

Development of a System for Classification of Rice Grains Using Convolutional Neural Networks

Josue Montenegro Herrera¹; Diego Peláez Carrillo¹; José Santiago Guevara¹

^{1,2,3}Universidad de Pamplona, Colombia, josue.montenegro@unipamplona.edu.co, diego.pelaez@unipamplona.edu.co, josesantiago@unipamplona.edu.co

Abstract– The growing demand for quality in the rice industry has driven innovative solutions for classifying rice varieties, preventing mixtures that impact the final product. This study introduces a convolutional neural network (CNN) for automatic rice grain classification using digital images. A dataset of 75,000 images, divided into five categories ('Ipsala,' 'Arborio,' 'Jasmine,' 'Karacadag,' and 'Basmati'), was used. The model was trained with 80% of the data (56,000 images) and validated with the remaining 20% (14,000 images), using 5,000 new images for final evaluation. The CNN achieved 99.2% accuracy, demonstrating high performance even among visually similar varieties. This approach modernizes traditional methods, improving efficiency and ensuring higher-quality products in the Colombian rice industry.

Keywords-- Classification, CNN, image processing, rice varieties, product quality.

Desarrollo de un Sistema para Clasificación de Granos de Arroz Usando Redes Neuronales Convolucionales

Josue Montenegro Herrera¹; Diego Peláez Carrillo¹; José Santiago Guevara¹

^{1,2,3}Universidad de Pamplona, Colombia, josue.montenegro@unipamplona.edu.co, diego.pelaez@unipamplona.edu.co, josesantiago@unipamplona.edu.co

Resumen– La creciente demanda de calidad en la industria arrocera ha impulsado soluciones innovadoras para clasificar variedades de arroz, evitando mezclas que afectan el producto final. Este estudio presenta una red neuronal convolucional (CNN) para la clasificación automática de granos de arroz mediante imágenes digitales. Se utilizó un conjunto de datos de 75,000 imágenes divididas en cinco categorías: 'Ipsala', 'Arborio', 'Jasmine', 'Karacadag' y 'Basmati'. El modelo se entrenó con el 80% de los datos (56,000 imágenes) y validó con el 20% restante (14,000 imágenes), evaluándose con 5,000 imágenes nuevas. La CNN alcanzó una precisión del 99.2%, mostrando alta capacidad incluso entre variedades similares. Este enfoque moderniza los métodos tradicionales, mejorando la eficiencia y garantizando productos de mayor calidad en la industria arrocera colombiana

Palabras clave– Clasificación, CNN, procesamiento de imágenes, variedades de arroz, calidad del producto.

I. INTRODUCCIÓN

La industria arrocera es un sector crucial a nivel global, proporcionando alimento básico a millones de personas y generando ingresos significativos en muchas economías, especialmente en países en desarrollo. Sin embargo, esta industria enfrenta desafíos importantes, como la mezcla no intencionada de granos de arroz de diferentes variedades durante el proceso de empaque. Este problema no solo afecta la calidad del producto, sino que también impacta negativamente en la satisfacción del consumidor. Según un informe de [1], la mezcla de variedades puede causar inconsistencias en el sabor y el tiempo de cocción, lo que disminuye la confianza del consumidor en los productos ofrecidos.

A pesar de que la clasificación manual sigue siendo el método predominante, este enfoque resulta ineficiente y propenso a errores humanos, lo que se convierte en una limitante crítica dada la alta producción diaria de arroz [2][3]. Además, se ha demostrado que las tecnologías avanzadas, como las máquinas de clasificación automatizadas que utilizan cámaras y sensores, pueden mejorar significativamente tanto la eficiencia como la calidad del proceso [4][5]. Por ejemplo, el uso de sistemas expertos para clasificar la calidad de granos de

arroz mediante procesamiento de imágenes ha mostrado resultados prometedores [6][7].

La necesidad de resolver este problema es evidente: los consumidores frecuentemente reciben productos inconsistentes que no cumplen con sus expectativas, lo que resulta en pérdidas económicas para los productores y una disminución en la satisfacción del cliente. La falta de tecnologías avanzadas para automatizar el proceso de clasificación limita la capacidad de la industria para satisfacer las demandas del mercado actual [8]. Además, un estudio reciente sobre el efecto del calentamiento climático en la calidad del grano de arroz menciona que las condiciones ambientales afectan directamente la calidad del arroz, agravando aún más este problema [9].

Este estudio propone una solución tecnológica innovadora basada en deep learning, utilizando un modelo de red neuronal convolucional (CNN) para realizar una clasificación multiclase supervisada de granos de arroz [10][11]. El objetivo principal es analizar imágenes de granos de arroz y clasificarlos automáticamente según su tipo, maximizando así la precisión en la identificación de las clases. Los objetivos específicos incluyen reducir los costos operativos y aumentar la eficiencia del proceso de clasificación [12].

Con un enfoque centrado en la innovación tecnológica y respaldado por una base de datos robusta, este proyecto busca transformar la industria arrocera colombiana. La implementación de un sistema automatizado no solo contribuirá a satisfacer las demandas actuales del mercado en términos de calidad, sino que también posicionará a los productores locales en un nivel competitivo a nivel global

II. ESTADO DEL ARTE

La clasificación de granos de arroz ha experimentado avances significativos en los últimos años, impulsada por la implementación de técnicas avanzadas como el aprendizaje automático y la inteligencia artificial. En este contexto, [13]

llevaron a cabo un estudio comparativo de arquitecturas avanzadas de aprendizaje profundo para la clasificación automatizada de granos de arroz. Evaluando modelos contemporáneos como Residual Network (ResNet) y EfficientNet, encontraron que el modelo basado en EfficientNet logró una precisión impresionante del 99.67%, mejorando así el control de calidad en la producción y optimizando costos para productores y comerciantes. Asimismo, [14] aplicó diferentes técnicas de aprendizaje automático en la clasificación de variedades de arroz, mostrando que la regresión logística alcanzó una precisión media del 93.02%, superando a otros modelos como SVM y Random Forest, lo que resalta la aplicabilidad del aprendizaje automático en entornos complejos. Por otro lado, [15] desarrolló una aplicación web que utiliza inteligencia artificial para clasificar la calidad del arroz en un molino en Ferreñafe, Perú, logrando una precisión del 99.08% mediante redes neuronales tras aplicar validación cruzada, lo que mejora la eficiencia del proceso y garantiza una evaluación más precisa del valor comercial del producto. Además, [16] realizaron un estudio que aplicó métodos de aprendizaje profundo para la clasificación de variedades de arroz, logrando superar las técnicas tradicionales con una alta tasa de precisión y destacando el potencial del aprendizaje profundo para optimizar el proceso de clasificación. En línea con esto, [17] exploraron diversas técnicas de inteligencia artificial para la clasificación de variedades de arroz, analizando varios algoritmos como redes neuronales y máquinas de soporte vectorial (SVM), mostrando que estas metodologías mejoran la precisión y eficiencia en comparación con los métodos tradicionales. Asimismo, [18] abordaron la necesidad urgente en la cría del arroz para equilibrar el rendimiento con la calidad culinaria mediante modelos como Random Forest y Redes Neuronales Artificiales, obteniendo precisiones del 63.9% para Random Forest y 69.4% para ambos modelos SVM y ANN al evaluar parámetros rutinarios como textura y propiedades estructurales del almidón. Por otro lado, [19] presentaron un método innovador para detectar e identificar defectos visibles en granos pulidos utilizando un sistema experto basado en visión artificial, mostrando resultados coincidentes con las evaluaciones manuales realizadas por expertos y destacando su capacidad para identificar defectos comunes que afectan la calidad del arroz. Finalmente, [20] propusieron una metodología utilizando procesamiento de imágenes y clasificación basada en representación escasa (SRC) para distinguir entre 30 variedades diferentes de arroz, logrando identificar características morfológicas y texturales con una precisión del 89.1%, lo que demuestra cómo el análisis basado en imágenes puede facilitar la identificación no destructiva y eficiente. En conjunto, estas investigaciones evidencian el potencial significativo del uso de técnicas avanzadas como el aprendizaje automático y el aprendizaje profundo para mejorar la clasificación y evaluación cualitativa del arroz, aumentando tanto la precisión como la eficiencia del proceso, lo que contribuye a la modernización y competitividad del sector arrocero colombiano en el mercado global.

III. METODOLOGIA

Para el estudio actual se seleccionaron las redes neuronales convolucionales como una potencial solución a la problemática planteada. Teniendo en cuenta su superioridad demostrada en la tarea de clasificación de imágenes, si las comparamos con métodos tradicionales o con otros algoritmos de aprendizaje automático [1]. Por ejemplo, usando técnicas como el análisis de color o textura utilizando filtros, es necesario extraer las características de manera manual, lo que conlleva a introducir sesgos que no permiten generalizar o encontrar patrones [2], [3]. Si se utilizan métodos estadísticos como regresión logística o random forest, dependemos de características ya predefinidas y son menos eficaces si se presentan cambios de iluminación u orientación [4], [5]. Si nos referimos a otras arquitecturas de Deep learning podemos cometer errores como desconocer la estructura espacial de las imágenes y caer también en el error de sobreajuste [6], [7].

Las CNN reducen todos los errores anteriormente descritos al reducir los parámetros a través de las diferentes capas convolucionales, además tienen las ventajas de ser invariante a transformaciones de traslación y rotación gracias a las capas pooling y finalmente las CNN automatizan el aprendizaje de características como bordes, texturas y diferentes patrones complejos, lo que ayuda a mejorar la precisión [8], [9].

A. Conjunto de Datos

En este estudio se utilizó el Rice Images Dataset, disponible en la plataforma Kaggle y desarrollado por [21]. Este conjunto de datos es ampliamente reconocido por su calidad y diversidad, lo que lo convierte en una opción ideal para tareas de clasificación automática de granos de arroz. La elección de este dataset permite comparar los resultados obtenidos con estudios previos que han utilizado la misma fuente, facilitando así una evaluación objetiva del desempeño del modelo propuesto.

El dataset consta de un total de 75,000 imágenes, originalmente en formato RGB y con una resolución de 250x250 píxeles. Para simplificar el procesamiento y reducir la complejidad computacional, las imágenes fueron convertidas a escala de grises. Las imágenes fueron capturadas en un entorno controlado, garantizando condiciones de iluminación constante y uniformidad en la resolución, lo que minimiza la variabilidad y mejora la calidad del conjunto de datos. Además, incluye imágenes de cinco variedades distintas de granos de arroz provenientes de Turquía: Ipsala, Arborio, Jasmine, Karacadag y Basmati. Cada clase está representada por un número equilibrado de imágenes, lo que ayuda a prevenir problemas de desbalance durante el entrenamiento del modelo.

Las diferentes variedades de arroz se ilustran en las Fig. 1 a 5. Fig. 1(a): Arroz Arborio, conocido por su grano corto y su capacidad para absorber líquidos, ideal para risotto. Fig. 1(b):

Arroz Basmati, con grano largo y aromático, utilizado en la cocina india y pakistaní. Fig. 1(c): Arroz Ipsala, de grano medio y textura esponjosa, común en platos turcos. Fig. 1 (d): Arroz Jasmine, de grano largo y fragante, popular en la cocina tailandesa. Fig. 1(e): Arroz Karacadag, resistente y adaptable, especialmente en climas áridos.

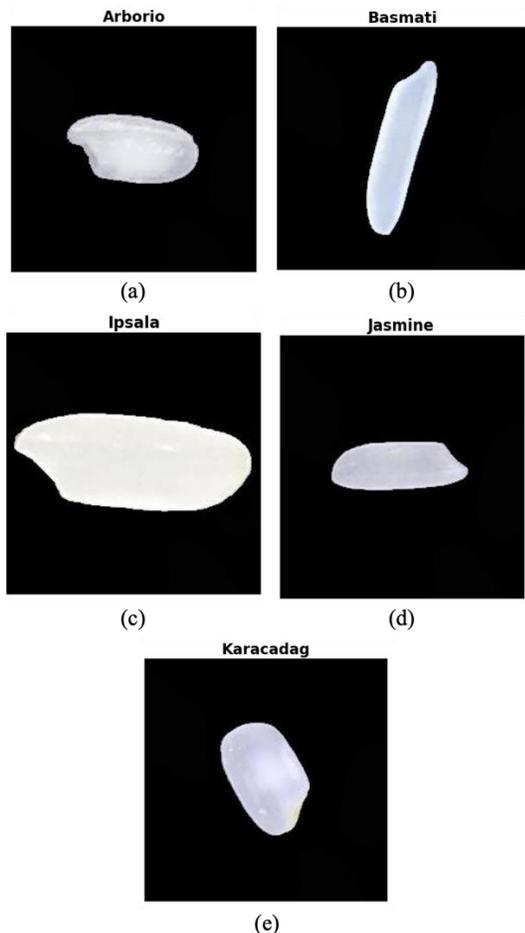


Fig. 1. Comparación visual de variedades de arroz. (a) Arborio. (b) Basmati. (c) Ipsala. (d) Jasmine. Fuente: elaboración propia.

B. Preprocesamiento de datos

El preprocesamiento es una etapa esencial en el desarrollo de modelos de aprendizaje automático, ya que garantiza que los datos estén en el formato adecuado para ser interpretados por una Red Neuronal Convolutiva (CNN). En este estudio, se llevaron a cabo varios pasos de preprocesamiento para optimizar las imágenes del Rice Images Dataset antes de su uso en el entrenamiento del modelo.

Primero, aunque las imágenes originales estaban en formato RGB, se realizó una conversión a escala de grises. Esta transformación simplifica el procesamiento y reduce la

complejidad computacional del modelo, permitiendo que la CNN se enfoque en características morfológicas y texturales relevantes de los granos de arroz.

A continuación, en (1), se aplicó la normalización de los valores de los píxeles al rango [0, 1]. Este proceso se llevó a cabo dividiendo cada valor de píxel por 255, lo que asegura que todos los datos estén en una escala uniforme y evita problemas relacionados con magnitudes numéricas grandes. La normalización es crucial para mejorar la eficiencia del entrenamiento y garantizar una convergencia más rápida del modelo.

$$I_{normalizada} = I / 255 \quad (1)$$

Donde I representa la intensidad original del píxel y $I_{normalizada}$ representa la intensidad después de la normalización.

Finalmente, se realizó la división del dataset en dos conjuntos principales para asegurar una evaluación objetiva del modelo. Se utilizaron 70,000 imágenes para el proceso de entrenamiento y validación interna, subdividiéndose en un 80% para entrenamiento (56,000 imágenes) y un 20% para validación (14,000 imágenes). Además, se reservaron 5,000 imágenes exclusivamente para una validación final. Cada clase está representada por 1,000 imágenes en esta última fase, asegurando así una distribución equilibrada. Esta división permite evaluar el rendimiento del modelo durante el entrenamiento y medir su capacidad de generalización con datos completamente nuevos.

C. Diseño del Modelo CNN

Las Redes Neuronales Convolucionales (CNN) son especialmente adecuadas para tareas de clasificación de imágenes debido a su capacidad para capturar patrones espaciales complejos, como bordes, texturas y formas. A diferencia de otros modelos de aprendizaje automático, las CNN pueden aprender automáticamente características relevantes de las imágenes sin necesidad de extracción manual, lo que las convierte en una herramienta poderosa para el análisis visual.

Arquitectura del Modelo

Se diseñó una CNN compuesta por varias capas que permiten la extracción progresiva de características a partir de las imágenes. Esta arquitectura incluye capas convolucionales y de pooling que extraen y reducen características, seguidas de capas densas que procesan esta información para realizar la clasificación final. A continuación, se presenta una representación gráfica que ilustra su arquitectura y las conexiones entre las diferentes capas (ver Fig. 2):

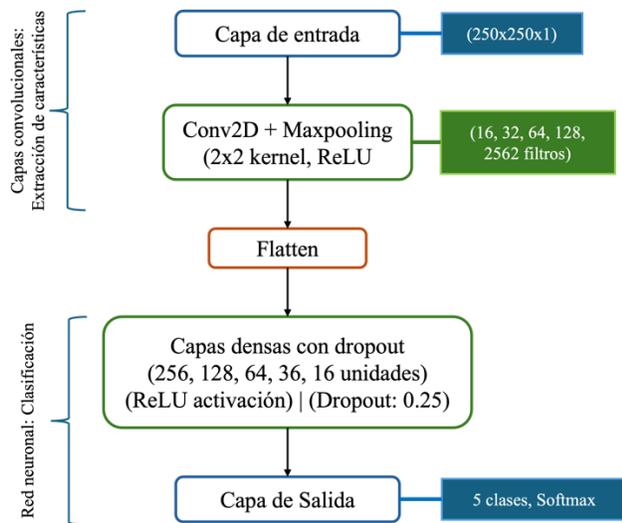


Fig. 2. Arquitectura del Modelo CNN.
Fuente: elaboración propia.

La arquitectura del modelo ha demostrado ser la más efectiva en la clasificación de imágenes de diversas variedades de arroz. Las capas convolucionales identifican patrones importantes en las imágenes, mientras que las capas densas combinan estas características para proporcionar una clasificación precisa en cinco categorías distintas.

D. Entrenamiento del Modelo

Para el entrenamiento del modelo, se utilizó un tamaño de lote de 32, con un total de 20 épocas y una tasa de aprendizaje de 0.0001. Se aplicó una técnica de dropout del 0.25 en las capas densas para ayudar a prevenir el sobreajuste. Los datos fueron divididos en dos conjuntos: 70,000 imágenes se utilizaron para el entrenamiento y la validación interna, mientras que las 5,000 imágenes restantes se reservaron para una validación final con imágenes que la red nunca había visto durante el entrenamiento. La evaluación del modelo se llevó a cabo utilizando métricas como la precisión y la matriz de confusión, lo que permite analizar su rendimiento en la clasificación de las diferentes variedades de arroz y proporciona una visión clara de su efectividad.

E. Evaluación del Modelo

La evaluación del modelo se llevó a cabo utilizando métricas clave que permiten medir su rendimiento en la clasificación de imágenes de diferentes variedades de arroz. Se utilizó la precisión como principal métrica, que se define como el número de predicciones correctas dividido por el número total de predicciones realizadas. Además, se generó una matriz de confusión para proporcionar una visión más detallada del desempeño del modelo en cada clase.

La matriz de confusión permite observar no solo la precisión general, sino también cómo se distribuyen los errores entre las distintas clases. Esto es crucial para identificar si el modelo tiene dificultades específicas con ciertas variedades de arroz. Los resultados de la evaluación se analizaron para determinar la efectividad del modelo y su capacidad para generalizar a partir de los datos de entrenamiento.

F. Validación Final

La validación final se realizó utilizando un conjunto de 5,000 imágenes que fueron reservadas específicamente para este propósito y que el modelo nunca había visto durante el entrenamiento. Este enfoque garantiza una evaluación objetiva de la capacidad del modelo para clasificar imágenes en un entorno realista.

Los resultados obtenidos en esta fase de validación final proporcionaron información valiosa sobre la robustez del modelo. Se compararon las predicciones realizadas por el modelo con las etiquetas reales de las imágenes, permitiendo calcular métricas como la precisión final y analizar la matriz de confusión correspondiente. Esta validación final es fundamental para confirmar que el modelo no solo ha aprendido a clasificar las imágenes del conjunto de entrenamiento, sino que también puede aplicarse eficazmente a nuevos datos.

IV. RESULTADOS

A. Precisión y Pérdida del Modelo

En la Fig. 3 se presenta la gráfica que muestra la evolución de la precisión durante las fases de entrenamiento y validación de la arquitectura CNN. Esta gráfica es fundamental para evaluar el rendimiento del modelo a lo largo de las épocas de entrenamiento, mostrando cómo la precisión mejora tanto en los datos de entrenamiento como en los de validación.

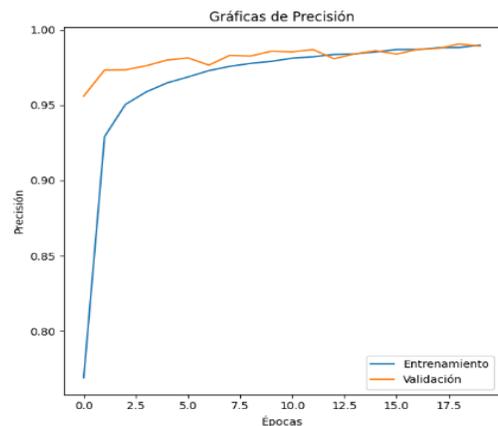


Fig. 3. Gráfica de precisión con el Modelo CNN.
Fuente: elaboración propia.

Como se observó en la gráfica (ver Fig.3), la precisión durante el entrenamiento alcanzó un valor máximo de 0.986, mientras que, durante la validación, el pico de precisión fue de 0.992. Este comportamiento indica que el modelo no solo aprendió de manera efectiva a partir de los datos de entrenamiento, sino que también logró una excelente generalización en los datos de validación. La diferencia en los picos de precisión sugiere que el modelo es capaz de adaptarse bien a datos no vistos, lo que resalta su capacidad para clasificar correctamente las imágenes de arroz.

En la Fig. 4 se muestra la evolución de la pérdida (loss) durante las fases de entrenamiento y validación de la arquitectura CNN. Esta gráfica es crucial para evaluar cómo el modelo ajusta sus parámetros a medida que avanza el entrenamiento, minimizando el error tanto en los datos de entrenamiento como en los de validación.

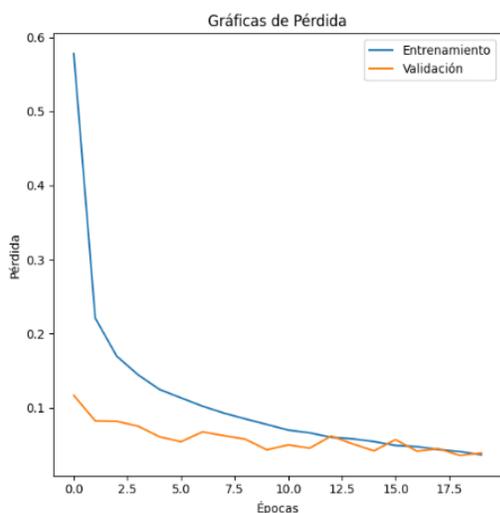


Fig. 4. Gráfica de precisión con el Modelo CNN. Fuente: elaboración propia.

Como se observó (ver Fig.4), al final del entrenamiento, la pérdida alcanzó un valor de 0.053, mientras que, durante la validación, el valor de **val_loss** fue significativamente menor, con 0.046. Este comportamiento sugiere que el modelo logró una mayor precisión en los datos de validación que en los de entrenamiento, lo que podría indicar una buena capacidad de generalización. La baja pérdida en los datos de validación resalta que el modelo está bien ajustado y ha aprendido de manera efectiva sin sobre ajustarse a los datos de entrenamiento.

B. Matriz de Confusión

A continuación, en la Fig.5 se presenta la matriz de confusión obtenida durante la validación final de la arquitectura CNN. Para esta etapa, se utilizaron 1,000 imágenes por clase, distribuidas en las cinco clases de arroz evaluadas. Esta matriz permite visualizar el desempeño del modelo al clasificar

imágenes no vistas y evaluar cómo se distribuyen los aciertos y errores en cada clase.

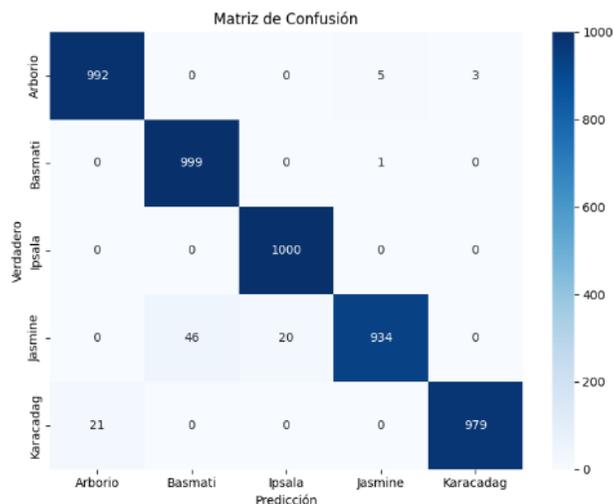


Fig. 5. Matriz de confusión con datos de validación con el Modelo CNN. Fuente: elaboración propia.].

V. CONCLUSIONES

En este estudio, se desarrolló y entrenó una red neuronal convolucional (CNN) para la clasificación automática de imágenes de granos de arroz en cinco categorías diferentes: Arborio, Basmati, Ipsala, Jasmine y Karacadag. La base de datos utilizada consistió en 75,000 imágenes en formato RGB con una resolución de 250x250 píxeles. Del total, el 80% (70,000 imágenes) se destinó al entrenamiento y validación cruzada del modelo, mientras que las 5,000 imágenes restantes, completamente nuevas para la red, se emplearon como conjunto de prueba. Los resultados obtenidos demuestran un rendimiento altamente satisfactorio, con una precisión general del 99.2% y una pérdida de 0.046 en el conjunto de prueba.

La matriz de confusión revela un desempeño consistente entre las distintas categorías, aunque se observaron leves confusiones entre las clases Jasmine y Basmati, lo cual puede atribuirse a su similitud física, particularmente en la forma y textura de los granos, que podrían dificultar la distinción incluso a simple vista. Este hallazgo pone de manifiesto la capacidad del modelo para capturar y aprender características sutiles, aunque persisten pequeños márgenes de error. Por otro lado, las demás categorías, como Arborio, Ipsala y Karacadag, presentan una diferenciación visual más marcada, lo que se refleja en una clasificación prácticamente perfecta en estas clases.

El éxito del modelo radica en su diseño y la normalización aplicada a los datos, lo que permitió optimizar el entrenamiento sin necesidad de aplicar técnicas de aumento de datos (data augmentation). Los resultados sugieren que la red neuronal

propuesta es una herramienta confiable para la clasificación automática de granos de arroz, con potencial aplicación en industrias alimentarias y procesos de calidad. Sin embargo, investigaciones futuras podrían centrarse en la implementación de técnicas adicionales, como el aumento de datos o arquitecturas más complejas, para minimizar las confusiones residuales entre clases similares.

AGRADECIMIENTO/RECONOCIMIENTO

Expresamos agradecimiento a la Universidad de Pamplona por su apoyo institucional y por proporcionar los recursos necesarios para llevar a cabo esta investigación. Su compromiso con la excelencia académica y el desarrollo científico fue clave para el éxito de este proyecto.

REFERENCIAS

[1] M. O. Badi. "Rice Quality". JICA. Accedido el 21 de diciembre de 2024. [En línea]. Disponible: https://www.jica.go.jp/Resource/project/english/sudan/001/materials/c8h0vm00007vrgs5-att/rice_quality_en.pdf

[2] M. S. Rayudu, L. K. Pampana, S. Myneni, S. Kalavari, and R. R. Madapa, "An automatic rice grain classification for agricultural products marketing," *Atlantis Highlights in Computer Sciences*, pp. 209–218, 2023, doi: 10.2991/978-94-6463-314-6_21.

[3] B. S. Anami, N. N. Malvade, and S. Palaiah, "Automated Recognition and Classification of Adulteration Levels from Bulk Paddy Grain Samples," *Information Processing in Agriculture*, 2019. [Online]. Available: [Enlace no disponible]. [Accessed: 21-Dec-2024].

[4] J. Pawelec. "Automatización del proceso de clasificación del arroz". MY MEYER. Accedido el 21 de diciembre de 2024. [En línea]. Disponible: <https://meyer-corp.eu/article/automating-rice-sorting-process/#:~:text=Rice%20color%20sorter%20machines%20use,minimizing%20waste%20and%20maximizing%20quality>.

[5] C. Kurade et al., "An Automated Image Processing Module for Quality Evaluation of Milled Rice", *Foods*, vol. 12, n.º 6, p. 1273, marzo de 2023. Accedido el 21 de diciembre de 2024. [En línea]. Disponible: <https://doi.org/10.3390/foods12061273>

[6] G. M. Sampallo, C. Acosta, A. González Thomas, and M. Cleva, "Sistema experto para clasificación de granos de arroz pulidos," in *V Congreso Argentino de AgroInformática (CAI)-JAIIO 42*, 2013.

[7] B. Mahale and S. Korde, "Rice quality analysis using image processing techniques," *International Conference for Convergence for Technology-2014*, Pune, India, 2014, pp. 1-5, doi: 10.1109/I2CT.2014.7092300.

[8] S. Chen, J. Xiong, W. Guo, R. Bu, Z. Zheng, Y. Chen, Z. Yang, and R. Lin, "Colored rice quality inspection system using machine vision," *J. Cereal Sci.*, vol. 88, pp. 87-95, 2019, doi: 10.1016/j.jcs.2019.05.010.

[9] L. Wang, D. Zhong, X. Chen, Z. Niu y Q. Cao, "Impact of climate change on rice growth and yield in China: Analysis based on climate year type", *Geogr. Sustainability*, vol. 5, n.º 4, pp. 548–560, diciembre de 2024. Accedido el 21 de diciembre de 2024. [En línea]. Disponible: <https://doi.org/10.1016/j.geosus.2024.06.006>

[10] Y. Lu, J. Wang, L. Fu, L. Yu y Q. Liu, "High-throughput and separating-free phenotyping method for on-panicle rice grains based on deep learning", *Frontiers Plant Sci.*, vol. 14, septiembre de 2023. Accedido el 21 de diciembre de 2024. [En línea]. Disponible: <https://doi.org/10.3389/fpls.2023.1219584>

[11] D. Agarwal and P. Bachan, "Machine Learning Approach for the Classification of Wheat Grains," *Smart Agricultural Technology*, 2023. [Online]. Available: [Enlace no disponible]. [Accessed: 21-Dec-2024].

[12] P. S., "RICE GRAIN QUALITY ANALYSIS USING IMAGE PROCESSING TECHNIQUES", *INTERNATIONAL J. SCIENTIFIC RES. ENG. MANAGE.*, vol. 06, n.º 05, mayo de 2022. Accedido el 21 de diciembre de 2024. [En línea]. Disponible: <https://doi.org/10.55041/ijsem12712>

[13] F. Farahnakian, J. Sheikh, F. Farahnakian, and J. Heikkonen, "A comparative study of state-of-the-art deep learning architectures for rice grain classification," *J. Agric. Food Res.*, vol. 15, Art. no. 100890, 2024, doi: 10.1016/j.jafr.2023.100890.

[14] J. J. Coronel Reyes, "Desarrollo del Proceso de Clasificación en Granos de Arroz utilizando Técnicas de Aprendizaje Automático," *Universidad Estatal de Milagro*, 2023.

[15] J. F. Lujan Piscocoya, "Desarrollo de una aplicación web para la clasificación de la calidad de arroz, mediante inteligencia artificial, en un molino de Ferreñafe," *Ingeniero, Facultad de Ingeniería, Universidad Católica Santo Toribio de Mogrovejo, Chiclayo, Perú*, 2022. [En línea]. Disponible en: <http://hdl.handle.net/20.500.12423/5541>.

[16] M. Koklu, I. Cinar, and Y. S. Taspinar, "Classification of rice varieties with deep learning methods," *Computers and Electronics in Agriculture*, vol. 187, p. 106285, 2021.

[17] Cinar and M. Koklu, "Classification of Rice Varieties Using Artificial Intelligence Methods," *International Journal of Intelligent Systems and Applications in Engineering*, vol. 7, no. 3, pp. 188-194, 2019.

[18] J. Redondo Antón, "Comparativa de modelos de random forest y redes neuronales aplicados al mantenimiento predictivo con valores ausentes y datos desbalanceados," 2021.

[19] C. Acosta, G. Sampallo, A. González Thomas, M. S. Cleva, and D. O. Liska, "Detección e identificación de defectos en granos de arroz empleando visión artificial," in *Proceedings of the 2017 IEEE Latin America Conference on Computational Intelligence (LA-CCEI)*, 2017.

[20] T.-Y. Kuo, C.-L. Chung, S.-Y. Chen, H.-A. Lin, and Y.-F. Kuo, "Identifying rice grains using image analysis and sparse-representation-based classification," *Computers and Electronics in Agriculture*, vol. 127, pp. 716–725, 2016, doi: 10.1016/j.compag.2016.07.020.

[21] M. B. Soroush. "Rice Images Dataset". Kaggle. Accedido el 21 de diciembre de 2024. [En línea]. Disponible: <https://www.kaggle.com/datasets/mbsoroush/rice-images-dataset/data>

[22] B. H. Sirenden, P. Mursanto, and S. Wijonarko, "Dynamic texture analysis using Temporal Gray scale Pattern Image for water surface velocity measurement," *Image Vis Comput*, vol. 137, p. 104749, Sep. 2023, doi: 10.1016/J.IMAVIS.2023.104749.

[23] H. Zhu, M. Liu, H. Shu, H. Zhang, and L. Luo, "General form for obtaining discrete orthogonal moments," *IET Image Process*, vol. 4, no. 5, pp. 335–352, Oct. 2010, doi: 10.1049/IET-IPR.2009.0195.

[24] I. Batioua, R. Benouini, K. Zenkour, and A. Zahi, "Image classification using separable invariants moments based on Racah polynomials," *Procedia Comput Sci*, vol. 127, pp. 320–327, Jan. 2018, doi: 10.1016/J.PROCS.2018.01.128.

[25] M. H. P. Pelegrino et al., "Optimizing soil texture spatial prediction in the Brazilian Cerrado: Insights from random forest and spectral data," *Geoderma Regional*, vol. 40, p. e00922, Mar. 2025, doi: 10.1016/J.GEODRS.2025.E00922.

[26] N. Jalal, A. Mehmood, G. S. Choi, and I. Ashraf, "A novel improved random forest for text classification using feature ranking and optimal number of trees," *Journal of King Saud University - Computer and Information Sciences*, vol. 34, no. 6, pp. 2733–2742, Jun. 2022, doi: 10.1016/J.JKSUCI.2022.03.012.

[27] P. R. Jeyaraj and E. R. Samuel Nadar, "Computer-assisted medical image classification for early diagnosis of oral cancer employing deep learning algorithm," *J Cancer Res Clin Oncol*, vol. 145, no. 4, pp. 829–837, Apr. 2019, doi: 10.1007/S00432-018-02834-7.

[28] S. M. Mathews, C. Kambhamettu, and K. E. Barner, "A novel application of deep learning for single-lead ECG classification," *Comput Biol Med*, vol. 99, pp. 53–62, Aug. 2018, doi: 10.1016/J.COMPBIOMED.2018.05.013.

[29] S. Kaushal, D. K. Tammineni, P. Rana, M. Sharma, K. Sridhar, and H. H. Chen, "Computer vision and deep learning-based approaches for detection of food nutrients/nutrition: New insights and advances," *Trends Food Sci Technol*, vol. 146, Apr. 2024, doi: 10.1016/j.tifs.2024.104408.

[30] Bhupendra, K. Moses, A. Miglani, and P. Kumar Kankar, "Deep CNN-based damage classification of milled rice grains using a high-magnification image dataset," *Comput Electron Agric*, vol. 195, p. 106811, Apr. 2022, doi: 10.1016/J.COMPAG.2022.106811.