

Detection of Chicken Meat Freshness Using NIR spectroscopy and Machine Learning Algorithms

Jimmy Oblitas-Cruz¹; Jhoana Uriarte-Valdivia¹; André Rodríguez-León²

^{1,3}Universidad Privada del Norte, Perú, jimmy.oblitas@upn.edu.pe, N00272826@upn.pe

²Universidad Nacional de Cajamarca, Perú, arodriguezl@unc.edu.pe

Abstract— Chicken meat freshness is a critical quality and safety indicator that requires rapid and non-destructive detection methods. This study aimed to develop a spectral classification model to identify chicken freshness using NIR spectroscopy and machine learning algorithms. A total of 180 spectra (1100–2495 nm) were collected and labeled as “fresh” (days 1–3) or “spoiled” (days 4–5). After Savitzky–Golay smoothing and SNV correction, five models (SVM, LASSO, Ridge, Elastic Net, Random Forest) were trained using stratified cross-validation. The LASSO model achieved the best performance with 97.2% accuracy and AUC = 0.977, with no false negatives in the spoiled class, followed by SVM (94.4%). Results demonstrate the effectiveness of regularized linear architectures for detecting chemical changes associated with spoilage. This approach provides a rapid, non-invasive, and accurate tool for freshness monitoring in poultry production chains.

Keywords—NIR, chicken meat, machine learning, freshness, classification.

Detección de la frescura de la carne de pollo mediante espectroscopia NIR y algoritmos de aprendizaje automático

Jimmy Oblitas-Cruz¹, Jhoana Uriarte-Valdivia¹; André Rodríguez-León²

^{1,3}Universidad Privada del Norte, Perú, jimy.oblitas@upn.edu.pe, N00272826@upn.pe

²Universidad Nacional de Cajamarca, Perú, arodriguezl@unc.edu.pe

Resumen– La frescura de la carne de pollo es un indicador crítico de calidad e inocuidad que requiere métodos rápidos y no destructivos para su evaluación. Este estudio tuvo por objetivo desarrollar un modelo de clasificación espectral para identificar el estado de frescura de carne de pollo mediante espectroscopia NIR y algoritmos de aprendizaje automático. Se adquirieron 180 espectros en el rango 1100–2495 nm, etiquetados como “fresco” (días 1–3) y “deteriorado” (días 4–5). Tras preprocesamiento con Savitzky–Golay y SNV, se evaluaron cinco modelos (SVM, LASSO, Ridge, Elastic Net y Random Forest) empleando validación cruzada estratificada. El modelo LASSO obtuvo el mejor desempeño con 97.2 % de precisión y AUC = 0.977, sin falsos negativos en la clase deteriorada, seguido de SVM (94.4 %). Los resultados confirman el potencial de los modelos lineales con regularización para detectar cambios químicos asociados al deterioro. Este enfoque ofrece una alternativa rápida, no invasiva y precisa para monitoreo de calidad en la industria avícola.

Palabras clave– NIR, carne de pollo, aprendizaje automático, frescura, clasificación.

I. INTRODUCCIÓN

La frescura de la carne avícola es un parámetro crítico para la seguridad alimentaria y la satisfacción del consumidor [1]. Mantener la calidad de la carne de pollo representa un desafío debido a su elevada susceptibilidad al deterioro una vez realizado su beneficio. Además existen otros factores adicionales que pueden enmascarar o acelerar los cambios de frescura, tales como variaciones asociadas al tipo de ave y prácticas de manipulación destinadas a prolongar artificialmente su aceptabilidad comercial más allá de su vida útil [2].

Los métodos tradicionales de evaluación, basados en parámetros fisicoquímicos o microbiológicos, suelen ser destructivos, requieren tiempos prolongados de análisis y no son compatibles con líneas de producción de alto flujo [3]. En este contexto, el desarrollo de tecnologías no destructivas y automatizadas ha emergido como una alternativa altamente eficiente para el diagnóstico de calidad en productos cárnicos [4]. Entre ellas, la espectroscopia en el infrarrojo cercano o en sus siglas en inglés “Near-infrared” (NIR) ha demostrado una notable capacidad para detectar cambios químicos asociados al deterioro, como variaciones en el contenido de agua, proteínas, lípidos o metabolitos derivados de la

descomposición microbiana [5]. Tal como se observa el uso de tecnologías espectrales se han probado en diferentes tipos de carne, como res [6], [7] o productos hidrobiológicos [8], con valores de precisión superiores al 84% en cada uno de ellos.

El uso de espectros NIR adquiere mayor relevancia cuando se integra con algoritmos de aprendizaje automático capaces de identificar patrones complejos no evidentes de forma visual [9]. De manera reciente, estudios han demostrado la eficacia de modelos como Support Vector Machines (SVM), regresión penalizada o redes neuronales para clasificar estados de frescura o predecir compuestos indicadores como TVB-N o cadaverina. Sin embargo, son necesarios avances adicionales que simplifiquen los sistemas propuestos, permitan una implementación industrial accesible y mantengan altos niveles de exactitud con muestras mínimamente preprocesadas.

En los últimos años, diversos estudios publicados en revistas indexadas han evidenciado el potencial de la espectroscopia y la visión por computador para la evaluación objetiva de la frescura de carnes. Kim et al. [10] desarrollaron modelos de regresión PLS basados en espectros Vis/NIR (1100–2495 nm) de pollo refrigerado, combinando selección de longitudes de onda y aumento sintético de datos. Sus mejores modelos lograron coeficientes de determinación de 0,79 para cadaverina, 0,77 para putrescina y 0,73 para tiramina, mientras que el enfoque de distribución multivariante (MVN) mejoró la predicción de uridine monophosphate (UMP) hasta un R^2 de 0,82. De esta misma forma, Xu et al. [11] hicieron un análisis de carne refrigerada mediante imágenes hiperespectrales (900–1700 nm), donde un modelo PLSR con preprocesamiento Savitzky–Golay y SNV alcanzó un R^2 de 0,9631 y un RMSEP de 0,7433 para nitrógeno básico volátil total (TVB-N), y la combinación S-G+MSC obtuvo una correlación de $R = 0,9601$ y RMSEP = 0,9122 para el recuento total de microorganismos aerobios viables (TVC). Estos resultados cuantitativos confirman la capacidad de las tecnologías espectrales para capturar cambios químicos y microbiológicos asociados al deterioro de la carne.

Este trabajo tiene como objetivo presentar el desarrollo de un modelo de clasificación basado en espectros NIR de carne de pollo almacenada en refrigeración durante cinco días,

empleando un enfoque comparativo entre cinco algoritmos supervisados. Destacando la aplicación de técnicas de preprocesamiento espectral, entrenamiento y validación cruzada para garantizar un rendimiento robusto. Además, la evaluación de múltiples modelos, tanto lineales como no lineales, permite comparar distintas capacidades de generalización y discriminación, fortaleciendo la validez del enfoque propuesto.

II. MATERIALES Y MÉTODOS

En esta sección se presenta el enfoque de aprendizaje automático desarrollado para la clasificación del estado de frescura de carne de pollo mediante espectros NIR. El modelo se implementó en Google Colab utilizando un conjunto de datos espectrales adquiridos a diferentes días de almacenamiento. Tal como se muestra en la Figura 1, el estudio inicia con la adquisición de una base de datos espectrales que pasó por un pre procesamiento que fue la base para el entrenamiento y evaluación de modelos de detección.



Fig. 1 Flujo de obtención de los modelos de predicción.

A. Instrumentación y adquisición espectral

Las mediciones espectrales se realizaron con un espectrómetro NIR Unity Scientific (SpectraStar 2500XL, EE. UU.) equipado con una lámpara halógena de tungsteno como fuente de luz con un rango de 1100 a 2500 nm y una resolución de 3 nm. Los espectros fueron adquiridos durante cinco días de almacenamiento refrigerado. Cada espectro se obtuvo mediante extracción de la firma promedio de la región de interés, asegurando representatividad del tejido muscular.

El estudio empleó 180 espectros NIR de carne de pollo adquiridos entre 1100 y 2495 nm. Cada espectro corresponde a una muestra individual, con absorbancia por longitud de onda como variables predictoras y el estado de frescura como variable objetivo. La clase se definió a partir del día de almacenamiento: días 1–3 como “Fresco” (n = 108) y días 4–5 como “Deteriorado” (n = 72).

B. Preprocesamiento espectral

Los espectros crudos fueron primero suavizados mediante el método Savitzky–Golay utilizando una ventana de 9 puntos y un polinomio de segundo orden, con el fin de reducir el ruido instrumental sin distorsionar la señal. Posteriormente, se aplicó la corrección Standard Normal Variate (SNV) para compensar variaciones debidas a efectos de dispersión y diferencias en la iluminación de las muestras.

Tras el preprocesamiento, se conservó el rango espectral original de 1100 a 2495 nm, manteniendo la resolución

instrumental completa. Esta matriz preprocesada se empleó directamente para el ajuste de los modelos de clasificación, lo que permitió capturar la información relevante asociada a la evolución química de la carne durante su almacenamiento.

C. División del conjunto de datos

El conjunto preprocesado de 180 espectros se dividió en dos subconjuntos de manera estratificada para preservar la proporción original de clases: 80 % para entrenamiento y 20 % para prueba. Esto resultó en 144 espectros para ajustar los modelos y 36 para la evaluación final del desempeño. La estratificación fue clave para evitar sesgos derivados del ligero desbalance entre las clases “Fresco” (n = 108) y “Deteriorado” (n = 72).

Adicionalmente, se empleó una validación cruzada de k = 5 pliegues durante el entrenamiento, garantizando estimaciones robustas de las métricas de desempeño y minimizando la varianza asociada a la selección puntual de muestras en el conjunto de prueba.

D. Entrenamiento de los modelos

Se evaluaron cinco algoritmos de clasificación supervisada: SVM-RBF, Ridge, LASSO, Random Forest, y Elastic Net, implementados en Python con scikit-learn. En todos los casos, el conjunto de entrenamiento (n=144) fue estandarizado previo al ajuste. El modelo SVM empleó un kernel radial base (RBF) con valor de penalización C=9, logrando un equilibrio entre margen amplio y minimización del error de clasificación. La regresión logística Ridge (penalización L2) utilizó el solver lbfgs y un término de regularización C=1.0, al igual que LASSO (penalización L1), que empleó el solver liblinear, favoreciendo la selección automática de variables espectrales relevantes.

Por su parte, el modelo Elastic Net combinó ambas penalizaciones (l1_ratio=0.5) para estabilizar la regularización ante colinealidad espectral. Finalmente, el modelo Random Forest se configuró con 300 árboles y extracción de variables max_features='sqrt', lo que permite eficiencia sin restringir el aprendizaje de relaciones no lineales. La predicción en todos los casos se basó en el cálculo de probabilidades mediante predict_proba(), posibilitando el cálculo posterior de métricas basadas en umbral como ROC-AUC.

E. Evaluación del rendimiento

El rendimiento fue evaluado en base a los indicadores:

- Accuracy (exactitud) es la proporción de todas las clasificaciones que fueron correctas, ya sean positivas o negativas. Se define matemáticamente de la siguiente manera:

$$Accuracy = \frac{\text{Clasificaciones correctas}}{\text{Total de clasificaciones}}$$

- F1-macro, es la puntuación F1 macropromediada de un modelo lo cual es simplemente un promedio simple de las puntuaciones F1 obtenidas por clase. La puntuación

F1 se calcula como la media armónica de las puntuaciones de precisión y recuperación.

- c. ROC-AUC. Es una representación gráfica de la tasa de verdaderos positivos (TPR) frente a la tasa de falsos positivos (FPR) en diferentes umbrales de clasificación. La curva permite visualizar el equilibrio entre la sensibilidad (TPR) y la especificidad (1 - FPR) en distintos umbrales. El área bajo la curva (AUC) cuantifica la capacidad general del modelo para distinguir entre clases positivas y negativas.
 AUC = 1: Modelo perfecto (siempre clasifica correctamente los positivos y negativos).
 AUC = 0,5: el modelo no funciona mejor que una suposición aleatoria.
 AUC < 0,5: el modelo tiene un peor rendimiento que una suposición aleatoria (lo que demuestra que el modelo está invertido).

III. RESULTADOS

La Figura 2 presenta los espectros superpuestos, donde se observa variabilidad atribuible a cambios químicos postmortem, los cuales son atribuibles a la degradación de las proteínas la cual afecta negativamente a la textura, el color y la seguridad de la carne, formando potencialmente aminas biógenas dañinas [12]. Al examinar los datos sin procesar, se observó que muchos espectros contienen ruido o características irrelevantes que no aportan información significativa, este ruido suele deberse a errores durante la adquisición del espectro, lo que genera variaciones no deseadas que complican el análisis posterior. Para mitigar estos problemas, se aplicó un filtro Savitzky-Golay (SG) para mejorar la calidad de los datos espectrales. Estos cambios son mostrados y se observa una separación visual evidente entre clases, lo que motiva el uso de modelos de aprendizaje automático.

Los espectros NIR mostraron dos picos principales alrededor de 1460 y 1920 nm, relacionados con el primer sobretono de O–H y la absorción de agua, esto puede ser representado en base a que conforme pasa el tiempo la carne de pollo empiece a deshidratarse. Asimismo, el pico a 1460 nm podría corresponder al estiramiento y deformación de CN enlace simple, C–H y NH₂ debido a la presencia de aminas, esta componente debe su presencia a posibles alteraciones de proteínas por metabolitos bacterianos responsables del deterioro de la carne, lo cual muestra que la espectroscopia NIR puede detectar estos cambios conforme pasa el tiempo de vida útil de la carne de pollo.




Fig.2 Espectros preprocesados mediante SG + SNV

El preprocesamiento empleado mejoró significativamente la claridad y la usabilidad de los datos para el modelamiento, garantizando que solo se conserve información espectral relevante y de alta calidad. Cada modelo aportó distintas ventajas al proceso de clasificación, mejorando el análisis de características espectrales complejas. Como es apreciable en la TABLA I, el modelo LASSO obtuvo el mejor desempeño global, seguido de SVM y Ridge. Random Forest presentó un comportamiento competitivo, mientras que Elastic Net obtuvo la menor precisión debido a su regularización mixta.

TABLA I
RESULTADOS COMPARATIVOS DE LOS MODELOS EVALUADOS

Modelo	Accuracy	F1-macro	ROC-AUC
LASSO	0.972	0.971	0.977
SVM-RBF	0.944	0.945	0.975
Ridge	0.944	0.943	0.95
RF	0.889	0.883	0.971
Elastic Net	0.861	0.856	0.968

Los altos valores en los indicadores de los 5 modelos evaluados motivaron el análisis posterior mediante curvas ROC y matrices de confusión para examinar el comportamiento de las predicciones entre clases.

La Figura 3 presenta, para cada uno de los cinco modelos evaluados, la matriz de confusión (columna izquierda) y la curva ROC correspondiente (columna derecha), lo que permite analizar simultáneamente el rendimiento basado en predicción categórica y en discriminación probabilística. En términos generales, todos los clasificadores superaron el 86 % de exactitud global, aunque con comportamientos diferenciales en la identificación de muestras deterioradas. La clase “Fresco” mostró tasas de acierto superiores debido a su mayor representación en el conjunto de entrenamiento, mientras que la clase “Deteriorado” concentró la mayor parte de los errores.

El modelo LASSO destacó con la mayor estabilidad, sin registrar falsos negativos en la clase deteriorada, lo que resulta crítico desde un punto de vista de inocuidad alimentaria. El SVM-RBF y Ridge mostraron patrones similares, con únicamente uno o dos errores por clase, manteniendo un equilibrio entre sensibilidad y precisión. En contraste, Random Forest presentó el mayor número de clasificaciones cruzadas, evidenciando que la inclusión de relaciones no lineales no garantiza una mejora sistemática frente a modelos lineales regularizados en dominios espectrales. Elastic Net ocupó una posición intermedia, penalizado ligeramente por la mezcla de regularizaciones L1–L2.

Las curvas ROC complementan este análisis, mostrando valores de AUC entre 0.968 y 0.977, lo que confirma una alta capacidad de discriminación independiente del umbral de decisión. Sin embargo, un análisis más detallado evidencia diferencias relevantes en términos de sensibilidad (recall) y especificidad para la detección de la clase “deteriorado”, lo cual resulta crítico desde el punto de vista de inocuidad alimentaria.

En particular, los modelos LASSO, SVM y Ridge alcanzaron una sensibilidad del 100 % (recall = 1.000) para la clase deteriorada, lo que implica ausencia de falsos negativos, es decir, ninguna muestra deteriorada fue clasificada erróneamente como fresca. En términos de precisión, estos modelos presentaron valores de 0.933 para LASSO y 0.875 para SVM y Ridge, con correspondientes valores de F1-score de 0.966 y 0.933, respectivamente, evidenciando un adecuado equilibrio entre sensibilidad y especificidad.

En contraste, Random Forest y Elastic Net mostraron una disminución en la capacidad de detección del deterioro, con sensibilidades de 0.857 en ambos casos, lo que implica la presencia de falsos negativos. Adicionalmente, sus valores de precisión fueron de 0.857 y 0.800, respectivamente, con F1-scores de 0.857 y 0.828, reflejando un menor desempeño en la discriminación efectiva de muestras deterioradas.

De esta forma, los resultados permiten afirmar que, aunque todos los modelos presentan curvas ROC cercanas al vértice óptimo (0,1), los modelos lineales regularizados (especialmente LASSO) ofrecen una ventaja significativa en términos de sensibilidad diagnóstica, minimizando el riesgo de clasificar incorrectamente muestras deterioradas como aptas para consumo. Por el contrario, los modelos no lineales presentan una ligera degradación en regiones intermedias de

probabilidad, lo que se traduce en una menor robustez en escenarios donde la prioridad es evitar falsos negativos.




Fig.3 Matriz de confusión y curvar ROC para cada modelo

IV. DISCUSIÓN

Los resultados demuestran que el modelo LASSO alcanzó una precisión del 97.2 % y un AUC de 0.977, siendo el algoritmo más eficiente para discriminar entre carne fresca (días 1–3) y deteriorada (días 4–5). Esta elevada capacidad predictiva parece asociada a su naturaleza de regresión con penalización L1, que favorece la selección automática de bandas espectrales relevantes. Resultados similares se observan en el trabajo de Xu et al.[11], quienes reportaron valores similares a los obtenidos en esta investigación en la predicción con muestras de carne, esta similitud en rendimiento puede explicarse por el uso de preprocesamiento SNV y la naturaleza global de los indicadores químicos asociados al deterioro. En ambos casos, la regularización adecuada y la selección de bandas parecen ser más determinantes que la complejidad del modelo para optimizar la discriminación espectral.

El modelo SVM con kernel radial también mostró un rendimiento sobresaliente (94.4 % de exactitud, AUC = 0.975), lo que coincide con lo reportado por Park et al. [13], quienes utilizaron dicho clasificador para determinar el estado de frescura de la carne de res, logrando una precisión del 96.57 %. En ambos casos, el kernel RBF parece haber capturado correctamente patrones no lineales entre clases que no son evidentes a simple vista en el dominio espectral. Sin embargo, la ligera superioridad de LASSO frente a SVM en este estudio se podría explicar por la menor variabilidad entre las clases evaluadas (solo dos grupos), lo cual favorece a los modelos lineales penalizados.

Por otro lado, Random Forest obtuvo la menor precisión entre los modelos no penalizados (88.9 %), lo que puede contrastarse con el éxito de modelos basados en visión por computador, como YOLOv8n_CA_DSC3, que alcanzó 95.6 % de exactitud en la clasificación de frescura de pechuga de pollo [13]. Esta diferencia se debe posiblemente a la naturaleza de los datos, es decir, las imágenes RGB capturan variaciones estructurales y de color a gran escala, mientras que los espectros NIR contienen información química más sutil que exige una selección rigurosa de variables. Así, el uso de múltiples árboles en Random Forest puede introducir ruido por redundancia espectral.

El modelo Elastic Net, que combina penalizaciones L1 y L2, presentó un rendimiento intermedio (AUC = 0.968), acorde con lo observado por Shen et al. [6], quienes destacaron la utilidad de regularización mixta ante colinealidad espectral en la predicción de indicadores bacterianos. En este caso, la penalización dual parece haber evitado el sobreajuste, aunque con un ligero sacrificio en sensibilidad en comparación con los modelos de penalización pura (como LASSO).

La evaluación conjunta mediante matrices de confusión y curvas ROC confirma una capacidad discriminativa muy alta en todos los casos, con valores AUC superiores a 0.96 para los cinco algoritmos. La ausencia de falsos negativos en la clase deteriorada en el caso de LASSO representa una ventaja

significativa desde el punto de vista de inocuidad alimentaria, asegurando que ninguna muestra en mal estado sea clasificada erróneamente como fresca. Este comportamiento coincide con lo señalado por Kim et al. [2], quienes también mejoraron la detección no destructiva mediante selección de longitudes de onda clave obteniendo coeficiente de determinación próximos a 0.80. Todo ello sugiere que el uso de espectros NIR combinado con modelos lineales penalizados puede ser una herramienta eficaz para implementar soluciones de monitoreo de calidad en la industria cárnica.

No obstante, los resultados deben interpretarse considerando ciertas limitaciones que pueden afectar la capacidad de generalización del modelo. Las muestras fueron obtenidas bajo condiciones controladas de almacenamiento (refrigeración y tiempos definidos), lo que restringe la variabilidad del sistema y no representa completamente escenarios reales donde intervienen factores como manejo postcosecha, fluctuaciones térmicas, transporte y contaminación cruzada. En este contexto, los patrones espectrales aprendidos podrían estar parcialmente condicionados por el entorno experimental. Asimismo, el uso de un único conjunto de datos y la ausencia de validación externa incrementan el riesgo de sobreajuste, especialmente en modelos con alto desempeño aparente. Por tanto, es necesario incorporar conjuntos de validación independientes y estrategias de muestreo más diversas que permitan evaluar la robustez y transferibilidad del modelo en condiciones operativas reales.

V. CONCLUSIONES

El uso de NIR (1100–2495 nm) permitió obtener una base de datos robusta con 180 espectros de carne de pollo en distintos días de almacenamiento. La exploración visual de los espectros confirmó variabilidad asociada a cambios químicos postmortem, pero sin separación evidente entre clases, lo que valida la necesidad de métodos de clasificación basados en aprendizaje automático.

El uso de modelos penalizados como LASSO y Ridge, junto con el SVM-RBF, demostró una alta capacidad para discriminar muestras frescas de deterioradas, alcanzando precisiones superiores al 94 % y valores AUC de hasta 0.977, este tipo de comportamiento han sido reportados con estos modelos en estudios en productos orgánicos [14]. En contraste, Random Forest presentó mayor confusión entre clases, lo que refuerza la utilidad de regularización para manejar colinealidad espectral.

Las curvas ROC y matrices de confusión confirmaron la eficacia del modelamiento, especialmente con LASSO, que no generó falsos negativos en la clase deteriorada. Esta característica es crítica desde la perspectiva de inocuidad alimentaria, ya que minimiza el riesgo de clasificar erróneamente productos no aptos para consumo [15]. Los resultados evidencian el potencial de integrar modelos NIR de clasificación en sistemas automatizados de monitoreo de frescura en la industria cárnica.

Los resultados demuestran que el modelamiento multivariado ofrece una alternativa viable y precisa para la detección temprana de deterioro en carne avícola, reforzando el potencial de estos sistemas como herramientas preventivas en la cadena alimentaria.

Las investigaciones futuras deben evaluar técnicas avanzadas de preprocesamiento e investigar nuevos modelos de aprendizaje para mejorar aún más la robustez del modelo y el rendimiento predictivo.

REFERENCES

- [1] H. Qi et al., «Comparative analysis of meat quality and flavor compounds in hot fresh, chilled, and frozen Qingyuan partridge chicken», *Applied Food Research*, vol. 5, n.o 2, p. 101216, dic. 2025, doi: 10.1016/j.afres.2025.101216.
- [2] H.-J. Kim, J. Ryu, G. Kim, y C. Jo, «Enhancement of non-destructive chicken freshness prediction using Vis/NIR spectroscopy through wavelength selection and data augmentation», *LWT*, vol. 221, p. 117602, abr. 2025, doi: 10.1016/j.lwt.2025.117602.
- [3] T. Chuquizuta et al., «Dielectric spectroscopy for the prediction of pork quality during the post-mortem time», *Journal of Food Composition and Analysis*, vol. 148, p. 108128, dic. 2025, doi: 10.1016/j.jfca.2025.108128.
- [4] K. G. Panchbhai y M. G. Lanjewar, «Portable and efficient chicken authentication: multi-scenario approach using NIR spectroscopy and advanced machine learning», *Food and Humanity*, vol. 5, p. 100831, dic. 2025, doi: 10.1016/j.foohum.2025.100831.
- [5] Y. Liu et al., «Rapid detection of microplastics in chicken feed based on near infrared spectroscopy and machine learning algorithm», *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy*, vol. 329, p. 125617, mar. 2025, doi: 10.1016/j.saa.2024.125617.
- [6] X. Shen, L. Xing, L. Pan, Y. Miao, y W. Zhang, «Prediction of chicken breast meat freshness based on hyperspectral imaging technique and high-throughput sequencing», *Poultry Science*, vol. 104, n.o 4, p. 104999, abr. 2025, doi: 10.1016/j.psj.2025.104999.
- [7] S. Park, S.-J. Hong, S. Kim, J. Ryu, S. Roh, y G. Kim, «Classification of Fresh and Frozen-Thawed Beef Using a Hyperspectral Imaging Sensor and Machine Learning», *Agriculture*, vol. 13, n.o 4, p. 918, abr. 2023, doi: 10.3390/agriculture13040918.
- [8] F. Pennisi et al., «Efficiency of NIR spectroscopy and chemometrics to assess mislabeling of fish fillets», *Journal of Food Composition and Analysis*, vol. 149, p. 108630, ene. 2026, doi: 10.1016/j.jfca.2025.108630.
- [9] S. A. Farenzena et al., «Eco-efficient quantification of creatinine in chicken burgers using digital imaging, NIR spectroscopy, and data-driven modeling», *Microchemical Journal*, vol. 219, p. 116205, dic. 2025, doi: 10.1016/j.microc.2025.116205.
- [10] H.-J. Kim, J. Ryu, G. Kim, y C. Jo, «Enhancement of non-destructive chicken freshness prediction using Vis/NIR spectroscopy through wavelength selection and data augmentation», *LWT*, vol. 221, p. 117602, abr. 2025, doi: 10.1016/j.lwt.2025.117602.
- [11] Z. Xu et al., «Research on non-destructive detection of chilled meat quality based on hyperspectral technology combined with different data processing methods», *Front. Nutr.*, vol. 12, jul. 2025, doi: 10.3389/fnut.2025.1623671.
- [12] S. Liu et al., «Construction of a rapid evaluation method for fermentation degree of low-fat fermented sour chicken meat based on Raman spectroscopy technology», *Food Control*, vol. 178, p. 111487, dic. 2025, doi: 10.1016/j.foodcont.2025.111487.
- [13] S. Park, S.-J. Hong, S. Kim, J. Ryu, S. Roh, y G. Kim, «Classification of Fresh and Frozen-Thawed Beef Using a Hyperspectral Imaging Sensor and Machine Learning», *Agriculture*, vol. 13, n.o 4, p. 918, abr. 2023, doi: 10.3390/agriculture13040918.
- [14] C. Wang, X. Zhang, N. Zhang, H. Guo, H. Wu, y X. Wang, «Optimizing the estimation of cotton leaf SPAD and LAI values via UAV multispectral imagery and LASSO regression», *Smart Agricultural Technology*, vol. 12, p. 101098, dic. 2025, doi: 10.1016/j.atech.2025.101098.
- [15] W. Castro, J. Oblitas, L. Nuñez, I. Yoplac, H. Avila-George, y M. De-la-Torre, «Adulterant estimation in paprika powder using deep learning and chemometrics through near-infrared spectroscopy», *Neural Comput. Appl.*, vol. 36, n.o 23, pp. 14263-14273, ago. 2024, doi: 10.1007/s00521-024-09830-8.