

Identificación de Adulteraciones en Quesos Rallados de Pasta Dura utilizando Análisis de Imágenes

Jorge I. Lopez Perez¹[0000-0001-7132-676X] y Lucas G. Visconti²[0000-0002-9579-6448]

¹ Universidad Nacional Del Sur, Instituto de Ciencias e Ingeniería de la Computación - ICIC (UNS-CONICET), Av. Alem 1253 (B8000CPB), Bahía Blanca, Buenos Aires, Argentina.

² Universidad Nacional Del Sur, Departamento de Química, INQUISUR (UNS-CONICET), Av. Alem 1253 (B8000CPB), Bahía Blanca, Buenos Aires, Argentina.
jorgeivanl620@gmail.com

Abstract. La adulteración de quesos rallados de pasta dura genera inquietudes en torno a la calidad y el valor nutricional de estos productos, planteando potenciales riesgos para la salud pública. Ante este desafío, se requiere un método eficaz que permita identificar aditivos y determinar su concentración, sin comprometer las propiedades organolépticas del producto. El análisis por imágenes se presenta como una alternativa rápida y económica para asegurar la autenticidad y calidad de los productos lácteos, al mismo tiempo que fomenta la transparencia en la industria alimentaria. En este estudio se presenta una implementación innovadora que combina una red neuronal convolucional pre entrenada, VGG16, con un regresor XGBoost para estimar el porcentaje de adulterante presente en quesos rallados. Esta metodología ofrece una evaluación precisa y confiable de la calidad y autenticidad de los productos lácteos. Los resultados obtenidos destacan la eficacia de este enfoque para abordar la adulteración en alimentos y fortalecer la seguridad alimentaria. Mediante el uso de técnicas avanzadas de análisis de datos y aprendizaje automático, este método proporciona una herramienta valiosa para la detección temprana de prácticas fraudulentas en la industria láctea, contribuyendo así a proteger la salud pública y garantizar la calidad de los alimentos para los consumidores.

Keywords: Adulteración de alimentos, Quesos rallados, Análisis por imágenes, Red neuronal convolucional, Aprendizaje automático, Seguridad alimentaria.

1 Introducción

En el complejo entorno de la industria alimentaria contemporánea, la preservación de la calidad y salubridad de los productos es un componente primordial para cultivar la confianza del consumidor y proteger la integridad de los alimentos. Sin embargo, en un escenario marcado por la globalización y el aumento de la demanda, la proliferación de prácticas fraudulentas y de adulteración se presenta como un desafío de gran relevancia[1]. En este contexto, la precisa detección de la presencia y la cuantificación de adul-

terantes en distintas variedades de quesos adquiere un protagonismo vital, dada su incidencia directa en la seguridad y calidad de estos productos lácteos de amplio consumo[2,3].

El queso, sin lugar a duda, ocupa un lugar central en la mesa de millones de consumidores alrededor del mundo, siendo apreciado en una diversidad de formas y presentaciones, entre ellas, el queso rallado, cuya versatilidad y conveniencia lo hacen particularmente popular en el ámbito culinario. Sin embargo, el paradigma se transforma cuando se considera la posibilidad de que estos quesos rallados alberguen adulterantes, como la micro celulosa (C), viruta de madera (VM) y el dióxido de silicio (D), cuya presencia puede comprometer no solo la calidad organoléptica, sino también la autenticidad y, en última instancia, la confianza del consumidor en el producto final. La legislación alimentaria argentina, la normativa europea y la Administración de Alimentos y Medicamentos (FDA) de Estados Unidos permiten el uso de dióxido de silicio en diferentes niveles: Argentina hasta un 0.5%[4], Europa hasta un 1.0%[5] y Estados Unidos hasta un 2.0%[6]. Además, la FDA[7] autoriza el uso de celulosa de acuerdo con las buenas prácticas de fabricación (GMP) y dióxido de silicio hasta un máximo del 1.0%. Expertos en quesos han determinado que el uso de celulosa en niveles entre el 1 y el 4% es suficiente para lograr el efecto funcional como agente anti aglomerante[8]. De ahí la imperiosa necesidad de detectar y cuantificar con precisión la cantidad de estos adulterantes en los quesos rallados, una tarea de vital importancia para salvaguardar su seguridad alimentaria y su idoneidad nutricional[9].

En respuesta a este desafío, el ámbito de la ciencia y la tecnología de los alimentos ha visto surgir la implementación de técnicas avanzadas de análisis de datos y aprendizaje automático como una estrategia prometedora para abordar el problema de la adulteración en los alimentos[10]. En particular, la sinergia entre el uso de una red neuronal convolucional pre entrenada, como VGG16[11], y un regresor XGBoost[12], ha emergido como un enfoque innovador y potente para detectar y cuantificar la presencia de adulterantes en diferentes tipos de quesos rallados.

Este enfoque se sustenta en la capacidad de la red neuronal convolucional para extraer características relevantes de las imágenes de los quesos, gracias a su capacidad para capturar patrones complejos y discriminativos en los datos visuales. Por su parte, el regresor XGBoost[13] se encarga de realizar una estimación precisa del porcentaje de adulterante presente en las muestras, aprovechando su capacidad para modelar relaciones no lineales y capturar estructuras complejas en los datos. La combinación de ambos enfoques permite superar las limitaciones individuales de cada método y lograr una detección y cuantificación confiable de adulterantes en los quesos rallados, allanando el camino hacia la mejora de los estándares de calidad y seguridad alimentaria.

En este contexto, el presente estudio se propone como objetivo principal evaluar la viabilidad y eficacia de esta metodología combinada para detectar y cuantificar la presencia de adulterante en distintas clases de quesos rallados, utilizando únicamente cámaras RGB. Al proporcionar una herramienta precisa y eficiente para la evaluación de

la calidad de los quesos rallados, esta investigación contribuirá significativamente a fortalecer la seguridad alimentaria y la confianza a lo largo de la cadena de comercialización en la industria láctea, sin requerir equipamiento adicional o costosos análisis, sentando las bases para futuros avances en el campo de la detección y prevención de la adulteración en alimentos.

2 Materiales y métodos

2.1 Adquisición de las imágenes

Se capturaron imágenes utilizando un dispositivo compuesto por una estructura metálica equipada con un soporte para una cámara digital portátil. Este dispositivo estaba conectado a seis fuentes de iluminación, incluyendo lámparas fluorescentes, halógenas, incandescentes, y luces LED tanto frías como cálidas. Para garantizar una iluminación uniforme, el dispositivo fue recubierto con etilvinilacetato blanco para reducir la dispersión de la luz, y las lámparas fueron colocadas estratégicamente para lograr una luminosidad homogénea[10].

Se emplearon imágenes de alta resolución de 3888x3888 píxeles y tres canales RGB en este estudio. Estas imágenes capturaron diferentes variantes de queso rallado, con una de ellas representando el queso sin adulterar y las demás mostrando el queso con diferentes concentraciones de viruta de madera, dióxido de silicio y microcelulosa que variaban entre el 3% hasta el 12%, como se puede observar en la **Tabla 1**. La viruta de madera se recolectó de diversos aserraderos ubicados en la provincia de Misiones, Argentina, seleccionados específicamente por sus propiedades especiales en textura y color, que podrían afectar la detección de adulterantes[10].

Tabla 1. Tabla con los niveles de concentración usados para adulterar las muestras.

Clases	Tipo de muestra	% De adulteración
1	Original	0
2	Microcelulosa	5, 7, 10, 12
3	Dióxido de silicio	3, 5, 6, 7
4	Viruta de madera	3, 4, 5, 6

2.2 Preprocesamiento de los datos

Para analizar estas imágenes de manera más detallada, se aplicó una técnica de división. Esta técnica permitió generar a partir de cada imagen de 3888x3888 píxeles, generar nuevas imágenes de 224x224 píxeles con un traslape de 112 píxeles entre ellas. Este enfoque permitió obtener una gran cantidad de muestras de cada imagen, lo que facilitó

un análisis exhaustivo de la presencia y concentración de adulterantes en el queso rallado.

En total, se generaron 1089 muestras para cada imagen, tanto para las que no presentaban adulteración como para aquellas que exhibían diferentes niveles de adulteración. Este proceso aseguró una representación significativa de cada variante de queso rallado, lo que permitió una evaluación precisa de su composición y autenticidad. La **Fig.1**, proporciona una representación visual de cómo se dividieron las imágenes en parches y cómo se distribuyeron las muestras resultantes para su análisis detallado.

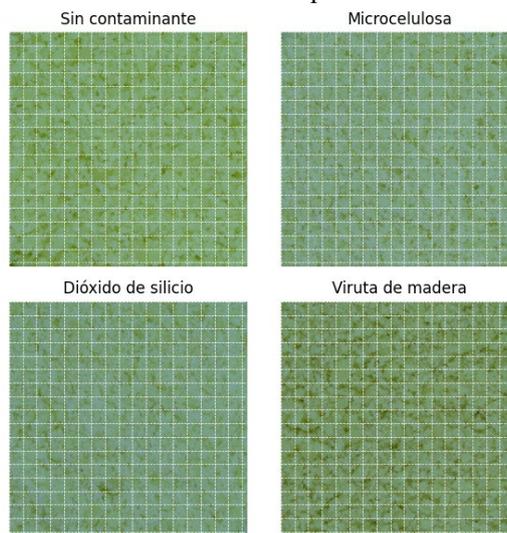


Fig. 1. Ejemplo del resultado de dividir las imágenes en parches de 224x224

Una vez recopiladas las muestras, se llevó a cabo un análisis exhaustivo para asegurar que las imágenes obtenidas fueran adecuadas para su procesamiento mediante la red VGG16. Este análisis incluyó la revisión y el ajuste de parámetros técnicos para optimizar la calidad y la relevancia de las imágenes, garantizando así resultados precisos y fiables en la fase de procesamiento y comparación[14].

Este estudio asegura un tratamiento equitativo y una comparación justa entre todas las muestras de queso rallado. Esto incluye tanto las muestras originales como las adulteradas, permitiendo evaluar de manera precisa y confiable las diferencias y similitudes entre ellas[15]. Esto es crucial para evitar sesgos en el análisis y garantizar la validez de los resultados obtenidos. Una vez los datos están listos para ser sometidos a análisis más avanzados, como la extracción de características y la modelización predictiva.

2.3 Transferencia de aprendizaje y regresión.

Después de haber generado los parches resultantes para cada tipo de queso con adulteración, se procedió a utilizarlos como datos de entrada para una red neuronal convolucional pre entrenada conocida como VGG16. Esta red ha sido previamente entrenada

utilizando el amplio conjunto de datos de ImageNet, lo que le ha permitido aprender características visuales complejas y generalizables. En nuestro enfoque, los parches obtenidos de cada variante de queso con adulteración se suministrarán como entrada a esta red VGG16[16]. Cada parche servirá como una instancia única para el aprendizaje de la red, permitiendo que capture las características relevantes de cada porción de la imagen de manera individual. Una vez que los parches se introducen en la red VGG16, se procesan a través de múltiples capas convolucionales y de pooling, lo que permite extraer y representar características visuales complejas de manera jerárquica. Estas características aprendidas en las capas convolucionales de la red se utilizan como entrada para un modelo de regresión XGBoost, que se implementa en la capa final de la red Fig. 2.

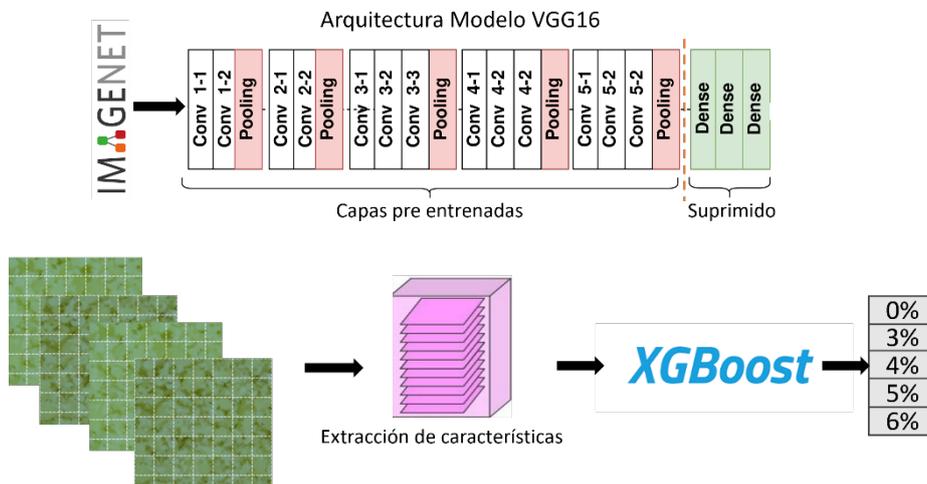


Fig. 2. Imagen ilustrativa de la adaptación de la arquitectura VGG16 para la extracción de características para el modelo de regresión.

El modelo de regresión XGBoost se encargará de predecir el valor en porcentaje del adulterante presente en el queso. Utilizando las características extraídas por la red VGG16 como vectores de características, el modelo de regresión XGBoost aprenderá a relacionar estas representaciones visuales con la cantidad de adulterante presente en cada muestra de queso.

Este enfoque integrado aprovecha la capacidad de las redes neuronales convolucionales pre-entrenadas para extraer características visuales relevantes de las imágenes de queso, mientras que el modelo de regresión XGBoost aprovecha estas características para realizar predicciones precisas sobre el contenido de adulterante en cada muestra. En conjunto, este enfoque ofrece una metodología sólida y efectiva para la detección y cuantificación del adulterante en quesos rallados.

3 Resultados

Los resultados del estudio demuestran una variabilidad en el desempeño del modelo de predicción del porcentaje de adulterantes en quesos rallados, dependiendo del tipo de adulterante considerado. El modelo fue entrenado en una laptop equipada con un procesador Intel(R) Core (TM) i7-9750H CPU @ 2.60GHz, con 16GB de RAM y una tarjeta gráfica RTX 2070 HQ y garantizar una evaluación adecuada y prevenir el sobreajuste, se dividió el conjunto de datos en conjuntos de entrenamiento (80%), prueba (20%) y validación (10%).

Para la viruta de madera, el modelo mostró un desempeño superior con un coeficiente de determinación (R^2) de 0.8101. Este valor indica que el modelo pudo explicar el 81.01% de la variabilidad en los datos de contenido de adulterante. Además, el error absoluto medio (MAE) y la raíz del error cuadrático medio (RMSE) fueron de 0.7164 y 0.8972, respectivamente. Estos valores sugieren una baja desviación entre las predicciones del modelo y los valores reales, evidenciando una alta precisión en la estimación del contenido de viruta de madera.

En contraste, para el dióxido de silicio, el desempeño del modelo fue ligeramente inferior, con un R^2 de 0.7909. Aunque este valor sigue siendo significativo, el aumento en el MAE a 0.8757 y el RMSE a 1.1348 señala una mayor variabilidad en las predicciones y una ligera desviación respecto a los valores reales. Esto indica que, aunque el modelo sigue siendo efectivo, su precisión es menor en comparación con la viruta de madera.

Finalmente, para la microcelulosa, el modelo mostró el rendimiento más bajo con un R^2 de 0.7605. En este caso, tanto el MAE como el RMSE fueron significativamente mayores, con valores de 1.6004 y 2.0384, respectivamente. Estos resultados sugieren una notable discrepancia entre las predicciones del modelo y los valores reales, así como una mayor variabilidad en los datos, indicando que el modelo es menos efectivo para predecir el contenido de microcelulosa en el queso rallado.

En resumen, aunque el modelo muestra una buena capacidad de predicción en general, su precisión varía significativamente según el tipo de adulterante, siendo más eficaz para la viruta de madera y menos para la microcelulosa. En la **Tabla 2**, se puede observar un resumen de las métricas usadas para evaluar el rendimiento del modelo.

Table 2. Resumen de las métricas usadas para evaluar el rendimiento del modelo.

Clases	Tipo de muestra	R^2	MAE	RMSE
1	Microcelulosa	0.7605	1.6004	2.0384
2	Dióxido de silicio	0.7909	0.8757	1.1348
3	Viruta de madera	0.8101	0.7164	0.8972

Se llevó a cabo un análisis detallado del comportamiento de cada uno de los contaminantes en relación con su concentración, como se muestra en la **Figura 3**. Los resulta-

dos revelan que el modelo es capaz de discernir entre diferentes niveles de concentración de adulterante, aunque muestra cierta confusión en algunos casos particulares. Específicamente, la detección de la concentración de microcelulosa, dada su naturaleza, se presenta como un desafío para el modelo, ya que tiende a pasar desapercibida debido a sus propiedades. Sin embargo, estos hallazgos han motivado la exploración de métodos alternativos para detectar adulterantes con propiedades de microcristalinidad. A pesar de la dificultad inicial, los resultados sugieren que es posible mejorar la capacidad de detección del modelo mediante la implementación de enfoques adicionales o la optimización del método actual. Este mismo análisis se extiende a las otras dos concentraciones de adulterantes evaluados. Se observa que el modelo tiene un desempeño relativamente mejor en la predicción de la viruta de madera y el dióxido de silicio en comparación con la microcelulosa, lo que resalta la capacidad del modelo para distinguir entre diferentes concentraciones de adulterantes con distintas propiedades físicas.

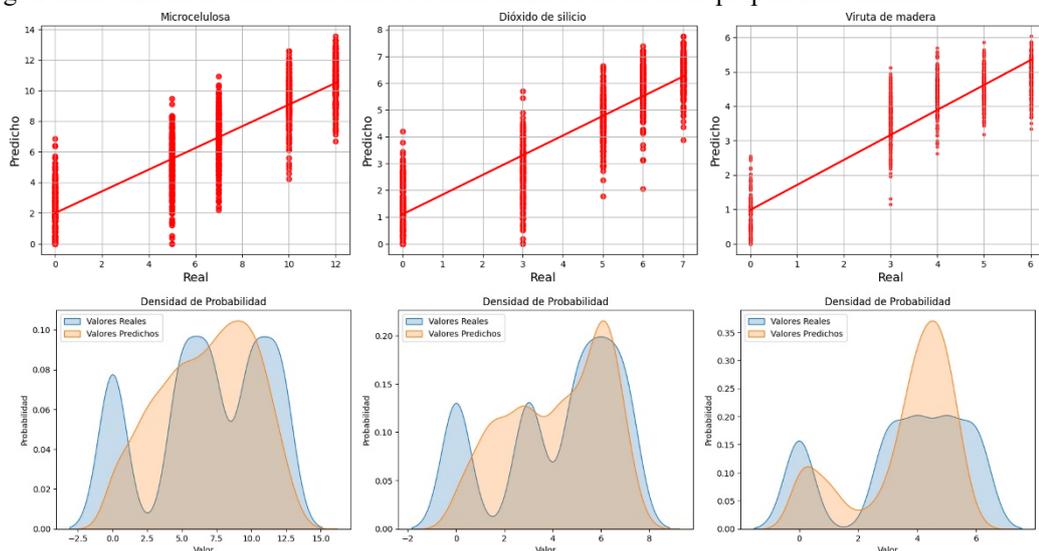


Fig. 3. Resultados obtenidos para cada tipo de adulterante.

4 Discusión

Los resultados obtenidos en este estudio proporcionan una visión valiosa sobre la capacidad del modelo para detectar y cuantificar contaminantes en quesos rallados de pasta dura. Al analizar detalladamente el comportamiento de cada contaminante en relación con su concentración, observamos que el modelo muestra una capacidad general para distinguir entre diferentes niveles de adulteración. Sin embargo, también identificamos ciertas limitaciones y desafíos que deben abordarse.

En particular, encontramos que la detección de la microcelulosa, un adulterante con propiedades que pueden hacerlo pasar desapercibido para el modelo, presenta dificultades significativas. Aunque el modelo puede detectar algunos niveles de microcelulosa, su capacidad para predecir con precisión la concentración de este contaminante es limitada. Este hallazgo resalta la necesidad de explorar métodos alternativos o mejorar el enfoque actual para mejorar la detección de la microcelulosa y otros adulterantes con propiedades similares.

Por otro lado, nuestros resultados también indican que el modelo tiene un mejor desempeño en la detección de otros contaminantes, como la viruta de madera. Este resultado sugiere que el modelo es más sensible a ciertos tipos de adulterantes en comparación con otros, lo que puede estar relacionado con las características físicas y químicas específicas de cada contaminante.

Es importante destacar que este estudio proporciona una base sólida para futuras investigaciones en este campo. Se necesitan esfuerzos adicionales para mejorar la precisión y la capacidad de detección del modelo, especialmente en lo que respecta a la microcelulosa y otros adulterantes difíciles de detectar. Además, se pueden explorar enfoques adicionales, como el uso de diferentes modelos de aprendizaje automático o la integración de técnicas avanzadas de procesamiento de imágenes, para mejorar la capacidad del modelo para identificar y cuantificar con precisión los contaminantes en los quesos rallados.

5 Conclusiones

En resumen, este estudio ofrece la capacidad del modelo para determinar la concentración contaminante en quesos rallados de pasta dura. Si bien hemos observado que el modelo demuestra una capacidad general para diferenciar entre diversos niveles de adulteración, nos enfrentamos a desafíos considerables en la detección precisa de ciertos contaminantes, como la microcelulosa. La dificultad para determinar la concentración para este tipo de adulterante resalta la necesidad de explorar métodos alternativos o mejorar el enfoque actual para abordar esta limitación específica. Sin embargo, estos resultados también revelan que el modelo exhibe un mejor desempeño en la detección de otros contaminantes, como la viruta de madera y el dióxido de silicio. Este descubrimiento sugiere que el modelo es más sensible a ciertos tipos de adulterantes, lo que podría estar relacionado con sus características particulares.

Estos hallazgos tienen implicaciones significativas para la detección de adulterantes en productos lácteos, subrayando la importancia de seguir investigando y desarrollando enfoques más efectivos para garantizar la seguridad y la calidad alimentaria. Se recomienda explorar métodos adicionales, como la implementación de diferentes modelos de aprendizaje automático o la integración de técnicas avanzadas de procesamiento de

imágenes, con el fin de mejorar la precisión y la capacidad de detección del modelo en futuros estudios.

En conjunto, este estudio contribuye al avance en la detección de adulterantes en alimentos y proporciona una base sólida para futuras investigaciones en este campo en constante evolución. Además de esto queda demostrado que a pesar de que la arquitectura de la VGG16 es un poco antigua aun puede dar resultados satisfactorios para diferentes aplicaciones.

Referencias

1. Codex Alimentarius Commission. (2018). Discussion paper on food integrity and food authenticity. Codex Committee on Food Import and Export Inspection and Certification Systems (CCFICS). FAO/WHO: CX/FICS18/24/7.
2. Spink, J. (2018). Food fraud and adulteration: Where we stand today. En: Melton, L., Shahidi, F., & Varelis, P. (Eds.), *Encyclopedia of food chemistry* (Vol. 1, pp. 657-662). Oxford, UK: Elsevier.
3. Stadler, R. H. (2019). Introduction to the volume: Food adulteration & contamination. In L. Melton, F. Shahidi, & P. Varelis (Eds.), *Encyclopedia of food chemistry* (pp. 317e319). Oxford, UK: Academic Press.
4. EU. (2011). Commission regulation 1129/2011. Retrieved from https://eur-lex.europa.eu/legalcontent/EN/TXT/PDF/?uri=CELEX:32011R1129&from=EN_L295/1-177. (Consultado el 2 Abril 2024).
5. Código Alimentario Argentino. (2006). Capítulo VIII: Alimentos Lácteos. Administración Nacional de Alimentos, Medicamentos y Tecnología Médica. Retrieved from <https://www.argentina.gob.ar/anmat/codigoalimentario>. (Consultado el 4 Abril 2024).
6. Codex Alimentarius. (2018). General standard for cheese: Codex stan 283-1978 (Adopted in 1973, amended in 2018). Codex Alimentarius Commission, joint FAO/WHO food standards program. Retrieved from <https://www.fao.org/fao-who-codexalimentarius/codex-texts/list-standards/es/>. (Consultado el 4 Abril 2024).
7. FDA. (2018). Food additive status list. In *Code of Federal Regulations (CFR)*. Washington, DC, USA: Food and Drug Administration. Retrieved from <https://www.fda.gov/Food/IngredientsPackagingLabeling/FoodAdditivesIngredients/ucm091048.htm>. (Consultado el 4 Abril 2024).
8. Cheese Reporter. (2008). Cellulose: Anti-caking suppliers clear up inaccuracies regarding appropriate levels of cellulose. *Cheese Reporter*. Retrieved from <http://www.cheesereporter.com/cellulose.htm>. (Consultado 2 Abril 2024).
9. Chamlee, V. (2017). The real problem with wood pulp in cheese. *Eater*. Retrieved from <https://www.eater.com/2016/3/3/11153876/cheese-wood-pulp-cellulose-lawsuits>. (Consultado el 2 Abril 2024).
10. Visconti, L.G., Martínez Vargas, S., Rodríguez, M.S., Di Anibal, C.V., & Delrieux, C. Determination of grated hard cheese adulteration by digital image analysis and multivariate analysis. *Journal of Food Science and Technology*. (2024).
11. Fan, Yiming, Jinqi Yang, Kun Han, Jun Lin and Jingyi Jia. "VGG-16 Image Recognition Model Based on Band-stop Convolution Filter Preprocessing," *2023 8th International Conference on Intelligent Computing and Signal Processing (ICSP)* (2023): 1685-1690.

12. Chen, Tianqi and Carlos Guestrin. "XGBoost : Reliable Large-scale Tree Boosting System." (2015).
13. Zhang P, Jia Y, Shang Y. Research and application of XGBoost in imbalanced data. *International Journal of Distributed Sensor Networks*. (2022).
14. Marcin K, Michał S, Rafał O, Does image normalization and intensity resolution impact texture classification? *Computerized Medical Imaging and Graphics* (2020).
15. G. Kumar and P. K. Bhatia, "A Detailed Review of Feature Extraction in Image Processing Systems," *2014 Fourth International Conference on Advanced Computing & Communication Technologies*, Rohtak, India, (2014). pp. 5-12.
16. Srikanth Tammina. Transfer learning using VGG-16 with Deep Convolutional Neural Network for Classifying Images; *International Journal of Scientific and Research Publications* (2019). (ISSN: 2250-3153).