



Universidad  
Autónoma  
de Coahuila



Journal of BioProcess and  
Chemical Technology

# Journal of Bioprocess and Chemical Technology

ISSN:2683-3271

## CONTENT



### Estudio preliminar de la respuesta eléctrica de la cactácea *Lophophora williamsii*

Guerra-Sánchez, C., Sandoval-García, E., Sifuentes-Gallardo, C., De la Rosa, I., Sánchez-Calderón, L., Alaniz-Lumbreras, D., Ortiz-Esquivel, D., Felix-Esquivel, R.



### Optimización en la producción de alimentos mediante el sistema ISO 9001:2015

Silva Aguilera, R., Garay Díaz, J., Figueroa Ibarra, G., Guirette-Barbosa, O., Cruz-Domínguez, O., Ortiz-Sánchez, L., Vera-Ponce, S.



### Detección y Estimación del Peso de Granos Llenos de una Muestra de Arroz Cáscara, Empleando Procesamiento Digital de Imágenes con ImageJ®

Cleva M., Liska D., Rodríguez-Hernández, B.

Vol. 16, No. 32  
Enero-Junio 2024

**YOU ARE INVITED TO SHARE  
YOUR ARTICLES**

For More Information  
[www.biochemtech.uadec.mx](http://www.biochemtech.uadec.mx)



## **Detección y Estimación del Peso de Granos Llenos de una Muestra de Arroz Cáscara, Empleando Procesamiento Digital de Imágenes con ImageJ®**

## **Detection and Estimation of the Weight of Filled Grains From a Paddy Rice Sample, Using Digital Image Processing with ImageJ®**

Cleva M.<sup>1\*</sup>, Liska D.<sup>1</sup>, Rodríguez-Hernández, B.<sup>2</sup>.

<sup>1</sup>*Centro de Investigación Aplicada en Tecnología de la Información y Comunicación. Universidad Tecnológica Nacional. Facultad Regional Resistencia. French 414, Resistencia, Chaco 3500, Argentina*

<sup>2</sup>*Unidad Académica de Ingeniería Eléctrica, Universidad Autónoma de Zacatecas. Jdn. Juárez #147, Centro Histórico, 98000. Zacatecas*

\* *Corresponding Author: clevamario@hotmail.com*

*Recibido: 13 de junio 2023*

*Aceptado: 20 de diciembre 2023*

### **Resumen**

La identificación y determinación del peso de granos llenos y vanos de arroz extraídos de una panoja es una variable relacionada a características genéticas de las plantas, a las condiciones ambientales durante el llenado de grano e influyen en el rendimiento. El Procesamiento Digital de Imágenes (PDI) es una herramienta objetiva, eficaz y aplicable a diferentes procesos de identificación y clasificación. Es útil para la caracterización morfológica de granos y semillas. El objetivo de este trabajo es presentar una técnica basada en PDI para la identificación de granos llenos y la estimación del peso de estos. Emplea una imagen de la muestra obtenida con un escáner de escritorio con adaptador de transparencias, una balanza y el programa ImageJ®, La detección de los granos llenos se realizó empleando el histograma del grano. El porcentaje de reconocimiento de granos fue en promedio de un 85%. Para la estimación del peso, se correlacionaron los píxeles correspondientes al área proyectada de los granos con su peso. Los valores obtenidos, tienen un error del 1.2% en promedio. El método propuesto es operacionalmente sencillo, eficiente y no requiere de un entrenamiento previo ni de equipamiento especial.

**Palabras clave:** Clasificación, Histograma, Peso por pixel, Transparencia.

### **Abstract**

The identification and determination of the weight of full and empty grains of rice extracted from a panicle is a variable related to genetic characteristics of the plants, to the environmental conditions during grain filling and influence yield. Digital Image Processing (DIP) is an objective, effective tool applicable to different identification and classification processes. It is useful for the morphological characterization of grains and seeds. The objective of this work is to present a technique based on PDI for the identification of full grains and the estimation of their weight. It uses an image of the sample obtained with a desktop scanner with a transparency adapter, a scale and the ImageJ® program. The detection of full grains was carried out using the grain histogram. The grain recognition percentage was on average 85%. For weight estimation, the pixels corresponding to the projected area of the grains were correlated with their weight. The values obtained have an error of 1.2% on average. The proposed method is operationally simple, efficient and does not require prior training or special equipment.

**Keywords:** Classification, Histogram, Weight per pixel, Transparency.

## INTRODUCCIÓN

El arroz (*Oryza sativa*) es un cultivo de particular interés en todo el mundo. Tanto a nivel mundial como regional, mucha de la investigación realizada sobre el cultivo apunta al incremento de los rindes, en modelos de producción sostenible. De acuerdo con los que menciona el Centro Internacional de Agricultura Tropical (1986), implica la necesidad de conocer la naturaleza del rendimiento para poder manejar los diferentes factores inherentes al cultivo y al ambiente (componentes bióticos y abióticos) con miras a optimizar la producción. En este contexto, la meta que cuenta es el rendimiento en grano, que depende de la cantidad de panojas/área; el número de granos/panoja; el porcentaje de granos llenos y el peso de los 1000 granos.

En ensayos/parcelas experimentales es habitual la determinación de cada componente del rendimiento por lo cual la búsqueda de métodos que faciliten tales tareas es constante. Para ello se emplean métodos manuales de determinación que requieren de personal entrenado para hacerlo. Las limitaciones en cuanto a la aplicación de recursos de carácter tecnológico están dadas por los costos que implica su empleo. Por otra parte, ayudan a mejorar y acelerar las tareas mencionadas evitando la subjetividad propia de los métodos manuales. También optimizan el empleo de los recursos humanos calificados. La aplicación del Procesamiento Digital de Imágenes (PDI) a la industria y a la producción agrícola se vio favorecida por el abaratamiento en los sistemas de adquisición de imágenes (escáneres, cámaras digitales, etc.).

Son numerosos los desarrollos hechos en los últimos años en relación con el procesamiento de imágenes aplicados a granos y semillas. Zhou y col (2023) proponen un sistema de imágenes duales termo infrarrojas y de luz visible para detectar rápidamente la tasa de fijación de semillas en arroz. La fusión de métodos logra una precisión del 97.66%, destacando por su eficiencia y potencial en la detección de la tasa. Wang y col (2022) presentan un sistema que permite estimar la calidad del arroz de manera precisa para la seguridad alimentaria y el impacto socioeconómico. Se presenta un sistema automático de estimación visual que clasifica granos según defectos, utilizando un innovador flujo de trabajo multietapa y una métrica para evaluar la calidad con precisión. Los contenidos de humedad son analizados por Makky y col (2019), quienes hicieron el estudio sobre variedades de arroz en Sumatra occidental, mediante un método no destructivo utilizando espectroscopía infrarroja de onda corta. Los modelos de calibración mostraron alta correlación y precisión, demostrando que la humedad de los granos de arroz puede identificarse con precisión mediante este enfoque no destructivo.

Por otra parte, un parámetro importante es la tasa de establecimiento de semillas de arroz para calcular los rendimientos y analizar la genética de este. Guo y col (2022) proponen un método basado en segmentación de imágenes y aprendizaje profundo para identificar automáticamente los granos y calcular este parámetro. Utilizando un algoritmo de optimización, se logra una precisión del 99.43%. Este enfoque no invasivo y efectivo es aplicable a cultivos como soja, trigo y otros con características similares. Cleva y col (2013) proponen un método basado en PDI para la determinación del volumen de un grano de arroz, con un error del 3% en promedio. Samrendra y col (2020) usan técnicas de aprendizaje supervisado para determinar tamaño y peso de diferentes variedades de arroz descascarado y pulido. En la mayoría de estos trabajos, el análisis se realiza sobre en una etapa posterior al descascarado y pulido y previa al consumo humano.

Existen así mismos desarrollos significativos para etapas previas a la cosecha. Para al reconocimiento de granos llenos y vanos, Liu y col (2016) desarrollaron un método de análisis de imágenes caracterizados por su rapidez y eficiencia. Utilizaron cuatro fuentes de luz para generar sombras desde diferentes direcciones y emplearon una cinta transportadora con velocidad controlada. La técnica de máquina de vectores de soporte demostró alta precisión, indicando su potencial para mejorar la evaluación de características en la investigación agrícola. Wang y col (2022) proponen un método de detección y conteo de panojas de arroz mediante aprendizaje profundo, diseñado para imágenes de campos de arroz extensos. YOLOv5 se selecciona como el mejor detector con una precisión del 92.77%. Introducen un método mejorado para eliminar detecciones repetidas, demostrando robustez y precisión en diversas condiciones.

El empleo de software de libre distribución o gratuito, permite emplear algoritmos para extraer información de las imágenes adquiridas. Existen diversos programas para el PDI como ImageJ® (Versión 1.53s; National Institutes of Health, Bethesda, MD, EE. UU). Este es un software de dominio público programado en Java y desarrollado en el National Institutes of Health. ImageJ fue diseñado con una arquitectura abierta que proporciona extensibilidad vía plugins Java y permite programar macros, que posibilitan la realización de secuencias de cálculo reiterativas. También desde el mismo programa se puede hacer la captura de la imagen desde el escáner con el empleo de un plugin. ImageJ es un software de amplia difusión en el ambiente académico científico. Santos y col (2019) proponen reemplazar las antiguas mediciones manuales de dimensiones en granos de arroz por tecnologías de imagen, permitiendo una evaluación

más rápida de la calidad del arroz basada en características físicas. Zhao y col (2023) propone un modelo de aprendizaje profundo, para medir automáticamente el número y tamaño de semillas de arroz. Comparado con ImageJ, este modelo mostró resultados prometedores con un error medio cuadrático no superior a 0.11 para 900 semillas. Lee y col (2019) proponen utilizar imágenes RGB y técnicas de procesamiento con ImageJ para cuantificar de manera precisa la progresión del tizón en tallos de arroz, mejorando la evaluación tradicional basada en la percepción visual.

El objetivo de este trabajo es presentar una técnica para la detección y estimación del peso de granos llenos de una muestra de arroz cáscara, empleando PDI con ImageJ. La metodología propuesta es fiable y factible de implementar con equipos de baja complejidad (escáner y un software de libre distribución) y puede impactar positivamente facilitando las labores tanto del sector productivo como de los grupos de investigación.

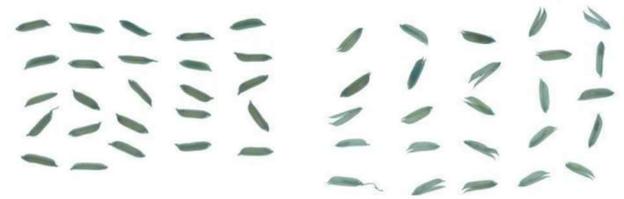
## MATERIALES Y MÉTODOS

El procedimiento se realizó en dos etapas. Una etapa corresponde a la identificación de los granos vanos y llenos y la otra corresponde a la determinación del peso de los granos llenos. Estas etapas son independientes entre sí, Para ambas, se empleó un escáner de escritorio con adaptador de transparencias (empleada en la primera etapa), una balanza digital (empleada en la segunda etapa) y para ambas etapas el software de libre distribución ImageJ (Kuo y col 2016).

**Identificación de granos llenos y vanos.** Se seleccionaron manualmente dos conjuntos de granos: vanos y llenos. Esta clasificación resultó de la trilla manual de las panojas y la separación manual/visual de los granos obtenidos en las clases mencionadas. Con los granos preclasificados se prepararon un total de 10 muestras formadas cada una por 25 granos de arroz llenos y 25 granos de arroz vanos, de las cuales se obtuvieron sus imágenes empleando el escáner con el adaptador de transparencias. La selección de la cantidad de granos a analizar fue arbitraria, aunque estuvo limitada por la reducida región para la adquisición de transparencias disponible en el escáner. Si bien existen dispositivos para la distribución de los granos sobre la bandeja que evita que estén en contacto entre sí (Zuniga Picado y col, 2022), esta se realiza de forma manual. Esto evita demoras relacionadas con el empleo de algoritmos (Sampallo y col, 2016) para separar granos en una imagen.

Los registros se obtuvieron con una resolución de 300 dpi y en formato BMP. Este valor de resolución es elegido porque permite tener velocidades de procesamiento aceptables sin perder calidad y poseen un adecuado tamaño de almacenamiento. Los granos se colocan sobre la bandeja del

escáner susceptible a ser retroiluminada, obteniendo una imagen como la que se presenta en la Figura 1. En la misma se aprecia la diferencia de translucidez entre los granos llenos de la izquierda y vanos que se encuentran a la derecha.

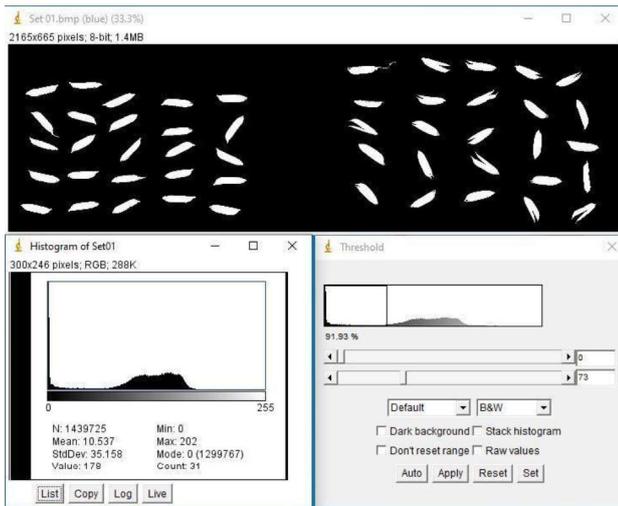


**Figura 1:** Imagen obtenida con adaptador de transparencias: Granos llenos (izquierda) y vanos (derecha)

Para mayor comodidad, se trabajó con el negativo de las imágenes obtenidas a fin de poder separar el fondo (tono oscuro) del grano (tono claro). Esta configuración se puede realizar desde el software de adquisición de imágenes del escáner o desde ImageJ. Posteriormente la imagen se separa en cada uno de sus canales para su análisis.

Una operación recurrente en el procesamiento de imágenes es la binarización de algunos de sus canales (Lurstwut y Pornpanomchai., 2017). Cada canal puede contener píxeles de un tono de 256 posibles. La binarización consiste en comparar el valor de intensidad de cada píxel contra uno denominado umbral (Tajima y Kato, 2011). Si el valor del píxel está por debajo de ese umbral, al píxel se le asigna el valor 0 y si está por encima, se le asigna el valor de 1 (o viceversa, dependiendo del problema). En este caso, el fondo oscuro se hace uniforme (valor 0) al igual que el objeto (valor 1) permitiendo la identificación de estos. La selección del umbral se realiza en función al histograma de la imagen.

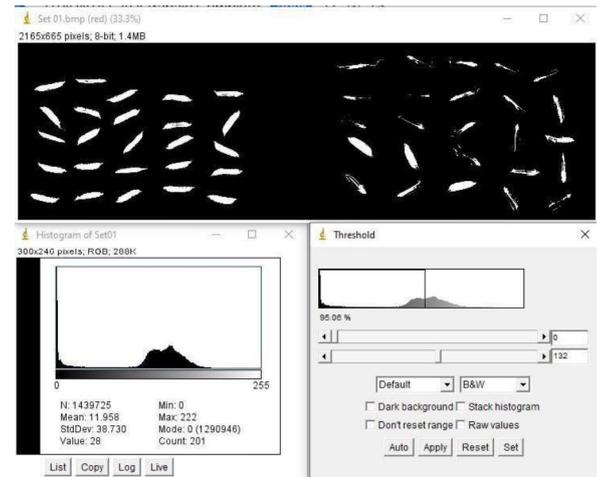
ImageJ también permite contar elementos presentes en una imagen binarizada (Muzzadiq y col, 2015), es decir todas las agrupaciones de píxeles contiguos que tengan una intensidad de 1. El conteo se puede filtrar empleando diferentes criterios para no incluir objetos que no representan granos. Uno de estos criterios es el tamaño del área, el cual permite eliminar objetos de dimensiones pequeñas que no pertenecen a las clases que se quieren identificar. Generalmente son impurezas o residuos que quedan en la bandeja del escáner durante el proceso de adquisición de la imagen. Para cualquiera de los canales se hizo una primera estimación del umbral a partir del cual se realizó la primera binarización. La Figura 2 presenta la imagen del canal azul sobre la cual se realizó esta operación.



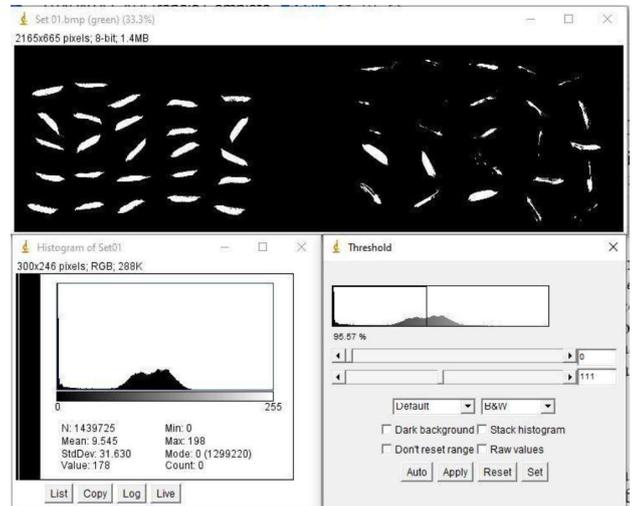
**Figura 2:** canal azul e histograma con primera binarización

Cualquier píxel con intensidad menor a 73 puede ser tomado como fondo y por encima como perteneciente al grano. A partir de esta binarización se determinó el número total de granos presentes en la imagen con la selección adecuada del área mínima (9 mm<sup>2</sup> en este caso) y que representa el valor mínimo de superficie para ser considerada como grano. En cualquiera de los canales la binarización fue igual de efectiva, ya que los granos contrastaron con el fondo sin dificultad. Se realizó luego sobre la imagen original de cada canal una segunda binarización con la intención de poder distinguir granos vanos y llenos a partir de la transparencia. El procedimiento es similar al descrito anteriormente para el conteo de granos. Para cada canal se analizó el histograma correspondiente para determinar si es visible la diferencia entre los granos vanos y llenos a partir de asumir que cada clase tiene histogramas diferentes (distribución bimodal). Como se comentó anteriormente, los granos vanos son más translúcidos que los llenos.

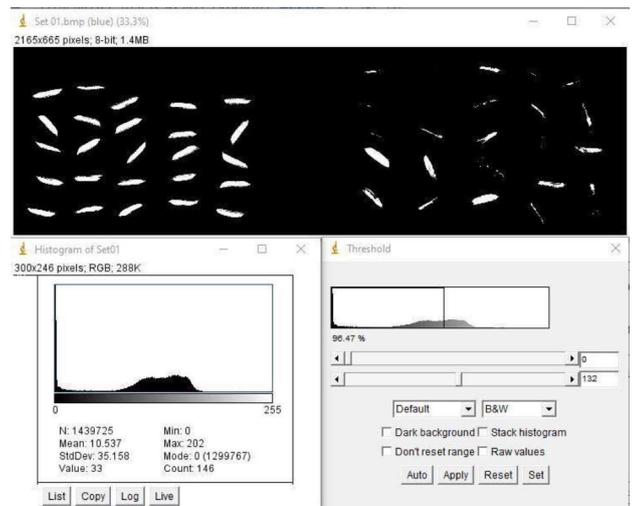
Las Figuras 3, 4 y 5 muestran las imágenes binarizadas de los canales rojo, verde y azul respectivamente. En la parte inferior de cada figura se presenta el histograma y la herramienta de binarización donde se puede visualizar el valor del umbral seleccionado. Este valor representa el punto de intersección entre los histogramas de los granos vacíos y llenos. La segunda binarización permite eliminar de la imagen parcialmente los granos vanos, por lo que el conteo de objetos en la imagen dará como resultado el total aproximado de granos llenos de la muestra.



**Figura 3:** Canal rojo, histograma y segunda binarización



**Figura 4:** Canal verde, histograma y segunda binarización



**Figura 5:** Canal azul, histograma y segunda binarización

A partir de la primera y segunda binarización, se puede calcular para la muestra analizada, el porcentaje de cada tipo de granos presentes en la muestra. Es importante destacar que el solapamiento entre gaussianas que se nota en el histograma representa píxeles de granos que pertenecen a ambas clases.

**Estimación del peso de los granos enteros de la muestra.** Se propone como estimador del peso de la muestra, al valor de la suma de las áreas proyectadas de los granos que la componen. Singh y col (2020) proponen una técnica similar pero con granos pulidos mostrando la relación existente entre cantidad de pixels y peso de la muestra. En una primera etapa, que es la etapa de calibración, se tomaron imágenes color de 5 muestras compuestas por alrededor de 100, 150, 200, 250 y 300 granos llenos (Figura 6). Para esta etapa, no es necesario el adaptador de transparencia del escáner para la obtención de las imágenes.



**Figura 6:** imagen de una porción de una muestra de granos para determinar el peso.

Se realizó, para cada imagen, la binarización del canal rojo para separar los granos del fondo. Con el factor de escala de la resolución de la imagen, se pudo obtener el valor del área proyectada de cada grano y el área proyectada total de la muestra en milímetros cuadrados. Se determinó luego el valor del peso de cada muestra con la balanza digital. Con los datos del área proyectada total para cada muestra y el peso determinado de las mismas, se construyó una gráfica del peso como función del área

proyectada para analizar la relación entre las variables área proyectada contra peso y construir una ecuación que vincula a dichas variables. Con el objetivo de validar la ecuación de ajuste, se prepararon otras 5 muestras de la misma variedad, se tomaron sus imágenes y se repitió el procedimiento para obtener las áreas proyectadas totales de los granos presentes en cada muestra y determinar las masas y aplicando la ecuación de regresión para compararlos con los obtenidos con la balanza y determinar el error correspondiente.

## RESULTADOS Y DISCUSION

En relación a la identificación de los granos llenos, en la Tabla 1 se presentan los resultados obtenidos en el procesamiento de las imágenes. Para el canal rojo se tomó el nivel de intensidad 140 como umbral para granos llenos y vanos, para los canales azul y verde se optó por 130 y 109 respectivamente.

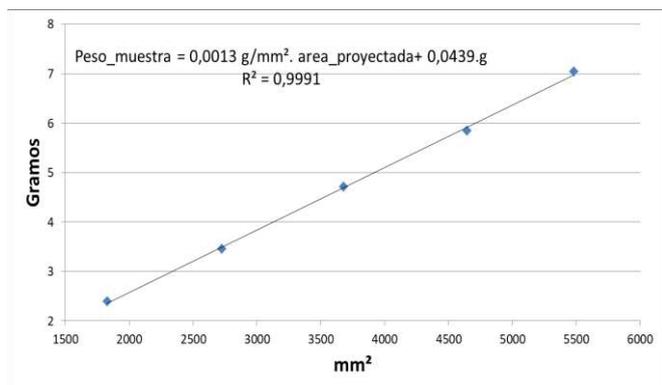
**Tabla 1:** Resultados de la identificación con sus desviaciones estándar respectivas.

Canal	Grano lleno (%)	Grano vano (%)	Ambas clases (%)
Rojo	71 ± 11	90 ± 6	10 ± 6
Azul	86 ± 7	88 ± 8	12 ± 8
Verde	98 ± 3	84 ± 9	17 ± 8

En la Tabla 1 los porcentajes presentados están en función del valor previamente conocido de la cantidad de granos de cada clase. Así, por ejemplo, en el canal rojo el 71% de granos llenos se expresa sobre los 25 granos que componen la muestra. Para el mismo canal el 90% de granos vanos reconocidos, se calcula sobre el total de esta clase en la muestra preclasificada. El 10% de la categoría “ambas clases” corresponde a los granos vanos, que fueron reconocidos como llenos. Idéntica información se presenta para los canales azul y verde. En todos los canales hay un porcentaje de granos pertenecientes a ambas clases. Los canales rojo y azul presentan los valores más bajos para esta categoría. Sin embargo, de todos los canales, el azul es el que presenta un porcentaje de aciertos mayor para la clasificación y el porcentaje de granos pertenecientes a ambas es apenas superior al que se puede visualizar en el canal rojo.

Para el caso de la determinación del peso, se construyó la gráfica de la Figura 7 de peso de la muestra en gramos en función del área proyectada total de la muestra en milímetros

cuadrados.



**Figura 7:** Peso de la muestra en función del área proyectada de los granos

En la gráfica se presenta la ecuación lineal de ajuste entre ambas variables y su coeficiente de correlación. La linealidad observada en esta curva de calibración, permite definir una cantidad a la que podemos denominar “peso por mm<sup>2</sup>” de área proyectada, que es la pendiente de la recta obtenida. Para las cinco muestras restantes, los valores de las áreas proyectadas de cada imagen fueron ingresados a la ecuación de ajuste, para obtener el peso correspondiente de cada muestra de control empleando la imagen digital. Luego se pesaron estas muestras, para determinar los errores porcentuales correspondientes. Los resultados se presentan en la Tabla 2.

**Tabla 2:** Errores en la determinación de los pesos.

Muestras de validación	Total de granos	Área total (mm <sup>2</sup> )	Masa real (g)	Masa estimada (g)	Error (%)
1	195	3511	4.55	4.61	1.3
2	286	5203	6.71	6.81	1.5
3	301	5407	7.06	7.07	0.2
4	266	4851	6.28	6.35	1.1
5	339	6152	7.9	8.04	1.8
Promedio					1.2

## CONCLUSIONES

La técnica presentada tiene una serie de ventajas como ser el bajo requerimiento tanto de hardware como de software. También no es destructiva y permite almacenar imágenes e información de las muestras para otros fines o para revalidación

de las mismas. El procedimiento no consume tiempo, ya que las operaciones realizadas sobre las imágenes, se pueden automatizar programando macros, función disponible en ImageJ.

Actualmente se está trabajando en mejorar la capacidad de detección, sobre todo por el inconveniente que generan aquellos granos que pertenecen a ambas clases. Se deben buscar otras variables (como la longitud del perímetro del área proyectada) y procedimientos que definan la pertenencia a una u otra clase. Algunos granos vanos presentan una característica conocida como pico de loro o straighthead que puede ser usada como elemento clasificador. Los tiempos que implican los algoritmos que permitan analizar granos en contacto, es otra cuestión a analizar. Esto es debido a que la ubicación de los granos sobre la bandeja del escáner para que no estén en contacto entre sí, consume tiempo sobre todo para grandes cantidades. En cuanto a la determinación de la masa, el método tiene bajo error lo que lo hace útil para uso rutinario. Esta metodología también es factible de ser usada con otros granos, trabajo que se encuentra en ejecución.

## REFERENCIAS

- Centro Internacional de Agricultura Tropical. 1986. Componentes del rendimiento en arroz; Guía de estudio. Contenido científico: International Rice Research Institute. Traducción y adaptación: Oscar Arregocés. Cali, Colombia. CIAT.
- Cleva, M. S., Sampallo, G. M., Gonzalez Thomas, A. O., & Acosta, C. A. (2013). Método para la determinación del volumen de una muestra de granos de arroz mediante el procesamiento digital de imágenes. *RIA. Revista de Investigaciones Agropecuarias*, 39(2), 185-190. Buenos Aires, Argentina.
- Guo, Y., Li, S., Zhang, Z., Li, Y., Hu, Z., Xin, D., Chen, Q., Wang, J., & Zhu, R. (2021, December 14). Automatic and Accurate Calculation of Rice Seed Setting Rate Based on Image Segmentation and Deep Learning. *Frontiers in Plant Science*, 12, 770916. <https://doi.org/10.3389/fpls.2021.770916>.
- Kuo, T.-Y., Chung, C.-L., Chen, S.-Y., Lin, H.-A., & Kuo, Y.-F. (2016). Identifying rice grains using image analysis and sparse-representation-based classification. *Computers and Electronics in Agriculture*, 127, 716-725. <https://doi.org/10.1016/j.compag.2016.07.020>.
- Lee, D.-Y., Na, D.-Y., Heo, Y. S., & Wang, G.-L. (2021). Digital image quantification of rice sheath blight: Optimized segmentation and automatic classification.

- arXiv:1907.04953.  
<https://doi.org/10.48550/arXiv.1907.04953>.
- Liu, T., Wu, W., Chen, W., Sun, C., Chen, C., Wang, R., Zhu, X., & Guo, W. (2016). A shadow-based method to calculate the percentage of filled rice grains. *Biosystems Engineering*, 150, 79-88.  
<https://doi.org/10.1016/j.biosystemseng.2016.07.011>.
- Lurstwut, B., & Pornpanomchai, C. (2017). Image analysis based on color, shape and texture for rice seed (*Oryza sativa* L.) germination evaluation. *Agriculture and Natural Resources*, 51(5), 383-389.  
<https://doi.org/10.1016/j.anres.2017.12.002>.
- Makky, M., Santosa, Putri, R. E., et al. (2019). Determination of moisture content in rice using non-destructive short-wave near infrared spectroscopy. *AIP Conference Proceedings*, 2155(September). <https://doi.org/10.1063/1.5125518>.
- Mussadiq, Z., Laszlo, B., Helyes, L., & Gyuricza, C. (2015). Evaluation and comparison of open source program solutions for automatic seed counting on digital images. *Computers and Electronics in Agriculture*, 117, 194-199.  
<https://doi.org/10.1016/j.compag.2015.08.010>.
- National Institutes of Health. (2022). *ImageJ (Versión 1.53s)* [Software de computadora]. Bethesda, MD, EE. UU.
- Sampallo, G. M., Cleva, M., & Liska, D. (2016). Separación de granos en contacto con spline-cúbico para la aplicación en visión artificial. En VIII Congreso Argentino de AgroInformática (CAI-2016) - JAIIO 45 (págs. 172-182). Sociedad Argentina de Informática e Investigación Operativa (SADIO). ISSN: 2525-0949. [Documento de conferencia].
- Samrendra K., Sriram K., Rakhee T. 2020. Machine learnt image processing to predict weight and size of rice kernels, *Journal of Food Engineering*, Volume 274.
- Santos, M. V., Cuevas, R. P. O., Sreenivasulu, N., & Molina, L. (2019). Measurement of Rice Grain Dimensions and Chalkiness, and Rice Grain Elongation Using Image Analysis. *Methods in Molecular Biology*, 1892, 99-108.  
[https://doi.org/10.1007/978-1-4939-8914-0\\_6](https://doi.org/10.1007/978-1-4939-8914-0_6).
- Singh, S. K., Vidyarthi, S. K., & Tiwari, R. (2020). Machine learnt image processing to predict weight and size of rice kernels. *Journal of Food Engineering*, 274, 109828.  
<https://doi.org/10.1016/j.jfoodeng.2019.109828>.
- Tajima, R., & Kato, Y. (2011). Comparison of threshold algorithms for automatic image processing of rice roots using freeware ImageJ. *Field Crops Research*, 121(3), 460-463. <https://doi.org/10.1016/j.fcr.2011.01.015>.
- Wang, X., Yang, W., Lv, Q., Huang, C., Liang, X., Chen, G., Xiong, L., & Duan, L. (2022). Field rice panicle detection and counting based on deep learning. *Frontiers in Plant Science*, 13, 966495.  
<https://doi.org/10.3389/fpls.2022.966495>
- Wang, X., Wang, K., Li, X., & Lian, S. (2022). Vision-Based Defect Classification and Weight Estimation of Rice Kernels. *IEEE Access*, 10, 122243-122253.  
<https://doi.org/10.1109/ACCESS.2022.3223137>.
- Zhou, J., Lu, X., Yang, R., Wang, Y., Chen, H., Shen, J., Chen, M., Zhou, Z., & Liu, F. (2023). Developing thermal infrared de-ghost and multi-level nested conglutinated segmentation algorithm for detection of rice seed setting rate. *Computers and Electronics in Agriculture*, 207, 107725.  
<https://doi.org/10.1016/j.compag.2023.107725>.
- Zhao, J., Ma, Y., Yong, K., Zhu, M., Wang, Y., Wang, X., Li, W., Wei, X., & Huang, X. (2023). Rice seed size measurement using a rotational perception deep learning model. *Computers and Electronics in Agriculture*, 205, 107583.  
<https://doi.org/10.1016/j.compag.2022.107583>.
- Zuniga Picado, L. A., Campos Boza, S., Mora Chaves, J. R., & Barboza-Barquero, L. (2022). Cuantificación del porcentaje de grano quebrado total en arroz (*Oryza sativa* L.) mediante análisis digital de imágenes. *Agron. Mesoam*, 33(spe1), 51568. <https://doi.org/10.15517/am.v33iespecial.51568>