



**INSTITUTO POLITÉCNICO NACIONAL**

CENTRO INTERDISCIPLINARIO DE CIENCIAS MARINAS



**PROPUESTA METODOLÓGICA PARA  
IDENTIFICAR FILETES DE PECES  
COMERCIALES MEDIANTE VISIÓN ARTIFICIAL**

**TESIS**

QUE PARA OBTENER EL GRADO DE  
MAESTRÍA EN CIENCIAS EN MANEJO DE RECURSOS MARINOS

**PRESENTA**

CLARA DE LOS SANTOS NOYOLA

LA PAZ, BAJA CALIFORNIA SUR, JULIO DE 2019



**INSTITUTO POLITÉCNICO NACIONAL**  
**SECRETARIA DE INVESTIGACIÓN Y POSGRADO**  
*ACTA DE REVISIÓN DE TESIS*

En la Ciudad de La Paz, B.C.S., siendo las 12:00 horas del día 12 del mes de Junio del 2019 se reunieron los miembros de la Comisión Revisora de Tesis designada por el Colegio de Profesores de Estudios de Posgrado e Investigación de CICIMAR para examinar la tesis titulada:

"PROPUESTA METODOLÓGICA PARA IDENTIFICAR FILETES  
DE PECES COMERCIALES MEDIANTE VISIÓN ARTIFICIAL"

Presentada por el alumno:

DE LOS SANTOS  
Apellido paterno

NOYOLA  
materno

CLARA  
nombre(s)

Con registro: 

A	1	7	0	8	3	4
---	---	---	---	---	---	---

Aspirante de:

MAESTRIA EN CIENCIAS EN MANEJO DE RECURSOS MARINOS

Después de intercambiar opiniones los miembros de la Comisión manifestaron **APROBAR LA DEFENSA DE LA TESIS**, en virtud de que satisface los requisitos señalados por las disposiciones reglamentarias vigentes.

**LA COMISION REVISORA**

Directores de Tesis

  
DRA. MIRTHA ORALIA ALBÁÑEZ LUCERO  
Directora de Tesis

  
DR. ALFREDO FLORES IRIGOLLEN  
2°. Director de Tesis

  
DR. FRANCISCO ARREGUÍN SÁNCHEZ

  
DR. RODRIGO MONCAYO ESTRADA

  
DR. LEONARDO ANDRÉS ABITIA CÁRDENAS

**PRESIDENTE DEL COLEGIO DE PROFESORES**

  
DR. SERGIO HERNÁNDEZ TRUJILLO



I.P.N.  
CICIMAR  
DIRECCIÓN



**INSTITUTO POLITÉCNICO NACIONAL**  
**SECRETARIA DE INVESTIGACIÓN Y POSGRADO**  
*ACTA DE REVISIÓN DE TESIS*

En la Ciudad de La Paz, B.C.S., siendo las 12:00 horas del día 12 del mes de Junio del 2019 se reunieron los miembros de la Comisión Revisora de Tesis designada por el Colegio de Profesores de Estudios de Posgrado e Investigación de CICIMAR para examinar la tesis titulada:

"PROPUESTA METODOLÓGICA PARA IDENTIFICAR FILETES  
DE PECES COMERCIALES MEDIANTE VISIÓN ARTIFICIAL"

Presentada por el alumno:

DE LOS SANTOS  
Apellido paterno

NOYOLA  
materno

CLARA  
nombre(s)

Con registro: 

A	1	7	0	8	3	4
---	---	---	---	---	---	---

Aspirante de:

MAESTRIA EN CIENCIAS EN MANEJO DE RECURSOS MARINOS

Después de intercambiar opiniones los miembros de la Comisión manifestaron **APROBAR LA DEFENSA DE LA TESIS**, en virtud de que satisface los requisitos señalados por las disposiciones reglamentarias vigentes.

**LA COMISION REVISORA**

Directores de Tesis

  
DRA. MIRTHA ORALIA ALBÁÑEZ LUCERO  
Directora de Tesis

  
DR. ALFREDO FLORES IRIGOLLEN  
2°. Director de Tesis

  
DR. FRANCISCO ARREGUÍN SÁNCHEZ

  
DR. RODRIGO MONCAYO ESTRADA

  
DR. LEONARDO ANDRÉS ABITIA CÁRDENAS

**PRESIDENTE DEL COLEGIO DE PROFESORES**

  
DR. SERGIO HERNÁNDEZ TRUJILLO



I.P.N.  
CICIMAR  
DIRECCIÓN



**INSTITUTO POLITÉCNICO NACIONAL  
SECRETARÍA DE INVESTIGACIÓN Y POSGRADO**

**CARTA CESIÓN DE DERECHOS**

En la Ciudad de La Paz, B.C.S., el día 21 del mes de Junio del año 2019

El (la) que suscribe ING. CLARA DE LOS SANTOS NOYOLA Alumno (a) del Programa

MAESTRÍA EN CIENCIAS EN MANEJO DE RECURSOS MARINOS

con número de registro A170834 adscrito al CENTRO INTERDISCIPLINARIO DE CIENCIAS MARINAS

manifiesta que es autor(a) intelectual del presente trabajo de tesis, bajo la dirección de:

DRA. MIRTHA ORALIA ALBÁÑEZ LUCERO Y DR. ALFREDO FLORES IRIGOLEN

y cede los derechos del trabajo titulado:

"PROPUESTA METODOLÓGICA PARA IDENTIFICAR FILETES

DE PECES COMERCIALES MEDIANTE VISIÓN ARTIFICIAL"

al Instituto Politécnico Nacional, para su difusión con fines académicos y de investigación.

Los usuarios de la información no deben reproducir el contenido textual, gráficas o datos del trabajo sin el permiso expreso del autor y/o director del trabajo. Éste, puede ser obtenido escribiendo a la siguiente dirección: clara\_dn@hotmail.com - mirtha.lucero@gmail.com - aflores@uabcs.mx

Si el permiso se otorga, el usuario deberá dar el agradecimiento correspondiente y citar la fuente del mismo.

ING. CLARA DE LOS SANTOS NOYOLA

*Nombre y firma del alumno*

# DEDICATORIA

*A la memoria de la Q. Br. Ramona Lauterio García.*

# AGRADECIMIENTOS

Al Consejo Nacional de Ciencia y Tecnología (CONACYT) por la beca otorgada.

Al Centro Interdisciplinario de Ciencias Marinas (CICIMAR) por el apoyo brindado.

Al laboratorio de alimentos marinos de la Universidad Autónoma de Baja California Sur (UABCS) por permitirme hacer uso de sus instalaciones.

A todos los miembros de mi comité tutorial y en especial a mis directores, la Dra. Mirtha Oralia Albañez Lucero y el Dr. Alfredo Flores Irigollen por todo su apoyo y paciencia.

Y a todas esas personas que directa e indirectamente me apoyaron durante el desarrollo del presente trabajo.

¡Gracias a todos!

# ÍNDICE

RESUMEN.....	i
ABSTRACT.....	iii
I. INTRODUCCIÓN .....	1
I.2.1.    Aplicaciones de redes neuronales artificiales. ....	5
I.2.2.    Arquitectura de una red neuronal artificial. ....	5
I.2.3.    Mecanismo de aprendizaje de la red neuronal artificial.....	6
I.2.4.    Tipos de redes neuronales artificiales.....	8
II. ANTECEDENTES.....	14
III. PLANTEAMIENTO DEL PROBLEMA .....	23
IV. JUSTIFICACIÓN.....	23
V. HIPÓTESIS .....	24
VI. OBJETIVOS .....	24
VII. MATERIAL Y MÉTODOS.....	25
VIII. RESULTADOS.....	39
IX. DISCUSIÓN.....	65
X. CONCLUSIONES.....	69
XI. RECOMENDACIONES .....	70
XII. LITERATURA CITADA .....	70
XIII. ANEXOS.....	81

## LISTA DE FIGURAS

Figura 1.- Esquema básico de una RNA. ....	6
Figura 2.- Esquema de una RNA Elman. ....	9
Figura 3.- Esquema de una RNA Hopfield. ....	11
Figura 4.- Musculatura del Pez (Knorr, 1974).....	13
Figura 5.- <i>Balistes polylepis</i> (cochito).....	26
Figura 6.- <i>Caulolatilus affinis</i> (conejo). ....	27
Figura 7.- <i>Caulolatilus princeps</i> (pierna). ....	28
Figura 8.- <i>Lutjanus argentiventris</i> (pargo amarillo).....	29
Figura 9.- <i>Lutjanus peru</i> (huachinango). ....	30
Figura 10.- <i>Paralabrax nebulifer</i> (verdillo). ....	31
Figura 11.- Proceso de fileteado.....	32
Figura 12.- Cámara fotográfica. ....	33
Figura 13.- Filete de <i>Balistes polylepis</i> (cochito).....	39
Figura 14.- Filete de <i>Caulolatilus affinis</i> (conejo). ....	40
Figura 15.- Filete de <i>Caulolatilus princeps</i> (pierna). ....	40
Figura 16.- Filete de <i>Lutjanus argentiventris</i> (pargo amarillo).....	41
Figura 17.- Filete de <i>Lutjanus peru</i> (huachinango).....	42
Figura 18.- Filete de <i>Paralabrax nebulifer</i> (verdillo). ....	42
Figura 19.- Histogramas RGB. ....	43
Figura 20.- <i>Balistes polylepis</i> ecualizada. ....	44
Figura 21.- Imágenes a escala de grises.....	45
Figura 22.- Imágenes binarizadas.....	47
Figura 23.- Interfaz gráfica.....	48
Figura 24.- Imagen cargada en la interfaz gráfica.....	48
Figura 25.- Imagen ecualizada .....	49
Figura 26.- Imagen con filtro desplegada en la interfaz gráfica.....	49
Figura 27.- Imagen binarizada en la interfaz gráfica. ....	50
Figura 28.- Cargar nueva foto. ....	51
Figura 29.- Filete de <i>B. polylepis</i> examinado durante el cálculo de los momentos de Hu.....	52
Figura 30.- Filete de <i>C. affinis</i> . Filete durante el cálculo de los momentos de Hu.....	53
Figura 31.- Filete de <i>C. princeps</i> .....	54
Figura 32.- Filete de <i>L. argentiventris</i> durante el cálculo de los momentos de Hu .....	55
Figura 33.- Filete de <i>L. peru</i> examinado durante el cálculo de los momentos de Hu .....	56
Figura 34.- Filete de <i>P. nebulifer</i> examinado bajo los momentos invariantes de Hu. ....	57
Figura 35.- Arquitectura de la RNA Elman compuesta de 39 neuronas. ....	59
Figura 36.- Imagen del entrenamiento de la RNA Elman.....	59
Figura 37.- Gráfica de los valores del gradiente y de $\mu$ de la RNA Elman. ....	60
Figura 38.- Curva de aprendizaje de la RNA Elman con 715 épocas .....	61
Figura 39.- Gráfica de la validación de la RNA Elman. ....	63
Figura 40.- Entrenamiento Hopfield de imágenes binarizadas. ....	64
Figura 41.- Filetes de <i>Balistes polylepis</i> (cochito).....	85
Figura 42.- Filetes <i>Caulolatilus affinis</i> (conejo).....	86
Figura 43.- Filetes de <i>Caulolatilus princeps</i> (pierna) .....	87
Figura 44.- Filetes de <i>Lutjanus argentiventris</i> (pargo amarillo).....	88
Figura 45.- Filetes de <i>Lutjanus peru</i> (huachinango) .....	89
Figura 46.- Filetes de <i>Paralabrax nebulifer</i> (verdillo).....	90



## LISTA DE TABLAS

Tabla 1.- Valores de los momentos invariantes de Hu para una imagen de <i>Balistes polylepis</i> .....	53
Tabla 2.- Valores de los momentos invariantes de Hu para una imagen de <i>Caulolatilus affinis</i> . ....	54
Tabla 3.- Valores de los momentos invariantes de Hu para una imagen de <i>Caulolatilus princeps</i> .....	55
Tabla 4.- Valores de los momentos invariantes de Hu para una imagen de <i>Lutjanus argentiventris</i> .....	56
Tabla 5.- Valores de los momentos invariantes de Hu para una imagen de <i>Lutjanus peru</i> .....	57
Tabla 6.- Valores de los momentos invariantes de Hu para una imagen de <i>Paralabrax nebulifer</i> .....	58
Tabla 7.- Resultados de la validación de la red Elman. ....	62

## RESUMEN

En el sector pesquero de Baja California Sur (BCS) una de las prácticas de fraude comercial que ocurre con mayor frecuencia es la sustitución de filetes de pescado con alto valor comercial por especies de menor valor para obtener una ganancia financiera. Esto representa un problema de calidad alimentaria y crea un problema de control de calidad de los alimentos. Para evitar el fraude y dar cumplimiento a las normas de calidad establecidas por el código alimentario, las autoridades correspondientes realizan inspecciones que a menudo no logran cumplir plenamente, debido a la velocidad de la producción. Por lo tanto, el presente trabajo propone una metodología más rápida y precisa para clasificar filetes de especies de interés comercial en BCS mediante el uso de técnicas de visión artificial que siguen la orientación de las fibras musculares distintivas (miómeros y mioseptos) presentes en las diferentes especies. Las especies objeto de estudio fueron *Balistes polylepis*, *Caulolatilus affinis*, *Caulolatilus princeps*, *Lutjanus argentiventris*, *Lutjanus peru* y *Paralabrax nebulifer*. Se obtuvieron 240 imágenes de filetes (40 por especie) que se analizaron con algoritmos de Redes Neuronales Artificiales (RNA) utilizando dos algoritmos diferentes, Elman y Hopfield. Estos algoritmos se usan comúnmente en la clasificación de objetos y reconocimiento de patrones. Los algoritmos de Elman y Hopfield se utilizaron para realizar la clasificación en imágenes que se habían tratado con herramientas y rutinas de procesamiento de imágenes digitales en MATLAB para la extracción de sus atributos distintivos. De las 40 imágenes, 30 de cada conjunto fueron procesadas y analizadas con ambos algoritmos y el resto de las imágenes se utilizaron como testigos para validar y evaluar el grado de efectividad de cada uno, para clasificar las especies correctamente con el error mínimo obtenido durante la etapa de entrenamiento. El algoritmo de aprendizaje supervisado Elman que responde a las etiquetas de las imágenes, presentó una eficiencia de aproximadamente el 80% con un error del  $2.94 \times 10^{-14}$ , lo que significa que es una red aceptablemente eficiente para la clasificación de los filetes de pescado. Por el contrario, el algoritmo de aprendizaje no supervisado Hopfield, que responde a una representación gráfica de la imagen, no identificó ni clasificó las imágenes de manera confiable. La razón de que el algoritmo de Hopfield no logró

una clasificación asociativa adecuada en el 100% de las imágenes es porque para usarlo fue necesario comprimir las imágenes a un tamaño de 20 píxeles, lo que resultó en una resolución débil que impidió la identificación precisa de los atributos de la especie, por lo que esta red no cumple con la finalidad del reconocimiento de filetes de pescado por el contrario del algoritmo de Elman.

**Palabras clave:** algoritmo, filete, procesamiento de imágenes, RNA, MATLAB, miómero, miosepto.

## ABSTRACT

In the fishing sector of Baja California Sur (BCS) one of the commercial fraud practices that occurs most frequently is the substitution of fish fillets with high commercial value for lower value species to obtain a financial gain. This creates a problem of food quality control. To avoid this food fraud and to comply with the quality standards established by the food code, the corresponding authorities carry out inspections but often fail to comply fully due to the speed of production. Therefore, this paper proposes a faster and more accurate methodology for classifying fillets of species of commercial interest in BCS by using artificial vision techniques that follow the orientation of the distinctive muscle fibers (myomers and myostases) among the different species. The species under study were *Balistes polylepis*, *Caulolatilus affinis*, *Caulolatilus princeps*, *Lutjanus argentiventris*, *Lutjanus peru* and *Paralabrax nebulifer*. We obtained two hundred and forty images of fillets (forty per species) and analyzed them with Artificial Neural Networks using two different algorithms, Elma and Hopfield. These algorithms are commonly used in the classification of objects and pattern recognition. The Elma and Hopfield algorithms were used to perform classification on images that had been treated using tools and digital image processing routines in MATLAB for the extraction of their distinctive attributes. We created sets of 40 images per species, thirty of each set were processed and analyzed in the two ANNs algorithms mentioned previously, the rest of images were used to validate each algorithm and evaluate the degree of effectiveness to classify the species correctly with the minimum error obtained during the training stage. The supervised learning Elman algorithm presented an efficiency of about 80% with an error of  $2.94 \times 10^{-14}$ , which means that it is an acceptably efficient network for the classification of fish fillets. On the contrary, the Hopfield algorithm of unsupervised learning did not identify or classify the images reliably. In this study, the Hopfield algorithm did not achieve an adequate associative classification in 100% of the images because to use this algorithm it was necessary to compress the images to a size of 20 pixels and this resulted in weak resolution that precluded accurate identification of the species attributes. In addition, it should be noted that the Hopfield

algorithm responds to a graphic representation of the image and not the labels of the images, as is the case with the Elman algorithm.

**Keywords:** algorithm, fillet, image processing, NNAs, MATLAB, myomer, myostases.

# I. INTRODUCCIÓN

## I.1. Visión Artificial

La visión artificial (VA) también conocida como visión por computadora es una rama de la inteligencia artificial que consiste básicamente en el análisis de imágenes por medio de ordenadores (De La Escalera *et al.*, 2016). Para Vélez *et al.* (2003) se trata de una disciplina que intenta emular la capacidad que tienen algunos seres vivos para ver una escena y entenderla, en el caso del ser humano, este captura la luz a través de los ojos y la información circula a través del nervio óptico hasta el cerebro donde se procesa y propone razones para creer que el primer paso de este procesado consiste en encontrar elementos más simples en los que descomponer la imagen (como segmentos y arcos) después, el cerebro interpreta la escena y por último actúa en consecuencia. Una combinación innovadora de visión artificial y técnicas de aprendizaje automático promete avanzar en el campo de la visión artificial, lo que contribuirá a una mejor comprensión de las aplicaciones complejas del mundo real.

Para transformar los sistemas de visión creados en laboratorio en sistemas de trabajo reales, es necesario evaluar las características de rendimiento de estos sistemas utilizando una variedad de datos reales y calibrados. El aprendizaje ofrece esta herramienta de evaluación, ya que no se puede aprender sin una evaluación apropiada de los resultados. Así pues, un sistema de aprendizaje tiene que demostrar y responder claramente a preguntas como: ¿qué se está aprendiendo?, ¿cómo se aprende?, ¿qué datos se utilizan para aprender?, ¿cómo representar lo que se ha aprendido?, ¿qué tan bien y qué tan eficiente es el aprendizaje que tiene lugar? y ¿cuáles son los criterios de evaluación de la tarea a realizar?, por lo que los detalles experimentales son esenciales para demostrar el aprendizaje de algoritmos y sistemas. Estos experimentos deben incluir una metodología de diseño científico experimental para entrenamiento/pruebas, estudios paramétricos y medidas de mejora del rendimiento con experiencia. Los experimentos que muestran la escalabilidad de los sistemas de visión basados en el aprendizaje también son muy importantes. El aprendizaje es una de las fronteras actuales para

la investigación en visión artificial y ha estado recibiendo una mayor atención en los últimos años. La tecnología de aprendizaje automático tiene un gran potencial para contribuir al desarrollo de algoritmos de visión flexibles y robustos que mejorarán el rendimiento de los sistemas de visión práctica con un mayor nivel de competencia y mayor generalidad, y el desarrollo de arquitecturas que acelerarán el tiempo de desarrollo del sistema y proporcionarán mejor presentación (Sebe *et al.*, 2004).

De acuerdo con Sebe *et al.* (2004), y desde el punto de vista de los sistemas de aprendizaje automático, la visión artificial puede generar problemas interesantes y desafiantes, tales como:

- Modelos de aprendizaje en lugar de la elaboración manual.
- Aprendizaje para transferir la experiencia adquirida en un dominio de aplicación a otro.
- Aprendizaje de grandes conjuntos de imágenes sin anotación.
- Diseño de criterios de evaluación de la calidad de los procesos de aprendizaje en sistemas de visión artificial.

### **I.1.1. Componentes principales de la visión artificial.**

Los componentes principales de un sistema de visión artificial son un sensor de imagen y un digitalizador, el primero es un dispositivo físico sensible en una banda del espectro de energía electromagnético que genera una señal eléctrica proporcional al nivel de energía incidente en un instante de tiempo. La señal eléctrica generada es una señal analógica y para obtener una imagen digital esta debe ser procesada a continuación por un dispositivo digitalizador, el cual es comúnmente conocido como tarjeta digitalizadora para computador, este dispositivo es capaz de convertir la señal analógica de salida del sensor de imagen en una señal digital, que puede ser procesada por un computador (Molleda, 2008).

### **I.1.2. Etapas del proceso de la visión artificial.**

La visión artificial está asociada a una enorme cantidad de técnicas computacionales que se dividen en cuatro etapas:

- 1. Adquisición de la imagen.** Esta etapa es puramente sensorial, consiste en la captura o adquisición de las imágenes digitales mediante algún tipo de sensor.
- 2. Preprocesamiento.** Consiste en el tratamiento digital de las imágenes, con objeto de facilitar las etapas posteriores. En esta etapa de procesamiento previo es donde mediante filtros y transformaciones geométricas se eliminan partes indeseables de la imagen o se realzan partes de interés.
- 3. Segmentación.** Consiste en aislar los elementos que interesan de una escena para comprenderla.
- 4. Reconocimiento o clasificación.** En ella se pretende distinguir los objetos segmentados, gracias al análisis de ciertas características que se establecen previamente para diferenciarlos.

Estas cuatro fases no se siguen siempre de manera secuencial, sino que en ocasiones deben realimentarse hacia atrás. Así, es normal volver a la etapa de segmentación si falla la etapa de reconocimiento o a la de preprocesamiento, o incluso a la de captura, cuando falla alguna de las siguientes (Vélez *et al.*, 2003).

Los sistemas de visión artificial están en continuo desarrollo y evolución tecnológica, y son muchas las empresas dedicadas a su fabricación debido al creciente número de consumidores que los utilizan con gran éxito. Estos sistemas nos permiten atender a las demandas más exigentes de calidad al permitir la inspección y el control del 100% del producto. Del mismo modo, resulta la opción idónea para el control de todo tipo de procesos y para el guiado de manipuladores y robots. Teniendo como principal ventaja que son sistemas que se amortizan rápidamente y tienen unos costes de funcionamiento muy reducidos. Una de las aplicaciones de los sistemas de visión artificial es la identificación o clasificación, donde se tiene como finalidad asignar a un objeto la clase a la que pertenece mediante la extracción y procesamiento de sus características visuales (forma, color, etiquetaje, dimensiones, textura, etc.), lo que permite identificar piezas o



productos por su perfil, realizar tareas de reconocimiento óptico extrayendo de una imagen los caracteres que la componen para almacenarlos en un formato con el cual puedan interactuar programas de edición (Molleda, 2008).

Actualmente, el empleo de nuevas tecnologías en la visión artificial, muestran resultados más eficaces para resolver los problemas de clasificación que enfrenta la industria. Una de estas tecnologías es la VA auxiliada con algoritmos de Redes Neuronales Artificiales (RNA) que, mediante procesos de obtención, caracterización e interpretación de información de imágenes tomadas de un mundo tridimensional han dado respuesta a muchos de los problemas que representa la clasificación a gran escala (García-Santillán, 2008).

## **I.2. Redes neuronales artificiales.**

Una neurona artificial por si sola posee una baja capacidad de procesamiento y su nivel de aplicabilidad también es bajo, pero su verdadero potencial radica en la interconexión de estas, tal como sucede en el cerebro humano. Esto ha motivado a diferentes investigadores a proponer diversas estructuras para conectar neuronas entre sí, dando lugar a las redes neuronales artificiales (RNA; Caicedo y López, 2017). Uno de estos investigadores fue Frank Rosenblatt (1958) quien desarrolló la red neuronal más antigua la cual después de aprender ciertos patrones es capaz de reconocer otros similares, esta red neuronal artificial fue llamada Perceptron. Existen numerosas formas de definir a las RNA, la Agencia de Investigación de Proyectos Avanzados de Defensa (DARPA, por sus siglas en inglés) las define como un sistema compuesto de muchos elementos simples de procesamiento los cuales operan en paralelo y cuya función es determinada por la estructura de la red y el peso de las conexiones, donde el procesamiento se realiza en cada uno de los nodos o elementos de cómputo (Caicedo & López, 2017). Las RNA son sistemas que aprenden de la experiencia; es decir, aprender a realizar ciertas tareas mediante un entrenamiento con ejemplos ilustrativos. La estructura y funcionamiento de las RNA están inspirados en las redes neuronales biológicas, que pueden ser consideradas como un sistema de procesamiento de información

mediante la adaptación de sus parámetros, basado en el aprendizaje de acuerdo con sus datos de entrada, con la capacidad de representar comportamiento inteligente obteniendo resultados optimizados y confiables (Montaño, 2002; Albañez-Lucero, 2010).

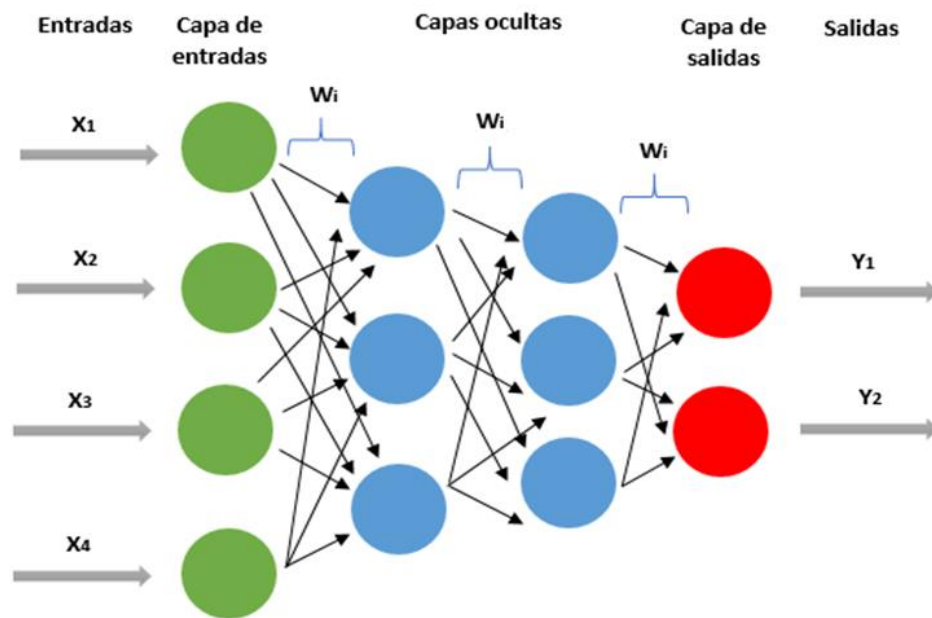
### **I.2.1. Aplicaciones de redes neuronales artificiales.**

Las redes neuronales artificiales son utilizadas en una extensa variedad de aplicaciones que requieren de reconocimiento y percepción humana para resolver problemas específicos emulando el comportamiento de las neuronas biológicas del cerebro humano. Las RNA son principalmente utilizadas en cuatro formas: modelos de sistemas nerviosos biológicos, inteligencia artificial, adaptador en tiempo real de procesos simples y en implemento de control en hardware para aplicaciones, tales como: robótica, análisis de datos y reconocimiento de patrones (Caicedo & López, 2017). Otra de las aplicaciones de las redes neuronales artificiales es la predicción (Abiodum *et al.*, 2018) y dentro de ella se encuentran las predicciones pesqueras que sirven para gestionar y aprovechar mejor los recursos utilizando registros históricos de captura, biomasa y otras variables que logren dar buenos resultados predictivos del comportamiento de tales recursos (Cisneros, 1996; Cavieses- Núñez *et al.*, 2018).

### **I.2.2. Arquitectura de una red neuronal artificial.**

Una red neuronal artificial está compuesta por neuronas que en conjunto forman capas de entrada, ocultas y de salida. Cada neurona recibe información a través de conexiones que tienen un determinado peso ( $W$ ), procesa la información y emite el resultado a través de sus conexiones con las neuronas de la capa siguiente, el número de capas intermedias y el número de neuronas de cada capa dependerá del tipo de aplicación al que se vaya a destinar la red neuronal (Haykin, 2009).

En la figura 1 se muestra un esquema básico de una RNA, donde los círculos representan a las neuronas, las conexiones entre ellas están representadas por las flechas de color negro, mientras que las flechas de color gris representan las entradas y salidas. La forma en que se estructuran las neuronas de una red neuronal artificial está íntimamente relacionada con el algoritmo de aprendizaje utilizado para entrenar la red. Por lo tanto, podemos hablar de algoritmos de aprendizaje utilizados en el diseño de redes neuronales como estructuras (Haykin, 2009).



**Figura 1.-** Esquema básico de una RNA (basado en Haykin, 2009).

### **1.2.3. Mecanismo de aprendizaje de la red neuronal artificial.**

Durante el proceso de aprendizaje o entrenamiento de la RNA y por aplicación de un conjunto de entradas, se van ajustando adecuada e internamente todos y cada uno de los pesos asociados a cada rama para obtener la salida deseada (o al menos una salida consistente), de forma que la red pueda responder después por sí sola a situaciones diferentes a las aprendidas, los pesos pueden ser

asignados por algún algoritmo (Calderón-Mendoza, 2014). En esta etapa, a cada presentación completa de todas las muestras que pertenecen al conjunto de entrenamiento para ajustar los pesos y umbrales sinápticos, se le conoce como *época de entrenamiento* (Haykin, 2009). En otras palabras, el entrenamiento consiste en proporcionar información y decirle a la red cuál debe ser la salida. Las redes neuronales proporcionan un método poderoso para la capacitación y la predicción del aprendizaje automático (Wagh *et al.*, 2019).

El aprendizaje puede ser supervisado o no supervisado:

**Aprendizaje supervisado.** Consiste en proporcionar parejas de patrones entrada-salida a la red neuronal y esta aprende a asociarlos, este tipo de aprendizaje es controlado por un agente externo llamado supervisor o maestro. Para cada conjunto de entrenamiento que alimenta a la red, la salida, por ejemplo, puede recibir directamente los resultados correctos de la red para las muestras que se comparan con la solución correcta y los pesos de la red se pueden cambiar de acuerdo con su diferencia. El objetivo es cambiar esas ponderaciones para que la red no solo pueda asociar los patrones de entrada y salida de manera independiente después del entrenamiento, sino que pueda proporcionar resultados plausibles, resultados a desconocidos, patrones de entrada similares, es decir, generaliza (Kriesel, 2007).

**Aprendizaje no supervisado.** En este caso el vector de datos que describe el problema, se le presenta directamente a la red, pero ahora ya no hay un supervisor o maestro que guíe el aprendizaje. En este caso los pesos de la red se calculan en función de la caracterización que se haga de la entrada que la red neuronal artificial esté recibiendo, de acuerdo con un objetivo específico que permita obtener el conocimiento que se desea representar con la red (Caicedo & López, 2017). En otras palabras, solo se dan los patrones de entrada; la red intenta identificar patrones similares y clasificarlos en categorías similares. El conjunto de entrenamiento consiste en patrones de entrada; después de completar una secuencia, se devuelve un valor a la red que indica si el resultado fue correcto o incorrecto y, posiblemente, qué tan correcto o incorrecto fue (Kriesel, 2007).

Basados en el trabajo de Mcarbonell y DeFreitas (2010), el entrenamiento o aprendizaje en general se detiene cuando alguna de las condiciones siguientes ocurre:

- El número máximo de épocas (iteraciones o repeticiones) es alcanzada.
- Se excede la máxima cantidad de tiempo.
- El rendimiento se minimiza hasta la meta u objetivo.
- La pendiente del rendimiento cae por debajo de la pendiente mínima aceptada.
- El rendimiento de la validación ha alcanzado el máximo.

El mecanismo de aprendizaje de una red neuronal artificial, su arquitectura y la forma en que se le presenta la información de entrada y de salida, son aspectos importantes que la caracterizan (Hilera & Martínez, 1995).

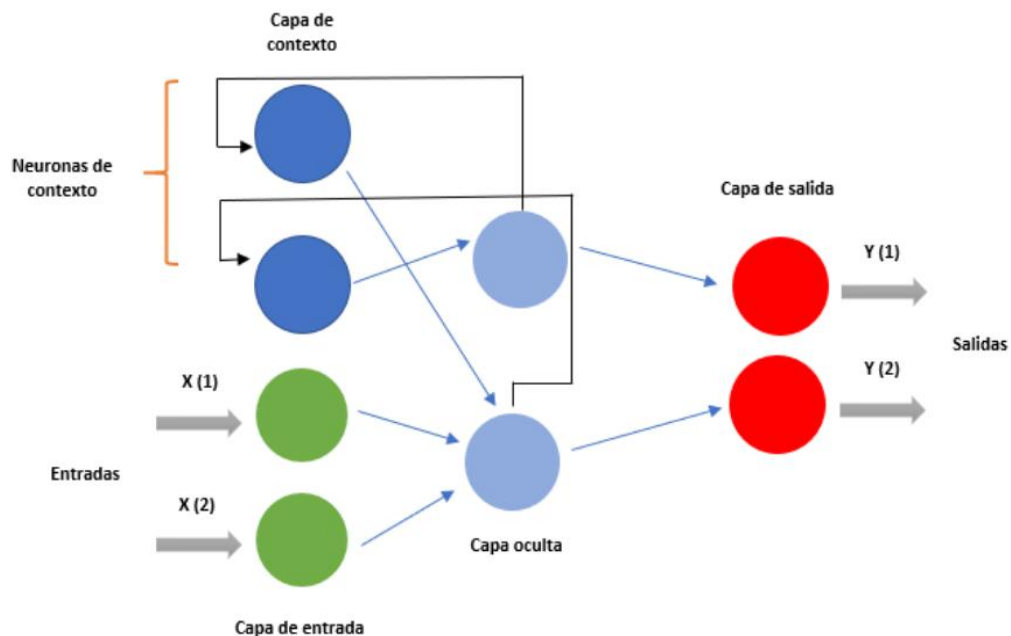
#### **1.2.4. Tipos de redes neuronales artificiales.**

Existen diferentes tipos de redes neuronales artificiales y la selección de una u otra depende del problema a resolver (Acevedo *et al.*, 2007). Estas redes pueden ser clasificadas en aplicaciones de predicción, clasificación, asociación, entre otras. De ellas, la clasificación es considerada como una de las áreas de investigación y aplicación más dinámicas (Saravanan & Sasithra, 2014). En una variedad de disciplinas científicas y de ingeniería, tales como la biología, la visión artificial, la inteligencia artificial y la percepción remota, son problemas importantes el reconocimiento automático, la clasificación, la descripción y la agrupación de los patrones. Un patrón podría ser una imagen de huella digital, una palabra cursiva escrita a mano, una cara humana o una señal de voz (Basu *et al.*, 2010).

Algunos tipos de redes comúnmente utilizados con éxito en el reconocimiento de patrones y clasificación son las redes Elman y Hopfield:

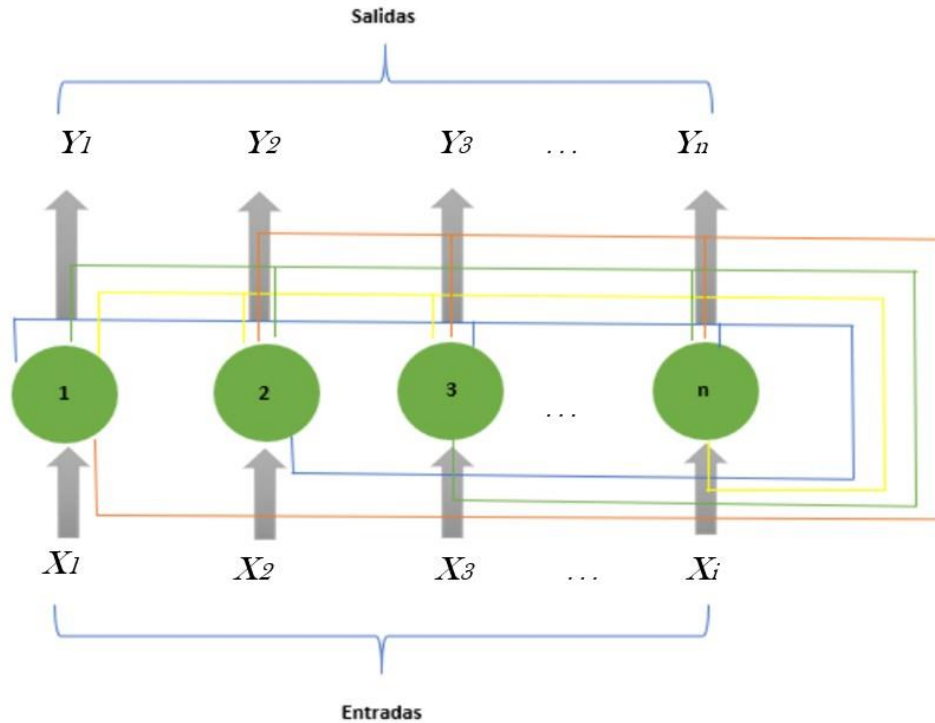
**Red de tipo Elman.** Es uno de los tipos de redes más usados en el reconocimiento de patrones y clasificación, pertenece al grupo de las redes llamadas realimentadas o recurrentes, su estructura consiste en una red de dos capas con retroalimentación

desde la salida de la primera capa, esta conexión recurrente permite a la red detectar y generar patrones variables en el tiempo, el único requerimiento es que la capa oculta posea suficientes neuronas (Valero & Senabre, 2010). La arquitectura de esta red está conformada por una capa de entrada por donde se presentan los datos, una capa oculta o más, donde se realiza la representación interna de la información y una donde se producen las salidas (capa de salida, figura 2). Adicionalmente existe otra capa llamada de contexto, la cual recibe información directamente de la capa oculta y transmite su salida a la misma capa oculta. Durante la etapa de entrenamiento o aprendizaje, la capa de contexto produce un retardo, el cual permite a la red almacenar información del estado anterior inmediato de las conexiones, por tanto, no solo es capaz de aprender a reconocer particularidades contenidas en los patrones de entrada sino también a construir una representación de las propiedades contenidas en los patrones de entrada (Castro, 2006). Con suficientes neuronas en la capa oculta, las redes de Elman pueden aprender cualquier relación dinámica de entrada-salida arbitrariamente bien.



**Figura 2.-** Esquema de una RNA Elman (basado en Castro, 2006 & Elman, 1990).

**Redes de tipo Hopfield.** Es un tipo de red neuronal dinámica, considerada así porque en esencia corresponde a un sistema cuyos estados dependen de la variable tiempo. Tienen una gran aplicación para el reconocimiento óptico de caracteres, su arquitectura se basa en una monocapa con  $N$  neuronas cuyos valores de salida son binarios, pudiéndose codificar los datos como cero y uno (0,1) o como más uno y menos uno (+1,-1), (Caicedo & López, 2017). Esta red recrea con mayor precisión el modelo natural del cerebro humano e imita en cierto modo la forma de procesar del neocórtex, que parece almacenar los recuerdos usando una memoria asociativa (Jiménez, 2014). Las redes con memoria asociativa son muy útiles para recuperar la información (patrones) que almacenan cuando el aprendizaje o entrenamiento ha concluido. Así, diferentes patrones pueden ser almacenados en la red durante la etapa de aprendizaje. Posteriormente, si se presenta a la entrada alguno de los patrones almacenados, la red evoluciona hasta estabilizarse, ofreciendo entonces en la salida el patrón almacenado que coincide con el presentado a la entrada. Si, por el contrario, la información de entrada no coincide con ninguno de los patrones almacenados, por estar distorsionada o incompleta, la red evoluciona generando como salida la más parecida. Esa información es aplicada directamente a la única capa de que consta la red, siendo recibida por las neuronas de dicha capa (cada neurona recibe una parte de la información, un elemento del vector que representa dicha información). Esta red utiliza un aprendizaje no supervisado de tipo Hebbiano, de tal forma que el peso de una conexión entre una neurona  $X_i$  y otra  $X_j$  se obtiene mediante el producto de los componentes  $i$ -ésimo y  $j$ -ésimo del vector que representa la información o patrón que debe almacenar. Si el número de patrones a “aprender” es  $M$ , el valor definitivo de cada uno de los pesos se obtiene mediante la suma de los  $M$  productos obtenidos por el procedimiento anterior, un producto por información a almacenar (figura 3). Una de las aplicaciones más comunes de esta red es en el reconocimiento de imágenes, puede reconstruir versiones distorsionadas o parciales de imágenes almacenadas durante la fase de aprendizaje (Hilera & Martínez, 1995).



**Figura 3.-** Esquema de una RNA Hopfield (basado en Mota, 2011).

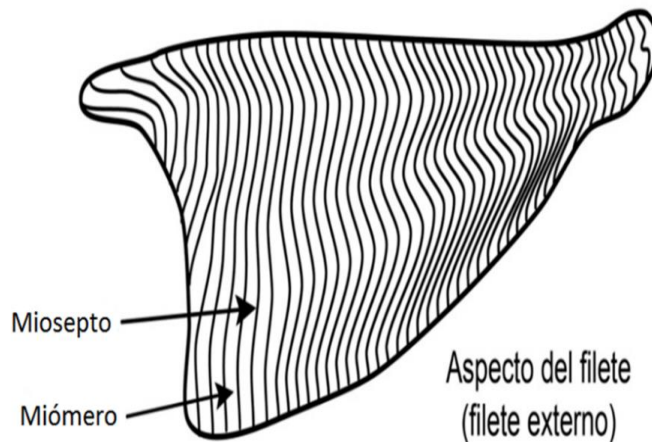
### **I.3. Uso de la visión artificial en la industria alimentaria.**

La industria alimentaria es una de las corporaciones que ha estado haciendo uso de la visión artificial ampliamente, con el fin de automatizar la inspección de la calidad de los alimentos y la clasificación de las categorías que permitan incrementar la productividad y competitividad de las empresas (García-García *et al.*, 2013). La preocupación por la seguridad y la calidad de los alimentos se muestra desde épocas remotas, pero solo hasta la mitad del siglo XIX se aprueban las primeras leyes y se implementan sistemas de control para vigilar el cumplimiento de esas normas. Con el incremento del comercio internacional de alimentos se evidencia la necesidad de establecer normas internacionales que rijan este intercambio; por lo que, tras la creación de la Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO, por sus siglas en inglés) se establece el *Codex Alimentarius* que constituye la base de muchas normas alimentarias



nacionales de cada país. En dicho código, uno de los aspectos importantes que se regula, es el etiquetado de los alimentos (Díaz & Durán, 2006). En el caso particular de los alimentos provenientes del mar, ríos, lagos y la acuicultura, el pescado es uno de los productos más comercializados en el mundo y tan solo en 2016 por primera vez supera los 20 kg *per cápita* a nivel mundial y se espera que para el 2020 se supere esta cifra, en México el consumo *per cápita* se incrementó 3.7 kg al pasar de 8.9 kg en 2012 a 12.6 kg en 2016 (FAO, 2018). Una de las presentaciones, en las que el pescado es mayormente comercializado es en filete. Es decir, lonjas de pescado de dimensiones y formas irregulares, separadas del cuerpo mediante cortes paralelos a la espina dorsal y los trozos cortados de dichas lonjas con o sin piel (Codex, 1995).

La musculatura del pescado constituye la parte más importante pues es la porción comestible, la cual está compuesta por segmentos funcionales llamados miómeros, dispuestos de modo seriado y separados entre sí por láminas de tejido conectivo denominadas mioseptos, el cartílago de los mioseptos forma a las costillas del pez (Olivares & Rojas., 2013). La apariencia del músculo segmentado es el resultado de la adaptación a la necesidad de flexionar el cuerpo durante el desplazamiento (Fig. 4). La morfología tridimensional de los miómeros y mioseptos muestra una complejidad creciente desde un modelo en V, presente en los elasmobranquios menos evolucionados, a la morfología en W, típica de los teleósteos (Bone, 1978).



**Figura 4.-** Musculatura del Pez (basado en Knorr, 1974).

Los componentes principales del músculo del pez varían considerablemente entre las especies, lo cual depende de la alimentación, edad, medio ambiente y la estación del año (Guerrero, 2009). La masa muscular de cada lado del pez forma un filete, la parte superior del filete es el músculo dorsal y la parte inferior del músculo ventral. De acuerdo con Codex (1995), los filetes de pescado destinados al consumo humano deben estar debidamente etiquetados y clasificados.

Por lo anterior, la necesidad de técnicas analíticas rápidas para medir la calidad de los productos del mar y la frescura es mayor que nunca, además de que varios estudios realizados a los consumidores indicaron que la calidad sigue siendo la clave de compra en productos como el pescado. Una de las técnicas más efectiva para medir la calidad del pescado es la evaluación sensorial; sin embargo, los avances en instrumentación, comprensión y técnicas estadísticas han creado una serie de nuevas oportunidades prometedoras. Los métodos actuales para evaluar la calidad de los productos alimenticios marinos son técnicas analíticas rápidas que utilizan instrumentos sofisticados, tales como el infrarrojo visible e infrarrojo cercano (VIS/NIR), la nariz electrónica, visión artificial, calorimetría de barrido diferencial (DSC), resonancia magnética nuclear (RMN), analizador de textura, entre otros, y se utilizan cada vez más para la seguridad y la calidad en los exámenes (Moreno *et al.*, 2009).

Por sus atributos las redes de tipo Elman y de tipo Hopfield puede utilizarse para el reconocimiento de patrones de filetes de pescado. Anteriormente, el término "reconocimiento de patrones" se refería a la detección de formas simples tales como caracteres escritos a mano, mapas del tiempo y espectros del lenguaje. Sin embargo, un objetivo más ambicioso ha sido durante mucho tiempo implementar la percepción artificial, es decir, imitar las funciones de los sistemas sensoriales biológicos en su forma más completa, especialmente en el análisis de imágenes (Caicedo & López, 2017).

## **II. ANTECEDENTES**

Anteriormente, en la identificación de especies de pescado la mayoría de los métodos se basaban en el análisis de proteínas, como el enfoque isoeléctrico (IEF) y los inmunoensayos; sin embargo, tiempo después, los métodos basados en el ADN crecieron en popularidad debido a su mayor especificidad, sensibilidad y capacidad de recuperación de productos alimenticios altamente procesados (Lenstra, 2003). Dentro del campo de identificación de especies basadas en ADN, existen numerosos métodos de detección disponibles, los principales incluyen: secuenciación de nucleótidos con información forense (FINS); polimorfismo de longitud de fragmentos de restricción (RFLP); ADN polimórfico de amplificación aleatoria (RAPD); polimorfismo de la longitud del fragmento amplificador (AFLP); polimorfismo conformacional monocatenario (SSCP); reacción en cadena de la polimerasa multiplex específica de especie (PCR); y PCR en tiempo real. De los cuales uno de los más utilizados es la PCR-RFLP que emplea un par de cebadores universales para amplificar (incrementar el número de copias de un fragmento de ADN) la misma región de ADN en todas las especies. El conjunto de moléculas de ADN idénticas (amplicón resultante) luego se digiere con enzimas de restricción que reconocen y cortan secuencias cortas de ADN. Para diferenciar las especies, se eligen enzimas que se dirigen a las regiones de variación entre las especies, y el resultado es un patrón específico de la especie de fragmentos de restricción que se pueden detectar con electroforesis en gel (separación fragmentos de ADN por su

tamaño y carga) o electroforesis capilar de laboratorio (separación basada en la diferente velocidad de migración de las distintas especies cargadas bajo la acción de un campo eléctrico). Este método es de bajo costo y relativamente simple, pero puede llevar mucho tiempo, ya que requiere un resumen de la restricción posterior a la PCR que puede durar hasta una noche (Rasmussen & Morrissey, 2011). Se han desarrollado ensayos PCR-RFLP para la detección de una amplia gama de especies, incluyendo pez blanco (Dooley *et al.*, 2015) y pargos. Para el método PCR-RAPD, un cebador de PCR corto (primers o cebadores son pequeñas piezas de ADN que anillan a secuencias específicas) está diseñado para amplificar fragmentos aleatorios a lo largo del genoma de la especie objetivo. El resultado es un perfil de banda de ADN específico de especie. Eso se puede visualizar con electroforesis en gel. Esta técnica es relativamente económica y fácil llevar a cabo; sin embargo, algunos problemas han sido reportados en términos de reproducibilidad e interpretación de resultados (Rasmussen & Morrissey, 2011). Las técnicas de identificación basadas en secuenciación, tales como PCR-FINS, han sido una ruta directa y confiable para obtener información específica de especie (Lockley & Bardsley, 2000; Bartlett y Davidson, 1992). Tras la amplificación por PCR y la secuenciación del gen, la secuencia de nucleótidos se compara con un conjunto de secuencias de referencia. Las especies pueden identificarse determinando qué secuencias de referencia exhiben la distancia genética más baja a la secuencia objetivo. Este método se ha utilizado para identificar numerosas especies de pescados y mariscos, como el pargo, el pez roca, la tilapia (Logan *et al.*, 2008), y sardina (Jerome *et al.*, 2013). También se creó una biblioteca de secuencias de referencia de códigos de barras de ADN obtenidos de especímenes para todas las especies de peces. Hasta el momento, se han obtenido secuencias de códigos de barras para más de 7,000 especies de peces y se han publicado numerosos estudios sobre el uso de códigos de barras de ADN para la identificación de especies de peces, su uso potencial sirve para detectar la sustitución de especies de peces. En un estudio para identificar especies en filetes de pescado ahumado se ha utilizado el código de barras del ADN, las especies, anguila longi (*Anguilla dieffenbachii*), pargo (*Pagrus auratus*), bacalao azul (*Parapercis colias*) y hoki

(*Macruronus novaezelandiae*) se identificaron en el nivel de 99 a 100% (Smith *et al.*, 2008). Por otra parte, Terrazas (2019) realizó un estudio en la Ciudad de México, Cancún y Mazatlán para verificar si las especies de pescado ofertadas en establecimientos como pescaderías, supermercados y restaurantes correspondían al nombre comercial con el que fueron vendidos, analizando 133 muestras de ADN encontró 116 casos de sustitución de especies de las cuales resaltan el mero, el robalo y el huachinango, las cuales fueron comúnmente sustituidos por tilapia, basa o raya. Siendo común el engaño con las especies favoritas de las personas, ya que se venden especies más baratas por aquellas más cotizada.

Pero aun cuando el código de barras del ADN ha resultado exitoso para la identificación de una variedad de especies de peces comerciales, puede resultar difícil obtener un código de barras completo a partir de productos altamente procesados que contienen ADN degradado. Así mismo, existe una gran cantidad de métodos genéticos y químicos para la identificación de especies de peces que están disponibles para autenticar todo tipo de productos de pesqueros. Sin embargo, muchos de ellos no han sido validados por estudios de colaboración y no tienen el estatus de métodos oficiales. En un contexto de creciente fraude y pesca ilegal, es necesaria la certificación de métodos para establecer su aceptabilidad en la industria y el comercio, así como en los tribunales (Rasmussen & Morrissey, 2011). Aunado a la necesidad de contar con técnicas analíticas rápidas para la identificación de especies en filetes de pescado, las técnicas de laboratorio no resultan tan convenientes pues son muy elaboradas y exigen material y reactivos específicos por lo que la inspección por caracteres morfológicos es la única forma de inspección rutinaria en los puntos de venta (Ordoñez, 2011). Respecto al campo de investigación que se enfoca a la clasificación y al reconocimiento de especies de filetes de pescado morfológicamente se han elaborado diversos manuales, uno de ellos fue propuesto por Kietzmann *et al.* (1974) para la inspección de peces, crustáceos y moluscos como alimento, quienes recurrieron al examen de la dirección y la anchura tanto de miómeros como de mioseptos en filetes de peces planos y redondos, sus resultados describen que los peces planos presentan trayectos ondulatorios de los miómeros y mioseptos, y que el espesor de sus filetes

es menor que el de los peces redondos. En 2011, Ordóñez elaboró una guía que tuvo como finalidad la identificación de filetes y rodajas de pescado de consumo usual en España, en dicha guía se tomaron en cuenta aspectos de la apariencia de la masa muscular del filete, tales como el tamaño, el color, y la disposición de los miómeros y mioseptos, los resultados señalaron que el tamaño de estos miómeros y mioseptos y el ángulo que forman varían de una especie a otra. Otra guía para identificar filetes de pescado fue elaborada por Gutiérrez (2012), en ella las características sujetas a evaluación fueron la coloración, la forma, el olor, el tamaño, el grosor y el peso del filete, así como la apariencia general de las fibras musculares que conforman a los miómeros y mioseptos. Por otra parte, González *et al.* (2013) a través de patrones morfológicos, merísticos y de pigmentación identificaron larvas de peces de la subdivisión Elopomorpha del Pacífico mexicano, en este estudio una de las características que tomaron en cuenta los autores fue el número de miómeros presentes en su musculatura, gracias a las características descriptoras tomadas en consideración lograron identificar las larvas leptocéfalas de la subdivisión antes mencionada.

Las características morfológicas son fundamentales en la clasificación de especies de peces, Tayama *et al.* (1982) describieron un método para clasificar las especies según su forma y longitud, logrando una fiabilidad de clasificación del 95% para cuatro especies de peces. En 1987 Wagner *et al.* usaron estas características para clasificarlos empleando funciones de discriminación lineal logrando una precisión de clasificación del 90% para nueve especies. Strachan (1993) para clasificar a los peces por especie utilizó los parámetros de color y forma, alcanzando una fiabilidad del 99% para 23 especies de peces (18 especies demersales y 5 pelágicas). Arnarson y Pau (1994) desarrollaron un algoritmo que usaba elementos de forma primitiva de estructuración para describir las características de la forma de los peces, que luego se alimentaron a una red neuronal para la clasificación de especies. Las tasas de clasificación de 100 y 94.6% se lograron con un conjunto de entrenamiento de 29 peces y un conjunto de prueba de 928 peces (tres especies: bacalao, platija y gallineta nórdica). Actualmente se cuenta con métodos de vanguardia para medir y clasificar automáticamente especies de peces utilizando

visión artificial, uno de ellos fue propuesto por White *et al.* (2006), los sistemas de visión artificial midieron automáticamente la longitud de los peces en un barco de investigación con una desviación estándar de 1.2 mm y con una fiabilidad de clasificación de hasta el 99.8% para siete especies de peces. Otro estudio fue el de Siddiqui *et al.* (2017), en el cual los autores emplearon videos subacuáticos y diversos modelos de redes neuronales profundas pre-adiestradas para clasificar peces, los resultados mostraron una precisión de la clasificación del 89%, que es competitiva o supera otros resultados recientemente reportados sobre tareas de identificación de especies de peces. Işçimen *et al.* (2018) realizaron un estudio con una base de datos que constaba de 1,321 imágenes de 16 familias y 35 especies de peces coloreadas en el espacio de color de canales rojo, verde y azul (RGB, por su abreviatura en inglés). Posteriormente se extrajeron dos conjuntos de características diferentes para peces mediante el examen de imágenes en modelos de color RGB y HSV (matiz, saturación, valor) se usaron por separado para fines de clasificación. La extracción de características se realizó utilizando un método basado en el color y para cada modelo de color, se extrajeron siete características estadísticas de cada componente del modelo de color. La clasificación se realizó según las familias y las especies utilizando el algoritmo de redes neuronales *Nearest Neighbor* como clasificador. Conforme a los resultados de la clasificación, los mejores rendimientos en las precisiones generales se lograron en un 93.5% y un 91% para familias de peces y clasificación de especies respectivamente. La visión artificial junto con métodos de computación como las redes neuronales artificiales también se han utilizado en la evaluación de la calidad de los huevos de la trucha arcoíris. En este sentido, las imágenes capturadas se transfirieron al dominio de color LAB (los tres ejes  $L^*a^*b^*$ , representan la luminosidad, la tonalidad rojo a verde y la tonalidad amarillo a azul, respectivamente), ya que este dominio se ve menos afectado por la cámara y las condiciones de iluminación, luego se extrajeron varias características de color y textura de las imágenes de los huevos de trucha arcoíris. Finalmente, las características extraídas se introdujeron en RNA como una capa de entrada. Los resultados mostraron que, con un ajuste óptimo de RNA, los huevos de peces vivos y muertos se clasificaron con el 99% de precisión (Bahrami *et al.*,

2015). Otro estudio vanguardista fue desarrollado por Viyuela (2016), quien creó una aplicación funcional para Windows destinada a la clasificación de langostinos cocidos según su color, la cual permite capturar la imagen de un langostino, procesarla y determinar su tipo empleando OpenCV (Microsoft Visual Studio y C/C++ como lenguaje de programación) para el procesamiento de las imágenes, esta aplicación cuenta con una tarjeta con las diferentes categorías de coloración del langostino y para la adquisición de imágenes, el langostino debe colocarse junto a la tarjeta clasificadora que reconoce y selecciona la región de interés con el fin de obtener su color y para el proceso de clasificación se compara el color detectado en el langostino con las distintas categorías.

Así mismo, el uso de tecnología basada en VA genera mejoras sustanciales en la inspección automática de calidad de frutas y verduras procesadas y no procesadas, los sistemas de visión artificial no solo reemplazan la inspección manual, sino que también pueden mejorar sus habilidades. Además, el desarrollo de tales sistemas adaptados a la industria alimentaria es fundamental para lograr ventajas competitivas (Saldaña *et al.*, 2013). Constante y Gordón (2015) desarrollaron un sistema de clasificación de tres tipos de fruta (fresa, mora y uvilla) con un porcentaje de reconocimiento del 87.5%, las técnicas empleadas se consideraron buenas prácticas agrícolas al mejorar la inspección visual humana y el manejo de los productos. Por otro lado, Figueroa y Roa (2016) crearon una herramienta computacional para la identificación del estado de maduración de granadillas, el algoritmo implementado se aplicó a 90 imágenes de granadillas en los diferentes estados de maduración. Los resultados obtenidos muestran 92.6% de aciertos en la identificación del estado de maduración de la fruta. Contar con diversos sistemas que permitan clasificar diferentes tipos de alimentos de acuerdo a su tamaño es también de gran importancia por lo que, Lizarazo y Palacios en 2017 elaboraron un sistema semiautomatizado que realiza la clasificación de cebolla cabezona o de bulbo en pequeña, mediana y grande, el método empleado brindó resultados coherentes con el desarrollo de un sistema que pretende trabajar en la industria a tiempo real, ayudando al proceso en cuanto a tiempo y esfuerzo del trabajador, disminuyendo los errores por la fatiga visual, ellos usaron el software



Labview 2013® para la captación de imágenes que permitiera distinguir el tamaño del producto y hacer su clasificación correcta, el uso de este software cumplió con lo propuesto en tiempo real y a la mínima latencia obtenida, lo que significa excelentes tiempos de respuesta utilizando este método. Un estudio ha demostrado que la inspección de productos alimenticios basada en máquinas puede implementarse de manera efectiva, reduciendo o incluso eliminando la necesidad de una intervención humana intensiva, en dicho estudio se analizó y presentó en detalle el sistema de control de calidad e inspección que se basa en técnicas de procesamiento de imágenes de dos tipos de productos alimenticios (pan de pita estilo árabe y tortillas mexicanas) con características visuales en 2D y 3D. Las características visuales de interés para este estudio se recopilan durante la fase de cocción para los productos y durante el proceso de clasificación. Los caracteres medidos para los productos fueron tamaño (ancho, largo, volumen y área), forma y color (color dominante, colores localizados, color promedio). Se usó un sistema de imágenes que utiliza una cámara digital de 5 megapíxeles para adquirir las imágenes, se utilizaron procedimientos como filtrado, binarización, zonificación, enmascaramiento y mejora para derivar los parámetros de control de calidad de los caracteres visuales de los productos bajo investigación (Alhusain, 2004). Herrera y Medina (2015) diseñaron un prototipo de un sistema de visión artificial de selección de frutos de café, el sistema se compone de tres principales componentes: el algoritmo de detección de brocas (un tipo de plaga), un algoritmo de detección por color, y un dispositivo mecánico de transporte y extracción de los frutos, los resultados obtenidos indican que este sistema de investigación propuesto fue capaz de discriminar entre cafés buenos para producción y los malos. En 2018 Palazzo señaló que el sistema de clasificación de imágenes puramente ascendente desde el análisis de patrones cerebrales puede superar el estado actual de la técnica con un método capacitado para extraer descriptores de contenido visual inspirados en el cerebro, plantea involucrar a las personas en los métodos de visión automatizados para mejorar su precisión. Recientemente, la visión artificial es utilizada en diferentes áreas de investigación y comúnmente hace uso de redes neuronales artificiales en el reconocimiento de patrones. Sarzuri (2014) también

aborda el problema de clasificación como un problema de reconocimiento de patrones complejo y plantea un diseño inicial de un algoritmo de clasificación de huellas dactilares basado en una red neuronal Función Base Radial, obteniendo un promedio del 90% al 95% de precisión en la clasificación, usando como referencia la base de datos NIST DB4. Por su parte, Flores (2015) empleó redes neuronales artificiales para el reconocimiento de cáncer de mama, el autor desarrolló una herramienta computacional para apoyo médico que identifica si se tiene un tumor maligno o benigno, así como el tipo de tejido mamario y realizar prediagnósticos a las pacientes que puedan ser propensas a padecer cáncer de mama y así reducir los falsos positivos y evitar procedimiento desagradables como la biopsias o cirugías que no sean necesarias.

Las redes neuronales artificiales también se han empleado para reconocer especies de flores con gran precisión. Gogul y Kumar (2017) utilizó redes neuronales convolucionales (CNN) para clasificar automáticamente diferentes especies de flores, el autor usó la cámara de un teléfono móvil para obtener las imágenes y la extracción de características de dichas imágenes se realizó mediante un enfoque de aprendizaje por transferencia (es decir, la extracción de características complejas de una red pre-entrenada). Los autores combinaron diferentes arquitecturas como extractores de características por transferencia (arquitectura OverFeat, Inception-v3 y Xception) con las CNN, las cuales produjeron impresionantes precisiones de 73.05% para OverFeat, 93.41% para Inception-v3 y 90.60% para Xception usando el conjunto de datos FLOWERS102. Por su parte, Iqbal y Aftab (2019) usaron MATLAB 2018 para desarrollar una investigación para analizar el rendimiento de la red neuronal artificial Feed-forward y la red neuronal artificial *Pattern Recognition* (PRANN). La red neuronal Feed-Forward se entrenó mediante el uso de la función de entrenamiento de regularización bayesiana, y la red neuronal de reconocimiento de patrones se entrenó mediante la función de entrenamiento graduado de gradiente conjugado. El conjunto de datos se dividió en tres partes diferentes: 70% de los datos de entrenamiento, 15% de los datos de validación y 15% de los datos de prueba. Para esto se determinó el coeficiente de correlación de Mathew (MCC) que se define como la relación entre las

clasificaciones binarias observadas y previstas, otra medida de rendimiento utilizada fue la precisión, el coeficiente de determinación ( $R^2$ ), el error cuadrático medio (por sus siglas en inglés MSE). Los resultados experimentales de los enfoques propuestos presentaron la red neuronal de reconocimiento de patrones muestra el error cuadrático medio más bajo siendo de 0.0086 para la detección de ataques con un MCC de 0.9934, un  $R^2 = 0.9941$  para una precisión de 99.6712.

Dentro del área de las pesquerías las redes neuronales artificiales se han empleado extensivamente como modelos predictivos, tal como lo hizo Cisneros (1996) al emplearlas en el pronóstico de biomasa de sardina del Pacífico y de su medio ambiente utilizando diversas series de tiempo de datos ambientales y biológicos del ecosistema nerítico de la Corriente de California (CC) y como predictores la velocidad del viento, la abundancia de huevos y larvas, la captura comercial y la biomasa desovante de la sardina del Pacífico (*Sardinops sagax caeruleus*) y de la anchoveta norte (*Engraulis mordux*), logrando para esta, buenas predicciones hasta con 9 años de anticipación de temperatura mensual a 10 m de profundidad de la CC, y para la biomasa desovante anual de la sardina del Pacífico con un año de anticipación. Así mismo, Joo (2018) identificó puntos de captura en los viajes pesqueros de anchoveta que fueron monitoreados por satélite mediante RNA logrando identificar correctamente un 80% de las calas entre las diferentes bases temporales.

El uso de las redes neuronales artificiales se ha incrementado con el paso del tiempo desde modelos predictivos hasta el reconocimiento de patrones junto a técnicas avanzadas de visión artificial; pero a pesar de esto, actualmente no se cuenta con registros de estudios realizados para la identificación de filetes de pescado mediante estos métodos.

### **III. PLANTEAMIENTO DEL PROBLEMA**

El etiquetado de diversos filetes de pescado con nombres de especies falsos es una de las prácticas de fraude alimentario que ocurren con frecuencia donde especies que tienen un alto valor comercial son sustituidas por especies de menor valor, representando un problema de calidad alimentaria. Los proveedores tienen como finalidad engañar a los consumidores poniendo deliberadamente en el mercado filetes con nombres falsos por una ganancia financiera. Existen diversos factores por los cuales la sustitución de especies representa un riesgo, uno de ellos es de salud pública, ya que el consumidor puede ser alérgico a la especie sustituta, otro puede ser de conservación de la biodiversidad, puesto que se han llegado a reportar algunas especies sustitutas que se encuentran en peligro de extinción, otro es que afecta a la economía del consumidor.

### **IV. JUSTIFICACIÓN**

De acuerdo con las normas de calidad alimentaria establecidas por la Organización de las Naciones Unidas para la Agricultura y la Alimentación (por sus siglas en Inglés, FAO) a través de su código alimentario de 1995, los filetes de pescado para su comercialización deben estar debidamente etiquetados y clasificados; es decir, deben presentarse con una etiqueta que indique su verdadera naturaleza de manera que no creen confusión o engaño al consumidor. A menudo en México como en otros países, un fraude pesquero de los sitios de venta de filetes de pescado es comercializarlos con nombres de especies caras remplazándolas por otras de menor valor comercial y el estado de Baja California Sur no es la excepción a este fraude. Las instancias correspondientes realizan inspecciones para dar cumplimiento a las normas de calidad establecidas por el código alimentario, pero la inspección visual y el control de calidad están a cargo de los ojos humanos, la inspección humana es un proceso lento, tiene poca capacidad de repetición y el resultado varía de persona a persona (Ashwin-Judal, 2015). Por lo tanto, se hace necesario estructurar una metodología rápida en la identificación de las especies de filetes de pescado lo cual se puede lograr utilizando técnicas de visión artificial en

el arreglo distintivo de los miómeros y mioseptos presentes en su musculatura porque la velocidad y la precisión del sistema de visión artificial según Ashwin-Judal (2015) satisfacen los crecientes requisitos de producción y calidad, ayudando así al desarrollo de procesos totalmente automatizados.

## **V. HIPÓTESIS**

Las técnicas de visión artificial son herramientas que logran identificar a las diferentes especies de peces comerciales, incluyendo aquellas taxonómica y morfológicamente más relacionadas en función de las características morfológicas de su musculatura.

## **VI. OBJETIVOS**

### **Objetivo general**

Desarrollar una técnica de visión artificial basada en algoritmos de redes neuronales artificiales que permita identificar filetes de peces comerciales.

### **Objetivos específicos**

1. Generar una base de datos de los filetes de pescado por medio de la captura de sus imágenes.
2. Procesar las imágenes de los filetes con un paquete computacional.
3. Entrenar dos algoritmos de redes neuronales artificiales utilizadas en el reconocimiento de patrones y determinar su eficiencia.
4. Validar el funcionamiento de los algoritmos de redes neuronales artificiales mediante un conjunto de imágenes testigo y el error mínimo.

## VII. MATERIAL Y MÉTODOS

### VII.1. Obtención e identificación de las especies.

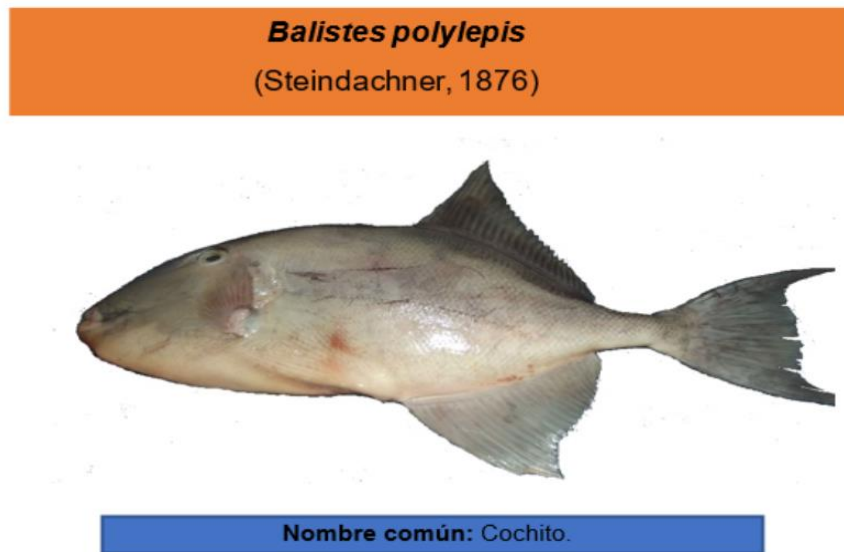
Con base en la importancia comercial pesquera en Baja California Sur (BCS) los organismos analizados fueron: *Balistes polylepis*, *Caulolatilus affinis*, *Caulolatilus princeps*, *Lutjanus argentiventris*, *Lutjanus peru* y *Paralabrax nebulifer*.

De los cuales, *Lutjanus argentiventris* y *Lutjanus peru* son consideradas especies de primera calidad y son sustituidas en ocasiones por otras de menor valor comercial como por ejemplo el *Bagre marinus* (bagre bandera) que se utiliza para sustituir a *Lutjanus peru* (Terrazas, 2019), mientras que *Balistes polylepis* y *Caulolatilus princeps* se encuentran catalogadas como especies de segunda calidad y son objeto de estudio debido a que los filetes de *B. polylepis* en ocasiones son remplazados por filetes de *Mugil cephalus* (lisa); de mismo modo, los filetes de *Caulolatilus princeps* son sustituidos por filetes de *C. affinis*. Por otro lado, *Caulolatilus affinis* y *Paralabrax nebulifer* son consideradas especies de tercera calidad y son utilizadas para remplazar a especies de valor comercial más elevado.

Los organismos antes mencionados se obtuvieron directamente de la pesca comercial efectuada en Agua verde, Loreto y en el Puerto de San Carlos, BCS. Con fines de preservación se llevó a cabo el eviscerado del pescado a bordo de la embarcación y se evitó en todo momento que las vísceras cayeran sobre la musculatura del pescado para no contaminarlo con los jugos digestivos. Las vísceras fueron recogidas en recipientes especiales; el pescado fue enjuagado con agua limpia. Para la conservación y transportación de los pescados fueron almacenados en capas alternadas hielo-producto y finalmente una capa gruesa de hielo encima (Díaz, 2006). Los organismos fueron trasladados al laboratorio de alimentos marinos de la Universidad Autónoma de Baja California Sur para su identificación y procesamiento, la identificación se realizó mediante claves taxonómicas (Fisher, 1995 a y b).

## VII.2. Descripción de las especies de este estudio.

***Balistes polylepis***. Es un pez que generalmente mide menos de 40 cm de longitud, es de cuerpo alto, cabeza grande, hocico pequeño y labios pronunciados, su piel es muy gruesa, su color corporal va de gris a marrón (Fischer *et al.*, 1995 a). Esta especie es uno de los recursos más importantes de la pesca ribereña en el Noroeste de México (Díaz, 2013). Es comúnmente capturado con líneas y anzuelos y ocasionalmente con redes de cerco (Fischer *et al.*, 1995 a), es usualmente comercializado en filete (Fig. 5).



**Figura 5.-** *Balistes polylepis* (cochito).

**Distribución:** Desde San Francisco, California hasta Callao, Perú.

**Hábitat:** Habita en aguas superficiales cerca de la costa y mar afuera (Fischer *et al.*, 1995). Se le encuentra en mares cálidos y asociados a arrecifes rocosos (Brito, 2003).

**Talla comercial:** 30 cm.

**Talla máxima:** 75 cm.

**Peso máximo:** 4 kg.

***Caulolatilus affinis***. Este pez tiene cuerpo oblongo, alargado y boca terminal (Fischer *et al.*, 1995), solo *C. affinis* y *C. chrysops* (del Atlántico) tienen una barra amarilla ancha desde debajo del ojo hasta el final del hocico (Dooley, 1978). Es capturado con redes de arrastre y otras artes de pesca artesanales, se comercializa en fresco y congelado (Fischer *et al.*, 1995) en presentación filete o entero (Fig. 6).



**Figura 6.-** *Caulolatilus affinis* (conejo).

**Distribución:** Desde el Sur de California hasta Perú.

**Hábitat:** Es un pez demersal que se encuentra entre 30 y 185 m de profundidad (Fischer *et al.*, 1995 b), asociado a fondos arenosos y lodosos, cerca de arrecifes aislados (Dooley, 1978).

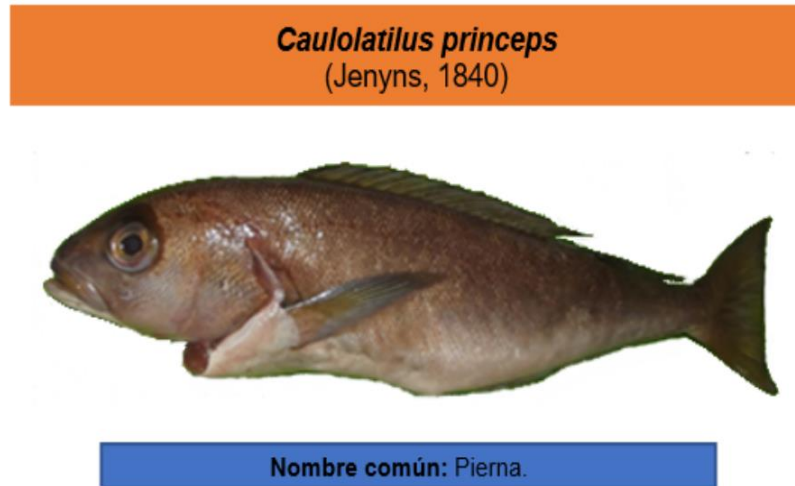
**Talla comercial:** 32 cm.

**Talla máxima:** 49.5 cm.

**Peso máximo:** 1.5 kg.



***Caulolatilus princeps***. Es un pez de cuerpo oblongo, alargado y boca terminal (Fischer *et al.*, 1995 b). El volumen de captura de esta especie en Baja California Sur fue de 3.7 toneladas por año en el período 1998-2005 para la Bahía de La Paz y de 12.5 toneladas para el resto del estado (Vázquez, 2011), se captura se lleva a cabo con redes de arrastre y también con anzuelos. Es comercializado en fresco y congelado, entero o en filete (Fig. 7).



**Figura 7.-** *Caulolatilus princeps* (pierna).

**Distribución:** Pacífico oriental desde la Isla de Vancouver en Columbia Británica, Canadá hasta Perú.


**Hábitat:** Se encuentra en fondos de tipo rocoso y arenosos, cerca de arrecifes aislados.

**Talla comercial:** 33 cm.

**Talla máxima:** La longitud máxima reportada es de 63.13 cm (Manríquez, 2018).

**Peso máximo:** 2.6 kg.

***Lutjanus argentiventris***. Tiene un cuerpo relativamente alto, cabeza grande, hocico algo puntiagudo, terminal y boca grande, su color es rosáceo-rojizo anterior, pero anaranjado o amarillo intenso en el resto del cuerpo y con la región ventral más clara, tiene una línea negra horizontal debajo del ojo (Fischer *et al.*, 1995 b). Se le pesca durante todo el año generalmente con anzuelo (4 y 5), aunque en ocasiones con redes de arrastre, siendo frecuente su aparición en los lances de camarón. Se consume fresco o congelado (Pérez & Ruiz, 1985), entero o fileteado (Fig. 8).



**Figura 8.-** *Lutjanus argentiventris* (pargo amarillo).

**Distribución:** Desde el Sur de California hasta Perú, es muy abundante frente a las costas de Mazatlán, México.

**Hábitat:** Abundante en zonas rocosas y de arrecife, principalmente en donde se den grandes poblaciones de camarones, cangrejos y peces pequeños de los cuales se alimenta.

**Talla comercial:** 32 cm.

**Talla máxima:** 71 cm.

**Peso máximo:** 5 kg (Pérez y Ruiz, 1985).

***Lutjanus peru***. Pez de cuerpo oblongo, cabeza grande, hocico puntiagudo, boca grande y terminal, su coloración corporal es roja (Fischer *et al.*, 1995). Es otra de las especies de la familia Lutjanidae de mayor demanda y cotización en el mercado (Pérez y Ruiz, 1985), está catalogada dentro del grupo de especies de primera calidad y es de las más capturadas en BCS, tan solo en la Bahía de La Paz entre los años 1998 y 2005 fue la especie más importante en cuanto a volumen de captura con 43% de la captura total (Vázquez *et al.*, 2010), es capturado principalmente con líneas de mano y ocasionalmente con redes de arrastre, se comercializa fresco y congelado (Fischer *et al.*, 1995 b) ya sea entero o en filete (Fig. 9).



**Figura 9.-** *Lutjanus peru* (huachinango).

**Distribución:** Desde Baja California hasta las costas de Perú.

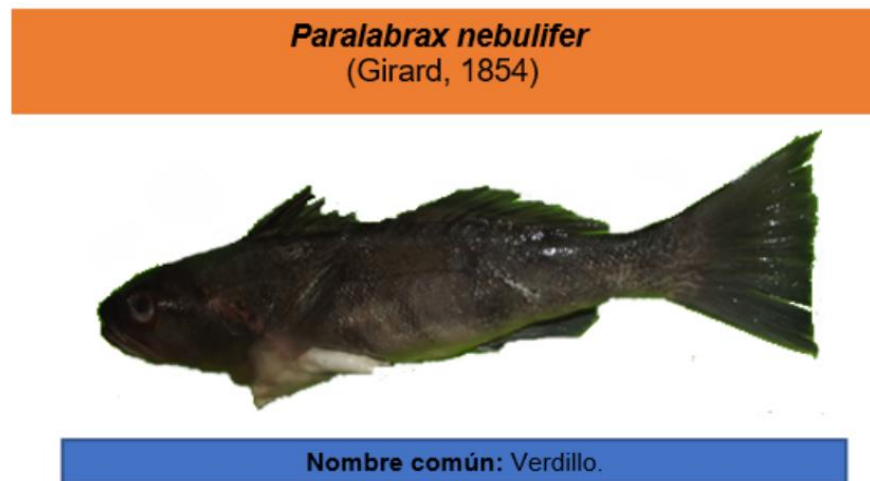
**Hábitat:** Demersal, común en mares tropicales y subtropicales (Fischer *et al.*, 1995 b), asociado a arrecifes de coral (Pérez y Ruiz, 1985).

**Talla comercial:** 34.3 cm.

**Talla máxima:** 60 cm.

**Peso máximo:** 2.789 kg (Ramos, 2001).

***Paralabrax nebulifer***. Este pez tiene un cuerpo bastante oblongo, una boca mediana, una coloración pardo-verdosa y franjas verticales oscuras (Fischer *et al.*, 1995 b, Mendoza y Rosales, 2002), está considerado como el recurso pesquero más importante de la pesca ribereña de escama en Baja California Sur (Díaz *et al.*, 2013) y es comercializado principalmente en filete. El 95% de las capturas se realizan con trampas y el 5% con redes y anzuelo, las dimensiones de las trampas son de 104 cm de largo, 78 cm de ancho y 47.5 cm de alto, la luz de malla es de 4 pulgadas (Álvarez, 2015; Fig. 10).



**Figura 10.-** *Paralabrax nebulifer* (verdillo).

**Distribución:** Desde Santa Cruz California, E.U.A. hasta Baja California Sur, México (abundante desde Punta Concepción hacia el sur) (Love *et al.*, 1996).

**Hábitat:** Se encuentra asociado a arrecifes y a sustratos arenosos.

**Talla comercial:** 29 cm.

**Talla máxima:** La talla máxima reportada es de 63 cm.

**Peso máximo:** 3.5 kg (Turner *et al.*, 1969).

### VII.3. Proceso de fileteado y fotografiado.

Después de la identificación de los organismos se llevó a cabo el proceso de fileteado, para ello se colocó el pescado de costado sobre la mesa con la cabeza hacia la derecha y el lomo del lado del que procesa, luego se realizó un corte paralelo a las espinas dorsales desde la cabeza hasta la cola alcanzando la inserción de las costillas a las vértebras y finalmente se procedió a levantar con la mano opuesta el corte anterior y se completa la separación del filete de las costillas en el mismo sentido del primer corte obteniendo el filete del lado izquierdo. Del mismo modo se procedió a la separación del filete del lado derecho, la diferencia radica en que los cortes se realizan de la cola hacia la cabeza. Finalmente, se les retiró la piel y se les extrajeron las espinas que salen de las vértebras en dirección a la línea lateral próximas a la cabeza (Balbuena, 2014; Fig. 11).



**Figura 11.-** Proceso de fileteado.

Los filetes fueron enjuagados con agua limpia y después fueron fotografiados empleando una cámara Fujifilm modelo FinePix S1800 con un lente de zoom óptico de 18x, dicho lente tiene un alcance que permite realizar acercamientos a distancia sin perder claridad en la imagen; además, tiene una resolución de 12.2 megapíxeles que permite tener fotografías de buena calidad manteniendo total nitidez sin importar el tamaño de la imagen. Su pantalla permite apreciar de manera clara los detalles en las imágenes y con la resolución de dicha pantalla se podrá tener una buena referencia de los filetes a capturar (Fig. 12).



**Figura 12.-** Cámara fotográfica.

Las imágenes de los filetes de pescado se almacenaron en formato JPEG (Joint Photographic Experts Group, por sus siglas en inglés) y fueron procesadas utilizando el paquete computacional MATLAB® (ver. 2013, 1994-2019 The MathWorks, Inc.). La unidad de procesamiento de este paquete es la matriz, por lo que su utilización en el procesamiento de imágenes (matrices) es una extensión natural de su lenguaje de programación (Cuevas *et al.*, 2010).

Para resaltar la orientación de los miómeros y mioseptos que conforman la musculatura de los peces e identificar y analizar los diferentes tipos de arreglos que perciben, se realizó un procesamiento digital de imágenes (PDI) que se compone de una serie de operaciones computacionales que tienen como fin interpretar alguna característica notable, dicho procesamiento es dividido en tres niveles: bajo, medio y alto. En el nivel bajo, se encuentran procesos que son correspondientes de suavizado, umbralización, eliminación de ruido, definición de los bordes para que los contornos exteriores e interiores sean identificados, estos se definen como preprocesamiento. Para llevar a cabo este proceso se buscó que todas las imágenes tuvieran el mismo nivel de intensidad para mejorar su calidad por lo que se obtuvieron los histogramas de cada una de ellas ya que describen la frecuencia con la que se presentan los valores de intensidad (píxeles), luego se ecualizaron utilizando la función:  $J = \text{histeq}(I, \text{hgram})$  para obtener imágenes con una intensidad equilibrada. En el nivel medio se definen procesos como extracción de las características y definición de límites. En el alto nivel se establecen relaciones semánticas entre los objetos de la descripción de la escena. Posteriormente, fueron pasadas a escala de grises, cuyos valores fueron escalados para representar un determinado número de intervalos. Después del proceso antes descrito, las imágenes fueron convertidas a binarias; es decir, blanco y negro que indican el estado falso (0) o verdadero (1). El *Toolbox* de MATLAB para el procesamiento de imágenes posee varias funciones que permiten realizar los escalamientos necesarios para convertir diferentes tipos de imágenes. En las operaciones de procesamiento de imágenes se realiza una discriminación y búsqueda de elementos y píxeles contenidos en la imagen por lo que las operaciones de indexado deben ser consideradas importantes. MATLAB soporta poderosos métodos de indexado para matrices y vectores que simplifica la elaboración de programas y mejora la eficiencia de los algoritmos (Cuevas *et al.*, 2010).

Posteriormente, se determinaron los momentos de Hu (1962) de las imágenes analizadas para el reconocimiento de formas invariantes con respecto a la rotación, pues la aplicación de la invarianza se requiere para que la imagen se reconozca correctamente independientemente de la posición y orientación en la

escena. Esto fue posible gracias a que Hu sentó las bases matemáticas de los momentos invariantes bidimensionales y demostró sus aplicaciones para el reconocimiento de formas, donde definió siete de estos valores de descriptor de forma calculados desde los momentos centrales hasta el orden tres que son independientes de la traslación, escala y orientación del objeto. La invarianza la logró calculando los momentos que se normalizan con respecto al centro de gravedad, de modo que el centro de masa de la distribución está en el origen (momentos centrales), los momentos invariantes de tamaño los derivó de los invariantes algebraicos y demostró que estos son el resultado de una normalización de tamaño simple.

A partir de los valores de segundo y tercer orden de los momentos centrales normalizados, se genera un conjunto de siete momentos invariantes que son independientes de la rotación. Los momentos invariantes se calculan en función de la información proporcionada por el límite de la forma y su región interior. Los momentos utilizados para construir el momento se definen en el continuo, pero para la implementación práctica se determinan en el espacio discreto. Dada una función  $f(x, y)$ , estos momentos regulares están definidos por:

$$M_{pq} = \iint x^p y^q f(x, y) dx dy \quad (1)$$

$M_{pq}$  es el momento bidimensional de la función  $f(x, y)$ . El orden del momento es  $(p + q)$  donde  $p$  y  $q$  son números naturales. Para su implementación en digital a partir de esto se convierte en:

$$M_{pq} = \sum_X \sum_Y x^p y^q f(x, y) \quad (2)$$

Para normalizar la traslación en el plano de la imagen, los centroides de la imagen se utilizan para definir los momentos centrales. Las coordenadas del centro de gravedad de la imagen se calculan utilizando la ecuación anterior y vienen dadas por:



$$\bar{X} = \frac{M_{10}}{M_{00}} \dots \bar{Y} = \frac{M_{01}}{M_{00}} \quad (3)$$

Los momentos centrales se pueden definir en su representación discreta como:

$$\mu_{pq} = \sum_X \sum_Y (X - \bar{X})^p (Y - \bar{Y})^q \quad (4)$$

Los momentos se normalizan aún más para los efectos del cambio de escala utilizando la siguiente fórmula:

$$\eta_{pq} = \mu_{pq} / \mu_{00}^Y \quad (5)$$

Donde el factor de normalización es:  $Y = (p + q/2) + 1$ , y desde los momentos centrales normalizados, se puede calcular un conjunto de siete valores que se definen por:

$$\phi_1 = \eta_{20} + \eta_{02}$$

$$\phi_2 = (\eta_{20} - \eta_{02})^2 + 4\eta_{11}^2$$

$$\phi_3 = (\eta_{30} - 3\eta_{12})^2 + (\eta_{03} - 3\eta_{21})^2$$

$$\phi_4 = (\eta_{30} + \eta_{12})^2 + (\eta_{03} + \eta_{21})^2$$

$$\phi_5 = (3\eta_{30} - 3\eta_{12})(\eta_{30} + \eta_{12}) [(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] + (3\eta_{21} - \eta_{03})(\eta_{21} + \eta_{03}) \times [3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2]$$

$$\phi_6 = (\eta_{20} - \eta_{02}) [(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] + 4\eta_{11}(\eta_{30} + \eta_{12})(\eta_{21} + \eta_{03})$$

$$\phi_7 = (3\eta_{21} - \eta_{03})(\eta_{30} + \eta_{12}) [(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] + (3\eta_{12} - \eta_{30})(\eta_{21} + \eta_{03}) \times [3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{30})^2]$$

Estos siete momentos invariantes establecidos por Hu, también fueron mostrados como independientes de la rotación. Sin embargo, se calculan sobre el límite de la forma y su región interior.

$$M_{pq} = \int_C x^p y^q ds \quad (6)$$

Para  $p, q = 0, 1, 2, 3$ , donde  $\int_C$  es la integral de línea a lo largo de la curva  $C$  y  $ds = \sqrt{(dx^2 + dy^2)}$ . Los momentos centrales se pueden definir de manera similar como:

$$\mu_{pq} = \int_C (X - \bar{X})^p (Y - \bar{Y})^q ds \quad (7)$$

Dado que los centroides son como en el método regular:

$$\bar{X} = \frac{M_{10}}{M_{00}} \dots \bar{Y} = \frac{M_{01}}{M_{00}} \quad (8)$$

Para una imagen digital, entonces la ecuación  $\mu_{pq}$  se convierte en:

$$\mu_{pq} = \sum_{(X, Y) \in C} (X - \bar{X})^p (Y - \bar{Y})^q \quad (9)$$

Estos nuevos momentos centrales también se pueden normalizar de modo que:

$$\eta_{pq} = \mu_{pq} / \mu_{00}^\gamma \quad (10)$$

Donde el factor de normalización es  $\gamma = p + q + 1$ . Los valores invariantes de siete momentos pueden calcularse como antes (Keyes & Winstanley, 2001).

#### **VII.4. Entrenamiento y validación de las RNA.**

El entrenamiento y la validación de la RNA se realizaron mediante el *Neural Network Toolbox* de MATLAB® ver. 2013 que cuenta con un diseño de arquitecturas de RNA para el reconocimiento de patrones que ya están proporcionados por defecto en el *Toolbox* para Elman y Hopfield. El *Toolbox* de MATLAB aportó gráficos para el análisis del comportamiento de las redes neuronales artificiales que resultan muy útiles en el estudio de la convergencia y estabilidad de los algoritmos de aprendizaje (Cuevas *et al.*, 2010; Bautista y Prieto, 2005).

El método de aprendizaje que utiliza el algoritmo Hopfield es Hebbiano, el cual mide la familiaridad de los datos de entrada. Las entradas y salidas permitidas a la neurona son binarias. La salida representa el grado de familiaridad o similitud entre la información que se le está presentando en la entrada y las informaciones que se le han mostrado hasta entonces (Match, 2001). La interfaz que se usó fue la proporcionada por el *Toolbox* de MATLAB. Este algoritmo es comúnmente usado en la clasificación de caracteres. Se ingresaron 30 imágenes binarizadas de filetes de pescado por especie al algoritmo Hopfield para la etapa del entrenamiento y el conjunto de imágenes testigo para la validación.

Mientras que para la etapa de entrenamiento del algoritmo Elman se emplearon los valores de los momentos invariantes de Hu de un conjunto de 180 imágenes (30 por especie) para alimentar a la red. En la etapa de validación el algoritmo se alimentó con un conjunto de imágenes testigos de 10 fotografías por especie, dichas imágenes no fueron utilizadas durante la etapa de entrenamiento y se evaluó si el algoritmo era capaz de clasificarlas en las categorías a las que pertenecen. Con la información resultante se evaluará el grado de eficiencia de ambos algoritmos y se elegirá el que resulte idóneo al presentar un error mínimo.

## VIII. RESULTADOS

Los filetes de los organismos analizados presentan distintas coloraciones, tamaños y formas entre las especies:

***Balistes polylepis*** tiene forma triangular y la coloración del filete es pardo-clara. Debido a sus características organolépticas es bien aceptado entre los consumidores, en el estado de Baja California Sur es uno de los filetes que se consume con mayor frecuencia, este producto es uno de los ingredientes principales en la preparación de ceviche. El filete de *Balistes polylepis*, que es considerado de segunda calidad tiene un coste de \$130.00 por kilogramo, dicho filete presenta fibras musculares (miómeros y mioseptos) que siguen un trayecto en forma de “W” con los brazos anchos (Fig. 13).



**Figura 13.-** Filete de *Balistes polylepis* (cochito).

***Caulolatilus affinis*** al ser comercializado en filete tiene un costo de \$110.00 por kilogramo, este filete es de coloración rosácea oscura, siendo esta una de las características que lo posiciona como filete de tercera calidad (Fig. 14).



**Figura 14.-** Filete de *Caulolatilus affinis* (conejo).

***Caulolatilus princeps*** comercializado en filete tiene un costo aproximado de \$125.00 por kilogramo en La Paz, BCS. Debido a su agradable sabor, textura y coloración clara resulta atractivo a la vista para el consumidor, esta especie se posiciona en una categoría comercial de segunda calidad (Fig. 15).



**Figura 15.-** Filete de *Caulolatilus princeps* (pierna).

Es importante destacar que el filete de *C. affinis* tiene un gran parecido al filete de *C. princeps*, tal como puede observarse en las figuras 14 y 15, y debido a esto algunos comerciantes utilizan a *C. affinis* (conejo) para remplazar a *C. princeps* (pierna).

***Lutjanus argentiventris*** en filete tiene un costo de \$190.00 por kilogramo, esta especie es considerada de primera calidad debido a diversas características entre ellas organolépticas. Los filetes de *L. argentiventris* presentan una coloración pardo-oscuro y forma elongada (Fig. 16).



**Figura 16.-** Filete de *Lutjanus argentiventris* (pargo amarillo).

***Lutjanus peru*** es considerada también como una especie de primera calidad, en presentación filete tiene un costo que ronda entre los \$190.00 por kilogramo, la coloración de este filete es pardo-oscuro y su forma es elongada (Fig. 17).



**Figura 17.-** Filete de *Lutjanus peru* (huachinango).

***Paralabrax nebulifer*** es una especie que se encuentra posicionada dentro de la tercera categoría comercial. El filete cuesta alrededor de \$110.00 el kilogramo en la ciudad de La Paz, BCS, dicho filete es de coloración marrón oscuro y tiene una forma elongada (Fig. 18).



**Figura 18.-** Filete de *Paralabrax nebulifer* (verdillo).

### VIII.1. Procesamiento de imágenes.

Para que las imágenes del dispositivo de almacenamiento fueran leídas en MATLAB se creó un *Script* que permitió cargar el extenso conjunto de imágenes, el cual fue capaz de leer las subcarpetas contenidas dentro de la carpeta de imágenes, esto con el fin de encontrar la totalidad de las imágenes (Anexo 1). Una vez cargadas las imágenes, se obtuvieron los tamaños de estas ejecutando la sintaxis:  $(M N) = \text{size}(A)$ . Donde la variable  $M$  almacenó el número de renglones de la imagen y  $N$  el número de columnas de la imagen  $A$ .

Posteriormente, se buscó que todas las imágenes tuvieran una distribución equilibrada de niveles de intensidad mediante la ecualización para que pudieran ser analizadas las propiedades importantes de la imagen con mejor. La figura 19 muestra los histogramas de una fotografía de *Balistes polylepis* que mediante la ecualización fue ajustada a una distribución equilibrada de niveles de intensidad (píxeles).

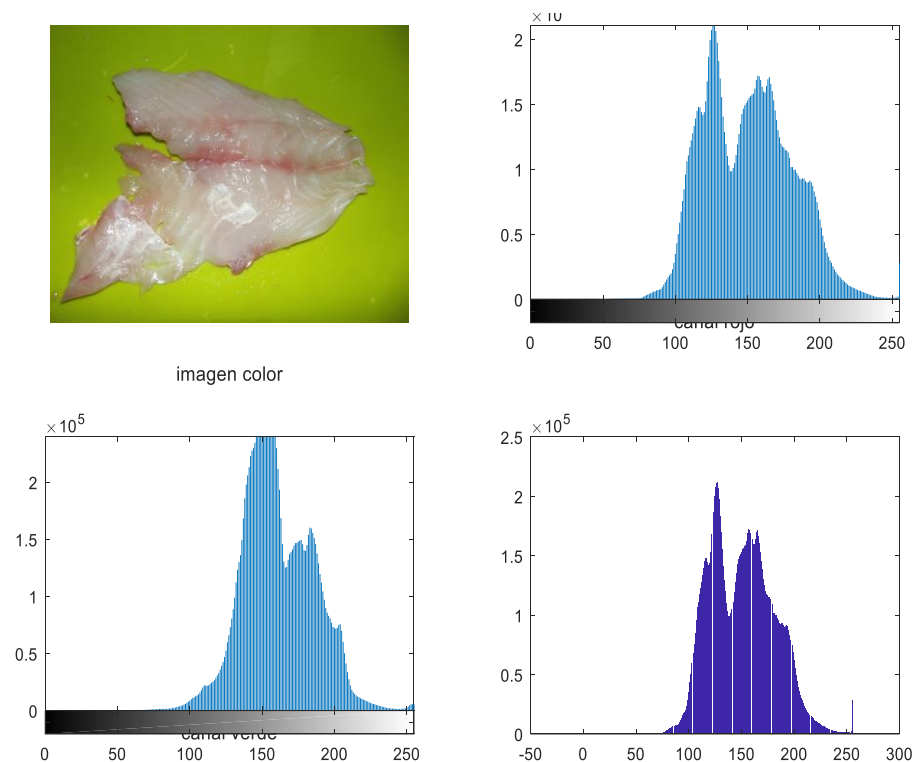



Figura 19.- Histogramas RGB.




Como se puede observar en la figura anterior no es posible eliminar todos los picos del histograma para tener uno igualmente distribuido para todos sus niveles de grises, por ello solo se transforma la imagen a una aproximación de la distribución equilibrada de niveles de intensidad para que mejore su distribución (Cuevas *et al.*, 2010). El resultado final de esta imagen equilibrada de niveles de intensidad (ecualizada) de brillo y contraste se muestra en la figura 20.



**Figura 20.-** *Balistes polylepis* ecualizada.

Las imágenes ecualizadas fueron pasadas a una segunda escala de grises cuyos valores han sido escalados para representar un determinado número de intervalos, ya que el objetivo es resaltar algunas regiones con un color de contraste que las identifique y con la ecualización no es suficiente, un ejemplo de dicho proceso se muestra en la figura 21.



**Figura 21.-** Imágenes a escala de grises. 1) *B. polylepis*, 2) *C. affinis*, 3) *C. princeps*, 4) *L. peru*, 5) *L. argentiventris* y 6) *P. nebulifer*.

Para la eliminación de ruido, mejorar la nitidez y extraer los bordes de las imágenes, se probaron diversos algoritmos de filtrado (Canny, Sobel, Binario) que, a su vez, nos generó una imagen binaria, la cual permite facilitar el entrenamiento de las RNA.

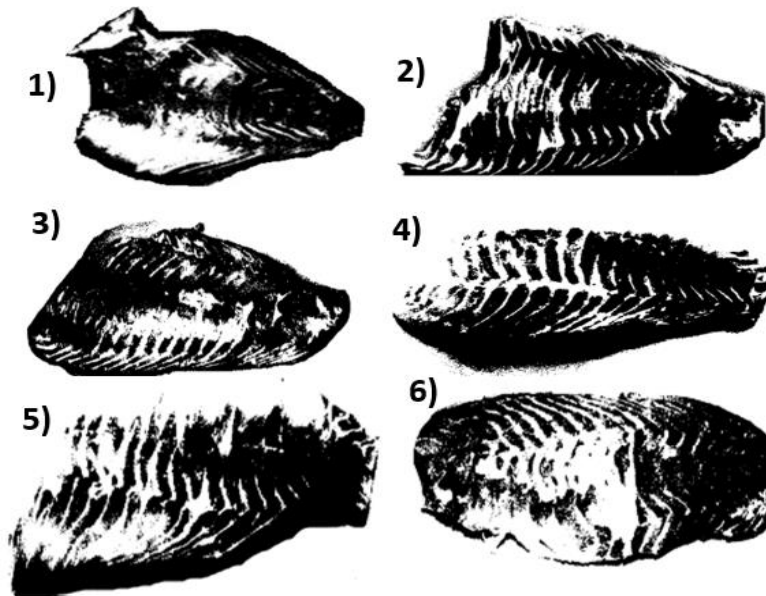
El filtro de Canny (Canny, 1986) es un método que se basa en la aplicación de una serie de filtros en direcciones y resoluciones diferentes, los cuales al final son combinados en un resultado único, con el fin de detectar los bordes en las imágenes. La selección de este filtro fue debido a que intenta alcanzar 3 objetivos: a) minimizar el número de bordes falsos, b) hacer una mejor localización de los bordes de la imagen, y c) entregar una imagen cuyo ancho de borde es un píxel. Debido a la amplia utilización de este filtro como etapa previa a la clasificación de objetos y a su robustez en la determinación de bordes es normalmente implementado en la mayoría de las librerías comerciales y herramientas de

procesamiento digital de imágenes (Cuevas *et al.*, 2010). En MATLAB se ejecutó mediante el formato Edge. Pero, el filtro de Canny no resultó ser efectivo para nuestro caso de estudio pues no muestra claramente los bordes y las regiones de interés en las imágenes; es decir, los miómeros y los mioseptos no se aprecian de manera inteligible, lo cual es la finalidad para el entrenamiento de las RNA. Por lo que se continuó con las pruebas con el Operador Sobel (Cuevas *et al.*, 2010), puesto que el filtro Sobel detecta los bordes horizontales y verticales sobre una imagen en escala de grises, calculando una aproximación al gradiente de la función de intensidad de la imagen en cada punto (píxel) (Patnaik & Yang, 2012). El resultado tras aplicar este filtro indica que no es idóneo para este caso de estudio, lo que da como resultado una imagen con una nitidez más clara que con el filtro de Canny; pero, aun así, no se observan los miómeros y mioseptos de manera más robusta, incluso en ciertas regiones se pierde información de estos. Por esta razón se decidió probar el filtro binario, el cual está constituido por ecuaciones booleanas que permiten eliminar el ruido tanto de las zonas blancas como de las zonas negras con un modelo RGB en escala de grises (Cuevas *et al.*, 2010) modificando el umbral para cada imagen hasta encontrar el valor que da mayor realce de los atributos distintivos de los filetes (miómeros y mioseptos) tal como se muestra en la figura 22.

El comando para realizar este último proceso es como sigue:

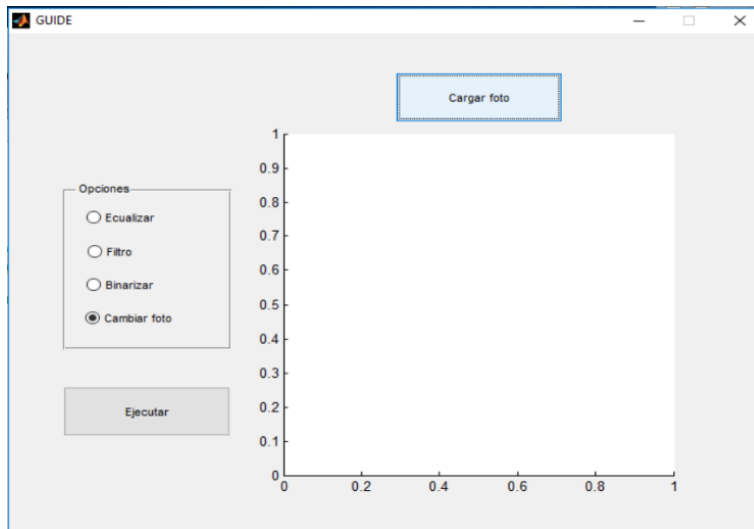
```
>>I=im2bw(imgray,L)
```

Donde L es el nivel de umbralización que está dentro del rango de 0=0 a 255=1.



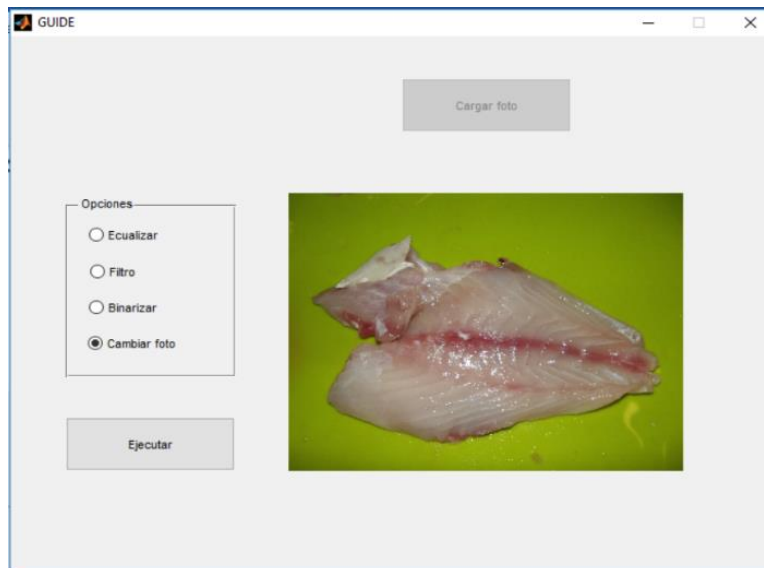
**Figura 22.-** Imágenes binarizadas. 1) *B. polylepis*, 2) *C. affinis*, 3) *C. princeps*, 4) *L. peru*, 5) *L. argentiventris* y 6) *P. nebulifer*.

Posteriormente, se creó en MATLAB una interfaz gráfica de usuario llamada en inglés GUI (Graphical User Interface) teniendo como finalidad aplicar los procedimientos anteriores de manera sencilla y didáctica al tratarse de un entorno de programación visual, este elemento gráfico le permite al usuario comunicarse con el sistema o estructura basándose en relaciones visuales como ventanas, íconos, menús y punteros (Wolf, 2015) con la finalidad de contar con un entorno en el que se pudiera procesar toda la base de datos de las imágenes de manera rápida y sencilla, tal como se muestra en la figura 23.



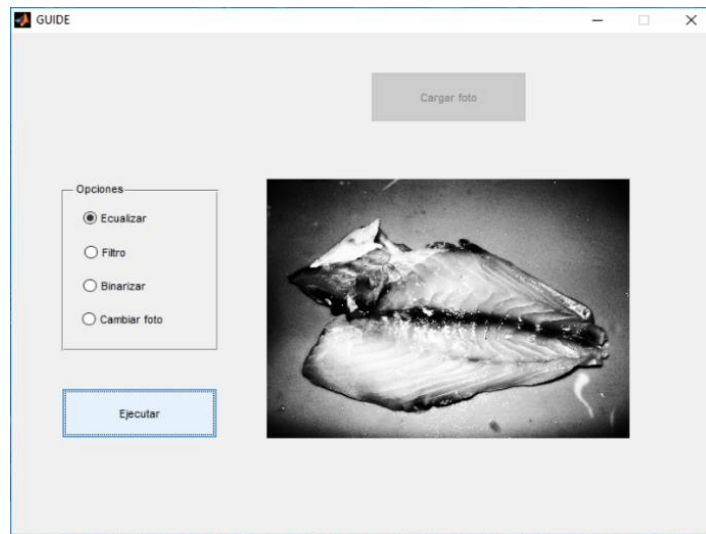
**Figura 23.-** Interfaz gráfica.

La interfaz gráfica, presenta un botón para cargar la foto, que una vez que hace la búsqueda en las carpetas y se selecciona el archivo, la imagen del filete de pescado es desplegada en la ventana de la interfaz (Fig. 24).



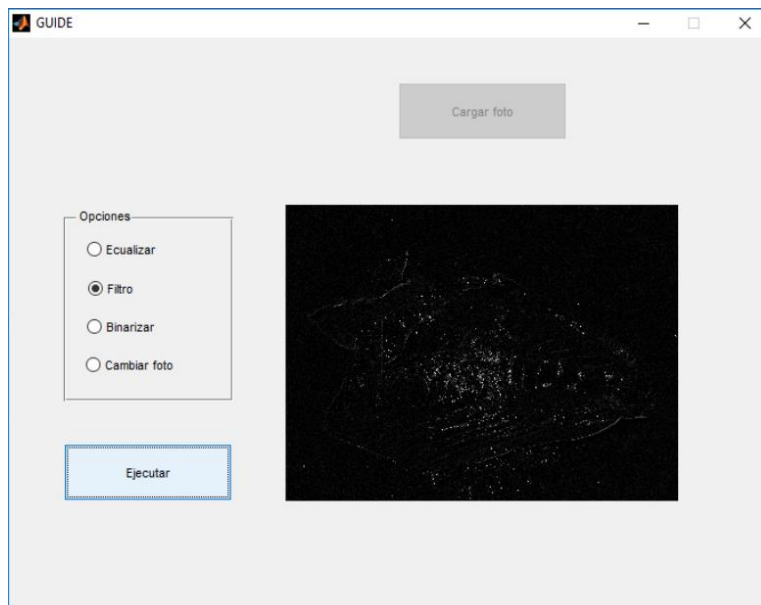
**Figura 24.-** Imagen cargada en la interfaz gráfica.

Después de cargar la imagen, el siguiente proceso es ecualizarla (botón <Ecuilizar>) (Fig. 25).



**Figura 25.-** Imagen ecualizada

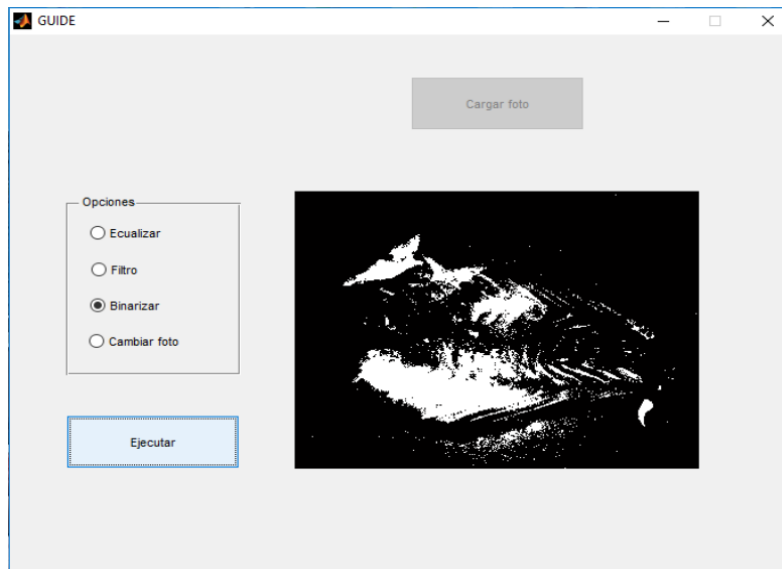
Una vez que la imagen es ecualizada, se procede a aplicar el filtro de Sobel (<Filtro>) para la detección de bordes (Fig. 26).



**Figura 26.-** Imagen con filtro desplegada en la interfaz gráfica.

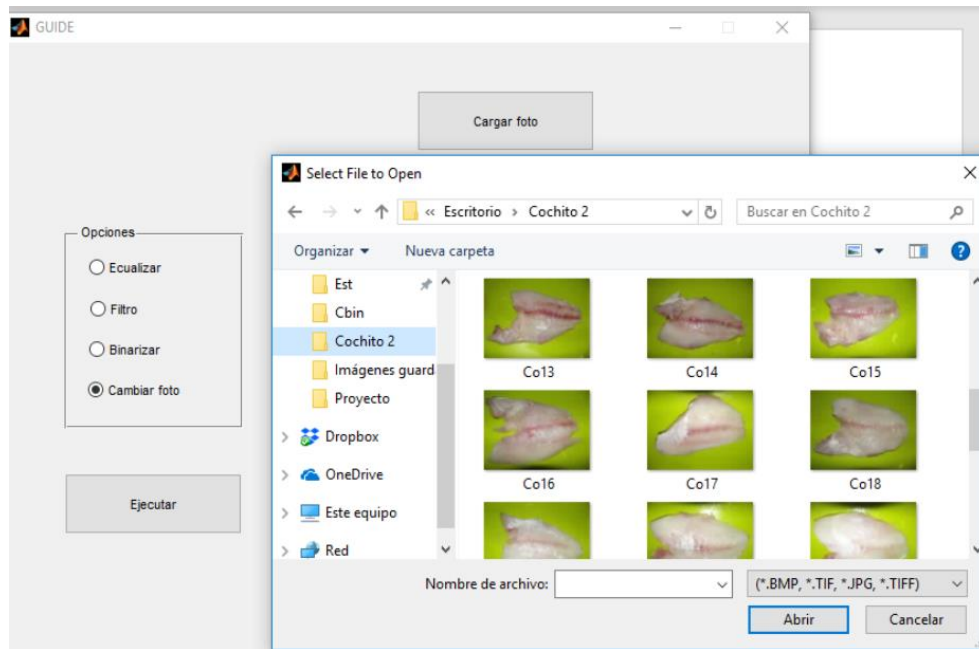
Al realizar la detección de bordes con el filtro Sobel se analiza la imagen correspondiente y si el resultado es el idóneo ya no se aplican los demás. Por lo que esta aplicación de filtros no es secuencial, sino más bien se elige entre uno u otro según se obtenga el resultado satisfactorio. Pero como se había mencionado anteriormente, al examinar el conjunto de fotografías con el filtro de Sobel se encontró que ninguna de ellas presentaba buenos resultados para el análisis basado en redes neuronales por lo que fueron binarizadas.

El siguiente paso es binarizar la imagen objeto de estudio, por medio del botón <Binarizar> como puede verse en la figura 27.



**Figura 27.-** Imagen binarizada en la interfaz gráfica.

Por último, se encuentra el botón <Cambiar foto> que sirve para elegir una nueva foto y comenzar el ciclo de las etapas del procesamiento de imágenes (Fig. 28).



**Figura 28.-** Cargar nueva foto.

Una vez que todas las imágenes son procesadas, el siguiente paso es realizar los cálculos de los momentos invariantes de Hu de cada una de ellas para alimentar los algoritmos de redes neuronales artificiales de manera que puedan ser reconocidas sin importar la orientación en la que se encuentren.


## **VIII.2. Cálculo de los momentos invariantes de las imágenes.**

Para calcular los momentos invariantes de las 240 imágenes se utilizó un algoritmo desarrollado en MATLAB (Anexo 2). Para ilustrar la manera en que opera el algoritmo, se muestra a continuación, como ejemplo, una foto de un filete por especie rotada en diferentes direcciones. Los momentos de Hu como se había mencionado en un principio, constan de siete descriptores que para este estudio cuantifican la forma de los filetes de pescado. Es decir, la forma característica de un objeto puede cuantificarse mediante momentos, los cuales describen la manera en que se distribuyen los píxeles de un objeto sobre el plano de la imagen. Los momentos deben ser invariantes (valores iguales) a las transformaciones



geométricas (traslación, rotación y escalamiento) que pueden sufrir las imágenes y al mismo tiempo deben ser discriminantes (valores distintos para imágenes de diferente tipo). Estas características son deseables para poder reconocer los objetos con mayor facilidad (Gómez, 2015; Hu, 1962).

A continuación, se muestra la imagen de un filete de *B. polylepis* rotada en diferentes direcciones para calcular sus momentos invariantes de Hu (Fig. 29).




**Figura 29.-** Filete de *B. polylepis* examinado durante el cálculo de los momentos invariantes de Hu. a) filete antes de aplicar la rotación. Las imágenes fueron rotadas en sentido contrario a las manecillas del reloj; b) 45°; c) 90°; d) 180°; e) 270°.

La tabla 1 muestra los resultados obtenidos del cálculo de los momentos invariantes de Hu para *Balistes polylepis*.

**Tabla 1.-** Valores de los momentos invariantes de Hu para una imagen de *Balistes polylepis*.

Imagen	$\phi 1$	$\phi 2$	$\phi 3$	$\phi 4$	$\phi 5$	$\phi 6$	$\phi 7$
45°	0.0013	0.0000	0.0000	0.0000	0.0000	-0.0000	-0.0000
90°	0.0013	0.0000	0.0000	0.0000	0.0000	-0.0000	-0.0000
180°	0.0013	0.0000	0.0000	0.0000	0.0000	-0.0000	-0.0000
270°	0.0013	0.0000	0.0000	0.0000	0.0000	-0.0000	-0.0000

La figura 30 nos muestra una imagen de filete de *Caulolatilus affinis* que fue sometida al procedimiento arriba mencionado.



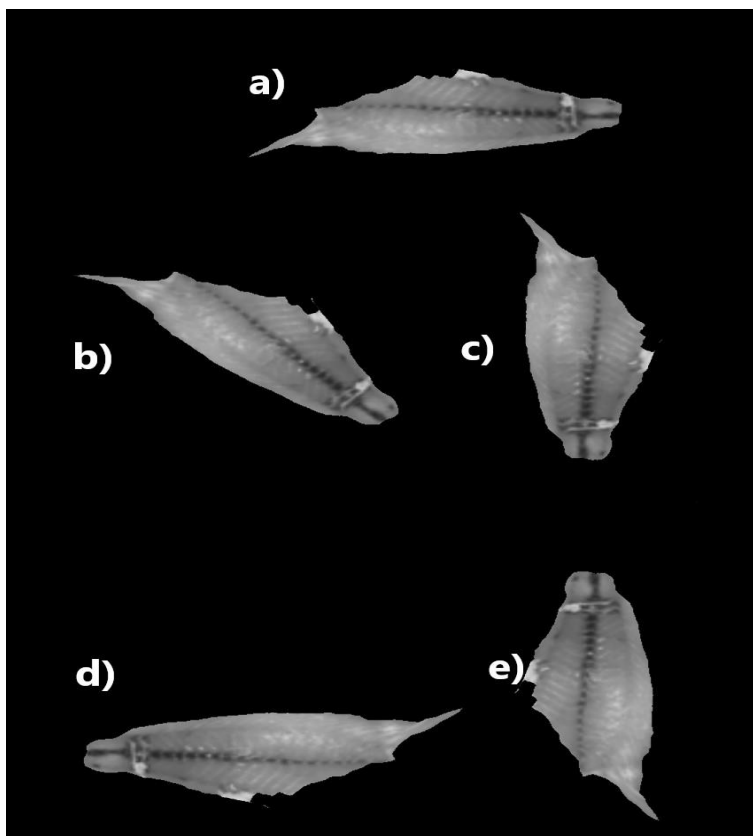
**Figura 30.-** Filete de *C. affinis* examinado durante el cálculo de los momentos invariantes de Hu. a) filete antes de aplicar la rotación. Las imágenes fueron rotadas en sentido contrario a las manecillas del reloj: b) 45°; c) 90°; d) 180°; e) 270°.

Los resultados obtenidos del cálculo de los momentos invariantes de Hu para la foto anterior se muestran en la tabla 2.

**Tabla 2.-** Valores de los momentos invariantes de Hu para una imagen de *Caulolatilus affinis*.

Imagen	$\phi_1$	$\phi_2$	$\phi_3$	$\phi_4$	$\phi_5$	$\phi_6$	$\phi_7$
45°	0.0012	0.0000	0.0000	0.0000	0.0000	0.0000	-0.0000
90°	0.0012	0.0000	0.0000	0.0000	0.0000	0.0000	-0.0000
180°	0.0012	0.0000	0.0000	0.0000	0.0000	0.0000	-0.0000
270°	0.0012	0.0000	0.0000	0.0000	0.0000	0.0000	-0.0000

Por otro lado, la figura 31 muestra un filete de *Caulolatilus princeps* examinado para el cálculo de los momentos invariantes de Hu.




**Figura 31.-** Filete de *C. princeps*. a) filete antes de aplicar la rotación. Las imágenes fueron rotadas en sentido a las manecillas del reloj; b) 45°; c) 90°; d) 180°; e) 270°.

En tanto, los valores del cálculo de los momentos invariantes de Hu para la foto arriba indicada se muestran en la tabla 3.

**Tabla 3.-** Valores de los momentos invariantes de Hu para una imagen de *Caulolatilus princeps*.

Imagen	$\phi_1$	$\phi_2$	$\phi_3$	$\phi_4$	$\phi_5$	$\phi_6$	$\phi_7$
45°	0.7992	0.0000	0.0000	0.0000	-0.0000	0.0000	0.0000
90°	0.7992	0.0000	0.0000	0.0000	-0.0000	0.0000	0.0000
180°	0.7992	0.0000	0.0000	0.0000	-0.0000	0.0000	0.0000
270°	0.7992	0.0000	0.0000	0.0000	-0.0000	0.0000	0.0000

En la figura 32 se muestra un filete de *Lutjanus argentiventris* presentado para el cálculo de los momentos invariantes de Hu.




**Figura 32.-** Filete de *L. argentiventris* examinado durante el cálculo de los momentos invariantes de Hu. a) filete antes de aplicar la rotación. Las imágenes fueron rotadas en sentido a las manecillas del reloj: b) 45°; c) 90°; d) 180°; e) 270°.

Los resultados producto del cálculo de los momentos invariantes de Hu para la imagen de anterior se muestran en la tabla 4.

**Tabla 4.-** Valores de los momentos invariantes de Hu para una imagen de *Lutjanus argentiventris*.

Imagen	$\phi_1$	$\phi_2$	$\phi_3$	$\phi_4$	$\phi_5$	$\phi_6$	$\phi_7$
45°	0.0026	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000
90°	0.0026	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000
180°	0.0026	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000
270°	0.0026	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000

El siguiente caso es una imagen de filete de *Lutjanus peru* sometida al igual que el resto al cálculo de los momentos invariantes de Hu (Fig. 33).




**Figura 33.-** Filete de *L. peru* examinado durante el cálculo de los momentos invariantes de Hu. a) filete antes de aplicar la rotación. Las imágenes fueron rotadas en sentido a las manecillas del reloj; b) 45°; c) 90°; d) 180°; e) 90°.

Los resultados derivados del cálculo de los momentos invariantes de Hu para la imagen anterior se indican en la tabla 5.

**Tabla 5.-** Valores de los momentos invariantes de Hu para una imagen de *Lutjanus peru*.

Imagen	$\phi_1$	$\phi_2$	$\phi_3$	$\phi_4$	$\phi_5$	$\phi_6$	$\phi_7$
45°	0.0024	0.0000	0.0000	0.0000	0.0000	0.0000	-0.0000
90°	0.0024	0.0000	0.0000	0.0000	0.0000	0.0000	-0.0000
180°	0.0024	0.0000	0.0000	0.0000	0.0000	0.0000	-0.0000
270°	0.0024	0.0000	0.0000	0.0000	0.0000	0.0000	-0.0000

Por último, se muestra una imagen de filete de *Paralabrax nebulifer* sometida al cálculo de los momentos invariantes de Hu (Fig. 34).



**Figura 34.-** Filete de *P. nebulifer* examinado bajo los momentos invariantes de Hu. a) filete antes de aplicar la rotación. Las imágenes fueron rotadas en sentido a las manecillas del reloj: b) 45°; c) 90°; d) 180°; e) 270°.

Los resultados obtenidos tras calcular los momentos invariantes de Hu de la imagen anterior se observan en la tabla 6.

**Tabla 6.-** Valores de los momentos invariantes de Hu para una imagen de *Paralabrax nebulifer*.

Imagen	$\phi_1$	$\phi_2$	$\phi_3$	$\phi_4$	$\phi_5$	$\phi_6$	$\phi_7$
<b>45°</b>	0.0015	0.0000	0.0000	0.0000	0.0000	0.0000	-0.0000
<b>90°</b>	0.0015	0.0000	0.0000	0.0000	0.0000	0.0000	-0.0000
<b>180°</b>	0.0015	0.0000	0.0000	0.0000	0.0000	0.0000	-0.0000
<b>270°</b>	0.0015	0.0000	0.0000	0.0000	0.0000	0.0000	-0.0000

Como puede observarse en las tablas anteriores, los valores de los momentos invariantes para cada imagen de las especies no varían aun cuando la orientación de la imagen cambia, lo que significa que el algoritmo es capaz de reconocer las imágenes que se le presentan invariablemente de la posición en la que se encuentren. Estos valores conforman la base de datos para continuar con el proceso del algoritmo de Elman.

### **VIII.3. Entrenamiento de las Redes de Elman en MATLAB.**

Los valores de los momentos invariantes de Hu de las 240 imágenes de filetes de pescado se ingresaron como vectores a las Redes Neuronales Artificiales (RNA) Elman teniendo como entrada los siete valores de los momentos invariantes de cada foto y los valores de la longitud y ancho de cada filete (9 entradas) como se muestra en la figura 35, dos capas ocultas y un número de neuronas que varió en un intervalo de 10 a 60 con el fin de generar el mínimo error cuadrático medio (MSE) y maximizar el coeficiente de correlación Spearman (R) como indicadores de eficiencia. El mejor resultado se logró con 39 neuronas en las capas ocultas con error cuadrático medio de  $2.94 \times 10^{-14}$  (Fig. 36).

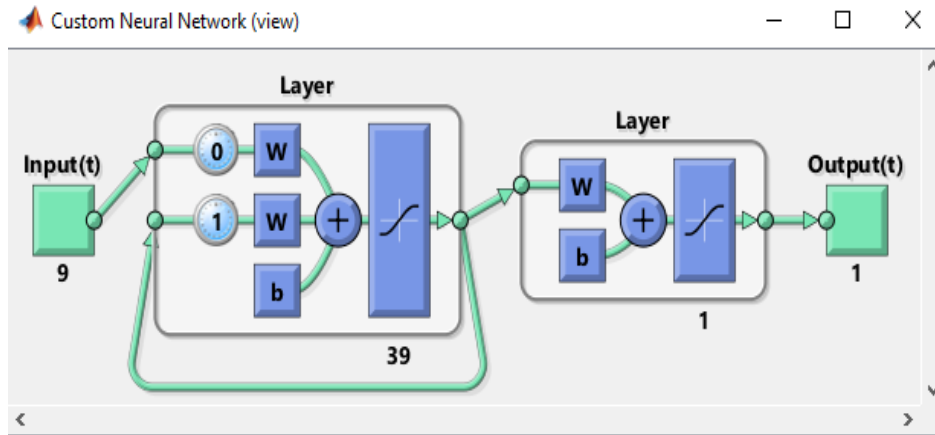


Figura 35.- Arquitectura de la RNA Elman compuesta de 39 neuronas.

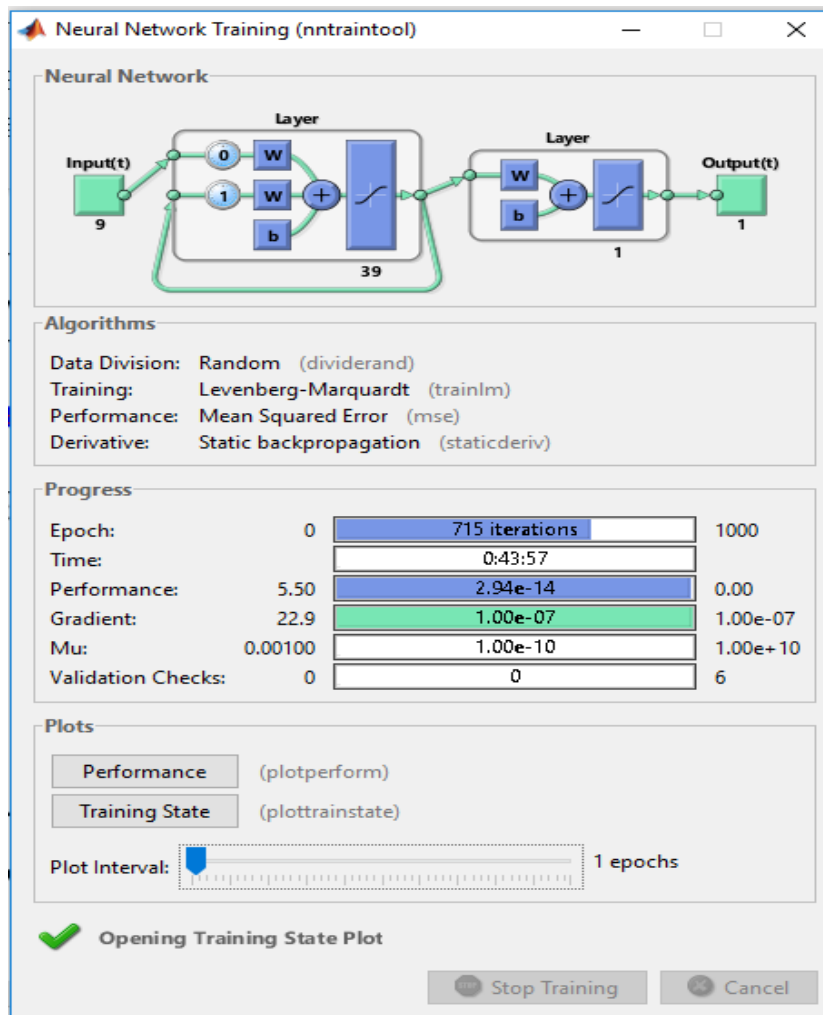
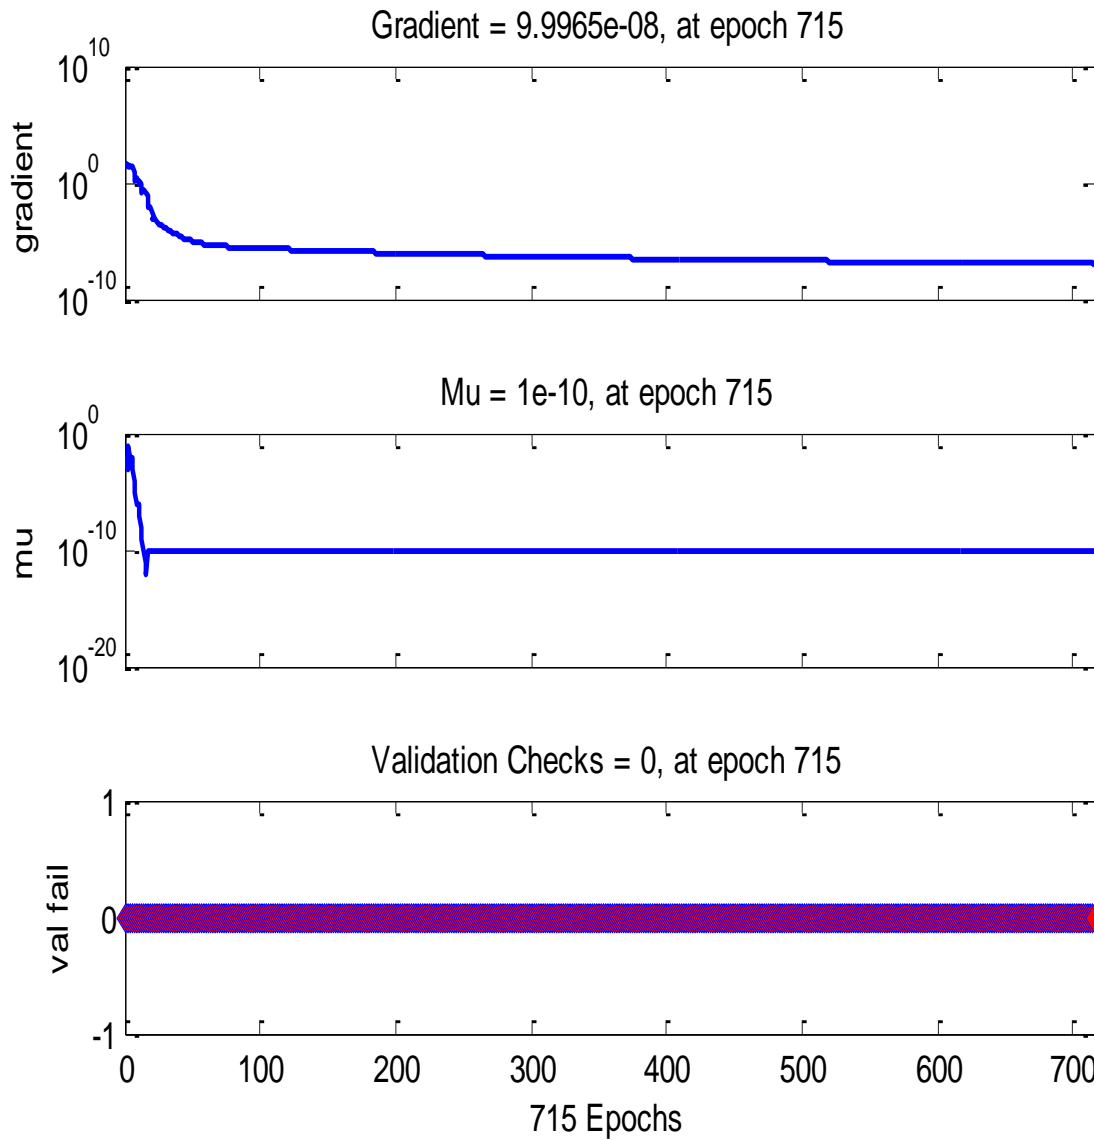


Figura 36.- Imagen del entrenamiento de la RNA Elman.

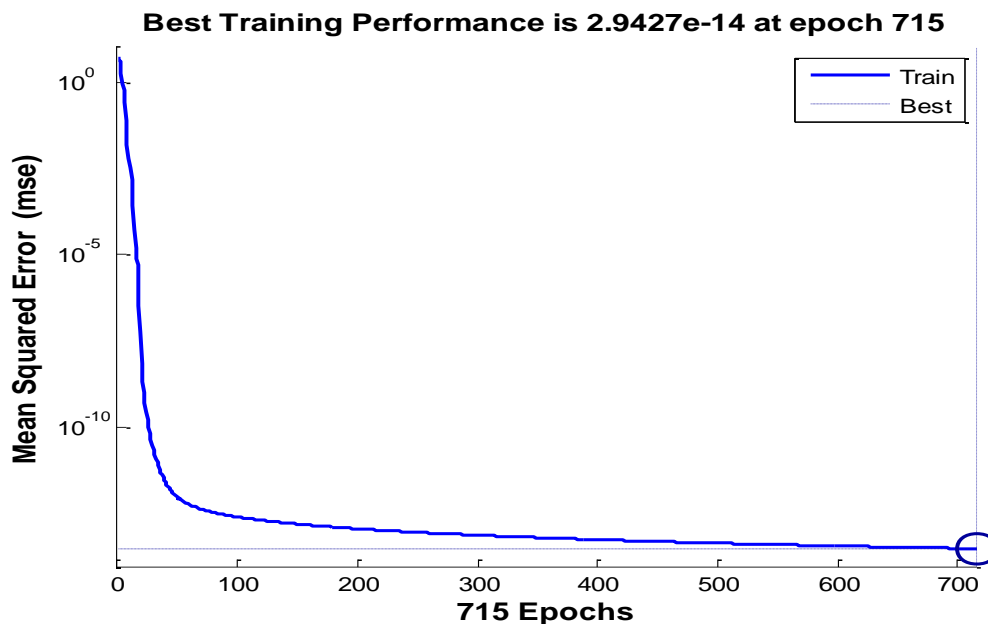


Las gráficas mostradas en la figura 37 presentan la evolución del proceso de convergencia de la red Elman para encontrar los factores de ponderación (pesos) que optimizan la eficiencia de la red.



**Figura 37.-** Gráfica de los valores del gradiente y de  $\mu$  obtenidos del entrenamiento de la RNA Elman.

El comportamiento del aprendizaje de esta RNA puede observarse en la figura 38, donde se busca un aprendizaje con el error mínimo posible.



**Figura 38.-** Curva de aprendizaje de la RNA Elman con 715 épocas. Muestra como el error va disminuyendo y convergiendo para minimizar el error de aprendizaje.

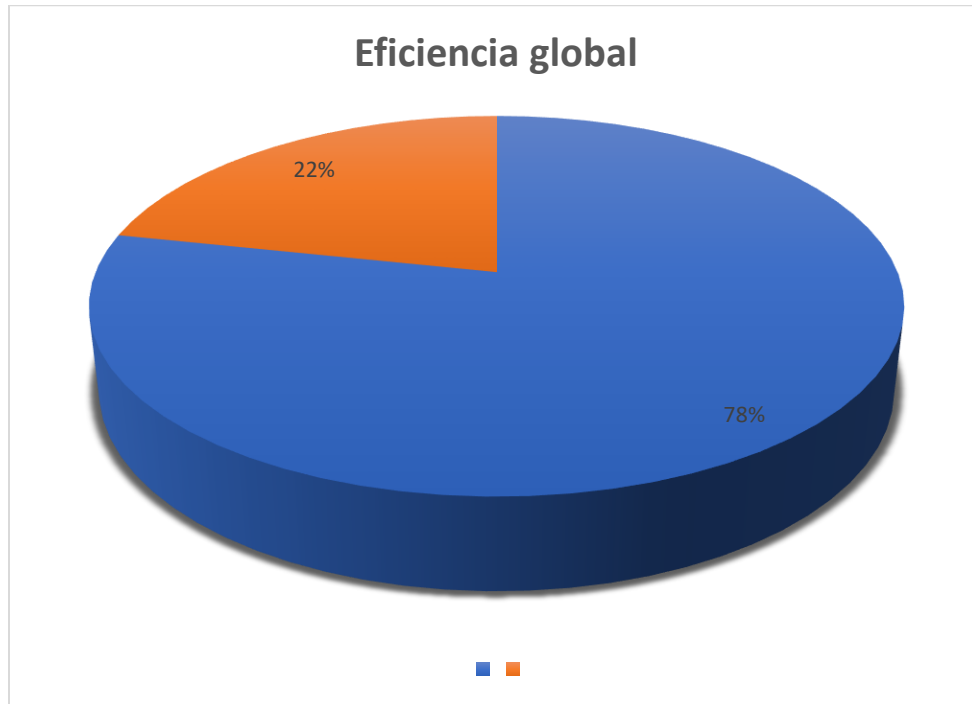
Para la etapa de validación de la red Elman se usó el conjunto de imágenes testigo que no fueron usadas durante el entrenamiento, el cual está compuesto por 10 imágenes de cada especie (60 fotografías) las cuales se etiquetaron para su mejor identificación: 1 para *Balistes polylepis*; 2 para *Caulolatilus affinis*; 3 para las pertenecientes a *Caulolatilus princeps*; 4 para la especie *Lutjanus argentiventris*; 5 para *Lutjanus peru*, y 6 indica que se trataba de *Paralabrax nebulifer*.

De acuerdo con los datos obtenidos durante la prueba de validación, la red Elman logró clasificar el 100% de las imágenes de *Caulolatilus princeps*, *Lutjanus peru* y *Paralabrax nebulifer*, el 90% de filetes de *Lutjanus argentiventris*, el 80% de *Balistes polylepis*, el 0% de *Caulolatilus affinis* ya que la confundió principalmente con la especie *C. princeps* (Tabla 7).

**Tabla 7.-** Resultados de la validación de la red Elman.

<b>No.</b>	<b>Etiqueta Elman</b>	<b>Etiqueta real</b>	<b>Aciertos</b>
1	[1.0000]	1 ( <i>B. polylepis</i> )	Sí
2	[1.2536]	1 ( <i>B. polylepis</i> )	Sí
3	[1.0000]	1 ( <i>B. polylepis</i> )	Sí
4	[1.0000]	1 ( <i>B. polylepis</i> )	Sí
5	[1.7685]	1 ( <i>B. polylepis</i> )	No
6	[1.2870]	1 ( <i>B. polylepis</i> )	Sí
7	[1.0002]	1 ( <i>B. polylepis</i> )	Sí
8	[1.0000]	1 ( <i>B. polylepis</i> )	Sí
9	[1.0001]	1 ( <i>B. polylepis</i> )	Sí
10	[2.9044]	1 ( <i>B. polylepis</i> )	No
11	[1.0858]	2 ( <i>C. affinis</i> )	No
12	[3.1933]	2 ( <i>C. affinis</i> )	No
13	[5.8491]	2 ( <i>C. affinis</i> )	No
14	[4.9962]	2 ( <i>C. affinis</i> )	No
15	[3.9625]	2 ( <i>C. affinis</i> )	No
16	[3.2114]	2 ( <i>C. affinis</i> )	No
17	[3.3298]	2 ( <i>C. affinis</i> )	No
18	[3.9221]	2 ( <i>C. affinis</i> )	No
19	[3.3031]	2 ( <i>C. affinis</i> )	No
20	[3.1150]	2 ( <i>C. affinis</i> )	No
21	[3.3139]	3 ( <i>C. princeps</i> )	Sí
22	[3.1866]	3 ( <i>C. princeps</i> )	Sí
23	[3.2787]	3 ( <i>C. princeps</i> )	Sí
24	[3.1487]	3 ( <i>C. princeps</i> )	Sí
25	[3.1111]	3 ( <i>C. princeps</i> )	Sí
26	[3.0767]	3 ( <i>C. princeps</i> )	Sí
27	[3.0636]	3 ( <i>C. princeps</i> )	Sí
28	[3.0578]	3 ( <i>C. princeps</i> )	Sí
29	[3.0480]	3 ( <i>C. princeps</i> )	Sí
30	[3.0590]	3 ( <i>C. princeps</i> )	Sí
31	[3.2163]	4 ( <i>L. argentiventris</i> )	No
32	[3.7738]	4 ( <i>L. argentiventris</i> )	Sí
33	[3.9823]	4 ( <i>L. argentiventris</i> )	Sí
34	[3.8974]	4 ( <i>L. argentiventris</i> )	Sí
35	[3.9927]	4 ( <i>L. argentiventris</i> )	Sí
36	[4.0502]	4 ( <i>L. argentiventris</i> )	Sí
37	[4.0383]	4 ( <i>L. argentiventris</i> )	Sí
38	[4.0068]	4 ( <i>L. argentiventris</i> )	Sí
39	[4.0179]	4 ( <i>L. argentiventris</i> )	Sí
40	[4.0016]	4 ( <i>L. argentiventris</i> )	Sí
41	[4.8173]	5 ( <i>L. peru</i> )	Sí
42	[4.9763]	5 ( <i>L. peru</i> )	Sí
43	[5.0130]	5 ( <i>L. peru</i> )	Sí
44	[5.0014]	5 ( <i>L. peru</i> )	Sí
45	[4.9980]	5 ( <i>L. peru</i> )	Sí
46	[5.0043]	5 ( <i>L. peru</i> )	Sí
47	[5.0059]	5 ( <i>L. peru</i> )	Sí
48	[5.0030]	5 ( <i>L. peru</i> )	Sí
49	[5.0024]	5 ( <i>L. peru</i> )	Sí
50	[5.0056]	5 ( <i>L. peru</i> )	Sí
51	[6.0000]	6 ( <i>P. nebulifer</i> )	Sí
52	[6.0000]	6 ( <i>P. nebulifer</i> )	Sí
53	[6.0000]	6 ( <i>P. nebulifer</i> )	Sí
54	[6.0000]	6 ( <i>P. nebulifer</i> )	Sí
55	[6.0000]	6 ( <i>P. nebulifer</i> )	Sí
56	[6.0000]	6 ( <i>P. nebulifer</i> )	Sí
57	[6.0000]	6 ( <i>P. nebulifer</i> )	Sí
58	[6.0000]	6 ( <i>P. nebulifer</i> )	Sí
59	[6.0000]	6 ( <i>P. nebulifer</i> )	Sí
60	[6.0000]	6 ( <i>P. nebulifer</i> )	Sí

Por otro lado, la eficiencia global de la red Elman, definida como la razón del total de aciertos al tamaño de la muestra de validación alcanzó un valor del 78% (Fig. 39).



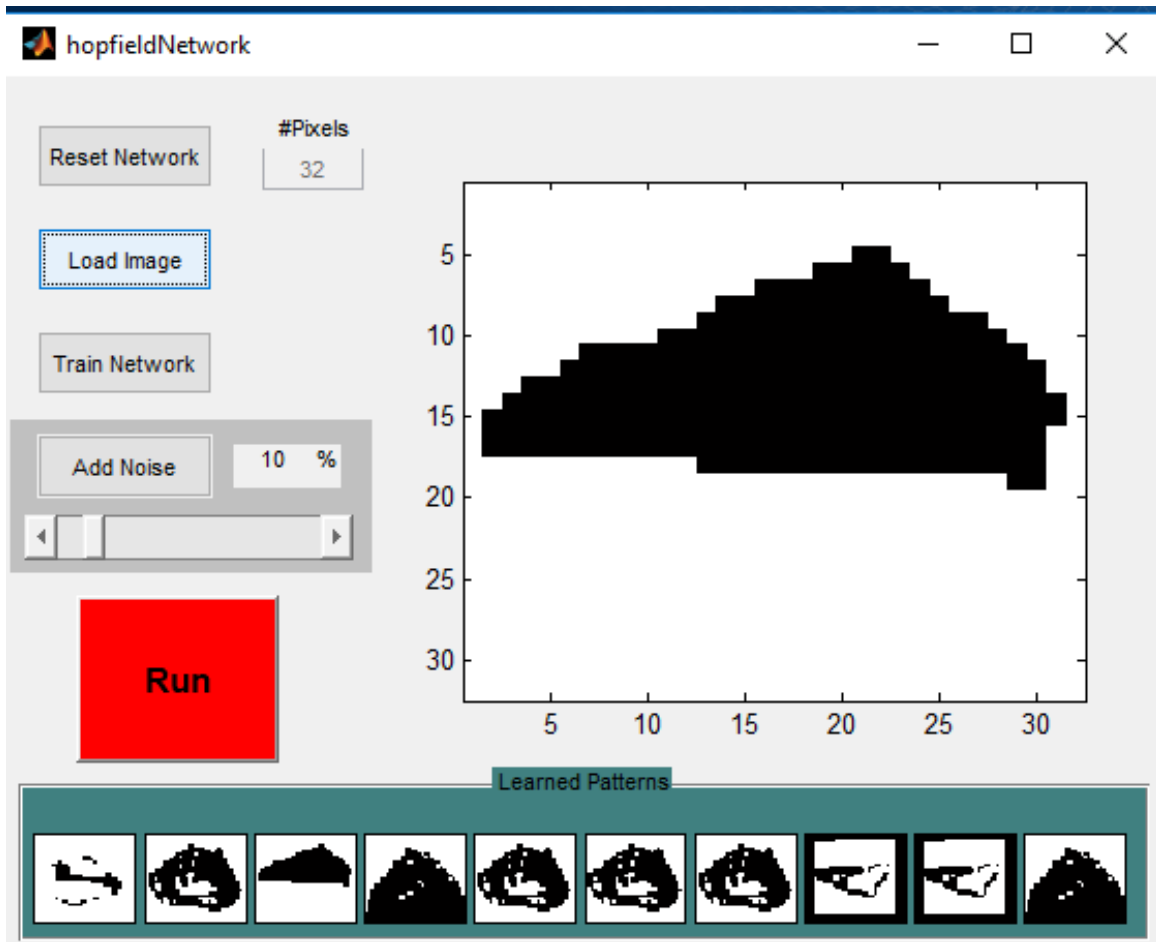
**Figura 39.-** Gráfica de la validación de la RNA Elman.

#### **VIII.4. Entrenamiento de Hopfield.**

La red de Hopfield no trabaja correctamente con los valores de los momentos invariantes, por lo que se utilizó la base de datos con las 180 fotografías binarias de los filetes de pescado. Este tipo de entrenamiento es no supervisado como se había mencionado en un principio, por lo que no fue necesario presentarle a la red la etiqueta; es decir, el nombre de las especies analizadas pues esta red asociando patrones da como valor respuesta la imagen a la que más se parece.

Los resultados de este algoritmo en la clasificación de objetos no fueron idóneos, ya que no logró asociar correctamente los patrones de entrada y salida, las imágenes presentan problemas en la resolución pues se distorsionan durante

este proceso de entrenamiento por lo que no vuelve factible este método para analizar el problema de clasificación. La figura 40 muestra la distorsión de una imagen al ser llevada a entrenamiento Hopfield mediante la aplicación del *Script*, la parte inferior de figura muestra las imágenes distorsionadas.



**Figura 40.-** Entrenamiento Hopfield de imágenes binarizadas.

## IX. DISCUSIÓN

En Baja California Sur las especies que principalmente son objeto de fraude comercial son *Balistes polylepis*, *Caulolatilus princeps*, *Lutjanus argentiventris*, *Lutjanus peru*, y algunas de las especies sustitutas son: *Caulolatilus affinis* y *Paralabrax nebulifer*.

Durante el proceso de la obtención de los filetes de los pescados se observó que el trayecto de los miómeros y mioseptos resalta más en la cara próxima a la piel, por lo que se decidió examinar esa parte del músculo, con la finalidad de tener los caracteres distintivos bien definidos para la identificación morfológica. En los exámenes de comparación de los filetes de pescado de venta en comercios se ha comprobado la importancia en el proceso de identificación de los caracteres morfológicos adicionalmente a la dirección y anchura de los miómeros o mioseptos, así como el color y la forma del tejido subcutáneo del filete (Kietzmann, 1974). Otras características importantes son la longitud y el ancho del filete, debido a que una persona que no este familiarizada con los organismos marinos, fácilmente es engañada.

Así pues, para lograr buenos resultados en el sistema de visión artificial, se tuvo especial cuidado en la calidad de las imágenes de los filetes, las cuales fueron capturadas bajo condiciones de luminosidad y con niveles de intensidad adecuados para que fueran viables para la etapa de procesamiento. Respecto a este tema, Chanona (2015) menciona que el éxito de la visión artificial depende en gran medida de la calidad de las imágenes que se adquieren y aspectos directamente relacionados con esta calidad son el sistema de captura y de iluminación, al grado de que, si estos dos aspectos son bien seleccionados, el procesamiento y análisis de imagen son mínimos y se facilitan considerablemente. Un buen sistema de iluminación debe proporcionar una radiación uniforme en toda la escena, evitando la presencia de brillos o sombras. Si la escena no está iluminada de forma adecuada, aumentará la incertidumbre y el error en la extracción de parámetros, y con respecto al sistema de captura se elige el dispositivo que mejor se adapte a las necesidades particulares de la aplicación. En este caso de estudio, se tuvo acceso

a una cámara fotográfica convencional con un lente de 18x para la adquisición de las imágenes, las cuales tienen una resolución de 72 píxeles ancho x 72 píxeles alto, lo que indica que su calidad es aceptable pues a mayor resolución de la imagen, se tiene más cantidad de píxeles que la describen; es decir, a mayor resolución, mejor representación se va a obtener, ya que puede proporcionar un mayor detalle descriptivo (Muñoz, 2014). Todo ello para que la escena sea interpretada a mayor detalle en la etapa de procesamiento digital de imágenes.

Para este estudio, la alta calidad y buena definición en las fotografías, es relevante debido a que se trata de definir los patrones que forman tanto miómeros como mioseptos de cada especie analizada con el fin de determinar que método es el mejor para la extracción de características, que de acuerdo con Martínez y colaboradores (2016) el uso de algoritmos que extraen información importante de las imágenes mejoran el porcentaje de reconocimiento e incrementan la eficiencia de entrenamiento de una RNA ya que se puede reducir el número de neuronas de entrada. Debido a que uno de los objetivos de nuestro trabajo tenía como finalidad identificar contornos, formas y regiones específicas de los miómeros y mioseptos en los filetes se probaron diversos algoritmos, Hidalgo & Sánchez (2015) también realizaron tareas para la identificación y clasificación de imágenes, así como la localización de áreas específicas al extraer exitosamente el código de barras de un conjunto de imágenes de contadores de gas de una distribuidora de gas natural para llevar un control automatizado del proceso de lectura de los contadores mediante el desarrollo de una aplicación informática y así conocer la cantidad de gas consumida por sus clientes, los autores emplearon el filtro Sobel para la detección de líneas que les dio resultados favorables en el procesamiento de imágenes para la detección de bordes de interés que en este caso era el código de barras. En relación a los diversos algoritmos que se probaron para la detección de bordes y de atributos distintivos (miómeros y mioseptos) de los filetes de pescado, el filtro binario fue el que mejor logró realzar estas características fundamentales de la musculatura de los filetes de pescado de las especies antes mencionadas, para posteriormente ser analizadas por las redes neuronales artificiales y llevar a cabo el proceso de clasificación.

Con respecto a su forma geométrica, topológica y morfológica, los momentos invariantes de Hu (1962) constituyeron otra de las fases más relevantes para el proceso de clasificación. García-García (2013) utilizó los momentos invariantes para alimentar una red neuronal tipo retropropagación (backpropagation) con el fin de clasificar imágenes de 25 hojas de 12 plantas distintas, donde obtuvo una eficiencia del 60%; mientras que Ochoa *et al.* (2013) emplearon los momentos para la extracción de características de objetos rígidos como tornillos, llaves y monedas para clasificarlos con la ayuda de un clasificador de k-means, reportando una eficiencia del 97.76%. En nuestro caso con el algoritmo de Elman no se habría podido clasificar las imágenes colocadas en diferentes orientaciones sin el uso de los momentos invariantes de Hu (1962) para cada imagen de los filetes de pescado. En este trabajo, se incluyeron además de los valores longitud y ancho de los filetes, se incluyó el nombre como etiqueta, como resultado a generar y se logró clasificar prácticamente el 80% de las imágenes testigo, una eficiencia aceptable, aunque es inferior a la reportada por Ochoa *et al.* (2013).

A la par de esto, se llevó a cabo un análisis con redes Hopfield, ya que trabajos como el de Jiménez (2014) indican que tienen buena precisión para la detección de patrones, el autor usó los valores binarios para alimentar un algoritmo de Hopfield para clasificar imágenes de marcas de cantero logrando una eficiencia media total del 69% en la detección de estas marcas. En nuestro caso de estudio, la red Hopfield fue alimentada con la matriz de imágenes binarizadas, pero no se logró completar la etapa de aprendizaje con éxito debido a que las imágenes sometidas para entrenamiento son devueltas por la red distorsionadas durante el proceso de aprendizaje, ya que este algoritmo generó resultados con mala resolución por lo que no se distinguían los atributos característicos (miómeros y mioseptos) presentes en la musculatura de los filetes. Por el contrario, en otros trabajos se ha reportado que cuando la información de entrada no coincide con ninguna de las almacenadas, por estar distorsionada o incompleta, la red Hopfield se propaga generando una salida lo más parecido posible a la información almacenada; esto ocurrió en un sistema para la evaluación de redes neuronales orientadas al reconocimiento de patrones de imágenes que analizaron cinco



caracteres alfabéticos (Ruge, 2013), pero para nuestro estudio esto no ocurrió. Otro trabajo exitoso empleando el algoritmo de Hopfield fue propuesto por Bonilla (2005) para identificar manuscritos, la eficiencia fue del 69%, las redes neuronales fueron capaces de reconocer dichos manuscritos, incluso al añadirles ruido y lograban converger en la imagen de referencia.

Es importante señalar que las redes Elman y Hopfield tienen un aprendizaje distinto, siendo supervisado y no supervisado respectivamente, en este estudio se entrenaron estos dos tipos de redes neuronales para encontrar el aprendizaje más adecuado en el reconocimiento de los filetes de pescado, las redes neuronales artificiales con aprendizaje supervisado (Elman) lograron mejores resultados que las redes neuronales con aprendizaje no supervisado (Hopfield) al clasificar con aceptable eficiencia (aproximadamente el 80%, como se dijo anteriormente) a la mayoría imágenes de filetes de pescado. Aunque, no lograron identificar a ninguna de las imágenes testigo de la especie de *C. affinis* pues las clasificó en su mayoría como *C. princeps*, lo cual resulta evidente al revisar la estructura de los miómeros y mioseptos por el parecido entre ellas, además se trata de especies del mismo género, por lo que se corroboró lo complicado que es identificarlas cuando presentan patrones morfológicos muy parecidos, esto representa una ventaja para los comerciantes pues sustituyen a *C. princeps* (pierna) por *C. affinis* (conejo) ya que el valor comercial de esta es más bajo que el de la pierna. No obstante, es importante señalar que el resto de las especies fueron identificadas correctamente.

Este trabajo contribuye a la identificación de filetes de pescado por medio de características morfológicas de manera fácil y rápida porque la necesidad de técnicas analíticas rápidas en la identificación de los filetes es mayor que nunca pues a pesar de que se implementan prácticas estrictas de control de calidad para garantizar la compra del consumidor debido al crecimiento internacional en el comercio y el consumo de pescado se ha originado un mayor potencial para la sustitución de especies o el etiquetado incorrecto (Ashwin-Judal, 2015). Esta práctica fraudulenta es ilegal en los mercados nacionales e internacionales y tiene numerosas consecuencias perjudiciales (Rasmussen, 2011). Si bien existen

diversos métodos para identificar especies de filetes de pescado, la metodología aquí propuesta resulta muy útil porque representa un avance en cuanto a la clasificación automatizada de las especies de dichos filetes. De igual manera, este método también pudiera utilizarse en conjunto con otra de las técnicas ya empleadas en la identificación de especies para mejores resultados. La eficiencia obtenida en la identificación de los filetes de pescado en el presente trabajo pudiera incrementarse si se mejora la extracción de las características representativas de su musculatura para que las RNA puedan hacer un mejor seguimiento de estas áreas y las clasifiquen con mayor certeza, sin embargo y como se mencionó antes, se tuvo la precaución de tomar fotografías de buena calidad para obtener mejores resultados, ya que este estudio es solo una propuesta metodológica, y si se toma como base para la creación de una aplicación, el usuario quizá no tenga las condiciones apropiadas para obtener fotos claras, por lo que sería un trabajo más agudo.

## **X. CONCLUSIONES**

Se logró obtener fotografías de alta calidad para aplicar técnicas computacionales que lograron procesar las imágenes de los filetes de pescado destacando sus atributos distintivos para poder identificarlas.

De los dos algoritmos de redes neuronales artificiales (Elman y Hopfield) que se probaron para el reconocimiento de patrones solo el de Elman fue capaz de llevar a cabo el proceso de aprendizaje y por consecuencia de identificación ya que el algoritmo de Hopfield tuvo problemas con la resolución de las imágenes.

La metodología planteada en el presente trabajo es aceptable, ya que logra mediante visión artificial identificar filetes de peces comerciales con un error del  $2.94 \times 10^{-14}$ . Es decir, las técnicas de visión artificial son herramientas que lograron identificar en función de características morfológicas musculares a la mayoría de las diferentes especies de peces comerciales analizadas en este trabajo. Por lo tanto, es posible emplear esta metodología como la base de un sistema automatizado

para llevar a cabo tareas de supervisión visual en la identificación de especies de filetes de pescado y ayudar a las autoridades y a los consumidores a discernir entre una especie y otra para evitar fraudes comerciales. Los resultados obtenidos indican que dicha identificación automática pudiera ser posible. Esta metodología también ayudaría a optimizar el proceso de clasificación de especies.

## **XI. RECOMENDACIONES**

Para trabajos futuros se recomienda aumentar el número de muestra y diversificar el tamaño de los ejemplares, a fin de que la clasificación por especie sea más eficiente y que pudiera identificar entre *C. affinis* y *C. princeps*.

Así como evaluar otros tipos de redes neuronales artificiales empleados en la clasificación de objetos y encontrar la idónea para este caso de estudio.

Para el método de aprendizaje Hopfield se recomienda usar solo una porción de las fibras musculares para no utilizar el filete completo y evitar una baja resolución en la calidad de las imágenes.

Para la aplicación del método antes mencionado se recomienda explorar métodos de compresión de imágenes para encontrar el que permita tener una alta resolución en la calidad de las imágenes.

## **XII. LITERATURA CITADA**

Abiodum, O. I., J. Aman, E. O. Abiodum, K. V. Dada, N. A. Mohamed & H. Arshad. 2018. State of the art in artificial neural network applications: A survey. *ELSEVIER-Heliyon*, 4 (11): 41.

Acevedo-Orduña, G. L., E. F. Caicedo-Bravo & H. Loaiza-Correa. 2007. Selección de personal mediante redes neuronales artificiales. *Revista de Matemática: Teoría y Aplicaciones*, 14 (1): 8-10.

Albañez-Lucero, M. O. 2010. Distribución espacial del mero (*Epinephelus morio*) del Banco de Campeche, México. Tesis de Doctorado en Ciencias Marinas. CICIMAR-I.P.N. México. 105 pp.

Alhusain, O., Z. Tóth, A. Rakusz, L. Almási & B Farkas. 2004. Vision-based System for Quality Control of Some Food Products. *International Archives of Photogrammetry, Remote Sensing, and Spatial Information Sciences*. Hungry. 1-6.

Álvarez-Flores, C.M. 2015. Análisis del estado actual de la pesquería de verdillo, *Paralabrax nebulifer* en la costa occidental de Baja California Sur. Informe final. INAPESCA / CRIP La Paz y Pronatura Noroeste A.C., Ensenada, B.C. 26 pp.

Arnarson, H., K. Bengoetxea & L.F. Pau. 1988. Vision applications in the fishing and fish product industries. *International Journal of Pattern Recognition and Artificial Intelligence*, 2: 657-671.

Ashwin-Judal, A. G. 2015. Role of Machine Vision System in Food Quality and Safety Evaluation. *International Journal of Advance Research and Innovation*, 3 (4): 611-615.

Bahrami, G., S. Kiani & H. Rezai. 2015. Computer Vision System Coupled with an Artificial Neural Network to Quality Evaluation of Rainbow Trout Eggs. *Academic Research Journal of Agricultural Science and Research*, 3 (9): 258-266.

Basu, J. K., D. Bhattacharyya & T. Kim. 2010. Use of Artificial Neural Network in Pattern Recognition. *International Journal of Software Engineering and Its Applications*, 4 (2): 23-28.

Balbuena Rivarola, E. D. 2014. Manual básico sobre procesamiento e inocuidad de productos de la Acuicultura. Organización para las Naciones Unidas para la Alimentación y la Agricultura (FAO). Paraguay. 67 p.

Bartlett, S.E. & W.S. Davidson. 1992. FINS (forensically informative nucleotide sequencing): a procedure for identifying the animal origin of biological specimens. *BioTechniques*, 12: 408-411.

Bone, Q. 1978. Locomotor Muscle in Fish Physiology. En: Fish physiology, Vol. VII. Eds. Hoar. W.S. & D. J. Randall. Academic Press. USA. 253 pp.

Bonilla-Martínez, E. G. 2015. Reconocimiento de caracteres mediante redes neuronales con MATLAB. Tesis de Ingeniería en Electrónica y Control. Escuela Politécnica Nacional. Ecuador. 214 p.

Brito, J. 2003. Nuevos registros de *Balistes polylepis* (Balistidae), *Sphoeroides lobatus* (Tetraodontidae), *Mola mola* y *M. ramsayi* (Molidae) en San Antonio, Chile (Pisces, Tetraodontiformes). Investigaciones Marinas. *Scielo*. 31 (1): 77-82.

Caicedo-Bravo, E. F. & J. A. López-Sotelo. 2017. Una aproximación práctica a las Redes Neuronales Artificiales. Programa editorial. Universidad del Valle. Colombia. 218 p.

Calderón-Mendoza, E. M. 2014. Desarrollo de un sistema de control neuro-difuso de la distribución de agua en un tramo de un canal principal de riego. Tesis de maestría en Ingeniería de Control y Automatización. Perú. 67-68 pp.

Castro-Ramírez, A. 2006. Construcción de una red neuronal artificial para clasificar cantos de aves: una aplicación de la inteligencia artificial a la Biología. Tesis de maestría. Universidad Rodrigo Facio. Costa Rica. 32-40 p.

Cavieses-Núñez, R. A., M. A. Ojeda-Ruíz de la Peña, A. Flores-Irigollen & M. L. Rodríguez-Rodríguez. 2018. Deep learning models for the prediction of small-scale fisheries catches: finfish fishery in the region of “Bahía Magdalena-Almejas”. *ICES Journal of Marine Science*, 75 (6): 2088-2096.

Cisneros-Mata, M., T. Brey, A. Jarre-Teichmann, W. García-Franco & G. Montemayor-López. 1996. Redes de neuronas artificiales para el pronóstico de biomasa de sardina del pacífico y de su medio ambiente. *Ciencias Marinas*. 22 (4): 427-442.

Codex Alimentarius FAO. 1995. Normas del CODEX para bloques de filetes de pescado, carne de pescado picada y mezcla de filetes y de carne de pescado picada congelada rápidamente. CODEX STAN 165. Italia. 10 pp.

Constante-Prócel, P. N. & A. M. Gordón-Garcés. 2015. Diseño e Implementación de un Sistema de Visión Artificial para Clasificación de al menos Tres Tipos de Frutas. Tesis de Maestría en Diseño, Producción y Automatización Industrial. Escuela Politécnica Nacional. Ecuador. 108 p.

Cuevas-Jiménez, E., D. Zaldívar-Navarro & M. A. Pérez-Cisneros. 2010. Procesamiento digital de imágenes con MATLAB y Simulink. Alfaomega editores. Primera edición. México. 815 p.

De La Escalera, A., G. Pajares & E. Alegre. 2016. Conceptos y métodos en visión por computador. Editorial CEA. España. 368 p.

Díaz-Montes, M. F. & F. Durán-Ramírez. 2006. Manual del Ingeniero de Alimentos. Colombia. Grupo Latino Editores. 15-18 pp.

Díaz-Uribe, J. G., V. M. Valdez-Ornelas, Danemann, G. D., E. Torreblanca-Ramírez, A. Castillo-López & M. A. Cisneros-Mata. 2013. Regionalización de la pesca ribereña en el noroeste de México como base práctica para su manejo. Centro Regional de Investigación Pesquera de Baja California Sur. Instituto Nacional de Pesca y Acuicultura. *Ciencia pesquera*. 21 (1): 5-14.

Dooley JK. 1978. Systematic and biology of tilefishes (Perciformes: Branchiostegidae and Malacanthidae), with description of two new species. NOAA Tech Rep. NMFS Circ. 411:1-79.

Elman, J. 1990. Finding structure in time. *Cognitive Science*, 14: 179-211.

Figuroa-Escobar, D. E. & Roa-Guerrero, E. 2016. Sistema de visión artificial para la identificación del estado de madurez de frutas (granadilla). *Revista Redes de Ingeniería*. 7 (1): 84-92.

FAO. Organización de las Naciones Unidas para la Alimentación y la Agricultura. 2018. El estado mundial de la pesca y la acuicultura 2018. Cumplir los objetivos de desarrollo sostenible. Roma, Italia. 233 p.

Fischer, F. W., Krupp, W. Schneider, C. Sommer, K. E. Carpenter & V. H. Niemeds. 1995 (a). Guía FAO para la identificación de especies para los fines de

pesca. Pacífico Centro-Oriental, Vol. II (Vertebrados parte 1). Roma, Italia. 905-908 p.

Fischer, W., F. Krupp, W. Schneider, C. Sommer, K. E. Carpenter & V.H. Niemeds. 1995 (b). Guía FAO para la identificación de especies para los fines de la pesca. Pacífico Centro-Oriental, Vol. III (Vertebrados parte 2). Roma, Italia. 1231-1609 p.

Flores-Gutiérrez, H. 2015. Redes Neuronales Artificiales aplicadas a la detección de Cáncer de Mama. Tesis de Maestría en Tecnología de Computo. Centro de Innovación y Desarrollo Tecnológico en Computo-IPN. 75 p.

Gaona-Barrera, A. E., N. A. Lugo-Currea & A. F. Hernández-Roldán. 2012. Estudio de dos estructuras neuronales feed-forward para la compresión de imágenes digitales. Universidad de Antioquia. Laboratorio de Automática, Microelectrónica e Inteligencia Computacional, LAMIC. *Revista de la Facultad de Ingeniería*, 65: 85-98.

García-García, P. P. 2013. Reconocimiento de imágenes utilizando redes neuronales artificiales. Tesis de Maestría en Ingeniería Informática para la Industria. Facultad de Informática. Universidad Complutense de Madrid. España. 72 p.

García-Garino, C., A. E. Mirasso, M. A. Storti & M. E. Tornello. 2013. Ponderación de calidad en frutas usando técnicas de visión artificial para la estimación de daños. *Revista de Mecánica Computacional*. Argentina. 32: 2473-2484.

García Santillán-Ibarra, I. D. 2008. Visión artificial y procesamiento de imágenes usando MATLAB. Alfaomega RA-MA Editorial. Ecuador. 103 p.

Gogul, I. & V. S. Kumar. 2017. Flower Species Recognition System using Convolution Neural Networks and Transfer Learning. Department of Electronics Engineering Madras Institute of Technology. Anna University. India. 4th International Conference on Signal Processing. *Communications and Networking (ICSCN -2017)*. 1-7 p.

Gómez-Flores, W. 2015. Reconocimiento de objetos en fotografías. Centro de Investigación en Computación del I.P.N. Centro de Investigación y de Estudios Avanzados del Instituto Politécnico Nacional (CINVESTAV-LTI). Tamaulipas, México. 20 p.

González-Navarro, E. A., R. J. Saldierna-Martínez, G. Aceves-Medina & S. P. A. Jiménez-Rosenberg. 2013. Atlas de Identificación de Larvas de Peces de la Subdivisión Elopomorpha del Pacífico Mexicano. *CICIMAR Océánides*. 28 (2): 7-40.

Gutiérrez-Delgado, V. 2012. Guía de identificación de filetes de pescado y mariscos. Costa Rica. Edición del Premio de la Unión "Antorcha Ambiental 2012". 64 p.

Guerrero, I. 2009. Tecnología de productos de origen acuático. Editorial LIMUSA. México. 57-73 pp.

Haykin, S. 2009. Neural Networks and Learning Machines. 3ra Edición. Pearson. Canadá. 938 p.

Herrera-Pérez, J. C. & S. M. Medina-Ortiz. 2015. Diseño de un sistema automático de selección de frutos de café mediante técnicas de visión artificial. Tesis para la obtención del grado de Ingeniero Mecatrónico. Universidad Autónoma del Caribe. Colombia. 70 p.

Hilera-González, J. R. & V. J. Martínez-Hernando. 1995. Redes Neuronales Artificiales. Fundamentos, modelos y aplicaciones. RA-MA Ediciones. España. 75-95 y 181-193 pp.

Hidalgo, I. & Sánchez, R. 2015. Reconocimiento de caracteres mediante imágenes en contadores de gas en entornos reales. Tesis para la obtención de grado en Ingeniería Informática e Ingeniería del Software. Universidad Complutense de Madrid. España. 70 p.

Hu, M. K. 1962. Visual pattern recognition by moment invariants. *Transactions on information theory*. 8 (2): 179-187.



Iqbal, A., S. Aftab. 2019. A Feed-Forward and Pattern Recognition ANN Model for Network Intrusion Detection. *International Journal of Computer Network and Information Security (IJCNIS)*, 11 (4): 19-25.

Instituto Nacional de Pesca y Acuacultura. 2006. Carta Nacional Pesquera. Diario Oficial de la Federación. México.

Işçimen, B., Y. Kutlu, C. Turan, & D. Selçuk-Teknik. 2018. Comparación del desempeño de regiones de interés diferentes en la clasificación de peces. *Journal of Selcuk-Technic*. 3 (1): 225-233.

Jerome, M., C. Lemaire, V. Verrez-Bagnis & M. Etienne. 2003. Direct sequencing method for species identification of canned sardine and sardine-type products. *Journal of Agricultural and Food Chemistry*, 51: 7326-7332.

Jiménez-De Parga, C. 2014. Modelos simbólico-conexionistas para la segmentación y descripción de marcas de cantero. Tesis de maestría en investigación en ingeniería de software y sistemas informáticos. Universidad de ingeniería de software. España. 90 p.

Joo, C. 2018. Identificación de puntos de pesca en los viajes pesqueros de anchoveta monitoreados por satélite mediante redes neuronales artificiales. Tesis de Ingeniería estadística. Instituto del mar del Perú. Ciencias marinas. 170 p.

Keyes, L. y A. Winstanley. 2001. Using moment invariants for classifying shapes on large-scale maps. *Elsevier*. 15 (1): 119-130.

Kietzmann, P., K. Reichstein. D. Rakow & K. Priebe. Inspección veterinaria de pescados. Editorial Acribia. España. 127-146 pp.

Knorr, G. 1974. Atlas sobre la Anatomía y Morfología de peces comerciales para uso práctico en Ciencia e Industria. Verlag Paul Parey, Berlin, Alemania.

Kriesel, D. 2007. A Brief Introduction to Neural Networks. Alemania. 51-55 pp.

Lenstra, J.A. 2003. DNA methods for identifying plant and animal species in food. *Food Authenticity and Traceability*. Lees, M (ed.), Woodhead Publishing Limited, Cambridge, UK, 34-53 pp.

Lizarazo-Cruz, J. J. & F. A. Palacios-Caicedo. 2017. Sistema semiautomatizado de clasificación de la cebolla cabezona. Tesis para la obtención del grado de Ingeniero Electrónico y Telecomunicaciones. Universidad Católica de Colombia. Colombia. 68 p.

Lockley, A.K. & R.G. Bardsley. 2000. DNA-based methods for food authentication. *Trends in Food Science and Technology*, 11: 67-77.

Logan, C.A., S.E Alter, A.J. Haupt, K. Tomalty & S.R. Palumbi. 2008. An impediment to consumer choice: overfished species are sold as Pacific red snapper. *Biological Conservation*, 141, 1591-1599.

Love, M.S., A. Brooks, D. Busatto, J. Stephens & P. A. Gregory. 1996. Aspects of the life history of the kelp bass, *Paralabrax clathratus*, and the barred sand bass, *P. nebulifer*, from the Southern California Bight. U.S. *Fishery Bulletin*, 94:472-481.

Martínez-Cabrera, J. M., A. Becerra-Sánchez, G. Zepeda-Valles, S. Esparza-Guerrero & U. Ramírez-García Correa. 2016. Sistema de reconocimiento de dígitos manuscritos utilizando redes neuronales. Tecnológico Nacional de México/Instituto Tecnológico de Celaya. *Pistas Educativas*, 120: 1075- 1093.

Mcarbonell-Alfonso, J. & D. DeFreitas-Ortega. 2010. Aplicación de diferentes arquitecturas de Redes Neuronales Artificiales sobre datos de paquetes de red en MATLAB con y sin reducción de características. Cuba. 16 p.

Medina-Olivera, V. J. 2018. Desarrollo de un Sistema Automatizado Basado en Procesamiento Digital de Imágenes para mejorar el control de Videovigilancia en empresas de Trujillo. Universidad César Vallejo. Facultad de Ingeniería. Tesis de Ingenierías en sistemas. Perú. 51-56 pp.

Mendoza-Carranza, M. & J. A. Rosales-Casián. 2002. Ecology of Juvenile Kelp Bass (*Paralabrax clathratus*) and Barred Sand Bass (*P. nebulifer*) in Punta Banda Estuary, Baja California, México. *Bulletin of the Southern California Academy of sciences*. 101 (3): 103-117.

Molleda-Meré, J. 2008. Técnicas de visión por computador para la reconstrucción en tiempo real de la forma 3D de productos laminados. Tesis de doctorado. Universidad de Oviedo. Departamento de Informática. España. 269 p.

Montaño-Moreno, J. J. 2002. Redes Neuronales Artificiales aplicadas al Análisis de Datos. Tesis de Doctorado. Universidad de las Islas Baleares. España. 275 p.

Moreno, I., R. Caballero, R. Galán, F. Matías & A. Jiménez. 2009. La Nariz Electrónica: Estado del Arte. *Revista Iberoamericana*, 6 (3): 76-91.

Muñoz-Manzo, R. 2014. Sistema de visión artificial para la detección y lectura de matrículas. Tesis de Grado en Ingeniería Electrónica Industrial y Automática. Universidad de Valladolid. Escuela de Ingeniería Industriales. 125 p.

Ochoa-Sommano, C., J. Pérez-Lara, J. Hassan-Toscano Martínez & C. G. Pereyra-Ramos. 2013. Clasificación de objetos rígidos a partir de imágenes digitales empleando los momentos invariantes de Hu. X Congreso Internacional sobre Innovación y Desarrollo Tecnológico. 11 al 15 de marzo de 2013. Cuernavaca, Morelos, México.

Olivares, R. & M. Rojas. 2013. Esqueleto axial y apendicular de vertebrados. *International Journal of Morphology*, 31(2): 377-387 p.

Ordóñez-Sánchez, J. I. 2011. Guía de identificación de filetes y rodajas de pescado de consumo usual en España. Editorial Omega. 299 p.

Palazzo, S. 2018. Sistemas híbridos de visión humano-máquina para la segmentación y categorización automática de objetos. Tesis de doctorado. Departamento de Ingeniería industrial y de la información. Universidad de Catania. Italia. 202 p.

Pérez-Salmerón, L. A. & A. Ruiz-Luna. 1985. Los animales comestibles de importancia comercial en aguas mexicanas. Peces, moluscos y crustáceos. Editorial Continental. México. 82-90 pp.

Patnaik, S. & Yang, Y. M. 2012. *Soft Computing Techniques in Vision Science* 395. Springer.

Ramos-Cruz, S. 2001. Evaluación de la pesquería de huachinango *Lutjanus peru* en la zona costera de Salina Cruz, Oaxaca, México, durante 1995. INP. SAGARPA. México. *Ciencia Pesquera*, 15: 151-158.

Rasmussen, R.S. & M.T. Morrissey. 2011. DNA-based detection of commercial fish species. Part II Seafood Safety. Handbook of seafood Quality, Safety and Health Applications. Wiley-Blackwell Editorial. 291-300.

Rosenblatt, F. 1958. The perceptron: A theory of statistical separability in cognitive systems. Buffalo: Cornell Aeronautical Laboratory, Inc. Rep. No. VG-1196-G-1.

Ruge-Ruge, I. & J. David-Alvarado. 2013. Sistema basado en FPGA para la evaluación de redes neuronales orientadas al reconocimiento de imágenes. *Revista Tecnura*, 17 (36): 87-95.

Saldaña, E., R. Siche, M. Luján & R. Quevedo. 2013. Revisión: visión artificial aplicada a la inspección y control de calidad de frutas y verduras. *Brazilian Journal of Food Technology*, 16 (4): 254-272.

Sarzuri-Flores, V. 2014. Algoritmo de Clasificación de Huellas Dactilares Basado en Redes Neuronales Función Base Radial. Revista Postgrado en Informática-Ciencia y Tecnología. Universidad Mayor de San Andrés, Bolivia. *Revista del Postgrado en Informática*, 102-108.

Saravanan, K. & S. Sasithra. 2014. Review on classification based on artificial neural networks. *International Journal of Ambient Systems and Applications*, 2 (4): 1-4.

Sebe N., I. Cohen, T. S. Huang & T. Gevers. 2004. Ski detection: a Bayesian network approach. *Proceeding of the 17th International Conference on Pattern Recognition (ICPR)*.

Siddiqui, S., M. Ahmad, S. Imran, M. Faisal, S. Ajmal & H. Mark. 2017. Automatic fish species classification in underwater videos: Exploiting pretrained deep neural network models to compensate for limited labelled. *Journal of Marine Science*, 75 (10): 109.

Smith, P.J., S.M. McVeagh & D. Steinke. 2008. DNA barcoding for the identification of smoked fish products. *Journal of Fish Biology*, 72, 464-471.

Strachan, N.J.C. 1993. Recognition of fish species by colour and shape. *Image Vision Computational*, 11(1): 2-10.

Tayama, M., N., Shimadate, N. Kubota & Y. Nomure, 1982. Application for optical sensor to fish sorting. *Reito (Tokyo). Refrigeration*, 57: 1146-1150.

Terrazas, R. 2019. Fraude y sustitución en la comida del mar. *Oceana México*. 20 p.

Trujillo-Quevedo, A. 2017. Sistema de reconocimiento de caracteres manuscritos usando redes neuronales convolucionales implementado en Python. Universidad de Sevilla. Departamento de Ingeniería en Sistemas y Automática. Tesis de Ingeniería Electrónica, Robótica y Mecatrónica. 29-71 pp.

Turner, C. H., E. E. Ebert & R. R. Given. 1969. Man-made Reef Ecology. State of California. Department of Fish and Game. Marine Resources Region. *Fish bulletin*, 146: 1-221.

Vázquez-Hurtado, M., M. Maldonado-García, C. H. Lechuga-Devéze, H. Acosta-Salmón & A. Ortega-Rubio. 2010. La pesquería artesanal en la Bahía de La Paz y su área oceánica adyacente (Golfo de California, México). *Ciencias marinas. Scielo*. 36 (4): 433-444.

Vázquez-Hurtado, M. 2011. Aspectos económicos y ambientales para el manejo sustentable de la pesca y acuicultura en la Bahía de La Paz, Baja California Sur, México. Tesis de Doctorado en Ciencias. CIBNOR. México. 60 p.

Valero-Verdú, S. & C. Senabre-Blanes. 2010. Aplicación de un modelo de red neuronal no supervisado a la clasificación de consumidores eléctricos. Editorial Club Universitario. España. 67-69 pp.

Vega-Huerta, H., A. Cortez-Vásquez, A. M. Huayna, L. Alarcón-Loayza & P. Romero-Naupari. 2009. Reconocimiento de patrones mediante redes neuronales artificiales. Facultad de Ingeniería de Sistemas e Informática. Universidad Nacional Mayor de San Marcos (FISI). *Revista de Ingeniería de sistemas e informática*, 6 (2): 17-26.

Vélez-Serrano, J. F., A. B. Moreno-Díaz, A. Sánchez-Calle & J. L. E. Sánchez-Marín. 2003. Visión por computador. Primera edición. Editorial DYKINSON. España. 252 p.

Viyuela-Fernández, M. 2016. Visión Artificial Aplicada a la Clasificación Basada en Color. Tesis de Ingeniería Informática. Universidad de Burgos. España. 31 p.

Wagh, S., D. Gupta & N. Chandran. 2019. Efficient and Private Neural Network Training. *Proceedings on Privacy Enhancing Technologies*, 1: 1-24.

Wagner, H., U. Schmidt & J.H. Rudek, 1987. Distinction between species of sea fish. *Lebensmittel industrie*, 34: 20-23.

White, D.J., C. Svellingen & N.J.C. Strachan. 2006. Automated measurement of species and length of fish by computer vision. *Fisheries Research*, 80: 203-210.

Wolf, G., E. Ruiz, F. Bergero & E. Meza. 2015. Fundamentos de sistemas operativos. Primera impresión. Universidad Nacional Autónoma de México. Instituto de Investigaciones Económicas. Facultad de Ingeniería. México. 367 p.

### XIII. ANEXOS

#### Anexo 1.- Lector de imágenes.

```
%El script "imlector" permite leer múltiples imágenes ubicadas en
%diferentes subcarpetas.

%INSTRUCCIONES:

% 1. Se creó una carpeta que se llamada "im_tesis"

% 2. Dentro de la carpeta anterior, crean varias
%   subcarpetas: "cabrilla", "Huachinango", "verdillo", "pargo" y
%   "pierna".

% 3. Se corre el script "imlector" y selecciona la carpeta "im_tesis"
a=uigetdir; %selecciona la carpeta "im_tesis"
```

```

d = dir(a);

c={};

isub = [d(:).isdir];

subcarpetas = {d(isub).name}';

subcarpetas(ismember(subcarpetas,{'.','..'})) = [];

for k=1:length(subcarpetas)

f=dir(fullfile(a,subcarpetas{k},'*.*jpg'));

c=[c fullfile(a,subcarpetas{k},{f.name})];

end

```

## Anexo 2.- Algoritmo que calcula los momentos invariantes de las imágenes (Hu).

```

function phi = invmoments(F)

% PHI = INVMOMENTS(F) calcula los momentos invariantes de las imágenes
% F. PHI es un vector de la fila de siete elementos que contienen el
% momento invariante.
% F debe ser una matriz 2-D, real, no dispersa, numérica o lógica.
% Copyright R. C. Gonzalez, R. E. Woods, y S. L. 2004. Prentice-Hall.
% Procesamiento digital de imágenes usando MATLAB.

if (ndims(F) ~= 2) | issparse(F) | ~isreal(F) | ~(isnumeric(F) | ...
islogical(F))
error(['F must be a 2-D, real, nonsparse, numeric or logical '
...'matrix.']);
end

F = double(F);

phi = compute_phi(compute_eta(compute_m(F)));

function m = compute_m(F)

[M, N] = size(F);

```

```

[x, y] = meshgrid(1:N, 1:M);

% Convierte x, y, y F en vectores de columna para hacer las columnas más
fáciles de calcular.

x = x(:);
y = y(:);
F = F(:);

% Ecuación del momento bidimensional.

m.m00 = sum(F);

% De protección contra las advertencias de división por cero.
if (m.m00 == 0)
    m.m00 = eps;
end

% Los otros momentos centrales:

m.m10 = sum(x .* F);
m.m01 = sum(y .* F);
m.m11 = sum(x .* y .* F);
m.m20 = sum(x.^2 .* F);
m.m02 = sum(y.^2 .* F);
m.m30 = sum(x.^3 .* F);
m.m03 = sum(y.^3 .* F);
m.m12 = sum(x .* y.^2 .* F);
m.m21 = sum(x.^2 .* y .* F);

%-----%

function e = compute_eta(m)

% Ecuaciones.

xbar = m.m10 / m.m00;
ybar = m.m01 / m.m00;

```



```

e.eta11 = (m.m11 - ybar*m.m10) / m.m00^2;
e.eta20 = (m.m20 - xbar*m.m10) / m.m00^2;
e.eta02 = (m.m02 - ybar*m.m01) / m.m00^2;
e.eta30 = (m.m30 - 3 * xbar * m.m20 + 2 * xbar^2 * m.m10) / m.m00^2.5;
e.eta03 = (m.m03 - 3 * ybar * m.m02 + 2 * ybar^2 * m.m01) / m.m00^2.5;
e.eta21 = (m.m21 - 2 * xbar * m.m11 - ybar * m.m20 + ...
          2 * xbar^2 * m.m01) / m.m00^2.5;
e.eta12 = (m.m12 - 2 * ybar * m.m11 - xbar * m.m02 + ...
          2 * ybar^2 * m.m10) / m.m00^2.5;

%-----%


function phi = compute_phi(e)

% Ecuaciones para calcular los siete momentos invariantes de Hu.


phi(1) = e.eta20 + e.eta02;
phi(2) = (e.eta20 - e.eta02)^2 + 4*e.eta11^2;
phi(3) = (e.eta30 - 3*e.eta12)^2 + (3*e.eta21 - e.eta03)^2;
phi(4) = (e.eta30 + e.eta12)^2 + (e.eta21 + e.eta03)^2;
phi(5) = (e.eta30 - 3*e.eta12) * (e.eta30 + e.eta12) * ...
        ( (e.eta30 + e.eta12)^2 - 3*(e.eta21 + e.eta03)^2 ) + ...
        (3*e.eta21 - e.eta03) * (e.eta21 + e.eta03) * ...
        ( 3*(e.eta30 + e.eta12)^2 - (e.eta21 + e.eta03)^2 );
phi(6) = (e.eta20 - e.eta02) * ( (e.eta30 + e.eta12)^2 - ...
        (e.eta21 + e.eta03)^2 ) + ...
        4 * e.eta11 * (e.eta30 + e.eta12) * (e.eta21 + e.eta03);
phi(7) = (3*e.eta21 - e.eta03) * (e.eta30 + e.eta12) * ...
        ( (e.eta30 + e.eta12)^2 - 3*(e.eta21 + e.eta03)^2 ) + ...
        (3*e.eta12 - e.eta30) * (e.eta21 + e.eta03) * ...
        ( 3*(e.eta30 + e.eta12)^2 - (e.eta21 + e.eta03)^2 );

```


**Anexo 3.** Fotografías de los algunos filetes de pescado analizadas en el presente trabajo.



**Figura 41.-** Filetes de *Balistes polylepis* (cochito). Imágenes tomadas por De los Santos-Noyola.




**Figura 42.-** Filetes *Caulolatilus affinis* (conejo). Imágenes tomadas por De los santos-Noyola.



**Figura 43.-** Filetes de *Caulolatilus princeps* (pierna). Imágenes tomadas por De los Santos-Noyola.



**Figura 44.-** Filetes de *Lutjanus argentiventris* (pargo amarillo). Imágenes Tomadas Por De Los Santos-Noyola.



**Figura 45.-** Filetes de *Lutjanus peru* (huachinango). Imágenes tomadas por De los Santos-Noyola.



**Figura 46.-** Filetes de *Paralabrax nebulifer* (verdillo). Imágenes tomadas por De los Santos-Noyola.