez, el puntaje F (F-Score) es la media armónica de la precisión y la sensibilidad, y nos da una idea de cuán preciso es nuestro clasificador. Un valor alto indica que el modelo se comporta mejor en casos positivos, y se calcula como:

$$\text{Puntaje } F = (2 * \text{Precision} * \text{sensibilidad}) / (\text{Precision} + \text{sensibilidad}). \quad (13)$$

También, como métrica para la evaluación del clasificador, se utiliza el gráfico de Característica Operativa del Receptor (ROC). El cual es un gráfico de tasa verdadera positiva (sensibilidad) vs la tasa de falsos positivos (especificidad). Este gráfico caracteriza la capacidad de la CNN para identificar casos positivos como positivos y los negativos como negativos. Además, el área bajo la curva ROC (AUC) es la probabilidad de que un par de casos positivos y negativos elegidos al azar se clasifiquen correctamente.

3.2.6.2. Métricas para la evaluación del MLR

Para evaluar el desempeño del MLR, que tiene la tarea de estimar el valor correcto de sólidos suspendidos y turbidez, se utilizaron las métricas que se describen a continuación.:

Coefficiente de determinación (R^2): es una medida estadística de la bondad de ajuste o de la fiabilidad del modelo de acuerdo con los datos. Este coeficiente determina la calidad del modelo para replicar los resultados. Los valores están entre 0 y 1. Un valor de cero implica que no existe una relación lineal, y el número uno que existe una relación lineal perfecta. El coeficiente de determinación se calcula como:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_{predicho_i} - y_{promedio})^2}{\sum_{i=1}^n (y_{real_i} - y_{promedio})^2}, \quad (14)$$

donde $y_{predicho}$ se define como el valor predicho por la MLR, y_{real} como el valor verdadero y $y_{promedio}$ como el promedio de los valores reales y .

Error absoluto medio (MAE): es una medida de evaluación utilizada en modelos de regresión. Es la media de la diferencia entre los valores reales y los valores predichos. Cada predicción es la diferencia entre y_{real} y $y_{predicho}$, matemáticamente se describe como:

$$MAE = \frac{\sum_{i=1}^n |y_{real_i} - y_{predicho_i}|}{n}, \quad (15)$$

donde n es el número total de datos.

Error cuadrático medio (MSE): se define como la diferencia entre los valores reales y los valores pronosticados al cuadrado. Cuanto menor sea este valor, mejor será el modelo. Además, nunca da valores negativos. Matemáticamente se representa como:

$$MSE = \frac{\sum_{i=1}^n (y_{real_i} - y_{predicho_i})^2}{n}. \quad (16)$$

Capítulo 4. Resultados y discusiones

En esta investigación se planteó la hipótesis de que usando iluminación LED de diferente color es posible mejorar la producción, el crecimiento y la composición nutricional de las tilapias, y de los bioflocs como fuente de alimento para las tilapias en la acuicultura. Y también se hizo la hipótesis de que usando la misma iluminación LED se podrá monitorear parámetros físico-químicos como la turbidez y los sólidos suspendidos totales (TSS) mediante redes neuronales convolucionales. La comprobación de estas dos hipótesis se expone en esta sección en dos subsecciones: La primera corresponde a la fase I que evalúa el efecto de la longitud de onda (color) en el crecimiento y la composición nutricional de la tilapia, y también el efecto de la luz de color en los bioflocs como fuente de alimento para los peces. Y la segunda subsección describe la fase II sobre el desarrollo de una nueva técnica de medición de turbidez y sólidos suspendidos, a través de un sistema de iluminación LED, un teléfono celular, y el uso de redes neuronales convolucionales.

4.1. Fase I

4.1.1. Calidad del agua

Los valores promedio de los parámetros de la calidad del agua se mantuvieron aproximadamente constantes en todos los tanques durante todo el período experimental. Los parámetros de calidad del agua se midieron diariamente, y los valores promedios para cada tanque se presentan en la Tabla 7.

Tabla 7. Parámetros de la calidad del agua

Parámetros	Tanques			
	R	G	B	Natural
Temperatura (°C)	28.03 ± 1.03	28.38 ± 0.96	28.94 ± 1.22	28.65 ± 0.93
Oxígeno disuelto (mg/l)	4.65 ± 0.58	4.67 ± 0.43	4.71 ± 0.47	4.72 ± 0.47
pH	7.91 ± 0.17	7.91 ± 0.16	7.92 ± 0.16	8.01 ± 0.20
NH ₃ -N (mg/l)	0.07 ± 0.010	0.07 ± 0.016	0.08 ± 0.008	0.10 ± 0.015
TAN (mg/l)	0.79 ± 0.18	0.76 ± 0.21	0.86 ± 0.14	0.93 ± 0.22

Datos presentados en: promedio ± desviación estándar.

Para investigar el efecto de la luz de color en los alevines de tilapia del Nilo, los parámetros que no fueran el color de la luz se mantuvieron constantes. Sin embargo, hubo

ligeras variaciones experimentales en los parámetros mostrados en la Tabla 7, en donde se indican mediante la desviación estándar. Por lo pequeño de esas variaciones, se espera que el objetivo de esta investigación no haya cambiado significativamente.

En el caso de la temperatura, está se mantuvo casi constante en todos los tratamientos, con una variación inferior a 1 ° C. Manteniéndose todo dentro del rango óptimo para el crecimiento de la tilapia (26°C - 30°C) de acuerdo con la Ref. [153]. Más aún, la temperatura promedio de todos los tratamientos fue de 28,50°C, un valor muy cercano a la temperatura óptima para el crecimiento de la tilapia, que es de 28 °C [154]. Por otra parte, el oxígeno disuelto tuvo una variación significativamente pequeña en todos los tratamientos, y se mantuvo por encima del nivel aceptable para la tilapia del Nilo (4 - 5 mg / l) de acuerdo con la Ref. [155], y con diferencias entre los tratamientos inferiores a 0.07 mg/l. En el caso del pH, este se mantuvo alrededor de 8, lo cual está dentro del rango adecuado para un crecimiento óptimo y una alta tasa de supervivencia para la acuicultura de la tilapia según lo recomendado por la Ref. [156]. El pH fue casi igual entre los tanques R, G y B, esto podría ser debido a un aumento de la actividad bacteriana, gracias al efecto de la luz artificial en comparación con el tratamiento Natural. En general, el pH presentó muy pequeñas diferencias por debajo del 1,25%. Por su parte, el amoníaco-nitrógeno $NH_3 - N$ nunca alcanzó los niveles letales para la tilapia, estos estuvieron por debajo del límite de 0,1 mg/l [157], gracias a la relación C/N de 20, y con diferencias inferiores a 0.03 mg/l. Por último, la concentración de TAN siguió un patrón similar al pH, y se mantuvo en niveles adecuados para la tilapia de acuerdo con la Ref. [158], y con variaciones pequeñas entre los tratamientos, menores a de 0.17 mg/l.

4.1.2. Tasa de crecimiento de las tilapias de Nilo

Para evaluar el efecto de la luz de color en las tilapias del Nilo se utilizaron las siguientes métricas: las biomásas inicial y final, la masa inicial y final, el número inicial y final de peces, la longitud corporal, la supervivencia, tasa de crecimiento específica (SGR), ganancia diaria de peso (DWG) y tasa de conversión de alimentación (FCR). Los valores obtenidos se muestran en la Tabla 8. Y de manera específica la distribución cuantitativa de la masa final de las tilapias para cada tratamiento se muestra en la Fig. 23. Los datos obtenidos muestran que los tratamientos R y G presentaron las mejores ganancias en masa y longitud. Sin embargo, el tratamiento G presentó la peor supervivencia entre todos los grupos. La FCR fue mejor en los grupos R y Natural, y la SGR fue significativamente mayor en los grupos R y G. Vale la pena

señalar que todos los tanques recibieron la misma cantidad de alimentos de acuerdo con la supervivencia que presentaron.

Tabla 8. Métricas obtenidas de las tilapias del Nilo.

Parámetros	Tratamientos			
	R	G	B	Natural
Biomasa inicial (g)	30	30	30	30
Masa inicial (g/pez)	0.2	0.2	0.3	0.3
Número inicial de peces	133	132	111	113
Biomasa final (g)	2193	1330	1461	1362
Total de biomasa ganada (g)	2163	1300	1431	1332
Número final de peces	127	79	94	84
Masa individual final (g/pez)	17.3 ± 3.3 ^a	16.8 ± 3.1 ^a	15.5 ± 2.8 ^b	16.2 ± 3.0 ^{ab}
Longitud individual final (cm/pez)	8.2 ± 1.0 ^a	8.0 ± 0.9 ^a	7.7 ± 0.9 ^b	7.9 ± 0.8 ^{ab}
Supervivencia (%)	95.5	59.9	84.7	74.3
SGR (%/día)	6.0	5.9	5.6	5.7
DWG (g/día)	0.2	0.2	0.2	0.2
FCR	0.8	1.3	1.2	1.0

Datos presentados en: promedio ± desviación estándar. Los valores en la misma fila con diferentes letras en superíndice indican diferencias significativas según el ANOVA de una vía y la prueba de Tukey ($p < 0.05$).




Figura 23. Peso final obtenido de los peces.

Las tilapias bajo luz roja tuvieron el mejor rendimiento en crecimiento debido a que obtuvieron los mejores valores de ganancia de masa, SGR, y DWG. Además, en el tratamiento R hubo una gran demanda de ingesta de alimento, el cual era consumido de inmediato al ser suministrado, lo cual se confirma por coincidir con el mejor FCR de 0.8. Esto en concordancia con la Ref. [159], donde se analizó la conducta de alimentación en juveniles de tilapia del Nilo, mostrando (en términos de tiempo (segundos) y señales químicas) que la motivación de alimentación es mayor bajo entornos de luz roja. También, un comportamiento similar fue observado en truchas arcoíris adultas [160], donde el crecimiento fue mayor bajo luz roja, y mostrando que bajo la luz roja, las truchas presentaron bajos niveles de cortisol (cortisol es la hormona asociada al estrés).

Por su parte, el tratamiento G mostró la segunda mejor ganancia de masa, pero también tuvo la menor supervivencia. Es posible descartar que esta baja supervivencia fuera causada por un pico de amoníaco y/o TAN, porque durante el período en que ocurrieron estas muertes, las mediciones de amoníaco y TAN estuvieron en el rango óptimo para la vida de las tilapias de Nilo. Un comportamiento similar de baja supervivencia bajo luz verde, fue también

observada y reportada para pequeños grupos de peces (4 peces por tanque) de tilapias del Nilo adultas [161]. Una posible razón de este fenómeno podría ser que se observó un comportamiento agresivo de los peces bajo el entorno de luz verde. Otra investigación relacionada, determinó a través de pruebas de sangre, los niveles de cortisol en tilapias de Nilo adulta, en esta encontraron que los niveles de cortisol incrementan bajo la luz verde [162]. Esto puede ser una causa de mortalidad, debido a que la luz verde crea ambientes estresantes que incrementan los niveles de cortisol en las tilapias. También, un alto nivel de cortisol afecta la composición nutricional de las tilapias, causando altos niveles de humedad y bajos niveles de proteína [163], como vamos a ver más adelante en nuestros resultados. Un bajo nivel de proteína se puede atribuir a un uso intensivo de proteínas musculares debido al intento de obtener energía adicional a la obtenida de los alimentos, lo que podría ser causado por el estrés debido a la luz verde [164].

Aly et al. [163] informaron que para la tilapia roja híbrida en agua salada, bajo luz azul, las tilapias presentaban el rendimiento de crecimiento más bajo y podían atribuirse a una visión reducida del pez bajo esta longitud de onda (también ver la Ref. [165]), lo que reduce la ingesta de alimentos. A su vez, Aly et al. encontraron que la tilapia bajo luz de color rojo tiene el mejor rendimiento de crecimiento. Estas observaciones están en concordancia con los resultados obtenidos, donde las tilapias del Nilo bajo luz azul presentaron el peor rendimiento de crecimiento, y bajo la luz roja el mejor rendimiento de crecimiento. Además, en la Ref. [161], para tilapias de Nilo adultas, se encontró que bajo la luz amarilla, estas tienen el mejor rendimiento de crecimiento, lo cual es similar a nuestros resultados, debido a que la luz amarilla tiene una longitud de onda larga cercana a la longitud de onda roja.

4.1.3. Composición nutricional de las tilapias y los bioflocs

Los valores promedios para la composición nutricional de las tilapias, y de los bioflocs como fuente de alimentos para los peces, se presentan en las Figs. 24 y 25, respectivamente.

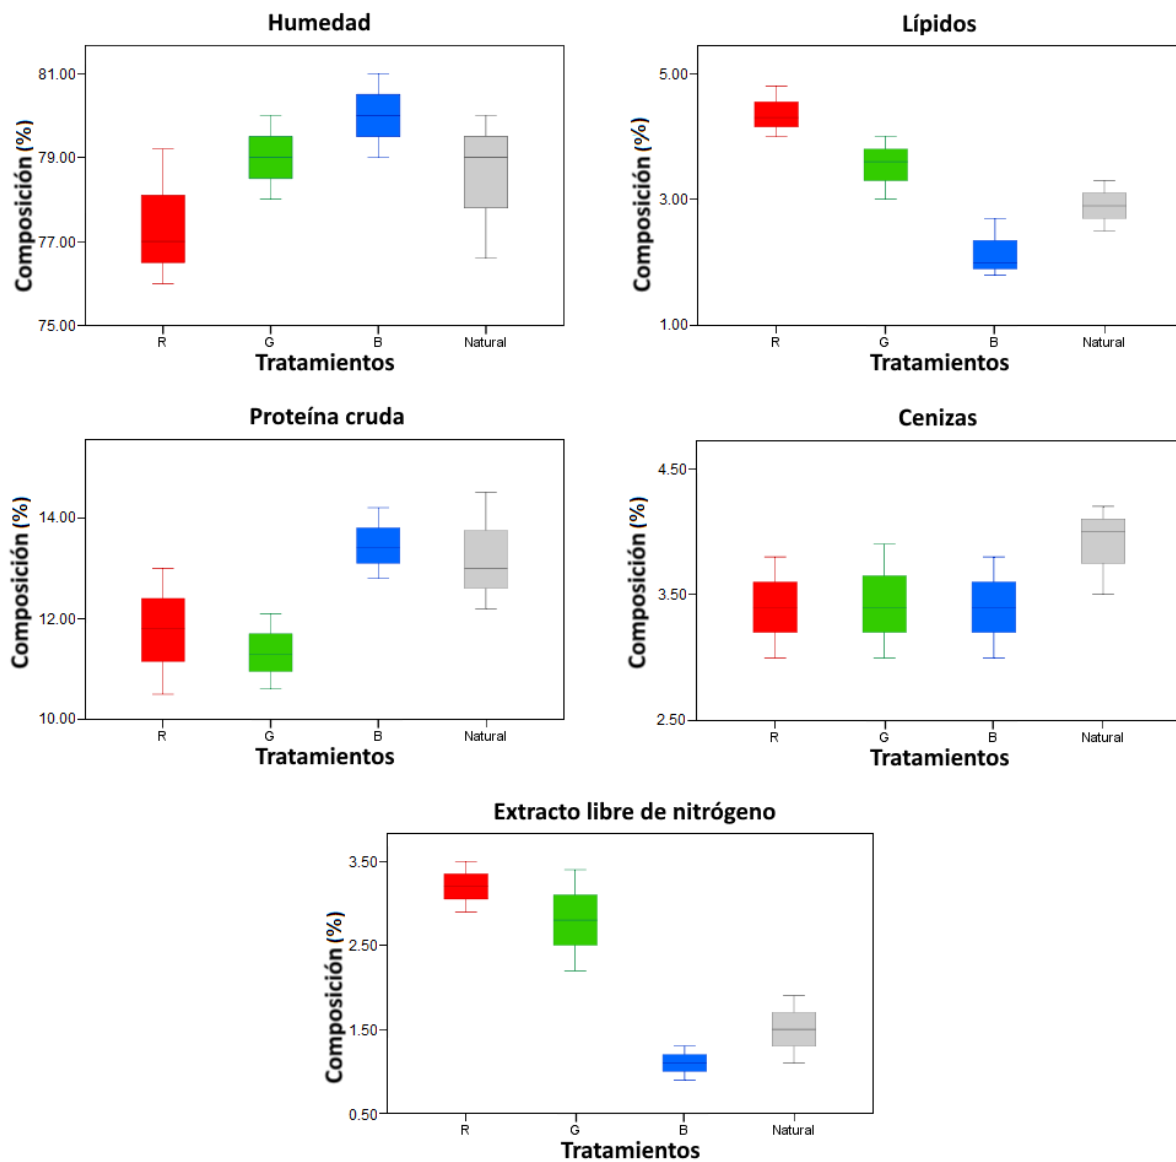


Figura 24. Composición nutricional de las tilapias en los tratamientos con luz R-G-B y Natural.

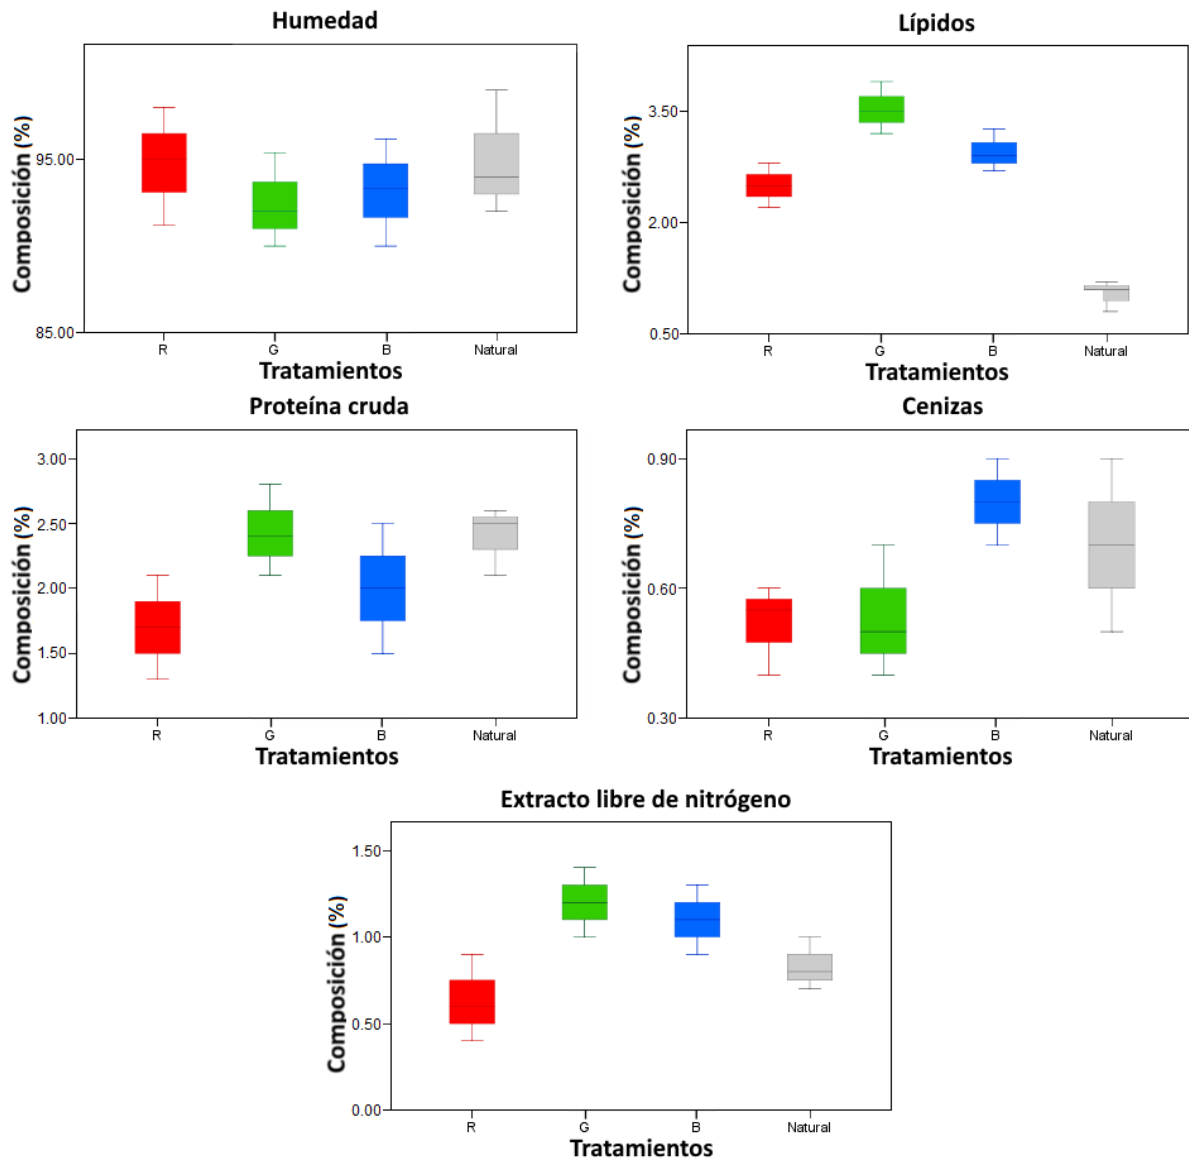


Figura 25. Composición nutricional de los bioflocs en los tratamientos con luz R-G-B y Natural.

De acuerdo con los resultados obtenidos de la composición nutricional de las tilapias del Nilo, el valor de humedad fue mayor en los peces bajo el tratamiento B. Además, los peces de los tratamientos B y Natural presentaron mayores niveles de proteína cruda en comparación con los otros tratamientos. Los contenidos minerales (cenizas) en los peces de los tratamientos R, G, y Natural fueron menores que los del tratamiento B. Los lípidos en la composición nutricional de los peces fueron muy influenciados por el uso de las luces de colores. Los peces en el tratamiento R mostraron un mayor contenido de lípidos y de extracto libre de nitrógeno, y también el menor contenido humedad. Esto indica que la humedad y los lípidos están inversamente relacionados, lo que está en concordancia con la Ref. [89].

Por su parte, las mediciones de la composición nutricional de los bioflocs en los grupos G y Natural mostraron una mayor concentración de proteína cruda en comparación con los otros tratamientos. Los niveles de cenizas en los bioflocs bajos los tratamientos R y G fueron menores que en los tratamientos B y Natural. Además, la composición nutricional promedio de los bioflocs bajo el tratamiento G, mostró un mayor contenido de lípidos y de extracto libre de nitrógeno. Además, aunque los bioflocs del tratamiento B tiene un alto nivel de lípidos, la composición nutricional de los peces bajo luz B tenía un bajo nivel de lípidos. Esta relación opuesta podría explicarse por la reducción del estrés por estar bajo luz azul [162], como también una reducción del estrés por tener una la dieta rica en lípidos [166]. Tal posible reducción del estrés reduciría la formación de depósitos de lípidos en los peces, lo que indica que la buena condición de salud de las tilapias bajo luz B podría deberse a la falta de estrés.

4.2. Fase II

En esta subsección presentamos los resultados de la evaluación de las métricas de rendimiento de la CNN. La CNN fue entrenada en cuatro ocasiones, en cada una se entrenó con un conjunto de datos de entrenamiento correspondientes a las imágenes de las muestras iluminadas con el mismo color de luz (4 colores de luz fueron utilizados: blanco, rojo, verde y azul). También, evaluamos la eficiencia de la MLR para estimar valores de TSS y turbidez. El conjunto de datos de validación utilizado consta de 9 clases para cada color, con 100 imágenes en cada clase.

Para la evaluación de la CNN, en la matriz de confusión, las filas están relacionadas con las predicciones verdaderas para las 9 clases, y las columnas con las etiquetas predichas por la CNN. A su vez, las celdas diagonales están vinculadas a las observaciones que se clasifican correctamente. Se alcanza una clasificación perfecta cuando cada espacio de los elementos de la diagonal principal alcanza el valor de 100. La matriz de confusión obtenida al final del proceso de entrenamiento para los cuatro colores de iluminación fue igual, y se muestra en la Fig. 26.

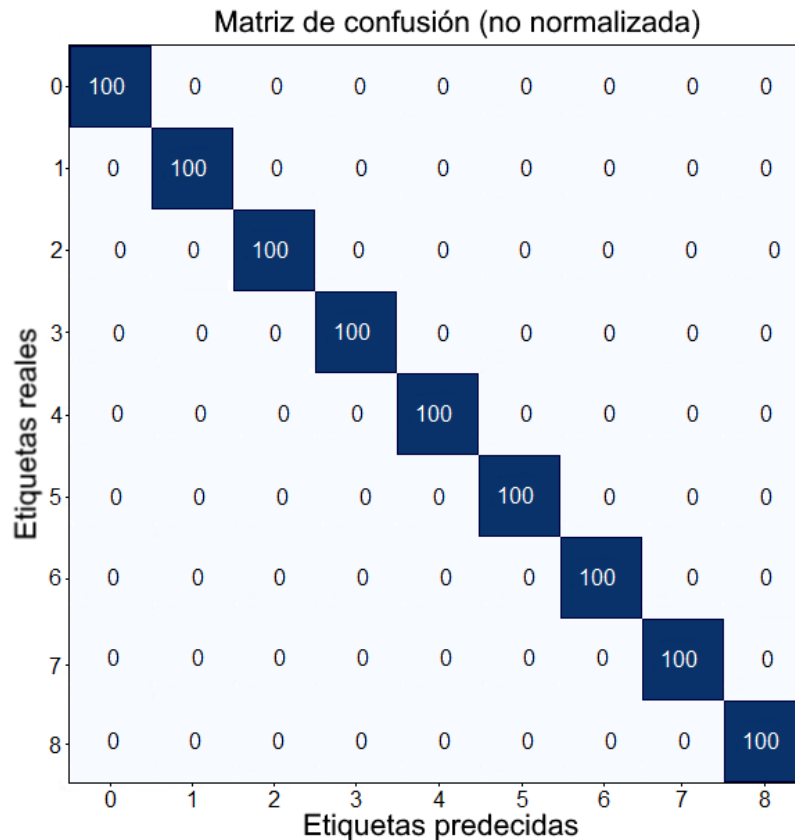


Figura 26. Matriz de confusión alcanzada en los cuatro entrenamientos.

Un aspecto relevante para comentar es que todos los colores alcanzan el mismo puntaje de matriz de confusión. Sin embargo, el tiempo de entrenamiento es diferente según el conjunto de datos de imagen, correspondientes a diferente color de iluminación, utilizado para entrenar la CNN. Aunque el interés está en los vectores de características obtenidos por la CNN para cada conjunto de datos de entrenamiento.

Al final del proceso de entrenamiento la CNN entrenada para cada conjunto de datos con diferente color de iluminación alcanza el puntaje máximo en: exactitud, precisión, sensibilidad, especificidad, puntaje F y ROC (ver Fig. 27).




Figura 27. Curva ROC obtenida en la evaluación del desempeño de la CNN. Nota: Todas las clases de color se superponen en la línea horizontal.

En la Tabla 9 se muestra el rendimiento obtenido para la CNN entrenada para cada conjunto de datos con diferente color de iluminación. El mejor tiempo de entrenamiento fue alcanzado por la CNN que usó las imágenes de las muestras iluminadas con luz blanca. Por otro lado, el peor tiempo de entrenamiento se obtuvo usando las imágenes iluminadas con luz verde. La diferencia entre el color blanco y el verde es del 266% en el tiempo de entrenamiento. Para el resto de los clasificadores, el color rojo fue el segundo lugar, mientras que el clasificador blanco alcanzó el puntaje máximo en casi la mitad del tiempo que el rojo.

Tabla 9. Métricas de evaluación del rendimiento de la CNN como clasificador

Métricas	Blanco	Rojo	Azul	Verde
Exactitud	1.0000	1.0000	1.0000	1.0000
Precisión	1.0000	1.0000	1.0000	1.0000
Sensibilidad	1.0000	1.0000	1.0000	1.0000
Puntaje F	1.0000	1.0000	1.0000	1.0000
Tiempo de entrenamiento (min)	65.380	102.88	156.53	174.11

La curva de aprendizaje y la pérdida de entrenamiento se muestran en la Fig. 28. Es fácil observar que el clasificador con el conjunto de datos de color azul fue el primero en un puntaje de exactitud alto, sin embargo, su proceso de entrenamiento comenzó con un valor de exactitud del 42% en su primera época, y sólo obtuvo el 100% de exactitud hasta la época número 15. Otro aspecto importante se refiere al clasificador con el conjunto de datos de color verde que comenzó con el puntaje de exactitud más bajo del 12%, y en la época 12, el clasificador verde alcanzó un valor de alta exactitud, pero continuó su proceso de entrenamiento con algunas fluctuaciones. El clasificador con el conjunto de datos de color blanco obtuvo el segundo lugar en alcanzar un puntaje alto de exactitud. Sin embargo, en su primera época, obtuvo un alto valor de exactitud del 90%, y en la época 7 obtuvo el 100% de exactitud.

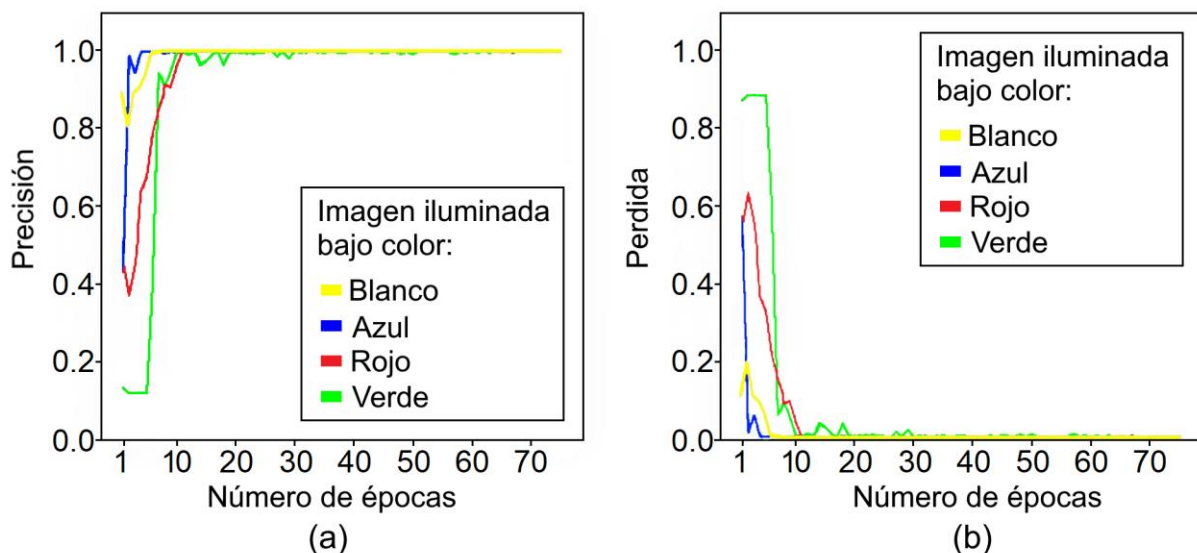


Figura 28. (a) Exactitud de entrenamiento del clasificador para cada conjunto de datos iluminado con diferentes colores, (b) Pérdida de entrenamiento del clasificador para cada conjunto de datos iluminado con diferentes colores.

Por otro lado, se calcularon las métricas de rendimiento para la MLR, y los resultados obtenidos para los diferentes conjuntos de datos bajo cada color de iluminación se muestran en la Tabla 10.

Tabla 10. Métricas de rendimiento de la MLR para los diferentes conjuntos de datos bajo cada color de iluminación.

Métricas	Blanco	Rojo	Azul	Verde
R^2	0.9911	0.9826	0.9579	0.9126
MAE	0.0161	0.0215	0.0350	0.0519
MSE	0.0004	0.0009	0.0022	0.0045
Desviación estándar	0.2281	0.2299	0.2241	0.2211

Al observar los resultados presentados en la Tabla 10, es fácil notar que la MLR para el conjunto de datos bajo luz blanca tiene el modelo con mejor calidad para replicar las mediciones debido a su mayor valor del coeficiente de determinación R^2 . Además, el MLR con el conjunto de datos bajo luz blanca tiene los valores más bajos de MAE y MSE, lo que implica que, con imágenes de muestras líquidas iluminadas bajo luz de color blanca, obtenemos el mejor rendimiento de MLR para la tarea de estimación, a diferencia de las imágenes iluminadas con color verde, con las cuales se obtiene el menor rendimiento de la MLR.

Las muestras líquidas creadas para esta investigación tienen un rango de TSS de 0-800 mg/l. Los TSS estimados por la CNN y la MLR para los diferentes conjuntos de datos bajo cada color de iluminación utilizado se muestra en la Tabla 11.

Tabla 11. Los valores de TSS estimados por la CNN y la MLR para cada conjunto de datos bajo diferente color de iluminación. Se muestran los valores promedio \pm desviación estándar en unidades de gL^{-1} .

Clases	Colores			
	Blanco	Rojo	Azul	Verde
0	0.0188 \pm 0.0237	0.0213 \pm 0.0016	0.0212 \pm 0.0353	0.0827 \pm 0.1017
1	0.1087 \pm 0.0130	0.1172 \pm 0.0264	0.1179 \pm 0.0307	0.1197 \pm 0.0560
2	0.1895 \pm 0.0141	0.2028 \pm 0.0163	0.2151 \pm 0.0410	0.2152 \pm 0.0187
3	0.2959 \pm 0.0168	0.3033 \pm 0.0157	0.3103 \pm 0.0362	0.2623 \pm 0.0197
4	0.3959 \pm 0.0203	0.3970 \pm 0.0333	0.3994 \pm 0.0607	0.3191 \pm 0.0429
5	0.4942 \pm 0.0360	0.4997 \pm 0.0516	0.4959 \pm 0.0387	0.5120 \pm 0.0410
6	0.5916 \pm 0.0152	0.5920 \pm 0.0351	0.5908 \pm 0.0627	0.5493 \pm 0.0646
7	0.7054 \pm 0.0138	0.7128 \pm 0.0232	0.6850 \pm 0.0501	0.6931 \pm 0.0541
8	0.8099 \pm 0.0126	0.7784 \pm 0.0221	0.7852 \pm 0.0686	0.8476 \pm 0.0105

La Fig. 29 muestra una comparación de los resultados presentados en la Tabla 11 con los valores reales de TSS.

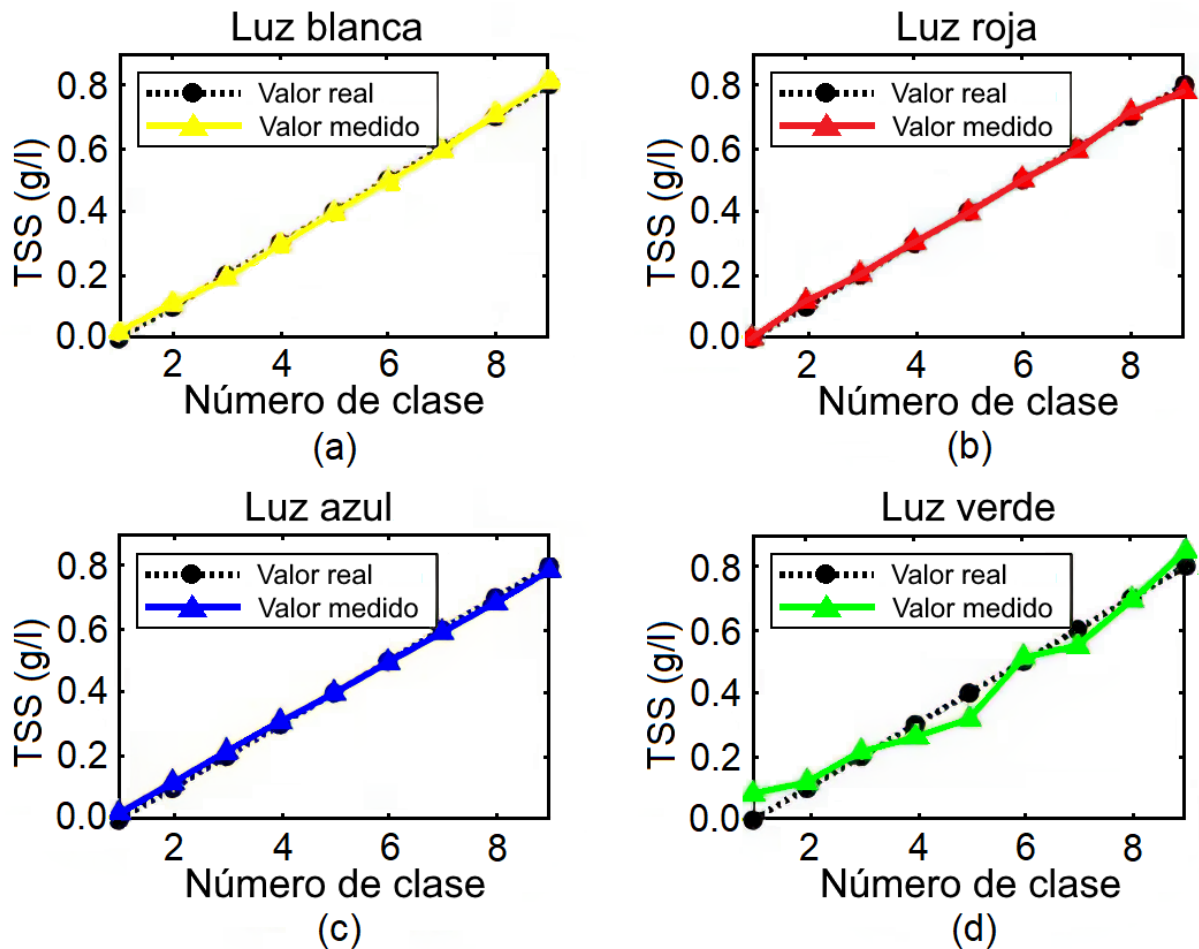


Figura 29. Comparación entre los valores medidos utilizando el método propuesto y los valores reales de concentración de TSS de las muestras líquidas. Los valores de concentración reales se dibujan usando una línea negra. Los gráficos muestran TSS versus valores predichos para (a) luz blanca, (b) luz roja, (c) luz azul y (d) luz verde.

El error calculado entre las mediciones estimadas por el método propuesto y las concentraciones reales de las muestras se presentan en la Tabla 12. Además, los valores del MAE y del MSE calculados para cada conjunto de datos para color también se muestran.

Tabla 12. Métricas de evaluación del método propuesto para todas las clases de acuerdo con cada conjunto de datos de color.

Colores	Métricas	Clases								
		0	1	2	3	4	5	6	7	8
Blanco	Error (%)	0.1880	8.7000	5.2500	1.3666	1.0250	1.1600	1.4000	0.7714	1.2375
	MAE	0.0188	0.0107	0.0143	0.0133	0.0163	0.0282	0.0141	0.0126	0.0133
	MSE	0.0006	0.0002	0.0003	0.0002	0.0004	0.0013	0.0002	0.0002	0.0002
Rojo	Error (%)	0.2130	17.2000	1.4000	1.1000	0.7500	0.0600	1.3333	1.8285	2.7000
	MAE	0.0213	0.0262	0.0131	0.0126	0.0267	0.0430	0.0267	0.0218	0.0242
	MSE	0.0000	0.0009	0.0002	0.0002	0.0011	0.0026	0.0012	0.0007	0.0009
Azul	Error (%)	0.2120	17.9000	7.5500	3.4333	0.1500	0.8200	1.5333	2.1428	1.8500
	MAE	0.0212	0.0282	0.0353	0.0297	0.0483	0.0289	0.0487	0.0401	0.0442
	MSE	0.0013	0.0012	0.0019	0.0014	0.0036	0.0015	0.0039	0.0027	0.0033
Verde	Error (%)	0.8270	19.7000	7.6000	12.5666	20.2250	2.4000	8.4500	0.9857	5.9500
	MAE	0.0827	0.0506	0.0194	0.0378	0.0810	0.0352	0.0664	0.0435	0.0649
	MSE	0.0111	0.0034	0.0005	0.0018	0.0083	0.0018	0.0066	0.0029	0.0054

El error relativo promedio para el método propuesto tiene un valor de 2.3442% para el estimador que usa el conjunto de datos bajo luz blanca, 2.9538% para el estimador que usa el conjunto de datos bajo luz roja, 3.9546% para el estimador que usa el conjunto de datos bajo luz azul y 8.7449% para el estimador que usa el conjunto de datos bajo luz verde. El promedio de MAE y MSE es 0.01573 y 0.00042 para el estimador que usa el conjunto de datos bajo luz blanca, 0.0237 y 0.00086 para el conjunto de datos bajo luz roja, 0.0360 y 0.00231 para el conjunto de datos bajo luz azul, y 0.0535 y 0.0046 para el conjunto de datos bajo luz verde, respectivamente. Por lo tanto, la mejor luz para el método propuesto es el color blanco.

El método propuesto con el conjunto de datos bajo iluminación de color blanco tiene un rango operativo de 0 a 0.8 g/L, y una alta repetibilidad de medición de 0.9911 de acuerdo con el R^2 . Además, el color blanco obtuvo un error de $\pm 2.3442\%$ y una desviación estándar general de ± 0.0183 .

De acuerdo con los valores de turbidez medidos con un turbidímetro HACH DR900, el rango operativo del método propuesto es de 0-263 NTU (consulte la Tabla 13). Las mediciones realizadas con el turbidímetro se replicaron seis veces para obtener la desviación estándar del dispositivo.

Se debe tener en cuenta que el turbidímetro DR900, cuando realiza mediciones cercanas a 200 NTU, tiene grandes desviaciones, debido a que el turbidímetro, se ajusta y/o aproxima a una curva de calibración utilizando la lectura obtenida con el estándar de formazin de 200 NTU.

Además, de acuerdo con el manual del usuario, el error del turbidímetro es de ± 21 NTU [167]. Con los resultados de la Tabla 14 es posible deducir que el MLR con imágenes iluminadas con luz blanca obtiene un error de valor máximo de ± 13.6800 NTU. El cual, es el error más bajo entre todos los conjuntos de datos bajo los diferentes colores de iluminación, y a su vez tiene un error más bajo que el del turbidímetro utilizado como referencia.

Tabla 13. Mediciones de turbidez con un turbidímetro DR900. Se muestran los valores de turbidez en valor promedio \pm desviación estándar, correspondientes a los valores de referencia de TSS o clase.

Clases	TSS(g/l)	Turbidez (NTU)
0	0.0000	0 ± 0.5477
1	0.1000	38 ± 2.6076
2	0.2000	77 ± 7.0616
3	0.3000	95 ± 13.6186
4	0.4000	132 ± 12.3720
5	0.5000	168 ± 12.6754
6	0.6000	189 ± 22.6578
7	0.7000	245 ± 21.6469
8	0.8000	263 ± 23.7343

Tabla 14. Valores de turbidez medidos con el método propuesto. Valores promedios \pm desviación estándar de la turbidez estimada por la CNN y la MLR para cada conjunto de datos bajo diferentes colores de iluminación.

Clases	Colores			
	Blanco	Rojo	Azul	Verde
0	7.1440 ± 9.0060	8.0940 ± 6.0800	8.0560 ± 13.4140	31.4260 ± 38.6460
1	41.3930 ± 4.9400	44.7080 ± 10.0320	44.9810 ± 11.6660	45.6830 ± 21.2800
2	75.0500 ± 5.3580	77.5040 ± 6.1940	79.7180 ± 15.5800	79.7360 ± 7.1060
3	94.2620 ± 6.3840	96.2210 ± 5.9660	98.8110 ± 13.7560	88.2140 ± 7.4860
4	130.4830 ± 7.7140	130.8900 ± 12.6540	131.7780 ± 23.0660	102.0670 ± 16.3020
5	165.9120 ± 13.6800	167.8920 ± 19.6080	166.5240 ± 14.7060	170.5200 ± 15.5800
6	187.2360 ± 5.7760	187.3200 ± 0.0351	187.0680 ± 23.8260	178.3530 ± 24.5480
7	245.9720 ± 5.2440	247.3040 ± 8.8160	236.6000 ± 19.0380	241.1360 ± 20.5580
8	266.2540 ± 4.7880	259.1120 ± 8.3980	260.3360 ± 26.0680	278.6480 ± 3.9900

La Tabla 15 muestra los errores relativos entre las mediciones de turbidez realizadas con el turbidímetro DR900 y el método propuesto con las imágenes bajo diferentes colores de iluminación.

Tabla 15. Error relativo entre la turbidez medida con el turbidímetro DR900 y el método propuesto para cada clase.

Colores	Error relativo (%) para cada clase								
	0	1	2	3	4	5	6	7	8
Blanco	71.4400	8.9289	2.5324	0.7768	1.1492	1.2428	0.9333	0.3967	1.2372
Rojo	80.9400	17.6526	0.6545	1.2852	0.8409	0.0642	0.8888	0.9404	1.4783
Azul	80.5600	18.3710	3.5298	4.0115	0.1681	0.8785	1.0222	3.4285	1.0129
Verde	314.2600	20.2184	3.5532	7.1431	22.6765	1.5000	5.6333	1.5771	5.9498

Los errores relativos promedio para los valores de turbidez obtenidos con el método propuesto son diferentes para cada color: 9.8585% para la luz blanca, 11.6383% para la luz roja, 12.5536% para la luz azul y 42.5012% para la luz verde. El rango de operación de 0-263 NTU es apropiado para ambientes acuáticos, debido a que el nivel de turbidez seguro para la vida acuática no debe exceder 25 NTU [168]. La precisión del método propuesto tiene un valor de ± 6.9877 , y una exactitud del 9.8585% para imágenes iluminadas con la luz blanca, que es el mejor color de luz para el método propuesto. Con respecto a otras investigaciones, encontramos que Mullins et al. realizaron mediciones de turbidez en el rango de 10-250 NTU, utilizando métodos de procesamiento de imágenes, donde deben procesar y analizar imagen por imagen en el proceso de medición, con condiciones ambientales controladas. Además, sus mediciones alcanzan un error del 10% [47]. Wang et al., realizan mediciones de turbidez en función de la detección de luz transmitida, y también alcanzan una exactitud del 10% [169]. En otra investigación desarrollada por Bayram et al., determinaron valores de turbidez usando un teléfono inteligente, sin embargo, el error entre las muestras medidas con el turbidímetro Hach calibrado y el turbidímetro de su teléfono inteligente fue de 51.4583% según los datos mostrados en su documento [170]. Leeuw y Boss también midieron la turbidez usando un teléfono inteligente a través de la detección remota de la reflectancia del agua de acuerdo a las condiciones ambientales, alcanzando una precisión del 26% [171].

CONCLUSIONES

En esta investigación se propuso la implementación de sistemas de iluminación LED en sistemas intensivos de tilapia con BFT, que mejoren la producción, el crecimiento y la composición nutricional de las tilapias, y de los bioflocs como fuente de alimento para las tilapias. Además, se desarrolló un nuevo método para monitorear parámetros como la turbidez y los sólidos suspendidos totales (TSS), mediante redes neuronales convolucionales.

En la primera fase investigamos la influencia de la luz de color RGB en el crecimiento y la composición nutricional de la tilapia en los sistemas de biofloc. También medimos el efecto de la luz de color en la composición nutricional del biofloc como fuente de alimento para las tilapias. Los resultados mostraron que la longitud de onda o el color de la luz tuvieron un efecto significativo en el crecimiento y la composición nutricional de la tilapia, que puede usarse para mejorar la sostenibilidad y la eficiencia de la producción de tilapia ajustada a la necesidad de los consumidores. En el caso de las tilapias bajo luz azul, estas presentaron la tasa de crecimiento más baja; sin embargo, bajo la luz azul mejoraron significativamente los niveles de proteína, se tuvo un bajo nivel de lípidos y se obtuvo el crecimiento más homogéneo entre todos los tratamientos. Por su parte, el efecto de la luz roja sobre el crecimiento de las tilapias fue bastante significativo. Las tilapias bajo luz roja presentaron el mejor aumento de peso, la mejor longitud del cuerpo y la mejor supervivencia, pero también el nivel más alto de contenido de lípidos. Por otra parte, las tilapias obtuvieron el menor contenido de cenizas en los tratamientos bajo las luces de color RGB en comparación con el tratamiento bajo solo luz natural. Además, estos resultados muestran que la luz de color afecta los contenidos de lípidos, proteínas y cenizas en los bioflocs, como fuente de alimento para los peces.

Estos resultados brindan apoyo a futuros estudios en la acuicultura para mejorar la producción de peces de una forma eficiente, sostenible e intensiva. Por ejemplo, nuestros resultados sugieren que la tasa de crecimiento, la eficiencia de utilización del alimento, la supervivencia y la composición nutricional de las tilapias se puede controlar mediante el uso de la luz de color. Además, investigaciones futuras podrían incluir el efecto de diferentes niveles de intensidad, fotoperiodos y espectros de luz. Por ejemplo: el espectro amplio de la luz con formas especialmente diseñadas [172], resultante de la combinación de LEDs de diferentes colores e intensidades, para obtener los mejores efectos de cada longitud de onda de la luz, a

fin de maximizar la calidad nutricional de las tilapias y los bioflocs, ajustados a la necesidad de los consumidores y, en el futuro, a la escasez de recursos alimentarios.

Por su parte en la segunda fase se propuso un nuevo método de medición para estimar en muestras líquidas valores de TSS y turbidez, utilizando una CNN, una MLR y un teléfono celular inteligente. La CNN y la MLR desarrolladas pueden estimar valores de TSS y turbidez utilizando imágenes grabadas por un teléfono inteligente común bajo iluminación LED. Se evaluó el método usando iluminación LED de diferentes colores, en específico: roja, verde, azul y blanca. El método se desempeñó mejor al iluminar las muestras con luz blanca. Este método reduce la necesidad de intervención humana y el costo de realizar mediciones de TSS y turbidez. Los resultados muestran la efectividad del método propuesto e indican una alta resolución y precisión en comparación con las mediciones realizadas con turbidímetros comerciales. Como trabajo futuro, se podría hacer una extensión de rango de medición (agregar muestras líquidas) y una ampliación del conjunto de datos de entrenamiento, con el objetivo de lograr un mejor rendimiento del método.

REFERENCIAS

1. Belton, B.; Bush, S.R.; Little, D.C. Not just for the wealthy: Rethinking farmed fish consumption in the Global South. *Global food security* **2017**, *16*, 85–92.
2. FAO The State of World Fisheries and Aquaculture, 2016. Contributing to food security and nutrition for all. In Proceedings of the The State of World Fisheries and Aquaculture, 2016. Contributing to food security and nutrition for all; Rome, Italy, 2016; p. 200.
3. Pauly, D.; Zeller, D. Comments on FAOs state of world fisheries and aquaculture (SOFIA 2016). *Marine Policy* **2017**, *77*, 176–181.
4. WWAP The United Nations World Water Development Report 2015: Water for a Sustainable World. *Paris, France* **2015**, UNESCO.
5. Arias-Moscoso, J.L.; Espinoza-Barrón, L.G.; Miranda-Baeza, A.; Rivas-Vega, M.E.; Nieves-Soto, M. Effect of commercial probiotics addition in a biofloc shrimp farm during the nursery phase in zero water exchange. *Aquaculture Reports* **2018**, *11*, 47–52.
6. Avnimelech, Y. *Biofloc Technology: A Practical Guide Book*; 1st ed.; World Aquaculture Society: Baton Rouge, Louisiana, United States., 2009; Vol. 1; ISBN 978-1-888807-16-5.
7. Crab, R.; Defoirdt, T.; Bossier, P.; Verstraete, W. Biofloc technology in aquaculture: beneficial effects and future challenges. *Aquaculture* **2012**, *356*, 351–356.
8. Avnimelech, Y. Feeding with microbial flocs by tilapia in minimal discharge bio-flocs technology ponds. *Aquaculture* **2007**, *264*, 140–147.
9. Avnimelech, Y.; Verdegem, M.; Kurup, M.; Keshavanath, P. Sustainable land-based aquaculture: rational utilization of water, land and feed resources. *Mediterranean Aquaculture Journal* **2008**, *1*, 45–55.
10. Azim, M.E.; Little, D.C. The biofloc technology (BFT) in indoor tanks: water quality, biofloc composition, and growth and welfare of Nile tilapia (*Oreochromis niloticus*). *Aquaculture* **2008**, *283*, 29–35.
11. Emerenciano, M.; Ballester, E.L.; Cavalli, R.O.; Wasielesky, W. Biofloc technology application as a food source in a limited water exchange nursery system for pink shrimp *Farfantepenaeus brasiliensis* (Latreille, 1817). *Aquaculture research* **2012**, *43*, 447–457.
12. Green, B.W.; Rawles, S.D.; Webster, C.D.; McEntire, M.E. Effect of Stocking Rate on Growing Juvenile Sunshine Bass, *Morone chrysops* x *M. saxatilis*, in an Outdoor Biofloc Production System. *Journal of the World Aquaculture Society* **2018**, *49*, 827–836.
13. Moyle, P.B.; Cech, J.J. *Fishes: An Introduction to Ichthyology*; Pearson Prentice Hall, 2004;
14. Njiru, M.; Okeyo-Owuor, J.; Muchiri, M.; Cowx, I. Shifts in the food of Nile tilapia, *Oreochromis niloticus* (L.) in Lake Victoria, Kenya. *African Journal of Ecology* **2004**, *42*, 163–170.
15. Asche, F.; Cojocar, A.L.; Roth, B. The development of large scale aquaculture production: A comparison of the supply chains for chicken and salmon. *Aquaculture* **2016**, *493*, 446–455.
16. Boeuf, G.; Le Bail, P.-Y. Does light have an influence on fish growth? *Aquaculture* **1999**, *177*, 129–152.
17. Ridha, M.; Cruz, E. Effect of light intensity and photoperiod on Nile tilapia *Oreochromis niloticus* L. seed production. *Aquaculture Research* **2000**, *31*, 609–617.
18. Heydarnejad, M.S.; Parto, M.; Pilevarian, A.A. *Journal of Animal Physiology and Animal Nutrition*. 2013.
19. Karakatsouli, N.; Papoutsoglou, E.S.; Sotiropoulos, N.; Mourtikas, D.; Stigen-Martinsen, T.; Papoutsoglou, S.E. Effects of light spectrum, rearing density and light intensity on growth performance of scaled and mirror common carp *Cyprinus carpio* reared under recirculating system conditions. *Aquacultural Engineering* **2010**, *42*, 121–127.
20. Ruchin, A.B. Environmental colour impact on the life of lower aquatic vertebrates: development, growth, physiological and biochemical processes. *Reviews in Aquaculture* **2018**, *1–18*.

21. Ruchin, A.B. Influence of Colored Light on Growth rate of Juveniles of Fish. *Fish Physiology and Biochemistry* **2004**, *30*, 175–178.
22. Karakatsouli, N.; Papoutsoglou, S.E.; Pizzonia, G.; Tsatsos, G.; Tsopelekos, A.; Chadio, S.; Kalogiannis, D.; Dalla, C.; Polissidis, A.; Papadopoulou-Daifoti, Z. Effects of light spectrum on growth and physiological status of gilthead seabream *Sparus aurata* and rainbow trout *Oncorhynchus mykiss* reared under recirculating system conditions. *Aquacultural Engineering* **2007**, *36*, 302–309.
23. Bayarri, M.; Madrid, J.; Sánchez-Vázquez, F. Influence of light intensity, spectrum and orientation on sea bass plasma and ocular melatonin. *Journal of pineal research* **2002**, *32*, 34–40.
24. Hoang, T.; Barchiesi, M.; Lee, S.Y.; Keenan, C.P.; Marsden, G.E. Influences of light intensity and photoperiod on moulting and growth of *Penaeus merguensis* cultured under laboratory conditions. *Aquaculture* **2003**, *216*, 343–354.
25. Neal, R.S.; Coyle, S.D.; Tidwell, J.H.; Boudreau, B.M. Evaluation of stocking density and light level on the growth and survival of the Pacific white shrimp, *Litopenaeus vannamei*, reared in zero-exchange systems. *Journal of the World Aquaculture Society* **2010**, *41*, 533–544.
26. Moreno, I.; Contreras, U. Color distribution from multicolor LED arrays. *Optics express* **2007**, *15*, 3607–3618.
27. Moreno, I.; Sun, C.C. Modeling the radiation pattern of LEDs. *Optics express* **2008**, *16*, 1808–1819.
28. Žukauskas, A.; Shur, M.; Gaska, R. *Introduction to Solid-State Lighting*; 1st ed.; Wiley, 2002; Vol. 1; ISBN 978-0-471-21574-5.
29. Zheludev, N. The life and times of the LED — a 100-year history. *Nature Photonics* **2007**, *1*, 189.
30. Dupuis, R.D.; Krames, M.R. History, Development, and Applications of High-Brightness Visible Light-Emitting Diodes. *J. Lightwave Technol.* **2008**, *26*, 1154–1171.
31. Mottier, P. *LED for Lighting Applications*; ISTE; 1st ed.; Wiley, 2010; Vol. 1; ISBN 978-0-470-61029-9.
32. Arredondo, F.; Lozano, S. Fundamentos de acuicultura. *Universidad Autónoma Metropolitana–Iztapalapa, México* **1996**, *1*, 1–23.
33. Juárez–Palacios, R. La acuicultura en México, importancia social y económica. *Desarrollo Pesquero Mexicano. Secretaría de Pesca. México.* **1987**, *1*, 219–232.
34. Ceballos Orozco, M.L.; Velázquez Escobar, M.A. *Perfiles de la alimentación de peces y crustáceos en los centros y unidades de producción acuícola en México. Cap. 2. Marco actual de la acuicultura en México*; 1st ed.; Organización de las naciones unidas para la agricultura y la alimentación (FAO): Pachuca, Hidalgo. México, 1988; Vol. 1; ISBN 968-817-159-X.
35. Martínez Palacios, C.A.; Chávez Sánchez, M.C.; Varsi, Enrico. La nutrición y alimentación en la acuicultura de América Latina y el Caribe. Cap. 8. El estado actual de la acuicultura en México y perfiles de nutrición y alimentación. In *Proceedings of the Taller regional sobre nutrición y alimentación en acuicultura*; FAO: Mazatlán, Sin., México, 1992; Vol. 1, p. 20.
36. Murray, F.; Bostock, J.; Fletcher, D. Review of recirculation aquaculture system technologies and their commercial application. *Highlands and Islands Enterprise. University of Stirling Aquaculture* **2014**, 1–82.
37. Chamberlain, G.; Hopkins, J. Reducing water use and feed cost in intensive ponds. *World Aquaculture* **1994**, *25*, 29–33.
38. Hopkins, J.S.; Hamilton, R.D.; Sandier, P.A.; Browdy, C.L.; Stokes, A.D. Effect of water exchange rate on production, water quality, effluent characteristics and nitrogen budgets of intensive shrimp ponds. *Journal of the World Aquaculture Society* **1993**, *24*, 304–320.
39. Avnimelech, Y.; Kochva, M.; Diab, S. Development of controlled intensive aquaculture systems with a limited water exchange and adjusted carbon to nitrogen ratio. *Israeli Journal of Aquaculture* **1994**, *46*, 119–131.
40. Teuscher, C.; Hofstadter, D.; Hofstadter, D.; Turing, A. *Alan Turing: Life and Legacy of a Great Thinker*; Springer, 2004; ISBN 978-3-540-20020-8.

41. Fukushima, K. Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biol. Cybernetics* **1980**, *36*, 193–202.
42. Lecun, Y.; Bottou, L.; Bengio, Y.; Haffner, P. Gradient-based learning applied to document recognition. *Proceedings of the IEEE* **1998**, *86*, 2278–2324.
43. Bilotta, G.S.; Brazier, R.E. Understanding the influence of suspended solids on water quality and aquatic biota. *Water research* **2008**, *42*, 2849–2861.
44. Qin, S.; Cai, X.; Ma, L. A novel light fluctuation spectrum method for in-line particle sizing. *Frontiers in Energy* **2012**, *6*, 89–97.
45. Moran, C.J.; Ward, D.L.; Gibb, A.C. Key Morphological Features Favor the Success of Nonnative Fish Species under Reduced Turbidity Conditions in the Lower Colorado River Basin. *Transactions of the American Fisheries Society* **2018**, *147*, 948–958.
46. Yang, Y.; Wang, H.; Cao, Y.; Gui, H.; Liu, J.; Lu, L.; Cao, H.; Yu, T.; You, H. The design of rapid turbidity measurement system based on single photon detection techniques. *Optics & Laser Technology* **2015**, *73*, 44–49.
47. O'Dell, J.W. Determination of turbidity by nephelometry. In *Methods for the Determination of Metals in Environmental Samples*; Elsevier, 1996; pp. 378–387 ISBN 978-0-8155-1398-8.
48. FAO *Depósito de documentos de la FAO: Los pequeños estanques: Grandes integradores de la producción agropecuaria y la cría de peces - Algunos elementos básicos de la Acuicultura: Historia, Definición y Objeto*; 2000; ISBN 92-5-304599-X.
49. Clarke, G.L.; Kelly, M.G. Measurements of diurnal changes in bioluminescence from the sea surface to 2,000 meters using a new photometric device. *Limnol. Oceanogr* **1965**, *10*, R54–R66.
50. Richardson, N.; McCleave, J. Locomotor activity rhythms of juvenile Atlantic salmon (*Salmo salar*) in various light conditions. *The Biological Bulletin* **1974**, *147*, 422–432.
51. McCleave, J.D.; Albert, E.H.; Richardson, N.E. *Perception and Effects on Locomotor Activity in American Eels and Atlantic Salmon of Extremely Low Frequency Electric and Magnetic Fields*; Defense Technical Information Center: Maine univ orono dept of zoology, 1974; p. 60.
52. Cole, J.J.; Findlay, S.; Pace, M.L. Bacterial production in fresh and saltwater ecosystems: a cross-system overview. *Marine ecology progress series* **1988**, *43*, 1–10.
53. Avnimelech, Y. Modelling the accumulation of organic matter in the sediments of a newly constructed reservoir. *Water Research* **1989**, *23*, 1327–1329.
54. Thorpe, J.; Adams, C.; Miles, M.; Keay, D. Some influences of photoperiod and temperature on opportunity for growth in juvenile Atlantic salmon, *Salmo salar* L. *Aquaculture* **1989**, *82*, 119–126.
55. Ounais-Guschemann, N. Définition d'un modèle d'élevage larvaire intensif pour la daurade *Sparus auratus*. PhD thesis, Université Aix-Marseille, Discipline: Océanologie, 1989.
56. Huisman, J.; Weissing, F.J. Light-limited growth and competition for light in well-mixed aquatic environments: an elementary model. *Ecology* **1994**, *75*, 507–520.
57. Gurung, T.B.; Urabe, J.; Nakanishi, M. Regulation of the relationship between phytoplankton *Scenedesmus acutus* and heterotrophic bacteria by the balance of light and nutrients. *Aquatic Microbial Ecology* **1999**, *17*, 27–35.
58. Timmons, Michael.; Ebeling, James. *Recirculating Aquaculture Systems, in Aquaculture Production Systems (ed J. H. Tidwell)*; 3rd ed.; Wiley-Blackwell: Oxford, UK, 2012; Vol. 3; ISBN 978-0-8138-0126-1.
59. Rier, S.T.; Stevenson, R.J. Effects of light, dissolved organic carbon, and inorganic nutrients on the relationship between algae and heterotrophic bacteria in stream periphyton. *Hydrobiologia* **2002**, *489*, 179–184.
60. Hari, B.; Kurup, B.; Varghese, J.; Schrama, J.; Verdegem, M. The effect of carbohydrate addition on water quality and the nitrogen budget in extensive shrimp culture systems. *Aquaculture* **2006**, *252*, 248–263.

61. Hari, B.; Kurup, B.; Varghese, J.; Schrama, J.; Verdegem, M. Effects of carbohydrate addition on production in extensive shrimp culture systems. *Aquaculture* **2004**, *241*, 179–194.
62. Saavedra, M. *Manejo Del cultivo de tilapia*; Facultad de Ciencia, Tecnología y Ambiente. Universidad Centroamericana. Managua, Nicaragua, 2006; pp. 1–15.
63. Alonso-Sáez, L.; Gasol, J.; Lefort, T.; Hofer, J.; Sommaruga, R. Effect of natural sunlight on bacterial activity and differential sensitivity of natural bacterioplankton groups in northwestern Mediterranean coastal waters. *AEM* **2006**, *72*, 5806–5813.
64. De Schryver, P.; Crab, R.; Defoirdt, T.; Boon, N.; Verstraete, W. The basics of bio-flocs technology: the added value for aquaculture. *Aquaculture* **2008**, *277*, 125–137.
65. Avnimelech, Y. Biofloc technology. *A practical guide book. The World Aquaculture Society, Baton Rouge* **2009**, 182.
66. Yoon, H.; Hwang, J.; Choi, S. Effect of light intensity on first feeding of the chub mackerel *Scomber japonicus* larvae. *Animal cells and systems* **2010**, *14*, 125–128.
67. Tello, J.; Martínez, C. Efecto del fotoperiodo y la temperatura en el crecimiento y determinación sexual del pez blanco de Pátzcuaro (*Menidia estor*). PhD thesis, Universidad Michoacana de San Nicolás de Hidalgo - Programa institucional de Maestría en Ciencias Biológicas, Morelia, Michoacán, 2010.
68. Coyle, S.; Bright, L.; Wood, D.; Neal, R.; Tidwell, J. Performance of pacific white shrimp, *Litopenaeus vannamei*, reared in zero-exchange tank systems exposed to different light sources and intensities. *Journal of the World Aquaculture Society* **2011**, *42*, 687–695.
69. Arredondo-Figueroa, J.; Núñez-García, L.; Heredia-Guzmán, P.; Ponce-Palafox, J. Reproductive performance of the Mesa silverside (*Chirostoma jordani* Woolman, 1894) under natural and controlled photoperiods. *Biocell* **2012**, *36*, 105–111.
70. Baloi, M.; Arantes, R.; Schweitzer, R.; Magnotti, C.; Vinatea, L. Performance of Pacific white shrimp *Litopenaeus vannamei* raised in biofloc systems with varying levels of light exposure. *Aquacultural engineering* **2013**, *52*, 39–44.
71. Olvera-Gonzalez, E.; Alaniz-Lumbreras, D.; Ivanov-Tsonchev, R.; Villa-Hernández, J.; Olvera-Olvera, C.; González-Ramírez, E.; Araiza-Esquível, M.; Torres-Argüelles, V.; Castaño, V. Intelligent lighting system for plant growth and development. *Computers and electronics in agriculture* **2013**, *92*, 48–53.
72. García, P.; Olvera, C.; Gonzáles, E. Evaluación de la composición de los Bio-flocs y determinación de la relación proteína-turbidez enfocado al desarrollo de un sistema de control. PhD. thesis, Universidad Autónoma de Zacatecas - Programa de Maestría en Ciencias de la Ingeniería, 2013.
73. Avnimelech, Y.; Bejerano, I. Probiotic effects of Biofloc technology: depression of tilapia infection by streptococcus. In Proceedings of the Proceedings of the Biofloc Technology and shrimp disease workshop. Saigon exhibition and convention center; Ho Chi Minh City, Vietnam, 2013.
74. Teo, C.; Atta, M.; Bukhari, A.; Taisir, M.; Yusuf, A.; Idris, A. Enhancing growth and lipid production of marine microalgae for biodiesel production via the use of different LED wavelengths. *Bioresource technology* **2014**, *162*, 38–44.
75. Collazos-Lasso, L.; Arias-Castellanos, J. Fundamentos de la tecnología biofloc (BFT). Una alternativa para la piscicultura en Colombia. Una revisión. *Universidad de Los Llanos. Orinoquia* **2015**, *19*, 77–86.
76. Xu, W.; Morris, T.; Samocha, T. Effects of C/N ratio on biofloc development, water quality, and performance of *Litopenaeus vannamei* juveniles in a biofloc-based, high-density, zero-exchange, outdoor tank system. *Aquaculture* **2016**, 453.
77. Wang, C.; Pan, L.; Zhang, K.; Xu, W.; Zhao, D.; Mei, L. Effects of different carbon sources addition on nutrition composition and extracellular enzymes activity of bioflocs, and digestive enzymes activity and growth performance of *Litopenaeus vannamei* in zero-exchange culture tanks. *Aquaculture Research* **2015**, *47*, 3307–3318.

78. Kumar, S.; Anand, P.; De, D.; Deo, A.; Ghoshal, T.; Sundaray, J.; Ponniah, A.; Jithendran, K.; Raja, R.; Biswas, G. Effects of biofloc under different carbon sources and protein levels on water quality, growth performance and immune responses in black tiger shrimp *Penaeus monodon* (Fabricius, 1978). *Aquaculture Research* **2015**.
79. Delabbio, J. Advantages of LED Lighting Systems in Larval Fish Culture. *World Aquaculture* **2015**, 1–25.
80. Delabbio, J. The importance of environmental light to the culture of marine fish larvae. *ONCE Innovations* **2015**, 1–7.
81. Ganesh, C.; Mokashi, V. Chronic exposure to low intensity natural light blocks spawning in the cichlid fish *Oreochromis mossambicus*. *The Journal of Basic and Applied Zoology* **2015**, *72*, 145–153.
82. Long, L.; Yang, J.; Li, Y.; Guan, C.; Wu, F. Effect of biofloc technology on growth, digestive enzyme activity, hematology, and immune response of genetically improved farmed tilapia (*Oreochromis niloticus*). *Aquaculture* **2015**, *448*, 135–141.
83. Bakar, N.; Nasir, N.; Lananan, F.; Hamid, S.; Lam, S.; Jusoh, A. Optimization of C/N ratios for nutrient removal in aquaculture system culturing African catfish (*Clarias gariepinus*) utilizing Bioflocs Technology. *International Biodeterioration and Biodegradation* **2015**, *102*, 100–106.
84. Ekasari, J.; Rivandi, D.; Firdausi, A.; Surawidjaja, E.; Zairin, M.; Bossier, P.; De Schryver, P. Biofloc technology positively affects Nile tilapia (*Oreochromis niloticus*) larvae performance. *Aquaculture* **2015**, *441*, 72–77.
85. Edwards, K.; Thomas, M.; Klausmeier, C.; Litchman, E. Light and growth in marine phytoplankton: allometric, taxonomic, and environmental variation. *Limnology and Oceanography* **2015**, *60*, 540–552.
86. Bantis, F.; Ouzounis, T.; Radoglou, K. Artificial LED lighting enhances growth characteristics and total phenolic content of *Ocimum basilicum*, but variably affects transplant success. **2016**, *198*, 277–283.
87. Sánchez-Romero, A.; Miranda-Baeza, A.; Rivas-Vega, M.; López-Elías, J.; Martínez-Córdova, L.; Tejeda-Mansir, A. Development of a model to simulate nitrogen dynamics in an integrated shrimp-macroalgae culture system with zero water exchange. *Journal of the World Aquaculture Society* **2016**, *47*, 129–138.
88. Mansour, A.T.; Esteban, M.Á. Effects of carbon sources and plant protein levels in a biofloc system on growth performance, and the immune and antioxidant status of Nile tilapia (*Oreochromis niloticus*). *Fish & shellfish immunology* **2017**, *64*, 202–209.
89. Younis, E.-S.M.; Al-Quffail, A.S.; Al-Asgah, N.A.; Abdel-Warith, A.-W.A.; Al-Hafedh, Y.S. Effect of dietary fish meal replacement by red algae, *Gracilaria arcuata*, on growth performance and body composition of Nile tilapia *Oreochromis niloticus*. *Saudi journal of biological sciences* **2018**, *25*, 198–203.
90. Ren, W.; Li, L.; Dong, S.; Tian, X.; Xue, Y. Effects of C/N ratio and light on ammonia nitrogen uptake in *Litopenaeus vannamei* culture tanks. *Aquaculture* **2019**, *498*, 123–131.
91. Daniela, L.-B.; Carlos, O.-O.; Hernandez, I.M.; Carlos, G.-M. Effect of the RGB Wavelengths of LED Light on Growth Rates of Nile Tilapia Fry in Biofloc Technology (BFT) Systems. *International Journal of Bioscience, Biochemistry and Bioinformatics* **2019**, *9*, 231–236.
92. Lopez-Betancur, D.; Moreno, I.; Guerrero-Mendez, C.; Gómez-Meléndez, D.; Macias P., M. de J.; Olvera-Olvera, C. Effects of Colored Light on Growth and Nutritional Composition of Tilapia, and Biofloc as a Food Source. *Applied Sciences* **2020**, *10*, 362.
93. McCulloch, W.S.; Pitts, W. A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics* **1943**, *5*, 115–133.
94. Hebb, D.O. *The Organization of Behavior: A Neuropsychological Theory*; Taylor & Francis, 2005; ISBN 978-1-135-63191-8.

95. Cybernetics, Automata Studies, and the Dartmouth Conference on Artificial Intelligence - IEEE Journals & Magazine Available online: <https://ieeexplore.ieee.org/abstract/document/5477410> (accessed on Jan 22, 2020).
96. Rosenblatt, F. The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review* **1958**, *65*, 386–408.
97. Widrow, B.; Hoff, M.E. *Adaptive switching circuits*; Stanford Univ Ca Stanford Electronics Labs, 1960;
98. Bishop, C.M. *Neural networks for pattern recognition*; Oxford university press, 1995; ISBN 0-19-853864-2.
99. Dechter, R. *Learning while searching in constraint-satisfaction problems*; University of California, Computer Science Department, Cognitive Systems ..., 1986;
100. Aizenberg, I.; Aizenberg, N.N.; Vandewalle, J.P. *Multi-Valued and Universal Binary Neurons: Theory, Learning and Applications*; Springer Science & Business Media, 2013; ISBN 1-4757-3115-9.
101. Russakovsky, O.; Deng, J.; Su, H.; Krause, J.; Satheesh, S.; Ma, S.; Huang, Z.; Karpathy, A.; Khosla, A.; Bernstein, M. Imagenet large scale visual recognition challenge. *International journal of computer vision* **2015**, *115*, 211–252.
102. Krizhevsky, A.; Sutskever, I.; Hinton, G.E. Imagenet classification with deep convolutional neural networks.; 2012; pp. 1097–1105.
103. Preisendorfer, R.W. Secchi disk science: Visual optics of natural waters 1. *Limnology and oceanography* **1986**, *31*, 909–926.
104. Toivanen, T.; Koponen, S.; Kotovirta, V.; Molinier, M.; Chengyuan, P. Water quality analysis using an inexpensive device and a mobile phone. *Environ Syst Res* **2013**, *2*, 9.
105. Khairi, M.T.M.; Ibrahim, S.; Yunus, M.A.M.; Famarazi, M.; Yusuf, Z. Artificial neural network approach for predicting the water turbidity level using optical tomography. *Arabian Journal for Science and Engineering* **2016**, *41*, 3369–3379.
106. Hussain, I.; Ahamad, K.; Nath, P. Water turbidity sensing using a smartphone. *RSC Advances* **2016**, *6*, 22374–22382.
107. Gaya, M.; Zango, M.; Yusuf, L.; Mustapha, M.; Muhammad, B.; Sani, A.; Tijjani, A.; Wahab, N.; Khairi, M. Estimation of turbidity in water treatment plant using Hammerstein-Wiener and neural network technique. *Indonesian Journal of Electrical Engineering and Computer Science* **2017**, *5*, 666–672.
108. Hamidi, F.N.; Zainuddin, M.F.; Abbas, Z.; Ahmad, A.F. Low cost and simple procedure to determine water turbidity with image processing.; 2017; pp. 30–34.
109. Mullins, D.; Coburn, D.; Hannon, L.; Jones, E.; Clifford, E.; Glavin, M. A novel image processing-based system for turbidity measurement in domestic and industrial wastewater. *Water Science and Technology* **2018**, *77*, 1469–1482.
110. FAO, The state of world fisheries and aquaculture, Part 1. World review of fisheries and aquaculture.; Rome, Italy, 2014; pp. 1–96.
111. Avnimelech, Y.; Verdegem, M.; Kurup, M.; Keshavanath, P. Sustainable land-based aquaculture: rational utilization of water, land and feed resources. *Mediterranean Aquaculture Journal* **2008**, *1*, 45–55.
112. Xu, W.; Pan, L.; Sun, X.; Huang, J. Effects of bioflocs on water quality, and survival, growth and digestive enzyme activities of *Litopenaeus vannamei* (Boone) in zero-water exchange culture tanks. *Aquaculture Research* **2013**, *44*, 1093–1102.
113. Craford, M.G. LEDs for solid state lighting and other emerging applications: status, trends, and challenges.; Ferguson, I.T., Carrano, J.C., Taguchi, T., Ashdown, I.E., Eds.; San Diego, California, USA, 2005; p. 594101.
114. Cho, J.; Park, J.H.; Kim, J.K.; Schubert, E.F. White light-emitting diodes: History, progress, and future: White light-emitting diodes. *Laser & Photonics Reviews* **2017**, *11*, 1600147.

115. Pimputkar, S.; Speck, J.S.; DenBaars, S.P.; Nakamura, S. Prospects for LED lighting. *Nature Photon* **2009**, *3*, 180–182.
116. Fan, J.; Mohamed, M.G.; Qian, C.; Fan, X.; Zhang, G.; Pecht, M. Color Shift Failure Prediction for Phosphor-Converted White LEDs by Modeling Features of Spectral Power Distribution with a Nonlinear Filter Approach. *Materials* **2017**, *10*, 819.
117. Steigerwald, D.A.; Bhat, J.C.; Collins, D.; Fletcher, R.M.; Holcomb, M.O.; Ludowise, M.J.; Martin, P.S.; Rudaz, S.L. Illumination with solid state lighting technology. *IEEE J. Select. Topics Quantum Electron.* **2002**, *8*, 310–320.
118. FAO Fisheries and Aquaculture Department Programa de información de especies acuáticas - Oreochromis niloticus (Linnaeus, 1758) Available online: http://www.fao.org/fishery/culturedspecies/Oreochromis_niloticus/es (accessed on Jan 22, 2020).
119. Hajian, A.; Styles, P. Artificial neural networks. In *Application of Soft Computing and Intelligent Methods in Geophysics*; Springer, 2018; pp. 3–69.
120. Paoletti, M.E.; Haut, J.M.; Plaza, J.; Plaza, A. A new deep convolutional neural network for fast hyperspectral image classification. *ISPRS journal of photogrammetry and remote sensing* **2018**, *145*, 120–147.
121. Ju, C.; Bibaut, A.; van der Laan, M. The relative performance of ensemble methods with deep convolutional neural networks for image classification. *Journal of Applied Statistics* **2018**, *45*, 2800–2818.
122. Cao, X.; Zhou, F.; Xu, L.; Meng, D.; Xu, Z.; Paisley, J. Hyperspectral image classification with Markov random fields and a convolutional neural network. *IEEE Transactions on Image Processing* **2018**, *27*, 2354–2367.
123. Cheng, G.; Han, J.; Zhou, P.; Xu, D. Learning rotation-invariant and fisher discriminative convolutional neural networks for object detection. *IEEE Transactions on Image Processing* **2018**, *28*, 265–278.
124. Dai, J.; Li, Y.; He, K.; Sun, J. R-fcn: Object detection via region-based fully convolutional networks. In Proceedings of the Advances in neural information processing systems; 2016; pp. 379–387.
125. Li, Y.; Wang, S.; Tian, Q.; Ding, X. Feature representation for statistical-learning-based object detection: A review. *Pattern Recognition* **2015**, *48*, 3542–3559.
126. Chan, W.; Jaitly, N.; Le, Q.; Vinyals, O. Listen, attend and spell: A neural network for large vocabulary conversational speech recognition. In Proceedings of the 2016 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP); IEEE, 2016; pp. 4960–4964.
127. Zhang, Y.; Pezeshki, M.; Brakel, P.; Zhang, S.; Bengio, C.L.Y.; Courville, A. Towards end-to-end speech recognition with deep convolutional neural networks. *arXiv preprint arXiv:1701.02720* **2017**.
128. Huang, K.-Y.; Wu, C.-H.; Hong, Q.-B.; Su, M.-H.; Chen, Y.-H. Speech Emotion Recognition Using Deep Neural Network Considering Verbal and Nonverbal Speech Sounds. In Proceedings of the ICASSP 2019-2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP); IEEE, 2019; pp. 5866–5870.
129. Bertinetto, L.; Valmadre, J.; Henriques, J.F.; Vedaldi, A.; Torr, P.H. Fully-convolutional siamese networks for object tracking. In Proceedings of the European conference on computer vision; Springer, 2016; pp. 850–865.
130. Nam, H.; Han, B. Learning multi-domain convolutional neural networks for visual tracking. In Proceedings of the Proceedings of the IEEE conference on computer vision and pattern recognition; 2016; pp. 4293–4302.
131. Fan, J.; Xu, W.; Wu, Y.; Gong, Y. Human tracking using convolutional neural networks. *IEEE Transactions on Neural Networks* **2010**, *21*, 1610–1623.
132. Zhou, Q.; Zheng, B.; Zhu, W.; Latecki, L.J. Multi-scale context for scene labeling via flexible segmentation graph. *Pattern Recognition* **2016**, *59*, 312–324.

133. Liu, F.; Lin, G.; Shen, C. CRF learning with CNN features for image segmentation. *Pattern Recognition* **2015**, *48*, 2983–2992.
134. Pinheiro, P.H.; Collobert, R. Recurrent convolutional neural networks for scene labeling. In Proceedings of the 31st International Conference on Machine Learning (ICML); 2014.
135. Gu, J.; Wang, Z.; Kuen, J.; Ma, L.; Shahroudy, A.; Shuai, B.; Liu, T.; Wang, X.; Wang, G.; Cai, J. Recent advances in convolutional neural networks. *Pattern Recognition* **2018**, *77*, 354–377.
136. Ferentinos, K.P. Deep learning models for plant disease detection and diagnosis. *Computers and Electronics in Agriculture* **2018**, *145*, 311–318.
137. Crab, R.; Kochva, M.; Verstraete, W.; Avnimelech, Y. Bio-flocs technology application in overwintering of tilapia. *Aquacultural Engineering* **2009**, *40*, 105–112.
138. Nhi, N.H.Y.; Da, C.T.; Lundh, T.; Lan, T.T.; Kiessling, A. Comparative evaluation of Brewer’s yeast as a replacement for fishmeal in diets for tilapia (*Oreochromis niloticus*), reared in clear water or biofloc environments. *Aquaculture* **2018**, *495*, 654 – 660.
139. NMX Water analysis-measurement of extractable fats and oils in natural waters, wastewaters and treated wastewaters. *Diario Oficial de la Federación de la Secretaría de Economía del Gobierno de México* **2013**.
140. AOAC Official methods of analysis of AOAC International. *18th edition, AOAC International, Gaithersburg, Maryland, USA* **2005**.
141. Gil, S.I.; de Lara, G.P.Z. *métodos estadísticos: un enfoque interdisciplinario*; Editorial Trillas Sa De Cv, 1990; ISBN 978-968-24-3838-7.
142. Han, X.; Zhong, Y.; Cao, L.; Zhang, L. Pre-Trained AlexNet Architecture with Pyramid Pooling and Supervision for High Spatial Resolution Remote Sensing Image Scene Classification. *Remote Sensing* **2017**, *9*, 848.
143. Zhang, Z.; Ning, G.; Cen, Y.; Li, Y.; Zhao, Z.; Sun, H.; He, Z. Progressive Neural Networks for Image Classification. *arXiv preprint arXiv:1804.09803* **2018**.
144. Krizhevsky, A. One weird trick for parallelizing convolutional neural networks. *arXiv preprint arXiv:1404.5997* **2014**.
145. Begum, N.; Islam, M.S.; Haque, A.; Suravi, I.N. Growth and yield of monosex tilapia *Oreochromis niloticus* in floating cages fed commercial diet supplemented with probiotics in freshwater pond, Sylhet. *1* **2017**, *45*, 27–36.
146. El-Sayed, A.F.M. *Tilapia Culture*; CABI Pub., 2006; ISBN 978-0-85199-014-9.
147. Hanna Instrument HI98703 Turbidity Portable Meter Available online: <https://hannainst.com/hi98703-turbidity-portable-meter.html> (accessed on Aug 1, 2019).
148. Hach USA DR6000™ UV VIS Spectrophotometer with RFID Technology - Overview Available online: <https://www.hach.com/dr6000-uv-vis-spectrophotometer-with-rfid-technology/product?id=10239244800> (accessed on Aug 1, 2019).
149. Hach USA DR900 Multiparameter Portable Colorimeter - Overview Available online: <https://www.hach.com/dr900-multiparameter-portable-colorimeter/product?id=15684103251> (accessed on Aug 1, 2019).
150. Deng, X.; Liu, Q.; Deng, Y.; Mahadevan, S. An improved method to construct basic probability assignment based on the confusion matrix for classification problem. *Information Sciences* **2016**, *340–341*, 250–261.
151. Qiu, S.; Xu, H.; Deng, J.; Jiang, S.; Lu, L. Transfer Convolutional Neural Network for Cross-Project Defect Prediction. *Applied Sciences* **2019**, *9*, 2660.
152. Sammut, C.; Webb, G.I. *Encyclopedia of Machine Learning*; Springer US, 2011; ISBN 978-0-387-30768-8.
153. Azaza, M.; Dhraief, M.; Kraiem, M. Effects of water temperature on growth and sex ratio of juvenile Nile tilapia *Oreochromis niloticus* (Linnaeus) reared in geothermal waters in southern Tunisia. *Journal of thermal Biology* **2008**, *33*, 98–105.

154. El-Sayed, A.-F.M.; Kawanna, M. Optimum water temperature boosts the growth performance of Nile tilapia (*Oreochromis niloticus*) fry reared in a recycling system. *Aquaculture Research* **2008**, *39*, 670–672.
155. Evans, J.J.; Shoemaker, C.A.; Klesius, P.H. Effects of sublethal dissolved oxygen stress on blood glucose and susceptibility to *Streptococcus agalactiae* in Nile tilapia *Oreochromis niloticus*. *Journal of Aquatic Animal Health* **2003**, *15*, 202–208.
156. El-Sherif, M.S.; El-Feky, A.M.I.; others Performance of Nile tilapia (*Oreochromis niloticus*) fingerlings. I. Effect of pH. *Int. J. Agric. Biol* **2009**, *11*, 297–300.
157. El-Shafai, S.A.; El-Gohary, F.A.; Nasr, F.A.; van der Steen, N.P.; Gijzen, H.J. Chronic ammonia toxicity to duckweed-fed tilapia (*Oreochromis niloticus*). *Aquaculture* **2004**, *232*, 117–127.
158. Zeitoun, M.M.; EL-Azrak, K.E.-D.M.; Zaki, M.A.; Nemat-Allah, B.R.; Mehana, E.-S.E. Effects of ammonia toxicity on growth performance, cortisol, glucose and hematological response of Nile Tilapia (*Oreochromis niloticus*). *Aceh Journal of Animal Science* **2016**, *1*, 21–28.
159. Volpato, G.L.; Bovi, T.S.; de Freitas, R.H.; da Silva, D.F.; Delicio, H.C.; Giaquinto, P.C.; Barreto, R.E. Red light stimulates feeding motivation in fish but does not improve growth. *Plos one* **2013**, *8*.
160. Karakatsouli, N.; Papoutsoglou, S.E.; Panopoulos, G.; Papoutsoglou, E.S.; Chadio, S.; Kalogiannis, D. Effects of light spectrum on growth and stress response of rainbow trout *Oncorhynchus mykiss* reared under recirculating system conditions. *Aquacultural Engineering* **2008**, *38*, 36–42.
161. Luchiari, A.; Freire, F. Effects of environmental colour on growth of Nile tilapia, *Oreochromis niloticus* (Linnaeus, 1758), maintained individually or in groups. *Journal of Applied Ichthyology* **2009**, *25*, 162–167.
162. Volpato, G.L.; Barreto, R. Environmental blue light prevents stress in the fish Nile tilapia. *Brazilian Journal of Medical and Biological Research* **2001**, *34*, 1041–1045.
163. Aly, H.; Abdel-Rahim, M.; Lotfy, A.; Abdelaty, B. Impact of Different Colors of Artificial Light on Pigmentation and Growth Performance of Hybrid Red Tilapia (*Oreochromis mosambicus* x *O. hornorum*) Reared in Saline Well Water. *J. Marine Sci. Res. Dev* **2017**, *7*, 229.
164. Sabri, D.M.; Elnwshy, N.; Nwonwu, F. Effect of environmental color on the behavioral and physiological response of Nile tilapia, *Oreochromis niloticus*. *Glob J Front Res* **2012**, *12*, 11–20.
165. Douglas, R.H.; Hawryshyn, C.W. Behavioural studies of fish vision: an analysis of visual capabilities. In *The Visual System of Fish*; Douglas, R., Djamgoz, M., Eds.; Springer Netherlands: Dordrecht, 1990; pp. 373–418 ISBN 978-94-009-0411-8.
166. He, A.-Y.; Ning, L.-J.; Chen, L.-Q.; Chen, Y.-L.; Xing, Q.; Li, J.-M.; Qiao, F.; Li, D.-L.; Zhang, M.-L.; Du, Z.-Y. Systemic adaptation of lipid metabolism in response to low- and high-fat diet in Nile tilapia (*Oreochromis niloticus*). *Physiological Reports* **2015**, *3*, e12485.
167. Hach USA DR900 Multiparameter Portable Colorimeter Available online: <https://www.hach.com/dr900-multiparameter-portable-colorimeter/product-downloads?id=15684103251&callback=qs> (accessed on Aug 16, 2019).
168. Lloyd, D.S. Turbidity as a water quality standard for salmonid habitats in Alaska. *North American journal of fisheries management* **1987**, *7*, 34–45.
169. Wang, Y.; Rajib, S.S.M.; Collins, C.; Grieve, B. Low-Cost Turbidity Sensor for Low-Power Wireless Monitoring of Fresh-Water Courses. *IEEE Sensors Journal* **2018**, *18*, 4689–4696.
170. Bayram, A.; Yalcin, E.; Demic, S.; Gunduz, O.; Solmaz, M.E. Development and application of a low-cost smartphone-based turbidimeter using scattered light. *Appl. Opt., AO* **2018**, *57*, 5935–5940.
171. Leeuw, T.; Boss, E. The HydroColor App: Above Water Measurements of Remote Sensing Reflectance and Turbidity Using a Smartphone Camera. *Sensors* **2018**, *18*, 256.
172. Ivan Moreno; I. R. Ramos-Romero Light spectrum for maximum luminous efficacy of radiation and high color quality.; 2018; Vol. 10745.

ANEXOS