

# MODELO PARA LA EVALUACIÓN DE LA CALIDAD DE PESCADO USANDO IMÁGENES HIPERESPECTRALES

Andrea Arribas<sup>a,b</sup>, Juan R. Herrera<sup>b</sup>, Marta López-Cabo<sup>b</sup>, Carlos Vilas<sup>a</sup>

<sup>a</sup>Grupo de Biosistemas e Ingeniería de Bioprocesos

<sup>b</sup>Grupo de Microbiología y Tecnología de Productos Marinos

Instituto de Investigaciones Marinas (CSIC), Vigo (España)

carlosvf@iim.csic.es

## Resumen

*Los consumidores de pescado demandan productos de calidad, la cual determina su valor comercial. Por lo tanto, existe un gran interés en el desarrollo de herramientas capaces de evaluar la calidad del pescado de forma rápida, fiable, y que no suponga la destrucción del alimento. En este sentido, la tecnología de imágenes hiperespectrales (HSI, por sus siglas en inglés) es de las más prometedoras y está experimentando un gran auge entre la comunidad científica. Sin embargo, en lo que se refiere a pescado, la mayoría de artículos se centran en pescado procesado, principalmente filetes. Por otra parte, dado que los datos HSI no son sencillos de interpretar, se recurre a modelos matemáticos que proporcionen estimaciones de la calidad del pescado a partir de dichos datos.*

*En este trabajo se propone un modelo matemático, obtenido mediante la combinación de HSI y regresión por mínimos cuadrados parciales, para la evaluación de calidad en pescado entero, concretamente rodaballo de acuicultura. Los resultados muestran que dicho modelo reproduce de forma satisfactoria el QIM, uno de los indicadores de calidad más utilizados.*

**Palabras clave:** Calidad de pescado, Modelos de regresión, Mínimos Cuadrados parciales, Imágenes hiperespectrales, QIM.

## 1. INTRODUCCIÓN

La industria pesquera, particularmente la acuicultura, constituye una de las de mayor crecimiento en el sector alimentario. Además, es una fuente importante de ingresos en muchos países [10]. Sin embargo, debido a la rápida degradación que sufren los productos de la pesca, cerca de un 15 % de los mismos se desperdicia, llegando hasta el 35 % cuando las condiciones de almacenamiento no son adecuadas [5, 14]. Las principales causas de desarte de alimentos entre consumidores y minoristas son la pérdida de calidad sensorial y la incertidumbre sobre la seguridad alimentaria [11]. La industria alimentaria es consciente de que la ca-

lidad del pescado es una característica clave que determina su valor comercial.

La alteración *post-mortem* del pescado está asociada con procesos de oxidación, degradación microbiana y autólisis [6]. Estos procesos se traducen en cambios detectables como, por ejemplo: el color y el aspecto de la piel, ojos y branquias; o la pérdida de firmeza y elasticidad del músculo. Además, se produce un crecimiento de ciertas poblaciones bacterianas que contribuyen a la degradación, principalmente debido a su capacidad de producir bases volátiles de olores desagradables e intensos a partir del óxido de trimetilamina y otros compuestos nitrogenados no proteicos que hay en el músculo. Existe una gran variedad de métodos para detectar estos cambios *post-mortem* en la calidad de pescado fresco [9, 13]. Entre los métodos tradicionales, algunos de los más utilizados son: métodos sensoriales (QIM, QSM); la determinación de bases volátiles, de diferentes compuestos de la degradación de nucleótidos, o de productos de la oxidación lipídica; recuentos microbianos; y técnicas para la evaluación de ciertas propiedades físicas. Sin embargo, estos métodos presentan ciertos inconvenientes, como por ejemplo: la naturaleza subjetiva del análisis sensorial, el carácter destructivo de los métodos bioquímicos y microbiológicos, la necesidad de personal cualificado, o el tiempo requerido para obtener resultados. En los últimos años se han ido desarrollando algunas técnicas (biosensores, narices y lenguas electrónicas, técnicas de espectroscopía VIS-NIR, etc.) rápidas, no destructivas, y que no requieren de personal altamente cualificado, para la evaluación de la calidad de pescado. Cabe destacar, además, que estas técnicas son potencialmente más económicas que las tradicionales, aunque la mayoría están en fase de investigación y no han sido transferidas al sector productivo. El trabajo [13] presenta una revisión completa de estos métodos novedosos. Las técnicas basadas en imágenes hiperespectrales (HSI, por sus siglas en inglés) son de las más prometedoras ya que: (i) permiten evaluar distintos indicadores de calidad (físicos, químicos, microbiológicos, sensoriales), (ii) no son invasivas, es decir, no hay contacto con el producto, (iii) ofrecen información acerca de su distribución espacial, y (iv) pueden

llegar a redundar en una evaluación de la calidad en tiempo real. Dichas técnicas han sido utilizadas previamente en distintos productos, como frutas, carne, o filetes de pescado, entre otros [8, 3, 4]. Sin embargo, no se conocen trabajos donde se hayan utilizado para la evaluación de la calidad en pescado entero.

Los datos de las imágenes HSI no son fácilmente interpretables por lo que, generalmente, se recurre al uso de modelos matemáticos que relacionen dichos datos con ciertos indicadores de calidad. Entre los métodos más utilizados para este fin se encuentran [3]: regresión lineal múltiple, regresión por mínimos cuadrados parciales (PLSR, por sus siglas en inglés), redes neuronales artificiales, o máquinas de vectores de soporte. El método PLSR es uno de los métodos más utilizados ya que es capaz de manejar conjuntos de datos grandes, altamente correlacionados, y que contienen información redundante y poco relevante [7]. Este método combina características de los métodos de análisis de componentes principales (PCA, por sus siglas en inglés) y regresión lineal múltiple.

En este trabajo, haremos uso de la combinación de imágenes HSI y modelos PLSR para evaluar la calidad de pescado fresco entero, concretamente de rodaballo (*Psetta maxima*) procedente de acuicultura. El indicador de calidad seleccionado como referencia es el método de índice de calidad (QIM, por sus siglas en inglés), por ser uno de los indicadores que reflejan de modo más completo y específico la calidad global del pescado entero.

## 2. MATERIALES Y MÉTODOS

### 2.1. DATOS EXPERIMENTALES

Los ejemplares de rodaballo fueron suministrados en cajas con hielo por Stolt Sea Farm (Galicia). Se emplearon 41 ejemplares de talla pequeña (300-400 g). Desde su sacrificio hasta su llegada a las instalaciones del Instituto de Investigaciones Marinas (IIM-CSIC) e inicio de la experimentación transcurrió un día. Tras su llegada, y hasta el momento del muestreo, los ejemplares se mantuvieron almacenados en cajas dentro de una cámara frigorífica a una temperatura aproximada de 5 °C. Cada día se extrajeron entre 3 y 5 ejemplares de la cámara frigorífica para realizar las distintas mediciones. Primero se adquirieron las imágenes hiperespectrales en ambos lados de cada ejemplar y después se evaluó la calidad mediante el QIM. A continuación se describe de forma más precisa cada uno de los pasos anteriores.

#### 2.1.1. Imágenes hiperespectrales

El equipo empleado para la adquisición de las imágenes hiperespectrales consta de cuatro componentes (ver Figura 1). (1) Dos cámaras hiperespectrales lineales, Specim FX10 y FX17, que se fijan en un soporte. La cámara FX10 toma imágenes entre  $\lambda = 400\text{nm}$  y  $\lambda = 1000\text{nm}$  con un intervalo de  $\Delta\lambda = 1,3\text{nm}$  (en total, 448 longitudes de onda). El rango espectral de la cámara FX17 es  $\lambda = 900 - 1700\text{nm}$ , con un intervalo de  $\Delta\lambda = 3,5\text{nm}$  (en total, 224 longitudes de onda). Las cámaras lineales sacan la fotografía en una línea, en este caso, la resolución de la cámara lineal es de 512 px/línea (eje horizontal). (2) Una plataforma móvil sobre la que se coloca cada rodaballo. Al moverse la plataforma, se obtiene la dimensión vertical (752 líneas) de la fotografía. (3) Fuente de iluminación (lámparas halógenas fijas). (4) Ordenador equipado con el software Lumo Scanner, utilizado tanto para la captura de las imágenes, como para la configuración de las cámaras. La zona en la que se encuentra instalado el equipo se rodea con una cortina opaca durante la toma de las imágenes para evitar diferencias en la iluminación producidas por la influencia de la luz solar.




Figura 1: Imagen del equipo HSI montado en las instalaciones del IIM-CSIC.

Los parámetros del equipo HSI (apertura del obturador, velocidad de la plataforma móvil, distancia focal, etc.) se seleccionaron previamente para evitar la aparición de zonas borrosas por el movimiento de la plataforma y de zonas saturadas en la imágenes, así como para un correcto enfoque de los ejemplares en la plataforma.

Previamente a la toma de cada imagen, se realiza una calibración de la cámara. Se utiliza un panel de madera blanco para obtener la referencia blanca. La referencia negra se obtiene cerrando el obturador. A continuación, se toman imágenes HSI de ambos lados del pescado. El resultado es

un tensor de datos ( $R_0$ ) en el que cada elemento se corresponde con la reflectancia en cada píxel y a cada longitud de onda, es decir las dimensiones de  $R_0$  son  $512 \times 752 \times 448$  para la cámara FX10 y  $512 \times 752 \times 224$  para la FX17. Cabe destacar que  $R_0$  contiene información tanto de píxeles del pescado como del fondo. Para eliminar del análisis los datos correspondientes al fondo, primero se calcula la media de  $R_0$  en todo el rango espectral. El resultado es una matriz  $\bar{R}_0$  con  $512 \times 752$  elementos. Aquellos elementos con  $\bar{R}_0 < R_{\text{corte}}$ , se eliminan del análisis. La selección de  $R_{\text{corte}}$  se realiza por el método de prueba y error, de forma que se eliminen los píxeles correspondientes al fondo, manteniendo los del pescado.

Los datos de reflectancia ( $R_0$ ) correspondientes a los píxeles del pescado se normalizan utilizando las referencias blanca ( $W$ ) y negra ( $B$ ), de la siguiente forma:

$$R_N = \frac{R_0 - B}{W - B} \tag{1}$$

Finalmente se calcula la media de las reflectancias ( $R_N$ ) en cada longitud de onda. El resultado es un vector de dimensión  $448 + 224$  para cada lado de cada ejemplar.

### 2.1.2. Evaluación del QIM

El QIM es uno de los indicadores que mejor reflejan la calidad sensorial del pescado. Se trata de un indicador desarrollado para cada especie y está basado en las siguientes características: aspecto externo de ojos, piel y agallas; olor; y textura. Para cada característica se emplea un sistema de puntuación entre 0 y 2 o 3 puntos de demérito. Así por ejemplo, en el caso del rodaballo, si los ojos son negros y claros, con borde dorado alrededor de la pupila, se asigna una puntuación 0. Si, por el contrario, son algo mates con borde dorado claro, se asigna una puntuación 1. Si son mates y presentan enrojecimiento, se asigna 2. La descripción detallada de la puntuación para cada uno de los parámetros valorados se pueden consultar en el siguiente enlace: <http://webs.ucm.es/BUCM/vet/doc20700.pdf>.

Las puntuaciones para todas las características se suman, obteniéndose una puntuación sensorial global. Esta puntuación es un número entero entre 0 (pescado fresco) y 28 (pescado totalmente deteriorado), en el caso del rodaballo.

En este estudio, 4 panelistas expertos del IIM-CSIC realizaron la evaluación sensorial de los ejemplares en condiciones estandarizadas, con la menor perturbación posible, a temperatura ambiente y bajo luz blanca fluorescente. Cada panelista puntuó de forma individual las muestras.

## 2.2. REGRESIÓN POR MÍNIMOS CUADRADOS PARCIALES

Típicamente, el objetivo de los métodos de regresión es estimar un conjunto de *variables respuesta* o *dependientes* (generalmente variables cuya medición resulta costosa, es lenta, implica la destrucción de la muestra, etc.) a partir de un conjunto de *predictores* o *variables independientes*, cuya medición resulta más sencilla. Consideremos que disponemos de  $m$  muestras, sobre las que se quiere determinar  $r$  variables dependientes a partir de  $p$  predictores. Sean  $Y^* \in \mathcal{M}^{m \times r}$ ,  $X^* \in \mathcal{M}^{m \times p}$  los conjuntos de variables respuesta y predictores, respectivamente. El objetivo de un método de regresión lineal sería encontrar los conjuntos de parámetros  $B_1 \in \mathcal{M}^{p \times r}$  y  $B_0 \in \mathcal{M}^{m \times r}$  tal que:

$$Y^* \approx \hat{Y}^* = X^* B_1 + B_0 \tag{2}$$

donde  $\hat{Y}^* \in \mathcal{M}^{m \times r}$  es una aproximación de  $Y^*$ . La ecuación (2) se puede simplificar *centrando* las variables  $X^*$  e  $Y^*$  en el origen de coordenadas. Esto es, se resta la media a cada una de las variables ( $Y = Y^* - \bar{Y}$ ,  $X = X^* - \bar{X}$ ). De esta forma, la ecuación (2) se puede escribir como:

$$\hat{Y} = XB \tag{3}$$

El centrado proporciona, además, estabilidad numérica [12]. Sin embargo cuando  $p \gg m$ , como suele ocurrir cuando se utilizan datos de HSI como predictores, el enfoque clásico de regresión no es factible.

El método PLSR es un método muy utilizado en quimiometría para calcular  $B$ , ya que es capaz de manejar conjuntos de datos grandes, altamente correlacionados, y que contienen información redundante y poco relevante [7]. Este método combina características de los métodos PCA y regresión lineal múltiple. Se asume que el sistema depende de un número de *variables latentes* ( $l$ ), donde  $l < p, r$ . Estas variables latentes se estiman de forma que sean capaces de explicar lo mejor posible la covarianza entre  $X$  e  $Y$ . En PLSR, los vectores latentes son las columnas de una matriz  $T \in \mathcal{M}^{m \times l}$  (matriz de *scores* de  $X$ ).  $T$  se calcula como una combinación lineal de los predictores  $X$ , es decir:

$$T = XW^* \tag{4}$$

Donde  $W^* \in \mathcal{M}^{p \times l}$  es una matriz que contiene los pesos de la combinación lineal. La matriz  $T$ , multiplicada por una matriz de *carga* ( $P \in \mathcal{M}^{p \times l}$ ), produce una buena estimación de  $X$ , de forma que:

$$X = TP^T + E \tag{5}$$

tiene residuos ( $E$ ) pequeños. La matriz  $U \in \mathcal{M}^{m \times l}$  (*scores* de  $Y$ ), multiplicada por una matriz

de carga ( $C \in \mathcal{M}^{r \times l}$ ), es una buena estimación de  $Y$ . Además,  $T$  también estima bien las variables respuesta  $Y$ :

$$\hat{Y} = UC^T; \quad \hat{Y} = TC^T \quad (6)$$

De las ecuaciones (4) y (6) se tiene que:

$$\hat{Y} = XW^*C^T = XB$$

Por lo tanto, la matriz con los coeficientes de la regresión se puede calcular como  $B = W^*C^T$ . Para una descripción más detallada del método de regresión PLSR se puede consultar alguno de los siguientes trabajos [1, 12].

El número de variantes latentes ( $l$ ) necesario para obtener una buena estimación no se conoce *a priori*. Cuanto mayor es  $l$ , mejor aproximación del modelo a los datos usados para el cálculo de los coeficientes en  $B$ . Sin embargo, dicha mejora podría ser debida a un sobreajuste, es decir, el modelo recogería el ruido en los datos. Como consecuencia, al considerar nuevos datos, no utilizados en el cálculo de  $B$ , la capacidad predictiva del modelo podría ser mala. La validación cruzada de  $k$  iteraciones [2] es un método que permite minimizar este efecto, y calcular el número óptimo de componentes. En este método, se separan los datos en  $k$  subconjuntos. Los coeficientes  $B$  se calculan usando  $k - 1$  subconjuntos (entrenamiento), mientras que el subconjunto restante se utiliza para validar el modelo. Este proceso se repite  $k$  veces, con un conjunto de validación distinto. Después, se calcula el promedio de los residuos en los datos de validación. El número de componentes óptimo es aquél que tenga un menor error, calculado como la raíz del error cuadrático medio (RECM).

$$RECM = \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}}$$

donde  $n$  es el número de datos usados en la validación. En este trabajo se ha usado la función `plsregress` de Matlab para obtener los coeficientes  $B$  del modelo.

Como prueba de las capacidades predictivas del modelo, se utilizará un conjunto de datos, llamado conjunto de *prueba o evaluación*, no considerado en la validación cruzada de  $k$  iteraciones.

### 3. RESULTADOS

En este trabajo, la variable respuesta ( $Y$ ) se corresponde con el indicador de calidad (QIM), mientras que los espectros de las imágenes HSI se utilizan como predictores ( $X$ ).

En primer lugar se eliminaron los píxeles correspondientes a la plataforma móvil (fondo) siguiendo el procedimiento descrito en la Sección 2.1.1 y utilizando un  $R_{\text{corte}} = 280$ . Como se puede ver en la Figura 2, los píxeles retenidos -puntos rojos en la Figura 2(b)- se corresponden, en general, con los del rodaballo.




Figura 2: (a) Imagen RGB de una muestra de rodaballo. (b) Píxeles retenidos después del proceso de separación fondo/muestra.

Una vez separado el fondo de la muestra, se calculan las reflectancias normalizadas ( $R_N$ ) a partir de los datos de reflectancias proporcionados por la cámara hiperespectral ( $R_0$ ) y las referencias blanca ( $W$ ) y negra ( $B$ ), usando la Ecuación (1). La Figura 3 muestra la media de  $R_N$  a distintos  $\lambda$  para tres muestras. La línea azul se corresponde con una muestra analizada nada más llegar a las instalaciones del IIM-CSIC. Las líneas roja y negra se corresponden con muestras almacenadas durante 4 y 8 días, respectivamente.

De las 41 muestras de rodaballo analizadas, 32 fueron seleccionadas de forma aleatoria para obtener los coeficientes de regresión  $B$ , mediante la validación cruzada. Se ha elegido  $k = 6$  iteraciones para que cada grupo estuviese formado por un número significativo de datos. En este caso, cinco de los grupos contenían los datos de 5 muestras, mientras que el sexto estaba compuesto los datos de 7 muestras. La selección de datos pertenecientes a cada grupo se realizó de forma aleatoria. La Figura 4 muestra cómo varía la RECM (calculada sobre los datos del conjunto de validación) según el número de componentes. Como se puede ver, a




Figura 3: Media de los espectros obtenidos para tres muestras almacenadas durante 0, 4 y 8 días, respectivamente.




Figura 4: Evolución de la RMSE según el número de componentes.

partir de 10 componentes la mejora de la RECM no es significativa, por lo que se ha seleccionado  $l = 10$  para obtener el modelo.

La Figura 5 muestra una comparación entre el QIM medido analíticamente y el estimado con el modelo propuesto. Los puntos azules representan los datos utilizados en la fase de modelado (conjuntos de entrenamiento y validación) mientras que los rojos representan el conjunto de datos de prueba (y que no han sido usados en el cálculo de los coeficientes  $B$ ). Si se consideran todos los datos disponibles, se tiene que  $RECM = 1,79$ , mientras que si solo se tiene en cuenta el conjunto de datos de prueba, se tiene que  $RECM = 2,96$ . Tanto la Figura 5 como los datos de la RECM indican que los resultados son satisfactorios.

La evolución del QIM con el tiempo para el conjunto de datos de prueba se representa en la Figura 6. Los puntos azules representan los datos de QIM medidos mientras que los rojos se refieren a los valores estimados por el modelo. Se puede observar que la estimación hecha por el modelo es buena, con la excepción del último día, donde las diferencias entre predicciones y medidas es ligera-

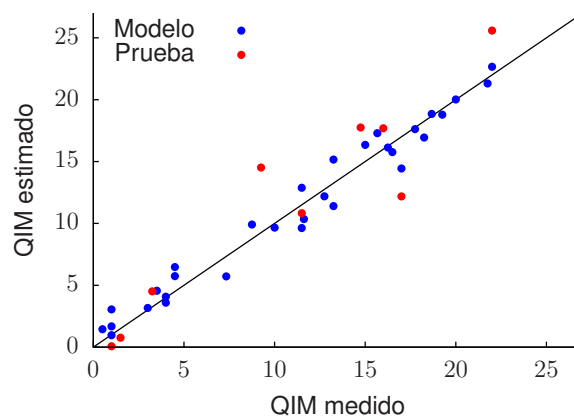


Figura 5: Representación de los datos estimados por el modelo frente a los medidos analíticamente.

mente mayor. Probablemente debido, en parte, a la presencia de valores incoherentes.

#### 4. CONCLUSIONES Y TRABAJO FUTURO

En este trabajo se ha desarrollado un modelo matemático, basado en regresión por mínimos cuadrados parciales (PLSR), para evaluar la calidad de pescado entero a partir de imágenes hiperespectrales (HSI). Como caso de estudio se ha utilizado rodaballo de acuicultura, aunque la misma metodología se podría aplicar a otras especies de pescado. El indicador de calidad seleccionado fue el QIM ya que el análisis sensorial es el método más usado en la industria. Se ha mostrado que un modelo PLSR con 10 componentes resulta en una buena estimación del QIM.

Respecto al trabajo futuro, se considerará la posibilidad de aumentar el número de indicadores de calidad y de especies de pescado. Además, y para mejorar los resultados de estimación, explorare-

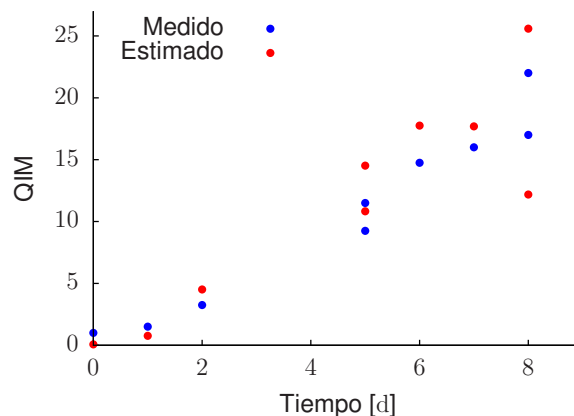


Figura 6: Evolución temporal del indicador de calidad QIM.

mos una serie de opciones. (i) Las imágenes HSI contienen información redundante y poco relevante. Este problema se alivia, en gran parte, utilizando PLSR. Sin embargo, la selección de bandas óptimas de las imágenes HSI podría mejorar los resultados. (ii) Se explorará la posibilidad de utilizar un  $R_{\text{corte}}$  para eliminar brillos en las imágenes, de la misma forma que se utilizó para separar fondo y muestra. (iii) También se considerarán métodos para la detección y eliminación de medidas incoherentes. (iv) Además, aunque la utilización de la media de los espectros es algo generalizado, el pescado presenta una distribución no homogénea de los indicadores de calidad. Las capacidades predictivas de los modelos podrían mejorar si se tiene en cuenta esta heterogeneidad. Se probarán métodos de *clustering*, que seleccionan grupos de píxeles basándose en las propiedades espectrales, de forma que en lugar de usar las medias de los espectros en todo el pez, se usarían aquellos grupos que mejor predicen el indicador seleccionado.

### Agradecimientos

Este trabajo ha sido financiado por el programa de becas de introducción a la investigación “JAE Intro ICU” (2021), en el marco del Programa “Junta para la Ampliación de Estudios” y apoyado a través del Convenio entre el CSIC y la Agencia Galega de Innovación para el desarrollo de programas de I+D+i en los institutos de investigación del CSIC en Galicia. El trabajo está, además, enmarcado dentro del programa de “Ciencias Marinas” financiadas por el Ministerio de Ciencia e Innovación y Xunta de Galicia con fondos Next-Generation de la Unión Europea (PRTR-C17.II), Fondo Europeo Marítimo y de Pesca (FEMP) y el Fondo Europeo Marítimo, de Pesca y de Acuicultura (FEMPA).

### English summary

## FISH QUALITY ASSESSMENT MODEL FROM HYPERSPECTRAL IMAGES

### Abstract

*Fish consumers demand high quality products. Quality determine the commercial value of fishing products. Therefore, the use of rapid, reliable, non-destructive tools able to assess quality indicators in fish is becoming critical. In this regard, techniques based on hyperspectral images (HSI) are among the most promising in this field and their interest is increasing among the*

*scientific community. Nevertheless, most of the contributions focus on processed fish, namely filets. Besides, HSI data are difficult to interpret, therefore, mathematical models able to provide estimations of fish quality from HSI data must be obtained.*

*In this work, we derive a mathematical model, by combining HSI and partial least squares regression, to assess quality in unprocessed fish. In particular, we consider turbot from an aquaculture farm. Results show that the model is able to satisfactorily assess the QIM, one of the most used indicators.*

**Keywords:** Fish quality, Regression models, Partial least squares, hyperspectral imaging, QIM.

### Referencias

- [1] Hervé Abdi. Partial least squares regression and projection on latent structure regression (pls regression). *WIREs Computational Statistics*, 2(1):97–106, 2010.
- [2] P. Burman. Estimation of optimal transformations using v-fold cross validation and repeated learning-testing methods. *Sankhya: The Indian Journal of Statistics, Series A*, 52(3):314–345, 1990.
- [3] J. H. Cheng, B. Nicolai, and D. W. Sun. Hyperspectral imaging with multivariate analysis for technological parameters prediction and classification of muscle foods: A review. *Meat Science*, 123:182–191, 2017.
- [4] Jun Hu Cheng, Da Wen Sun, Xin An Zeng, and Dan Liu. Recent Advances in Methods and Techniques for Freshness Quality Determination and Evaluation of Fish and Fish Fillets: A Review. *Crit. Rev. Food Sci. Nutr.*, 55(7):1012–1225, 2015.
- [5] Maria G. Corradini. Shelf Life of Food Products: From Open Labeling to Real-Time Measurements. *Annu. Rev. Food Sci. Technol.*, 9:251–269, 2018.
- [6] Jorge Freitas, Paulo Vaz-Pires, and José S. Câmara. Quality index method for fish quality control: Understanding the applications, the appointed limits and the upcoming trends. *Trends in Food Science & Technology*, 111:333–345, 2021.

- [7] C. Q. Li, Z. Fang, and Q. S. Xu. A partition-based variable selection in partial least squares regression. *Chemometrics and Intelligent Laboratory Systems*, 198:103935, 2020.
- [8] Y. Lu, Y. Huang, and R. Lu. Innovative hyperspectral imaging-based techniques for quality evaluation of fruits and vegetables: A review. *Applied Sciences*, 7(2), 2017.
- [9] Emilia Martinsdóttir, Rian Schelvis, Grethe Hyldig, and Kolbrun Sveinsdóttir. *Sensory Evaluation of Seafood: Methods*, chapter 20, pages 425–443. John Wiley & Sons, Ltd, 2009.
- [10] Olumide A. Odeyemi, Christopher M. Burke, Christopher C.J. Bolch, and Roger Stanley. Seafood spoilage microbiota and associated volatile organic compounds at different storage temperatures and packaging conditions. *International Journal of Food Microbiology*, 280:87–99, 2018.
- [11] Norbert Raak, Claudia Symmank, Susann Zahn, Jessica Aschemann-Witzel, and Harald Rohm. Processing- and product-related causes for food waste and implications for the food supply chain. *Waste Management*, 61:461–472, 2017.
- [12] S. Wold, M. Sjöström, and L. Eriksson. Pls-regression: a basic tool of chemometrics. *Chemometrics and Intelligent Laboratory Systems*, 58(2):109–130, 2001. PLS Methods.
- [13] Leilei Wu, Hongbin Pu, and Da Wen Sun. Novel techniques for evaluating freshness quality attributes of fish: A review of recent developments. *Trends Food Sci. Technol.*, 83:259–273, 2019.
- [14] Sebastian Zöller, Markus Wachtel, Fabian Knapp, and Ralf Steinmetz. Going all the way - detecting and transmitting events with wireless sensor networks in logistics. In *38th Annual IEEE Conference on Local Computer Networks - Workshops*, pages 39–47, 2013.



© 2022 by the authors.  
Submitted for possible  
open access publication  
under the terms and conditions of the Creative  
Commons Attribution CC-BY-NC 4.0 license  
(<https://creativecommons.org/licenses/by-nc-sa/4.0/deed.es>).