

Inteligencia Artificial en Computer Visión para determinar tipo y calidad de granos de Soja

Maranzana, R.^{1,2}; Santander, C.^{1,2}; Marinzalda, F.^{1,2}; Buffarini, L.^{1,3}; Grasso, C.¹; Ibarzabal, C.¹; Ordoñez, M.¹; Ordiales, H.¹; Correa, C.¹; Verrastro, S.¹

¹ Grupo de Inteligencia Artificial y Robótica, Universidad Tecnológica Nacional, FRBA

² Departamento de Ingeniería Industrial, Universidad Tecnológica Nacional, FRBA

³ Centro de e-Learning, Universidad Tecnológica Nacional, FRBA

Rmaranzana@frba.utn.edu.ar

Resumen. Este trabajo presenta un sistema de inteligencia artificial basado en técnicas de visión por computadora para evaluar la calidad de granos de soja, proponiendo una alternativa rápida y económica frente a los métodos manuales, al automatizar la evaluación de atributos como el tamaño, la forma, el color de los granos, la presencia de insectos y materias extrañas. Para ello, se recolectaron muestras de granos de soja sanos y dañados por diversas causas, incluyendo contaminación con materias extrañas e insectos. Se aplicaron distintas estrategias de clasificación automática de imágenes, que incluyeron modelos de Machine Learning con extracción manual de características y modelos de Deep Learning que no requieren este paso. Los resultados obtenidos demuestran que los modelos de Deep Learning superan en desempeño a los de Machine Learning en la tarea de clasificación de calidad de granos de soja.

Palabras clave: Calidad de granos, Visión por computadora, Inteligencia artificial, Machine Learning, Deep Learning.

Computer Vision Artificial Intelligence to establish variety and quality of soybean grains

Abstract. This work presents an artificial intelligence system based on computer vision techniques to assess soybean grain quality, offering a fast and cost-effective alternative to manual methods by automating the evaluation of attributes such as grain size, shape, color, and the presence of insects and foreign materials. To this end, samples of healthy and damaged soybean grains were collected, including those contaminated with foreign materials and insects. Various image classification strategies were applied, including Machine Learning models with manual feature extraction and Deep Learning models that do not require this step. The results show that Deep Learning models outperform Machine Learning models in the task of classifying soybean grain quality.

Keywords: Grain Quality, Computer Vision, Artificial Intelligence, Machine Learning, Deep Learning.

1 Introducción

Los estudios sobre calidad de granos han evaluado históricamente atributos como tamaño, color, forma y defectos determinantes en su clasificación, precio, seguridad alimentaria y eficiencia agroindustrial. Dicho análisis suele realizarse manualmente a través de peritos clasificadores, presentando subjetividad y siendo susceptibles de errores humanos (Saleres et al., 2019; Librandi et al., 2021).

La implementación de diferentes modelos de Machine Learning y Deep Learning permiten una evaluación más eficiente de la calidad de un lote de granos. Zhu et al. (2023) y Agarwal et al. (2023) abordan estrategias tradicionales de clasificación con modelos de Machine Learning que implican la extracción de variables analíticas seleccionadas por analistas expertos e ingeniería de características. Sobre la base del trabajo de Librandi et al. (2021), se desarrolló DeepSeed, una aplicación multiplataforma que emplea el modelo Faster RCNN ResNet152 COCO para estimar el grado de comercialización del maíz a partir de imágenes. A nivel internacional, la evaluación de calidad de granos incorpora modelos ligeros de redes neuronales profundas. Yang et al. (2024) con YOLOv7-tiny y Ma et al. (2024) con YOLOv8-HD demostraron su efectividad para detección en tiempo real. Con el objetivo de detectar granos no partidos, Bicici et. al (2025) emplea un etiquetado de granos de soja mediante Segment Anything Model (SAM) para detectar cada ejemplar individual que se desplazan a través de una cinta transportadora.

Esta investigación presenta un sistema de visión por computadora basado en inteligencia artificial como una alternativa rápida, precisa y económica a los métodos convencionales. Se emplean métodos de Machine Learning y Deep Learning para la determinación de la calidad de granos de soja.

2 Materiales y métodos

2.1 Muestras de granos y obtención de imágenes

Se tomaron ejemplares sanos junto con brotados, verdes, calcinados, quebrados, picados, amohosados, podridos y fermentados; además de materias extrañas, chamico e insectos. Se fabricó un dispositivo mediante impresión 3D, como se observa en la Figura 1 a), que mantiene una altura de captura de 23 cm. Se iluminó con luz artificial indirecta.

2.2 Etiquetado de imágenes

Se etiquetaron las imágenes con bounding boxes en Label Studio (Figura 1 b). Inicialmente, se clasificaron en dos grupos: granos sanos y “malos” (defectuosos, materias extrañas, chamico e insectos). Se segmentan 1274 imágenes de cada grano.




Fig. 1. a) Dispositivo de captura. b) Etiquetas. En rojo, un grano malo y en verde, otro bueno.

2.3 Modelos de clasificación

Se implementaron dos enfoques de inteligencia artificial:

1. Machine Learning, con extracción manual de características y modelos de ensamble (Random Forest, Gradient Boosting, AdaBoost, LightGBM y XGBoost) que son utilizados frecuentemente en modelos productivos (Géron, 2019).
2. Deep Learning con la red YOLOv8, aplicando transfer learning sobre un modelo preentrenado con COCO.

El desempeño se evaluó mediante exactitud (accuracy), tasa de positivos (recall), precisión y F1-score.

3 Resultados

3.1 Machine Learning con extracción manual de características



Se evaluó la calidad de 381 granos de soja con los métodos de la sección 2.3, y los resultados métricos se resumen en la Tabla 1. El modelo Random Forest se destacó con un F1 score del 62%, clasificando correctamente 283 de 305 granos “buenos” y 40 de 76 “malos”.

3.2 Deep Learning

El entrenamiento de YOLOv8 muestra curvas de pérdida decrecientes (Figura 2), evidenciando aprendizaje. Con una muestra de 192 granos, se alcanza un 98% de exactitud. Para comparar con Random Forest, la Figura 3 presenta las curvas F1-confidence de ambos modelos, donde YOLOv8 supera significativamente en F1-score.

Tabla 1. Comparativa de performance para modelos con características manuales.

Métrica	Accuracy (%)	Recall (%)	Precisión (%)	F1 (%)
Random Forest	86.61	56.44	71.83	62.06
Gradient Boosting	86.39	58.04	69.65	61.96
AdaBoost	85.82	54.77	69.1	59.93
LightGBM	84.58	53.95	65.04	58.18
XGBoost	84.47	51.76	66.59	56.48

**Fig. 2.** Curva de error por epochs de YOLOv8 en etapas de: a) Entrenamiento ; b) Validación.**Fig. 3.** a) Curvas F1-confidence de Random Forest. b) Curva F1-confidence de YOLO v8.

4 Conclusiones

Se experimentó con la captura de imágenes digitales de granos de trigo, maíz y soja, utilizando un soporte 3D diseñado y construido específicamente para este propósito.

Los modelos de inteligencia artificial procesaron las imágenes obtenidas. Del análisis de los modelos de visión por computadora, se determina que YOLOv8 muestra el mejor rendimiento en la determinación de la calidad de los granos de soja.

Para futuras investigaciones, se propone realizar experimentos que verifiquen la validez del método, explorando otras variantes para refinar los resultados y ampliando las evaluaciones a trigo y maíz, añadiendo una segmentación multiclase para detectar diferentes tipos de daños. Para la detección de granos, se estudiará la utilización del modelo SAM para la detección de ejemplares de granos.

5 Agradecimientos

La presente publicación es realizada en el contexto del Proyecto de Investigación y Desarrollo SIECBA0010264 del Grupo de Inteligencia Artificial y Robótica y el Departamento de Ingeniería Industrial de la Universidad Tecnológica Nacional.

Referencias

- Agarwal, D. y Bachan, P. (2023). Machine learning approach for the classification of wheat grains, *Smart Agricultural Technology*, 3, Artículo 100136.
- Bicici, U. C., Timmel, M. y Riegler-Nurscher, P. (2025). Automated labeling of soybeans for size measurements. 45. *GIL-Jahrestagung, Digitale Infrastrukturen für eine nachhaltige Land-, Forst- und Ernährungswirtschaft*, 207–212.
- Géron, A. (2019). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems* (2ª ed.). O'Reilly Media.
- Librandi, M., Corino, J., Tristán, P. y Felice, L. (2021). DeepSeed: aplicación multiplataforma para estimar la calidad de granos de maíz. *Memorias del Congreso Argentino en Ciencias de la Computación - CACIC 2021*, 1.
- Ma, N., Su, Y., Yang, L., Li, Z. y Yan, H. (2024). Wheat Seed Detection and Counting Method Based on Improved YOLOv8 Model. *Sensors*, 24(5), Artículo 1654.
- Saleres, A. S., Tristán, P. y Felice, L. (2019). Clasificador automático de la calidad de los granos de maíz. *Anales de CAI 2019*.
- Yang, L., Liu, C., Wang, C. y Wang, D. (2024). Maize Kernel Quality Detection Based on Improved Lightweight YOLOv7. *Agriculture*, 14(4), Artículo 618.
- Zhu, J., Cai, J., Sun, B., Xu, Y., Lu, F. y Ma, H. (2023). Inspection and classification of wheat quality using image processing. *Quality Assurance and Safety of Crops and Foods*, 15(3), 43–54.