



# Agroindustrial Science

Website: <http://revistas.unitru.edu.pe/index.php/agroindscience>

Escuela de Ingeniería  
Agroindustrial

Universidad Nacional de Trujillo

## Predicción de la frescura de *Sciaena deliciosa* "lorna" utilizando imágenes hiperespectrales

Prediction of the freshness of *Sciaena deliciosa* "lorna" using hyperspectral images

Yordy Guzmán-Bermúdez<sup>1</sup>; Anthony Lozano-Gallardo<sup>1</sup>; Royer Gonzales-Rubio<sup>1</sup>; Jeffrey Méndez<sup>2</sup>; Jorge Correa-La Torre<sup>1</sup>; Raúl Siche<sup>2,\*</sup> 

<sup>1</sup> Facultad de Ciencias Biológicas, Universidad Nacional de Trujillo, Av. Juan Pablo II s/n, Ciudad Universitaria, Trujillo, Perú.

<sup>2</sup> Facultad de Ciencias Agropecuarias, Universidad Nacional de Trujillo, Av. Juan Pablo II s/n, Ciudad Universitaria, Trujillo, Perú.

### RESUMEN

El objetivo de esta investigación fue encontrar un modelo basado en imágenes hiperespectrales para predecir la frescura de *Sciaena deliciosa*. En la investigación se utilizaron muestras de *Sciaena deliciosa* "lorna" que luego de capturadas, fueron colocadas en un cooler con hielo y transportadas al laboratorio para su respectivo análisis. Para el análisis sensorial se utilizó el esquema sensorial propuesto por Imarpe (Perú) para especies grasas. Respecto a las imágenes hiperespectrales, cada espécimen fue colocado en el equipo para analizar el humor vítreo del ojo y obtener la huella espectral correspondiente. Para el índice de refracción se extrajo el humor vítreo de ojo y colocado en el refractómetro para cuantificar el grado de alteración. Todos estos resultados fueron correlacionados para predecir la frescura, buscando el modelo más adecuado. El modelo de predicción obtenido para la frescura de pescado tuvo un  $R^2 = 0,6359$ , valor adecuado para considerarlo como un modelo de posible uso práctico.

**Palabras clave:** Índice de refracción; humor vítreo; imagen hiperespectral; *Sciaena deliciosa* "lorna".

### ABSTRACT

The aim of this research was to find a model based on hyperspectral images to predict the freshness of *Sciaena deliciosa*. In the investigation, samples of *Sciaena deliciosa* "lorna" were used, which after being captured, were placed in a cooler with ice and transported to the laboratory for their respective analysis. For the sensory analysis the sensory scheme proposed by Imarpe (Peru) for fatty species was used. Regarding hyperspectral images, each specimen was placed in the equipment to analyze the vitreous humor of the eye and obtain the corresponding spectral footprint. For the refractive index, the vitreous humor of the eye was removed and placed in the refractometer to quantify the degree of alteration. All these results were correlated to predict freshness, looking for the most appropriate model. The prediction model obtained for the freshness of fish had an  $R^2 = 0.6359$ , adequate value to consider it as a model of possible practical use.

**Keywords:** Refractive index; vitreous humor; hyperspectral image; *Sciaena deliciosa* "lorna".

### 1. Introducción

El mar peruano es uno de los más productivos a nivel mundial en lo concerniente a su amplia diversidad en flora y fauna, caracterizada mayormente por los recursos pesqueros que están catalogados como recursos pesqueros artesanales e industriales que van a sustentar el PBI del país, así como también el consumo humano directo, por lo que se hace necesario mantener su frescura y de este modo contribuir a mejorar la calidad e inocuidad alimentaria

aplicando métodos de conservación y sistemas de calidad tales como HACCP, BPM, guías laborales para evitar accidentes de trabajo, así como también, guías ambientales (Armendaris, 2013; Mortimore y Wallace, 2001).

La FAO, a escala mundial en el 2010, reporta que las pescas marítimas y la acuicultura produjeron 148 millones de toneladas de pescado para consumo humano, la cual se traduce a 18,6 kg per cápita (Barrantes, 2013), por lo que se hace necesario mantener su

Recibido 19 noviembre 2018

Aceptado 7 marzo 2019

\*Autor correspondiente: [rsiche@unitru.edu.pe](mailto:rsiche@unitru.edu.pe) (R. Siche)

DOI: <http://dx.doi.org/10.17268/agroind.sci.2019.01.13>

frescura toda vez que son recursos altamente perecederos en el tiempo debido a su composición químico-bromatológica que da lugar a alteraciones por efecto del oxígeno ambiental, actividad bacteriana y acción enzimática, entre otros.

Para determinación de frescura de pescado, al estado fresco, refrigerado y congelado, existen los métodos físicos, sensoriales, bioquímicos y microbiológicos, cada uno de ellos con sus respectivos procedimientos (Anzaldúa, 2005; Cáceda, 2003; Duflos et al., 2002).

Las investigaciones de frescura de pescado aplicando esquemas de puntuación son importantes en la industria por su practicidad y rapidez basados principalmente en los datos sensoriales del analista que son subjetivos y que deben ser corroborados con otras pruebas físicas. Vásquez y García (2013) reportan que el análisis sensorial aplicado al paiche congelado y envasado al vacío, aplicando la prueba del análisis descriptivo cuantitativo (UDA), que el mejor tratamiento estuvo constituido con el 25% de NaCl y 10 °C de temperatura del proceso, en sus atributos de textura y apreciación general del producto.

En la aplicación de los métodos físicos existen diferentes determinaciones tales como determinación del pH, medición de la resistencia eléctrica e índice de refracción del líquido ocular (Ludorff, 1998), definiéndose este último método como la relación entre la velocidad de una luz monocromática en el aire y su velocidad en la sustancia considerada, y es la división entre los senos de los ángulos de incidencia y refracción, cuando la luz pasa del aire a la sustancia (Alvarado y Aguilera, 2016). Se han estudiado los métodos físicos de determinación de frescura de pescado tales como el de Azabache (2017) en recursos pesqueros procedente de la pesca artesanal del Puerto Salaverry y las Delicias, concluyendo que los peces sometidos al medio ambiente tenían un mayor valor del índice de refracción que los peces sometidos al enfriamiento con hielo, y por lo tanto su alteración es más rápida. Así mismo, Yapar y Yetim (1999) estudiaron la determinación de frescura de la anchoveta por medio del índice de refracción en el fluido ocular, señalando que los valores encontrados podrían ser utilizados para evaluar la frescura de anchoveta.

Vásquez y García (2013) investigaron sobre la obtención de un producto mínimamente procesado a partir de la especie *Arapaima gigas* (paiche) congelada y empacada al vacío y reportando valores de índice de refracción

que fueron desde 1,3350 hasta 1,3365 correspondiente a una calidad de pescado excelente. En los últimos años, en la industria alimenticia se han ido creando distintas técnicas y/o métodos instrumentales cuya finalidad es evaluar la calidad del producto alimentario.

Una de las técnicas que ha tenido un desarrollo favorable ha sido la aplicación y estudio de las imágenes hiperespectrales (Vejarano et al., 2017), técnica que sería de gran beneficio si se aplica a peces y otros alimentos marinos para proporcionar productos de alta calidad para la salud y el comercio internacional. Dicha técnica trabaja bajo la función de crear imágenes (mapas) espaciales del alimento a analizar utilizando la variación espectral, los cuales son denominados como datacubos o hipercubos. Dichos datacubos no son más que bases de datos que almacenan información tridimensional (dos dimensiones espaciales y una tercera la dimensión espectral). La dimensión espectral se representa por cada pixel; estos datacubos fusionan el estudio de las imágenes convencionales con la espectroscopia visible (VIS) y el infrarrojo cercano (NIR) (Barreto et al., 2018; Cheng y Sun, 2014; Elmasry y Sun, 2010)

En el enfoque alimentario, los estudios se centran a especies hidrobiológicas, especialmente a peces óseos; ya que el pescado siendo magro o graso es altamente perecedero; por lo cual se hace necesario analizar la frescura del pescado antes de hacer llegar dicho producto al consumidor a fin de garantizar la frescura e inocuidad alimentaria.

Así, el objetivo del presente estudio fue obtener un modelo de predicción del índice de refracción del humor vítreo del ojo, como indicador de frescura, basado en imágenes hiperespectrales.


## 2. Material y métodos

### 2.1 Material biológico


*Sciaena deliciosa* "lorna" se distribuye desde Puerto Pizarro (Perú) hasta Antofagasta (Chile) observándose mayor concentración entre Chimbote y Pisco (Culquichicón et al., 2012).

Las muestras fueron colectadas de la pesca artesanal del Puerto Chicama, para lo cual se utilizó espinel de playa. Los ejemplares fueron colocados en un cooler con hielo y llevadas al laboratorio para el análisis correspondiente. En lo concerniente al análisis sensorial (Figura 1) las muestras se colocaron en un cooler con hielo y se aplicó el esquema sensorial del IMARPE citado en Correa y Gonzáles (2016).

Para la toma de las imágenes hiperespectrales, se separó la cabeza del cuerpo del ejemplar y se colocó en la placa del sistema de captura hiperespectral, marca Headwall Photonix modelo 1003B-00572 procediendo a hacer la captura de cada ojo a una distancia focal de 0,35 m, enfoque de F/2.8, velocidad de 2,00 mm/s y en el rango de posición de 60 mm hasta 150 mm, obteniendo el número de frames por imagen de 440 (Figura 2).



**Figura 1.** Análisis sensorial de *Sciaena deliciosa* "lorca". (a) Superficie y consistencia, (b) Ojos, (c) Agallas, (d) Cavidad abdominal.



**Figura 2.** Captura de las imágenes hiperespectrales del ojo.

En el índice de refracción se extrajo los ojos de los ejemplares para luego diseccionar, extraer el humor vítreo y hacer la lectura en el refractómetro digital marca KRUSS, modelo DR305-95. Los valores Brix fueron transformados a valores de índice de refracción aplicando una fórmula de transformación.

Para la percibibilidad del recurso se tomaron los valores del índice de refracción en función al número de días que se llevó a cabo el experimento en el rango de luz visible; así mismo, se trató de valorar los componentes del humor vítreo utilizando la longitud de onda en relación a la brillantez en el espectro infrarrojo. Para el tratamiento de datos se utilizó el software MatLab v.10, el programa estadístico PLS y MS Excel.

## 2.2 Procesamiento de imagen y análisis espectral

Las imágenes espectrales de las muestras de Humor Vítreo se adquirieron en el modo de reflectancia mediante el empleo de un sistema de imagen hiperespectral de barrido de laboratorio. Los principales componentes de este sistema son (Figura 4) una cámara Link (CL, Technology, USA) y lentes objetivos (Ajuste de apertura de la lente a f/2.4 para sensores Hyperspec de alta eficiencia). Un sistema de iluminación (Model 21DC, Headwall inc., USA) de lámparas QTH de alta intensidad ajustable (dependiendo del sensor y del rango espectral) con impacto de luz a 45°; una plataforma de transporte móvil automático (DMX-J-SA-17, Arcus Technology Inc., USA); un procesador Think Pad Intel Inside CORE i7 (Lenovo Inc., USA) con software que permite la adquisición y posterior obtención de datos (software Hyperspec III, USA) que nos posibilita establecer ciertos parámetros para la captura de la imagen, por ejemplo el número de líneas a tomar, tiempo de captura, la velocidad del motor, el modo de combinación y la gama de longitud de onda. Además de poder regular la intensidad de luz que emitan las lámparas para la mejor captura de la imagen. El procedimiento de adquisición de las imágenes y posterior tratamiento se explica a continuación (Figura 6).

### Adquisición de imágenes hiperespectrales

Con las muestras de *S. deliciosa*, la colocamos en la plataforma móvil para capturar la imagen, configuramos a una velocidad de 2,0 mm/s. Con una distancia entre el lente y la superficie de la plataforma de 35 cm, la fuente de



iluminación tiene una inclinación de 45° y una apertura de diafragma de 6,5 mm, con una iluminación equivalente a 450 lux. Cada imagen está compuesta de 320 x 440 sensores o bandas espectrales y fueron captadas desde la posición inicial de 90 mm hasta 150 mm. Se capturó 2 tomas por ejemplar, una toma de cada ojo (Figura 5).

En total fueron 80 imágenes hiperespectrales que fueron tomadas y utilizadas para un posterior análisis y proceso de modelación.



Figura 5. Captura del lóbulo izquierdo del pescado sin mejorar, preparado para la etapa de calibración.




Figura 4. Sistema de imágenes hiperespectrales.

### 2.3 Segmentación de la imagen y extracción de los espectros

El proceso de segmentación de la imagen se realizó de 90,00 mm a 150,00 mm. Luego aplicamos la función de binarización con el fondo homogéneo en el software Matlab 2010.

La imagen procesada se denomina "máscara completa" y ésta almacena la región que muestra la degradación del humor vítreo la cual se denomina como la región de interés (ROI). En dicha imagen se seleccionó el área del ojo. Luego unimos las imágenes en secuencia para observar la variación de la frescura en un patrón de colores.

### 2.4 Calibración de la imagen

Para realizar la calibración de las imágenes, utilizamos los valores de las imágenes de calibración obtenidas del archivo de la cámara hiperespectral, dichos archivos negro (D) y blanco (W).

Estas imágenes las obtenemos calibrando previamente a la captura de la muestra, cubriendo el lente en el caso de la imagen en negro y hacer correr la plataforma para una captura en blanco.

Dichos valores nos servirán para corregir las imágenes hiperespectrales para lo cual aplicamos la siguiente ecuación:

$$R = \frac{I_S - I_D}{I_W - I_D}$$

Donde R: Imagen hiperespectral corregida en modo reflectancia relativa;  $I_S$ : Imagen hiperespectral corregida en unidad de reflectancia relativa;  $I_D$ : Imagen en negro;  $I_W$ : Imagen de referencia en blanco.

### 2.5 Suavizado de espectro

Para mejorar la información espectral del ROI, suavizamos las imágenes con el algoritmo de Savitzky-Golay, basándonos en el modelo utilizado por Sun (2010).

Tanto la imagen como los datos obtenidos del equipo de imágenes hiperespectrales presentan "ruido" para el completo análisis e interpretación de la curva espectral; y además contienen información de la muestra y de la plataforma de movimiento; es necesario pre-procesar y seleccionar una región de interés para análisis mucho más certeros. Para estos los archivos de datos de cada una de las muestras se importaron mediante un algoritmo al software de Matlab R2016a. Todo el pre-

procesamiento y selección de ROI se realizó usando scripts internos junto a Hypertools. Luego de realizar distintas pruebas y comparaciones entre cada uno de los pre-procesamientos e interactuando entre ellos; se logró determinar que aquellos que nos muestran un espectro mucho más sencillo de analizar son: SNV (Variables normales estándar) para linealizar todas las curvas obtenidas de la imagen, Smoothing (D = 5, P = 1) para eliminar el ruido y suavizar las curvas del espectro y Derivadas (D = 5, P = 2, G = 1) para acercar la curva y así poder detonar mejor los picos que se forman. En cuanto a la selección de la región de interés (ROI) se compararon distintas máscaras, las cuales tienen como función determinar esta

área, eligiendo al final la máscara de K-mean clustering (1), de esta manera la imagen se segmentó en base a un patrón de colores, a fin de diferenciar las zonas a analizar; en caso no ser homogénea se realiza la prueba manual para la obtención de las longitudes de onda. Por último, se determinó un promedio de los espectros de reflectancia relativa de cada uno de los píxeles que integran el ROI. Estos datos se exportaron a Microsoft Excel para la aplicación de análisis multivariados.

### 2.6 Eliminación banda ruidos

Esta parte representa al criterio del autor para modelar su posterior análisis con el fin de obtener un menor sesgo y una mayor precisión.

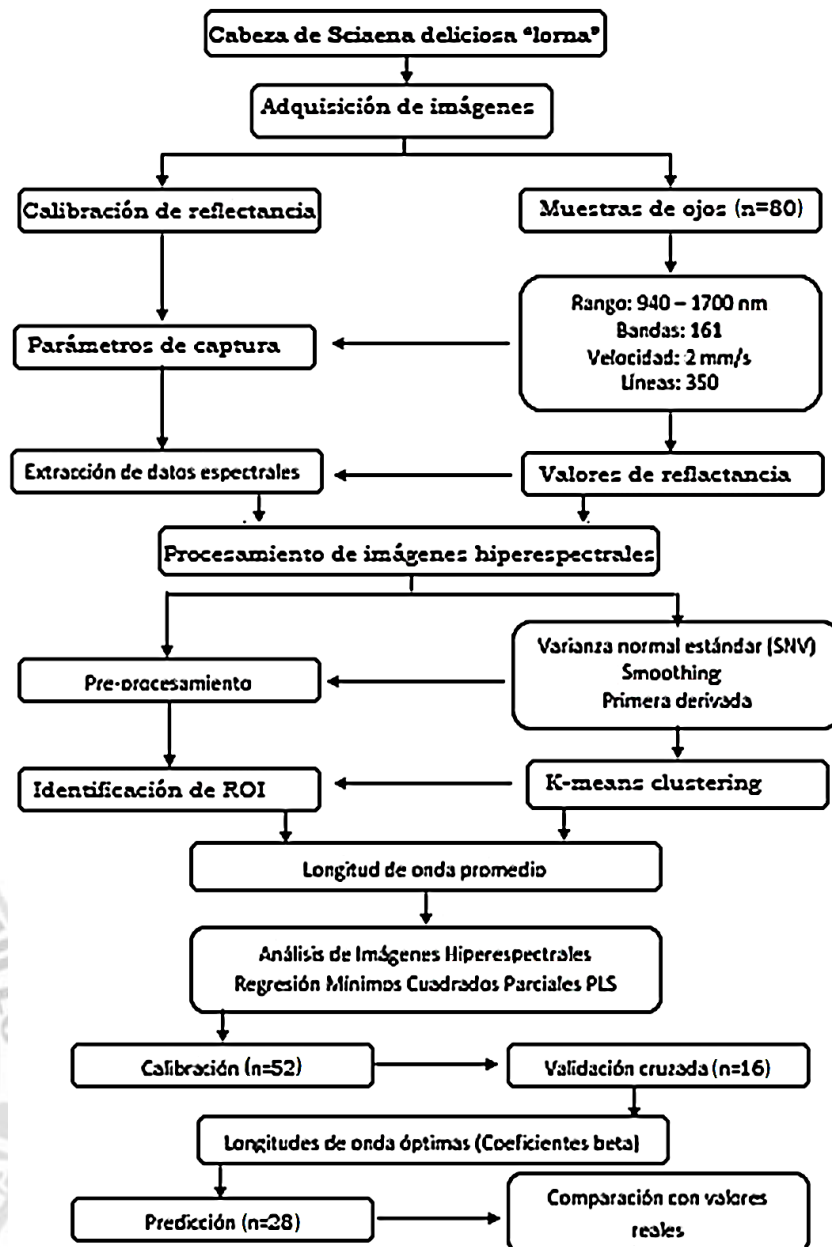


Figura 6. Diagrama del procedimiento de adquisición y procesamiento de las imágenes hiperespectrales.

## 2.7 Modelado mediante mínimos cuadrados parciales (PLS o PLSR)

- Modelado PLSR
- Selección de las longitudes de onda óptimas
- Nuevo modelado PLSR
- Validación del modelado PLSR

Se utilizó el modelo lineal multivariado de regresión de mínimos cuadrados parciales (PLSR) para desarrollar el modelo de calibración, Cross-validación y predicción. El modelo resultante se representa según la ecuación:

$$Y = X * b + e$$

Dónde: Y: Matriz de mediciones independientes; X: Matriz de datos predictores (80 muestras x 161 longitudes de onda); b: Matriz de los coeficientes  $\beta$  de regresión, obtenidos mediante el análisis PLSR; e: Matriz de información residual no explicada por las variables latentes. Los resultados del análisis de los datos multivariados fueron calculados mediante algoritmos definidos en el software Matlab R2016a. Este análisis se determina el número de variables latentes, la variable latente donde el error es mínimo y finalmente como resultado final los coeficientes  $\beta$  de regresión. A continuación, se validó el modelo multivariado. Para lo cual empleamos el método de Cross-validación, donde se toma solo un conjunto de 30% de las muestras de la calibración y a continuación se pudo establecer un modelo PLSR, para las muestras restantes que no fueron consideradas en la calibración, conocidas como muestras de predicción.

Las imágenes hiperespectrales obtenidas tienden a representar una alta dimensionalidad con redundancia y multicolinealidad entre las diversas bandas de longitud de onda contigua, lo que genera dificultad para el consiguiente proceso de calibración, ya que consume tiempo y afecta la velocidad de cálculo relacionada con el procesamiento de las imágenes hiperespectrales. Por lo tanto, es necesario encontrar el número mínimo de longitudes de onda que llevan la información más valiosa, que puede ser igual o más eficiente que el rango de longitud de onda completa y proporcionar resultados de predicción satisfactorios. Por eso, para la simplificación del modelo de PLS, se seleccionó las bandas de onda óptimas, este es un método utilizado para disminuir el "ruido" que puedan contener los datos espectrales, se aplica seleccionando los picos que estén formados notoriamente, debido a que si se consideran los puntos centrales existe una gran posibilidad de tomar datos

irrelevantes para nuestro estudio, afectando los resultados.

## 3. Resultados y discusión

El análisis sensorial a través del tiempo muestra oscilación en la valoración de puntos con una clasificación que va de óptimo hasta no apto (Tabla 1).

**Tabla 1**

Puntuación promedio del análisis sensorial de *Sciaena deliciosa* "lorna"

Días	Valoración por puntos	Clasificación
1	32	Óptimo
2	31	Óptimo
3	26	Bueno
4	19	No apto


En el análisis hiperespectral del humor vítreo del ojo se observan los valores en las longitudes de ondas que dan lugar a los coeficientes beta (picos mayores) (Tabla 2), las cuales reflejan la probable composición química del humor vítreo del ojo.

**Tabla 2**

Relación del índice de refracción y Coeficientes beta en Imágenes hiperespectrales

Longitud de Onda (nm)	Coefficiente beta
1001,04	0,0208
1043,73	0,0185
1081,67	0,0236
1290,37	0,0344
1636,61	0,04

La Figura 7 muestra los valores experimentales y predichos del índice de refracción del humor vítreo del ojo según el modelo PLSR.




**Figura 7.** Beta coeficientes del modelo PLSR (relación índice de refracción con imágenes hiperespectrales).

En el análisis hiperespectral del humor vítreo del ojo se observan los valores en las longitudes de ondas que dan lugar a los coeficientes Beta (Picos mayores), referentes al análisis sensorial (Tabla 3, Figura 10), las cuales reflejan la probable composición química del humor vítreo del ojo (Figura 8).

**Tabla 3**


Longitud de onda de los picos mayores de los posibles componentes químicos del humor vítreo (análisis sensorial vs. Imágenes hiperespectrales)

Longitud de Onda (nm)	Coefficiente beta
996,3	59,4665
1100,6	60,1525
1271,4	63,9096
1342,5	156,1213
1442,2	65,0904




**Figura 8.** Modelo predictivo de la frescura de *Sciaena deliciosa* "lorna" en relación al Índice de Refracción.

La **Figura 9** muestra los valores experimentales y predichos del análisis sensorial del pescado según el modelo PLSR.

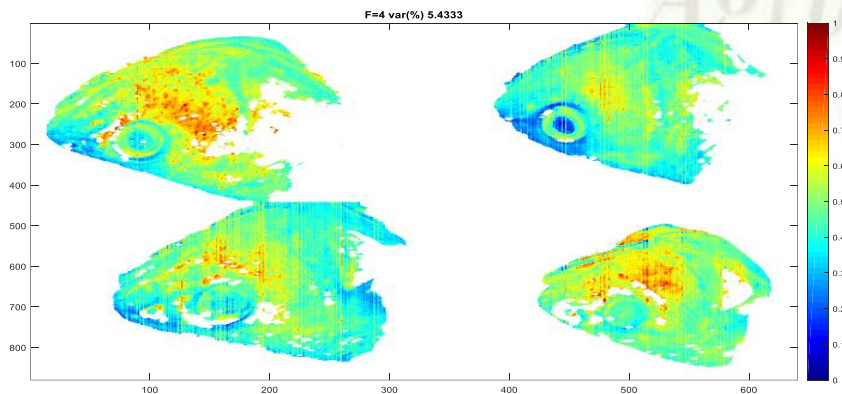


**Figura 9.** Análisis del coeficiente de correlación (relación análisis sensorial con imágenes hiperespectrales).




**Figura 10.** Beta coeficientes del modelo PLSR (relación análisis sensorial con imágenes hiperespectrales).

Al aplicar el mapa de colores se puede observar la perecibilidad del humor vítreo en transcurso del tiempo (**Figura 11 y 12**).



**Figura 11.** Comparación de la degradación del humor vítreo mediante la aplicación de cluster.



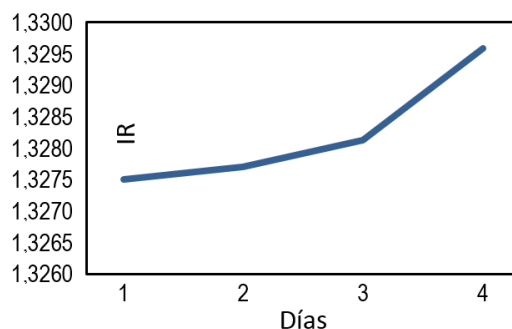

**Figura 12.** Longitud de onda de la variación de los cluster.



**Tabla 4**

Valores del índice de refracción en función del tiempo

Día	Promedio por día	Desviación estándar ( $S_x$ )	Valoración cualitativa
1	1,3275 $\pm$ 0,0001	0,0005	Muy buena
2	13277 $\pm$ 0,0001	0,0005	Muy buena
3	13281 $\pm$ 0,0002	0,0009	Muy buena
4	1.3296 $\pm$ 0,0002	0,0010	Muy buena

**Figura 13.** Variación del índice de refracción en función del tiempo.**Figura 14.** Intensidad de reflectancia vs longitud de onda para los tratamientos experimentales, relación entre el primer día de muestreo y el último día.

Al analizar el [Tabla 1](#) observamos que la puntuación sensorial promedio por día para *Sciaena deliciosa* "lorna" osciló entre 32 y 19 puntos consiguiendo la clasificación de óptimo los dos primeros días, bueno en el tercer día y no apto en el cuarto día, cuando estos ejemplares se encontraban al estado refrigerado, lo que es aceptable ya que este recurso es una especie grasa que se altera rápidamente por acción del oxígeno ambiental, actividad bacteriana y la actividad enzimática lo cual va a dar lugar a la formación de otros metabolitos secundarios que van a actuar sobre las características organolépticas de los especímenes alterándolas tal como lo reporta [Caceda \(2003\)](#), para el caso de *Scomber japonicus* "Caballa" alcanzando calidades de excelente, bueno, regular y malo en 5 días, pero con una proporción de hielo de 2:1 lo cual alargaría ligeramente el tiempo de frescura.

Los valores promedios del Índice de refracción de los días analizados del humor vítreo del ojo de *S. deliciosa* "lorna" oscilaron desde 1,3275 hasta 1,3296 y que al valorarlas según las tablas establecidas por [Ludorff \(1998\)](#), son calificados como muy buenas, por lo que se puede deducir que este método óptico es algo más preciso que el sensorial, que es subjetivo y podría ser una alternativa de uso para determinar frescura de pescado, pero que la cuantificación podría variar en función al tipo de especie, tal es el caso de la anchoveta que fue estudiada por [Yapar y Yetin \(1999\)](#), encontrándose valores de índice de refracción desde 1,3314 hasta 1,3347 con una calificación de excelente debido a que posiblemente la composición química bromatológica de este recurso es diferente al que analizamos, podrían haberse producido otros componentes que darían lugar a la modificación de opacidad del ojo del pescado y por lo tanto variando la lectura del índice de refracción ([Tabla 4](#)).

Con respecto a la perecibilidad de *S. deliciosa* "lorna" se puede notar que los valores del índice de refracción se incrementan con el tiempo ([Figura 13](#)) lo cual implica el desmejoramiento de la calidad y que también queda reflejado en el mapa de colores donde se observan la variación del color del ojo como consecuencia de la degradación que sufren los componentes del humor vítreo y que también se notan en los diferentes picos de los clusters para la escala de colores ([Figura 14](#)).

Analizando los valores del índice de determinación ( $R^2$ ) en las imágenes hiperespectrales, para el caso del humor vítreo ([Tabla 2](#)), se obtuvieron picos elevados que fueron considerados como sus componentes químicos ([Figura 7](#)) los cuales dieron lugar a los coeficientes beta que fueron utilizados en la ecuación lineal para determinar el valor de índice de determinación. Asimismo, notamos que con respecto al índice de refracción se consiguieron datos predictivos aceptables de  $R^2 = 0,6359$  ([Figura 8](#)), que es algo menor al reportado por [Ivorra et al. \(2015\)](#) con  $R^2 = 0,927$ , pero referido a la pupila de *Sparus aurata* "dorada" debido a que la información espectral extraída resulta más precisa al tener menor variabilidad entre las muestras y poderse ajustar mejor a un modelo PLSR. Así mismo, se realizó un modelo predictivo paralelo de análisis sensorial encontrándose un  $R^2 = 0,8322$ .

Con respecto al análisis sensorial vs imágenes hiperespectrales ([Tabla 3](#)) también se observa



picos que indicarían la variación de los diferentes componentes químicos y que el modelo PLSR lo visualiza encontrándose que  $R^2 = 0,8322$ , valor mayor al conseguido en el análisis comparativo con el índice de refracción (Figura 9 y 10); probablemente debido a que la calidad de la frescura en la muestras analizadas no sufrieron muchos cambios superficiales en la cavidad abdominal, textura, olor, ojos y branquias.

#### 4. Conclusiones

La valoración del análisis sensorial de *Sciaena deliciosa* "lorna" fue muy buena. El modelo predictivo de la frescura del pescado al aplicar imágenes Hiperespectrales fue aceptable con un  $R^2 = 0,6359$ . El valor del índice de refracción del humor vítreo del ojo de *Sciaena deliciosa* "lorna" estuvo dentro de las normas establecidas para determinar frescura de pescado. La perecibilidad de pescado en función al tiempo fue de cuatro días y puesta en manifiesto a través de la escala de colores del humor vítreo del ojo.

#### Orcid

R. Siche  <https://orcid.org/0000-0003-3500-4928>

#### Referencias bibliográficas

- Alvarado, J.; Aguilera, J. 2016. Métodos para medir propiedades físicas e industrias de alimentos. Universidad Técnica de Ambato. Ecuador. pág. 347-368.
- Anzaldúa, A. 2005. La evaluación sensorial de los alimentos en la teoría y la práctica. Editorial Acribia. Zaragoza, España. 198 pp.
- Armentaris, J. 2013. Gestión de la calidad y de la seguridad e higiene alimentarias. Edición Paraninfo. SA. Madrid, España. 1ª Ed. 288 pp.
- Azabache, R. 2017. Evaluación refractométrica del Humor Vítreo en peces procedentes de la pesca artesanal del Puerto Salaverry y Playa Las Delicias. Tesis para optar el título de biólogo pesquero. Universidad Nacional de Trujillo. Facultad de Ciencias Biológicas. Departamento de Pesquería.
- Barrantes, T. 2013. Estudio retrospectivo de la prevalencia de histamina en especies procedentes de la pesca en territorio costarricense durante los años 2008 al 2012 reportados por el laboratorio nacional de servicio veterinario (LANASEVE). Universidad para la Cooperación Internacional. Trabajo de Máster en gerencia de programas sanitarios en inocuidad de alimentos. San José, Costa Rica.
- Barreto, A.; Cruz-Tirado, J.P.; Siche, R.; Quevedo, R. 2018. Determination of starch content in adulterated fresh cheese using hyperspectral imaging. Food Bioscience 21: 14-19.
- Cáceda, C. 2003. Evaluación de la frescura de *Scombre japonicus* caballa en hielo. Universidad Nacional Jorge Basadre. Facultad de Ciencias. Tacna, Perú.
- Cheng, J.H.; Sun, D.W. 2014. Hyperspectral imaging as an effective tool for quality analysis and control of fish and other seafood: Current resarh potential applications.trends in food science and technology 37: 78-91.
- Correa, J.; Gonzáles, F. 2016. Manual de tecnología pesquera. Universidad Nacional de Trujillo. Fac. de Ciencias Biológicas. Departamento de Pesquería. Cátedra de Tecnología Pesquera. 115 pp.
- Culquichicón, Z.; Tresierra, A.; Solano, A.; Atoche, D. 2012. Crecimiento, mortalidad y tasa de explotación de *Sciaena deliciosa* durante 2001 a 2003 y 2009 a 2012. REBIOL 32(2): 108-117.
- Duflos, G.; Fur, B.; Mulak, V.; Becel, P.; Malle, P. 2002. Comparison of methods of differentiating between fresh and frozen-thawed fish of fillet. Journal of the Science of Food and Agriculture. 82: 1341 – 1345
- Elmasry, G.; Wen, D.W. 2010. Mest Quality Assessment using a hyperspectral imaging system. In:Hyperspectral Imaging of Food Quality analysis and control. 175-240 pp.
- Ivorra, E.; Sánchez, A.; Verdú, S.; Grau, R. 2015. Estimación de la frescura de *Sparus aurata* (dorada) mediante técnicas hiperespectrales en el rango del SW – NIR. Comité Español de Automática de la IFAC (CEA-IFAC).
- Ludorff, M. 1998. El pescado y los productos de la pesca. Ed. Acribia. Zaragoza, España. 309 pp.
- Mortimore, S.; Wallace, C. 2001. HACCP enfoque práctico. Ed. Acribia. Zaragoza, España.
- Sun, D. 2010. Hiperespectral imagin for food quality Analysis and Control. Dublin: Elsevier.
- Vásquez, D.; García, R. 2013. Obtención de un producto mínimamente procesado a partir de la especie *Arapaima gigas* (paiche) congelada y empacada al vacío. Conoc. amaz. 4(1): 15-28.
- Vejarano, R.; Siche, R.; Tesfaye, W. 2017. Evaluation of biological contaminants in foods by hyperspectral imaging: A review. International journal of food properties 20 (sup2), 1264-1297.
- Yapar, A.; Yetim, H. 1999. Determination of anchovy freshness by refractive index of eye fluid. Food Research International 31(10): 693-695.

