



Revista ASCE Magazine, Periodicidad: Trimestral Octubre-Diciembre, Volumen: 4, Número: 4, Año: 2025 páginas 876 - 899

Doi: <https://doi.org/10.70577/asce.v4i4.474>

Recibido: 2025-09-17

Aceptado: 2025-09-29

Publicado: 2025-10-28

Optimización del envejecimiento artificial del arroz en una planta ecuatoriana: estudio de procesos, análisis de datos y propuesta de automatización

Optimization of Artificial Aging of Rice in an Ecuadorian Plant: Process Study, Data Analysis, and Automation Proposal

Autores

Milton Iván Villafuerte López¹

Carrera de Ingeniería Industrial

<https://orcid.org/0000-0003-2848-6877>

mvillafuerte@uteq.edu.ec

Universidad Técnica Estatal de Quevedo

Quevedo – Ecuador

Edison Eliceo Guano Trujillo²

Carrera de Ingeniería Industrial

<https://orcid.org/0009-0008-4910-7577>

edison.guano2018@uteq.edu.ec

Universidad Técnica Estatal de Quevedo

Quevedo – Ecuador

Ángel Moisés Avemáñay Morocho³

Carrera de Ingeniería Industrial

<https://orcid.org/0000-0003-3233-9730>

aavemanaym@uteq.edu.ec

Universidad Técnica Estatal de Quevedo

Quevedo – Ecuador

Cómo citar

Villafuerte López, M. I., Guano Trujillo, E. E., & Avemáñay Morocho, Ángel M. (2025). Optimización del envejecimiento artificial del arroz en una planta ecuatoriana: estudio de procesos, análisis de datos y propuesta de automatización. *ASCE MAGAZINE*, 4(4),



Resumen

El estudio aborda la optimización del proceso de envejecimiento artificial del arroz mediante la integración del análisis de procesos, la analítica de datos y la automatización industrial. Se mapeó el flujo del área de envejecimiento y se analizaron registros históricos de control de calidad que incluyen humedad, quebrado, color y temperatura, con el propósito de identificar las variables críticas que inciden en la estabilidad del producto. Para ello, se aplicó un modelo de regresión lineal múltiple orientado a predecir el tiempo de receta, alcanzando un coeficiente de determinación $R^2 \approx 0,65$ en entrenamiento y 0,61 en prueba, con un error medio absoluto (MAE) de 4,46 horas y un error cuadrático medio (MSE) de 26,9 horas cuadradas. Los resultados evidencian una fuerte correlación entre el quebrado de ingreso y el de salida ($r \approx 0,98$), lo que confirma que la calidad de la materia prima influye directamente en la conformidad del producto final. Asimismo, se identificó un desacople promedio de 4–7 °C entre la temperatura de receta y la temperatura real del arroz, asociado a pérdidas térmicas y variaciones en la operación. Estos hallazgos indican que la variabilidad del proceso no proviene principalmente de las condiciones del grano, sino de la gestión tiempo–temperatura durante el envejecimiento. En conjunto, el estudio demuestra que la combinación de técnicas de modelado estadístico y análisis de datos proporciona una base objetiva para mejorar la uniformidad, reducir el desperdicio y fortalecer la eficiencia operativa en el procesamiento de arroz envejecido.

Palabras clave: Arroz envejecido; Control de procesos; Regresión múltiple; Analítica de datos; Calidad.



Abstract

This study focuses on optimizing the artificial aging process of rice through the integration of process analysis, data analytics, and industrial automation. The workflow of the aging area was mapped, and historical quality-control records—including moisture, broken grains, color, and temperature—were analyzed to identify critical variables influencing product stability. A multiple linear regression model was applied to predict recipe time, achieving a coefficient of determination of $R^2 \approx 0.65$ for training and 0.61 for testing, with a mean absolute error (MAE) of 4.46 hours and a mean squared error (MSE) of 26.9 hours squared. Results showed a strong correlation between broken grains at inlet and outlet ($r \approx 0.98$), confirming that raw material quality directly affects final product conformity. Additionally, an average offset of 4–7 °C was observed between the recipe setpoint and the actual rice temperature, attributed to thermal losses and operational variations. These findings indicate that process variability originates primarily from time–temperature management rather than grain properties. Overall, the study demonstrates that combining statistical modeling techniques and data analytics provides an objective foundation for improving product uniformity, reducing waste, and strengthening operational efficiency in rice aging operations.

Keywords: Aged rice, Process control, Multiple regression, Data analytics, Quality.

Introducción

El arroz (*Oryza sativa L.*) constituye uno de los cereales más importantes en la alimentación humana, siendo el sustento diario de más de la mitad de la población mundial. Su alto contenido de carbohidratos lo convierte en una fuente energética esencial y en un componente central de la dieta básica en Asia, África y América Latina. En Ecuador, su relevancia trasciende el ámbito nutricional, pues representa un pilar socioeconómico que sostiene a miles de productores, comercializadores y trabajadores vinculados a la agroindustria. De acuerdo con la Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO), el consumo per cápita de arroz en el país alcanzó 42,3 kg en 2018, cifra cercana al promedio mundial (58,4 kg) pero superior al promedio latinoamericano (38 kg) (Andrade et al., 2022). Esta demanda constante consolida al arroz como uno de los principales aportantes al Producto Interno Bruto (PIB) agrícola nacional, con una participación del 9,1 % (Plan V, 2021). Desde una perspectiva geográfica, la producción arrocera ecuatoriana se concentra en las provincias de Guayas y Los Ríos, que reúnen más del 70 % del área cultivada (Diego et al., 2021). Aunque Ecuador no es un exportador neto, su mercado interno es robusto y altamente competitivo, caracterizado por márgenes de precio sensibles y una fuerte diferenciación por calidad. El precio promedio del arroz blanco en 2019 fue de 0,94 USD/kg (Andrade et al., 2022), lo que obliga a las plantas industriales a optimizar la eficiencia de sus procesos y mantener estándares de calidad estables para conservar su rentabilidad.

La calidad del arroz está determinada por un conjunto de propiedades fisicoquímicas: humedad, color, porcentaje de grano quebrado y comportamiento en cocción, que dependen tanto de la variedad como del manejo postcosecha y de los procesos industriales. En Ecuador predominan variedades como SFL 011, Ferón y INIAP 14, desarrolladas por el Instituto Nacional de Investigaciones Agropecuarias (INIAP) para combinar productividad y rendimiento en molienda (Diego et al., 2021). No obstante, cada variedad responde de manera distinta al almacenamiento, al secado y a los tratamientos térmicos, factores que inciden directamente en la estabilidad del grano y su aceptación por parte del consumidor.

Entre los tratamientos postcosecha más importantes se encuentra el envejecimiento del arroz, proceso que busca mejorar las características sensoriales y de cocción mediante cambios fisicoquímicos controlados en la estructura del grano. Tradicionalmente, este envejecimiento era

natural y requería varios meses de almacenamiento bajo condiciones de humedad y temperatura específicas. Sin embargo, las limitaciones de espacio, tiempo y riesgo de infestación condujeron al desarrollo del envejecimiento artificial o acelerado, que reproduce en horas los efectos del reposo prolongado. En este método, el arroz pilado se somete a temperaturas entre 70 °C y 80 °C durante un período controlado, reduciendo su humedad interna por debajo del 10 % y promoviendo la gelatinización parcial del almidón, lo que mejora la firmeza y reduce la pegajosidad durante la cocción (Saikrishna et al., 2018).

El envejecimiento artificial no solo permite obtener un producto con comportamiento culinario más uniforme, sino que también ofrece ventajas operativas como la reducción de inventarios inmovilizados y la optimización del flujo de producción. A diferencia del arroz fresco, que tiende a formar masas pegajosas por su mayor contenido de amilopectina, el arroz envejecido presenta granos más sueltos, resistentes y con mejor rendimiento volumétrico, atributos especialmente apreciados por los consumidores de la región andina ecuatoriana (Andrade Fornell & Tobalina Ditto, 2009).

No obstante, el éxito del envejecimiento artificial depende del control preciso de las variables de proceso: temperatura, tiempo de exposición, humedad inicial, ventilación, y características de la materia prima. De acuerdo con el Instituto Ecuatoriano de Normalización (INEN, 2014), el arroz pilado debe presentar un máximo de 13 % de humedad y un porcentaje de granos enteros superior al 70 %. Cualquier desviación en estos parámetros puede afectar la conformidad del producto final. El control empírico o manual de estas variables puede conducir a variaciones significativas en la calidad, manifestadas en el color del grano, su quebrado o su grado de deshidratación.

Desde la ingeniería industrial, estas variaciones se interpretan como fuentes de variabilidad del proceso que deben identificarse, medirse y minimizarse. La literatura especializada coincide en que la estandarización de procesos y la aplicación del control estadístico constituyen las herramientas más efectivas para lograr consistencia y reducir defectos (Cuatrecasas, 2005; Uribe Gómez, 2021). A través de técnicas como los gráficos de control o el análisis de capacidad de proceso, es posible determinar si la variación observada proviene de causas comunes, inherentes al sistema o de causas especiales (errores), fallas o condiciones externas (Hernández-Pedrera & Da Silva-Portofilipe, 2016).

Complementariamente, el análisis de datos y la incorporación de modelos predictivos permiten transformar la información operativa en conocimiento útil para la toma de decisiones. En la última década, herramientas como Python y R han demostrado ser plataformas robustas para el análisis estadístico y la implementación de modelos de regresión, clasificación y control predictivo (Condor & Rocca, 2020; Belt, 2020). En la industria alimentaria, el uso de big data y aprendizaje automático ha permitido detectar patrones, optimizar recetas, reducir desperdicios y anticipar fallas en tiempo real (Sadiku et al., 2020; Zhu et al., 2022).

Un ejemplo análogo es el trabajo de Deng y Lyu (2020), quienes desarrollaron un sistema de evaluación y predicción del estado operativo de un alto horno mediante big data, mejorando la eficiencia y el control térmico. Del mismo modo, Weichert et al. (2019) destacan que la adopción de machine learning en procesos de manufactura reduce tiempos, consumo energético y defectos de producción, al permitir ajustar los parámetros en función de datos históricos y condiciones del entorno.

En este contexto, el arroz envejecido puede considerarse un producto de proceso térmico multivariable, donde el resultado final depende de la interacción entre propiedades iniciales del grano y condiciones de operación. El tratamiento inadecuado —ya sea por exceso de calor, insuficiente ventilación o tiempos incorrectos— puede ocasionar daños irreversibles, como el aumento del porcentaje de grano partido, la pérdida de brillo o el oscurecimiento del color, reduciendo la aceptación del producto y su valor de mercado (Silos Córdoba, 2021).

El ciclo de Deming, resulta especialmente útil para estructurar procesos de mejora sostenible. En la fase de *planificación* se definen los parámetros críticos de control; en la de *ejecución* se aplican los estándares y se documentan resultados; en la etapa de *verificación* se analizan los indicadores de desempeño; y en la de *actuación* se implementan ajustes correctivos (Manobanda et al., 2019). Este enfoque favorece la reducción de desperdicios, la trazabilidad de la información y la consolidación de una cultura de calidad basada en evidencia.

Finalmente, la relevancia académica del presente estudio radica en su capacidad para integrar disciplinas complementarias. Esta convergencia permite construir un marco metodológico replicable en otras industrias alimentarias, consolidando el papel de la ingeniería industrial como motor de innovación y sostenibilidad productiva en el país.

Material y Métodos

Diseño del estudio y enfoque

Estudio aplicado, descriptivo-analítico y de corte transversal, orientado a optimizar el envejecimiento artificial del arroz mediante estudio de procesos, analítica de datos operativos y diseño de control automático. El mapeo de procesos siguió lineamientos de diagramación institucional para asegurar trazabilidad de entradas, actividades, salidas y controles (IICA, 2022). El análisis de procesos en organizaciones productivas busca detectar ineficiencias en el uso de recursos mediante un estudio sistemático de las actividades, con el fin de sustituirlas por métodos de trabajo más eficientes y efectivos (Núñez & Sarmiento, 2014).

Contexto del proceso y unidad de análisis

La unidad de análisis es el área de envejecimiento de una planta arrocera ecuatoriana con líneas de pilado, envejecedoras, ventilación/temple y selección. El proceso objeto incluye: recepción y pilado, acondicionamiento, envejecimiento a temperatura controlada, ventilación y liberación a selección/empacado, con parametrización tiempo–temperatura definida por receta.

Datos y fuente

Se trabajó con registros históricos del control de calidad y operación del periodo perteneciente al año 2024, consolidados desde hojas de ruta/formatos internos. Se excluyeron registros incompletos o inconsistentes y se anonimizaron identificadores de marca/semilla.

Variables e indicadores

Variables de materia prima y proceso: humedad de ingreso/salida (%), quebrado de ingreso/salida (%), color (escala interna), temperatura de arroz/ambiente (°C), tiempo de receta (h), temperatura de receta (°C), marca/semilla y observaciones de cocción. Indicadores derivados: merma/desperdicio por lote, tiempo de ciclo y conformidad contra especificación (INEN, 2014).



Procedimiento

- Levantamiento y validación de datos: depuración, codificación de variables y control de calidad de registros.
- Mapeo del proceso: diagramas de flujo para identificar puntos de control (IICA, 2022).
- Caracterización estadística: estadísticos descriptivos, análisis de distribución, boxplots y correlaciones de Pearson para relaciones clave (p. ej., quebrado ingreso–salida; humedad–tiempo).
- Modelado predictivo: regresión lineal múltiple con partición entrenamiento/prueba para explicar el tiempo de receta a partir de variables de materia prima y setpoints, siguiendo buenas prácticas de modelado en entornos industriales (Jeong et al., 2020, Fuentes, 2015).

Análisis estadístico

Se verificaron supuestos del modelo (linealidad, homocedasticidad, normalidad de residuos, multicolinealidad) y se evaluó desempeño con R^2 , MAE y MSE. El control de procesos se enmarcó en principios de CEP para monitorear estabilidad y capacidad (Uribe Gómez, 2021).

Consideraciones éticas y de confidencialidad

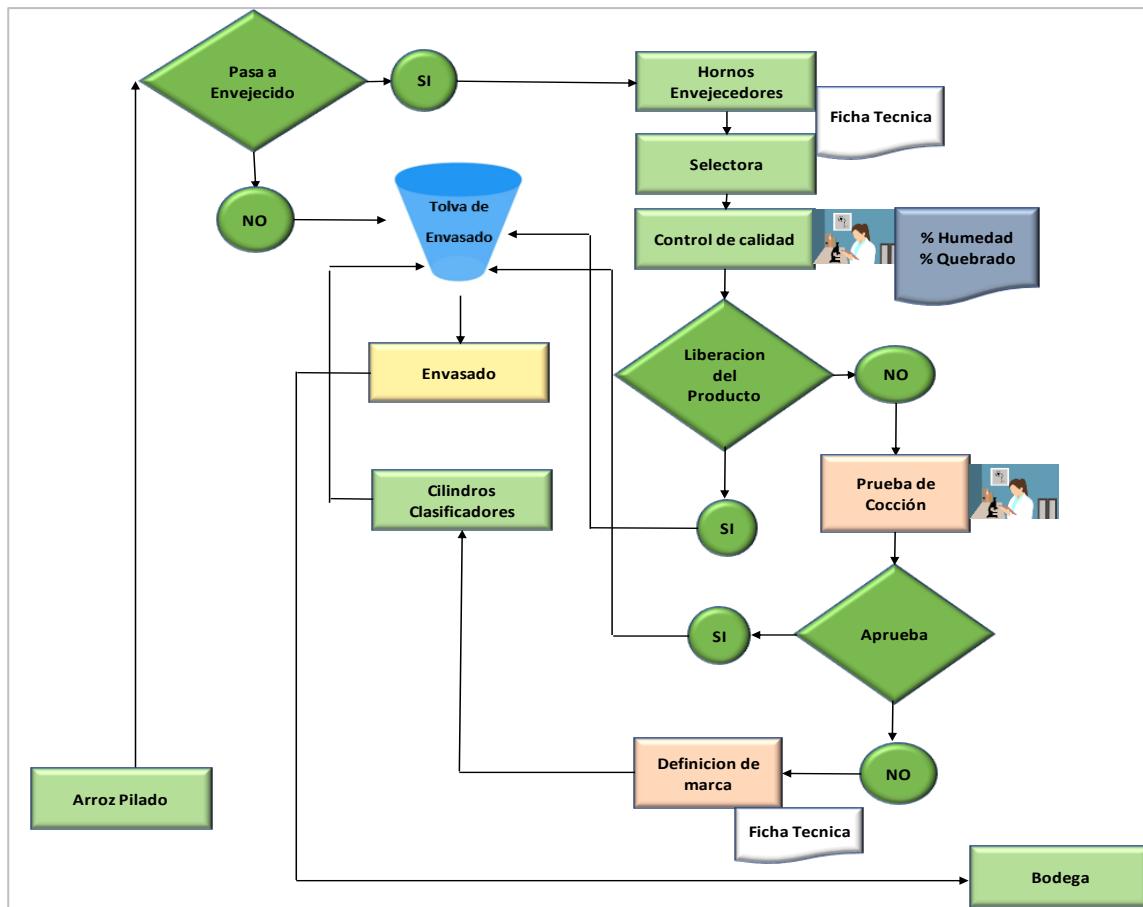
Se utilizaron datos operativos anonimizados, sin información personal, con autorización interna y uso exclusivo para fines de mejora del proceso.

Resultados

El envejecimiento artificial del arroz se lo realiza mediante maquinas envejecedoras donde se deposita el arroz pilado en un compartimiento cerrado para luego ser sometido a altas temperaturas con el fin de acelerar el proceso de envejecido. De igual forma es importante resaltar que este proceso tiene un tiempo de duración de 35-40 horas aproximadamente, dependiendo de las características fisicoquímicas del grano, el tipo y la variedad del arroz que se producen en la zona de milagro y sus comunidades cercanas.

Figura 1

Diagrama de flujo del área de envejecimiento artificial del arroz



Fuente: Elaboración propia.

En la línea de producción secuencial del arroz envejecido, las operaciones de fabricación desempeñan un papel crucial en la generación de subproductos. Un secado y almacenado adecuados son fundamentales para evitar que el arroz se parta y debilite durante el traslado al área de envejecimiento. De esta forma, se reduce el margen de error y se controla el porcentaje de granos partidos, evitando irregularidades en los estándares de calidad establecidos para cada marca de arroz envejecido.

Una forma en que la industria alimentaria puede tomar más control de sus parámetros de calidad es a través del análisis de datos. Para mantenerse competitivo y seguir el ritmo de los hábitos de compra volubles de los consumidores, la industria alimentaria debe considerar la implementación



de herramientas de análisis de datos. Lo bueno del análisis de datos es que se puede implementar en cualquier parte del mundo (Sadiku et al., 2020).

En la tabla 1, se observa el promedio de las temperaturas registrada en la envejecedora 14 en el mes de octubre del 2024, una de las maquinas con una capacidad aproximada de 155 qq. Este control de temperatura se lo realiza de manera manual digitalizando cada 1 o 2 horas para monitorear si hay algún error tanto en las resistencias quienes son las que regulan el proceso y la temperatura del arroz mediante su exposición calorífica.

Tabla 1
Promedio de temperatura registrada en la envejecedora N°14

ENVEJECEDORA N°14		
Horas de Proceso	Temperatura de Arroz (C)	Temperatura de las resistencias (C)
16:50	34	76
1:13	40	76
2:39	45	76
4:23	50	76
6:45	55	76
8:55	60	76
10:47	63	76
12:28	66	76
15:20	67	76
17:32	68	76
19:10	68	76
22:38	70	77
24:17	70	77
26:55	70	77
28:40	71	77
30:35	71	77
32:46	71	78
34:42	72	78
36:00	72	78

Nota: Elaboración propia.

Si existe alguna irregularidad con la humedad y el color durante el proceso se suele cambiar los parámetros ocasionando una variabilidad de temperatura durante todo el proceso de envejecido

ocasionando que el arroz en su interior se deshidrate hasta llegar a quebrarse y no lograr las características deseadas del producto final. En el envejecido artificial del arroz por lo general si el grano presenta buenas condiciones de humedad, quebrado y color llega a partirse hasta máximo un 2%. Respecto a la humedad en el ingreso muestra porcentajes generales de alrededor de 9-11% y en la salida del proceso del 7-9% aproximadamente.

De igual forma durante todo el seguimiento por parte del procesador está expuesto a las condiciones del entorno de trabajo ya que al ser un espacio cerrado provoca fatiga tanto por el ruido y el calor acumulado durante la operación de las máquinas. Así mismo los movimientos monótonos influyen en la toma de decisiones al momento de procesar el arroz provocando que se lo realice de manera incorrecta y por ende el producto no sea el adecuado para los consumidores.

En la figura 2 se puede observar el proceso cronológico en relación a las máquinas para el envejecimiento del arroz.

Figura 2

Cronología de las maquinarias para el proceso del arroz envejecido.



Fuente: Elaboración propia.

Este cuadro muestra cómo las características fisicoquímicas del arroz pueden afectar la producción y el desperdicio en el proceso de envejecimiento. De acuerdo con los operarios cuando las características son buenas, la producción es de 154 quintales con solo 1 de desperdicio. Sin embargo, si los controles son deficientes y las características son malas, la producción se reduce a

151-152 quintales con un desperdicio de 3-4. Por ello es importante mantener un control de calidad adecuado para obtener una producción óptima y minimizar el desperdicio en este proceso.

Análisis exploratorio de datos.

Se realizó el siguiente análisis de las variables de importancia del control del envejecimiento artificial del arroz, en la tabla 2 se puede observar las estadísticas básicas de la base de datos disponible. Una de las características destacadas de Python es su naturaleza de tipado dinámico en la programación. Esto significa que no es necesario que el programador declare explícitamente el tipo de las variables, ya que se determina de forma automática durante la ejecución del programa (Romero, 2019).

Tabla 2.
Estadísticas básicas de la base de datos

	count	mean	std	min	25%	50%	75%	max
Tolva de Origen	114.0	1.631579	0.484506	1.000	1.000	2.000	2.00	2.000
Cantidad qq	114.0	154.684211	0.801721	153.000	155.000	155.000	155.00	156.000
Color de Ingreso	114.0	0.378158	0.013567	0.360	0.360	0.380	0.39	0.399
Humedad de Ingreso %	114.0	0.107105	0.004973	0.093	0.106	0.108	0.11	0.113
Quebrado de Ingreso %	114.0	0.050000	0.032750	0.020	0.030	0.030	0.07	0.110
Humedad de Salida %	114.0	0.073737	0.006733	0.065	0.068	0.071	0.08	0.084
Quebrado de Salida %	114.0	0.060000	0.044084	0.020	0.030	0.040	0.11	0.140
Temperatura del arroz ©	114.0	70.526316	1.965231	65.000	70.000	71.000	72.00	74.000
Temperatura del ambiente ©	114.0	26.315789	1.177336	25.000	25.000	26.000	28.00	28.000
Tiempo h de la Receta	114.0	6.096491	7.564436	1.000	1.000	1.000	12.00	20.000
Temperatura de la Receta	114.0	76.570175	0.911765	74.000	76.000	77.000	77.00	78.000

Nota: Elaboración propia.

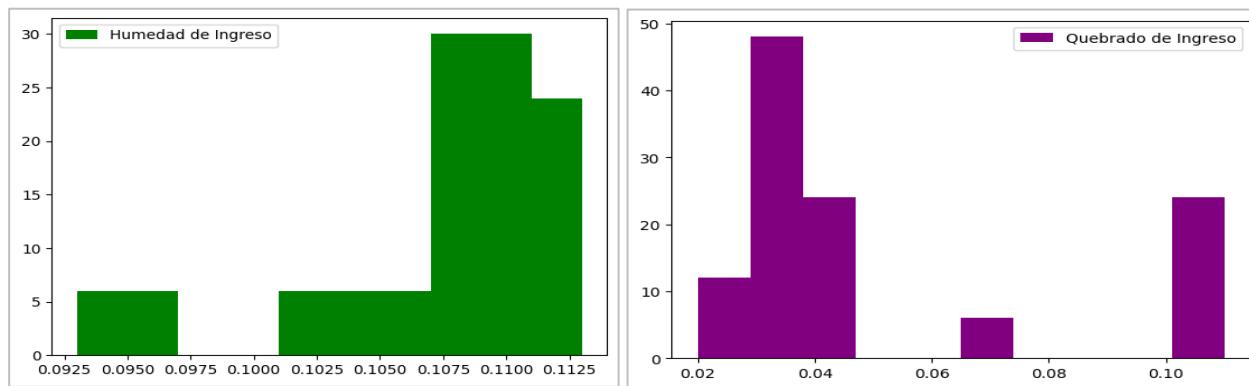
Los resultados muestran baja variabilidad en “tolva de origen” ($DE = 0,484$) y “cantidad qq” ($DE = 0,801$), así como desviaciones aún menores en las propiedades fisicoquímicas del grano: “Color de Ingreso”, “Humedad de Ingreso %”, “Quebrado de Ingreso %”, “Humedad de Salida %” y “Quebrado de Salida %”. En contraste, el “tiempo h de la receta” ($DE = 7,564$) y la “temperatura de la receta” ($DE = 0,911$) exhiben mayor dispersión, lo que sugiere que los ajustes operativos de estos parámetros son la principal fuente de heterogeneidad del proceso. En términos de gestión,

esta evidencia apunta a priorizar la estandarización y el control en lazo cerrado sobre tiempo–temperatura, dado su potencial impacto en la calidad del arroz envejecido y en la estabilidad de los indicadores de merma y quebrado, en caso de valores fuera de los límites de control se deben tomar medidas correctivas (Cabezón Gutiérrez & Blas Zurro, 2014).

En la estadística por cuartiles, el 25% de los datos (Q1) se concentra en la tolva 1, con ingreso constante de 155 qq y valores estables: color = 36%, humedad de ingreso ≈ 10,6%, quebrado de ingreso = 3%, humedad de salida = 6,8% y quebrado de salida = 3%. En la mediana (Q2), predomina la tolva 2 y se mantienen rangos intermedios similares (color = 38%, humedad de ingreso = 10,8%, quebrado de ingreso = 3%, humedad de salida = 7,1%, quebrado de salida = 4%). Para el 75% (Q3), continúa la tolva 2 y se observan leves incrementos (color = 39%, humedad de ingreso = 11%, quebrado de ingreso = 7%, humedad de salida = 8% y quebrado de salida = 11%), junto con temperaturas más altas (hasta 77 °C) y un aumento del tiempo de receta (~12 h), coherentes con el mayor quebrado observado.

Figura 3

Variables de ingreso del arroz



Humedad de ingreso del arroz.

Quebrado de ingreso del arroz

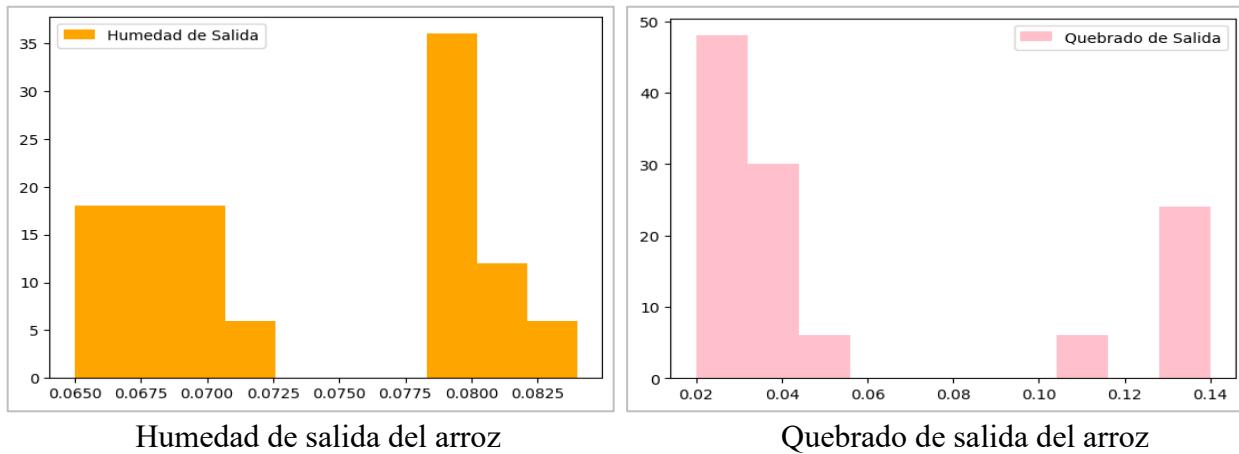
Fuente: Elaboración propia.

En la figura 3 se puede ver el comportamiento de las variables clave de ingreso muestran concentraciones claras y pocos modos secundarios: la humedad de ingreso se agrupa principalmente en 10,75–11,0% (~30% de observaciones), con un pico en 11,25% (23%) y aportes menores en 9,3–9,7% y 10,1–10,7% (6% cada rango). En el quebrado de ingreso, predomina el 3%

(48%), seguido por 4% y 11% (23% cada uno), mientras que el 2% y el 7% representan 12% y 5%, respectivamente. En conjunto, estos patrones sugieren insumos relativamente estables alrededor de rangos operativos esperados, con colas que conviene vigilar para mitigar variabilidad desde el origen del proceso.

Figura 4

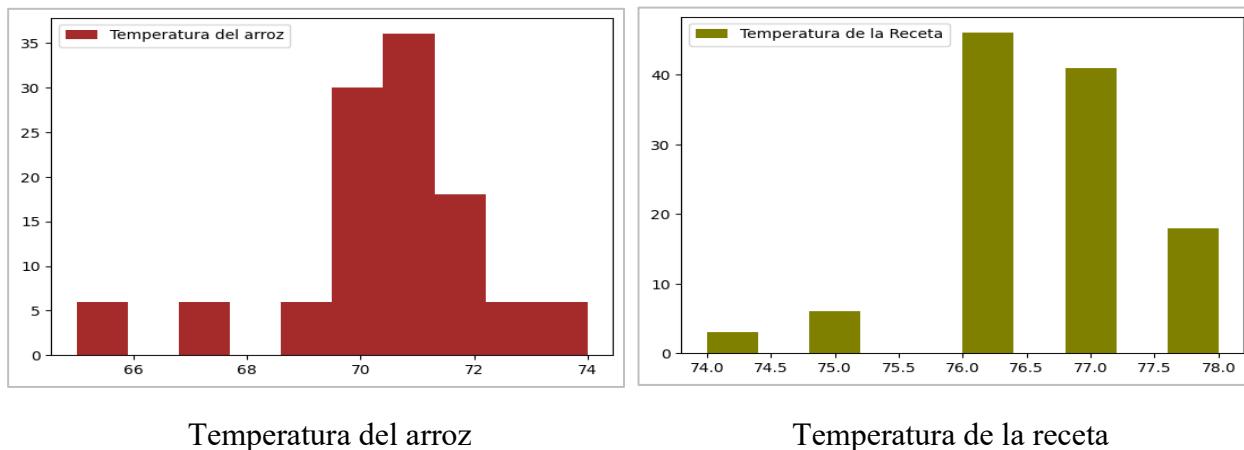
Variables de salida del arroz



Fuente: Elaboración propia.

En la figura 4 se puede observar las variables de salida; en humedad de salida, predomina 7,9–8,0% (33%), seguido por 6,5–7,0% (18%) y 8,1% (12%); los valores de 7,1% y 8,2% aportan 6% del total. En quebrado de salida, el 2–3% reúne 48% de los registros, el 4% aporta 30% y el rango 13–14% alcanza 23%; porcentajes menos frecuentes como 5% y 11% suman 5%. En conjunto, el proceso tiende a centrarse cerca de los objetivos de calidad (humedad ~8% y quebrado bajo), pero presenta colas que conviene monitorear para reducir variabilidad y prevenir desviaciones en el producto final.

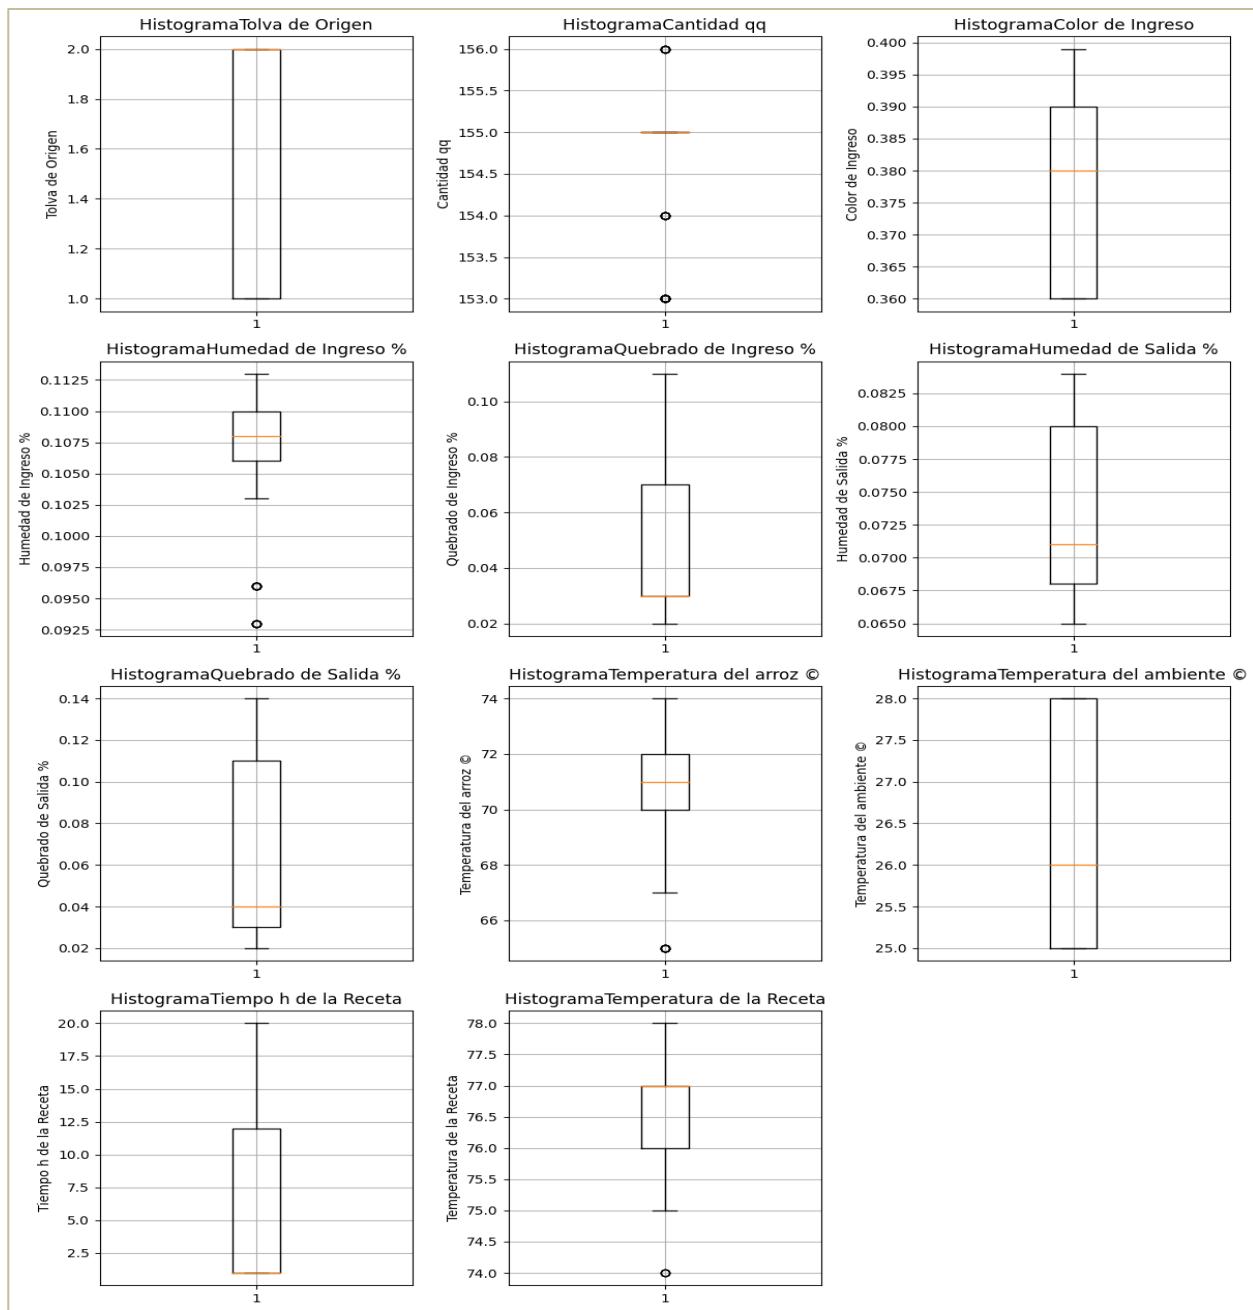
Figura 5
Variables de salida del arroz



Fuente: Elaboración propia.

Los diagramas de cajas (Figura 6) revelan que la “tolva de origen” tiene una media proveniente de la tolva 2. En cuanto a la capacidad de llenado, se observa una frecuencia normal de 155 quintales de arroz, pero también se presentan outliers (valores atípicos) de 153, 154 y 156 quintales. Respecto a los valores porcentuales se encuentra que en el color de ingreso oscilan entre 36 a 39,9% siendo la más recurrente el 38%. Dichos diagramas se desarrollan para todas las variables importantes. La temperatura ambiente se mantiene relativamente constante (~25–27 °C). En conjunto, el proceso entra con insumos homogéneos, pero requiere cerrar y estabilizar el control tiempo–temperatura para reducir variabilidad en el quebrado final.

Figura 6
Diagramas de cajas de las variables vitales

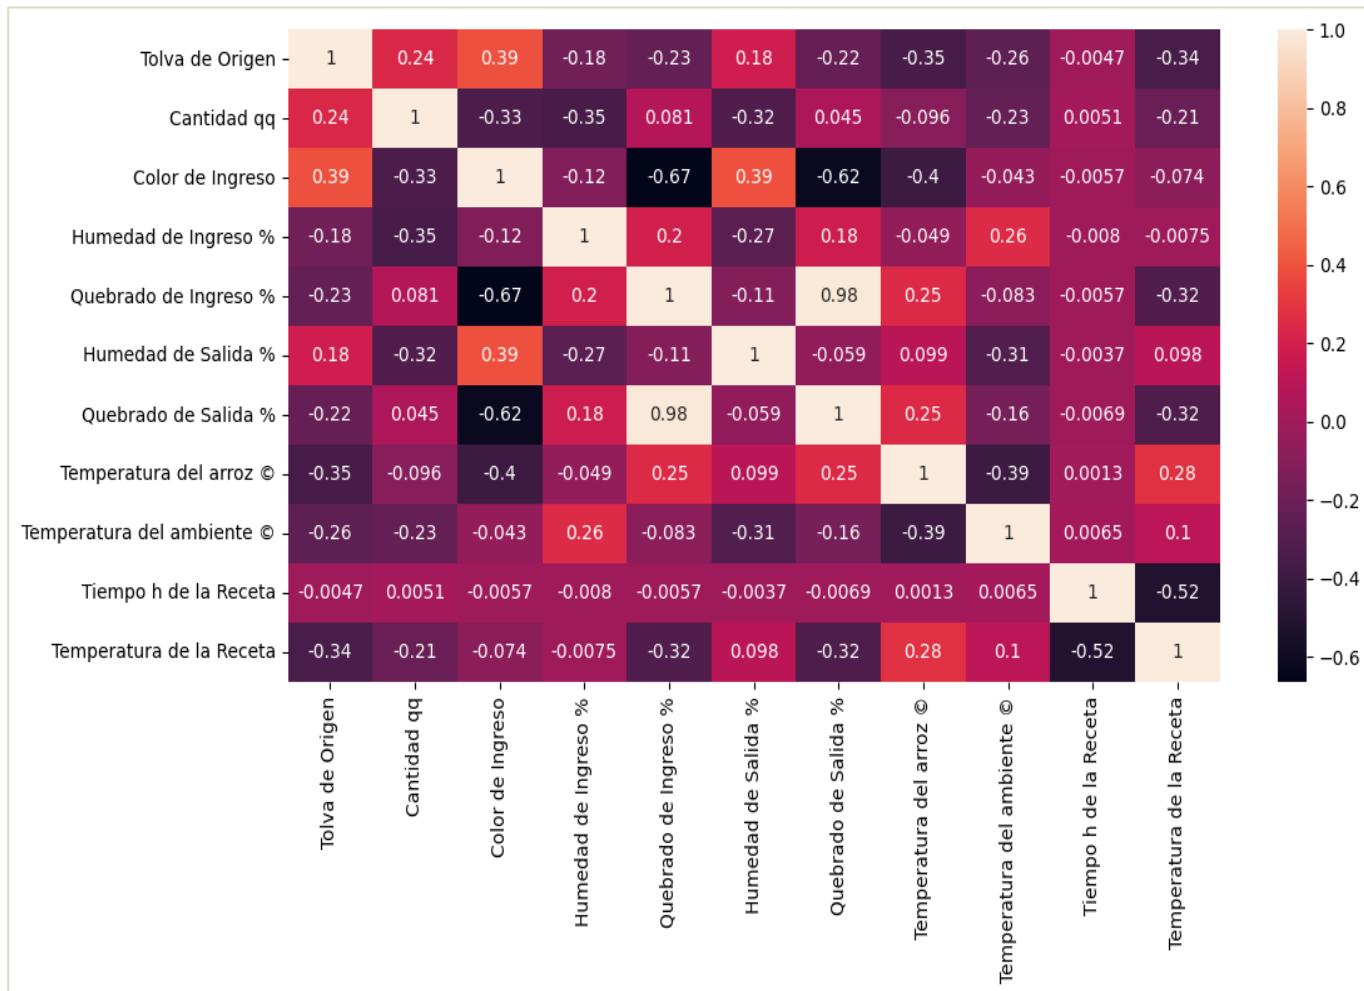


Fuente: Elaboración propia.

Para explorar relaciones entre variables del proceso, se presenta un heatmap de correlaciones de Pearson que incluye humedad (ingreso/salida), quebrado (ingreso/salida), temperatura del arroz, temperatura de la receta y tiempo de receta. Los tonos intensos indican asociaciones más fuertes ($|r| = 0.5\text{--}0.8$), útiles para identificar pares críticos, así como posibles redundancias (multicolinealidad) que conviene considerar antes del modelado.

Figura 7

Heatmap de correlación de las variables



Fuente: Elaboración propia.

Modelo de regresión lineal múltiple

Objetivo del modelo

Estimar el tiempo de la receta (h) en función de características de entrada y setpoints operativos, con el fin de identificar palancas de control y cuantificar su efecto esperado (Rojo, 2017; Ochoa Sangrador, Molina Arias, & Ortega Páez, 2023).

Variables y preprocesamiento

Variables candidatas: humedad de ingreso (%), quebrado de ingreso (%), color de ingreso, temperatura de la receta (°C), temperatura del arroz (°C), cantidad (qq) y tolva (como factor si aplica). Se inspeccionó ausencia de datos, valores atípicos, codificación de categóricas y escalas; se estandarizaron predictores si fue necesario para interpretación comparada de coeficientes (Uribe Gómez, 2021).

Especificación del modelo

La ecuación que se aplica al modelo de estudio sería:

$$TiempoReceta_i[h] = \beta_0 + \beta_1.HumIng_i[\%] + \beta_2.QueIng_i[\%] + \beta_3.ColorIng_i[^\circ C] + \beta_4.TempReceta_i[^\circ C] + \beta_5.TempArroz_i[^\circ C] + \beta_6.Cantidad_i[qq] + \varepsilon_i. \quad (1)$$

Donde:

TiempoReceta: horas de envejecimiento programadas (h).

HumIng: humedad de ingreso (%).

QuebIng: quebrado de ingreso (%).

ColorIng: color de ingreso (escala interna, adimensional).

TempReceta: temperatura de la receta (setpoint, °C).

TempArroz: temperatura del arroz medida (°C).

Cantidad: carga del lote (qq).

ε_i : término de error.

Estimación y validación.

Se ajustó OLS con partición train/test (70/30) y validación cruzada k-fold para robustez. Métricas: R², R² ajustado, MAE y MSE. La importancia relativa se reporta con coeficientes estandarizados (β) y IC=95%.

Resultados del modelo.

Figura 8
Score del modelo de predicción

```
[ ] # bondad del modelo o capacidad predictiva R2 o factor de determinación (0, 1)
      modelo.score(X_train,y_train)
0.6475696857329409

[ ] # R2 con la data de test
      modelo.score(X_test,y_test)
0.61470310043239
```

Fuente: Elaboración propia.

En la figura 8 se observa un R² de 0.647 en el conjunto de entrenamiento y 0.614 en el conjunto de prueba, lo cual sugiere que el modelo explica aproximadamente el 65% y el 61.5% de la variabilidad en el tiempo de envejecimiento del arroz, respectivamente.

El valor que se evidencia responde más del 50% cercano a 1 indicando que el modelo se ajusta bien a los datos y es capaz de predecir la variable objetivo con precisión. Sin embargo, hay una brecha entre el R² del conjunto de entrenamiento y el conjunto de prueba, lo que podría sugerir cierto grado de sobreajuste o falta de generalización del modelo.

El modelo (Figura 9) presenta un MAE = 4,46 (unidades de tiempo), es decir, en promedio sus predicciones del tiempo de envejecimiento se desvían del valor real en unas 4,5 unidades. El MSE = 26,87 implica un RMSE = 5,18, lo que indica que los errores grandes pesan más que los pequeños (mayor sensibilidad a atípicos que el MAE). En conjunto, las métricas señalan un desempeño

moderado: el MAE resume el error típico y el RMSE sugiere la presencia de algunos desvíos mayores. La utilidad práctica del modelo dependerá de comparar estos errores con la escala operativa del proceso (p. ej., rango/mediana del tiempo de receta); si 4–5 unidades representan una fracción manejable del ciclo, el modelo puede apoyar el ajuste de setpoints y la planificación, aunque conviene explorar mejoras (variables adicionales, no linealidades, robustez a outliers).

Figura 9
MAE Y MSE del modelo de predicción

```
[ ] MAE = mean_absolute_error(y_test,y_pred)
MAE
4.4646739130434785

[ ] MSE = mean_squared_error(y_test,y_pred)
MSE
26.867357336956523
```

Fuente: Elaboración propia.

Discusión

La homogeneidad de entradas indica que la variabilidad del producto no proviene principalmente de la materia prima, sino de la ejecución de tiempo–temperatura. El offset entre setpoint y temperatura real del arroz sugiere pérdidas térmicas, efectos de carga/ventilación y/o rezagos de control; cerrar el lazo de temperatura con sensórica adecuada y lógica PLC debería reducir el error estacionario (Dorf & Bishop, 2005; Weichert et al., 2019). La fuerte dependencia del quebrado de salida respecto al quebrado de ingreso resalta la relevancia del control de calidad a la entrada y la necesidad de bandas de receta condicionadas por humedad/quebrado iniciales (INEN, 2014). Los resultados del modelo ($MAE = 4\text{--}5 \text{ h}$) son operativamente útiles para recomendación de setpoints y planificación, aunque todavía hay margen de mejora incorporando interacciones/no linealidades y gestión de outliers (Ochoa Sangrador, Molina Arias, & Ortega Páez, 2023; Jeong et al., 2020).

Conclusiones

El desempeño del proceso confirma que la variabilidad del producto final no se origina principalmente en la materia prima: las variables de entrada (humedad, color y quebrado de ingreso) muestran dispersión baja y estabilidad operativa. La heterogeneidad relevante proviene de la ejecución tiempo–temperatura durante el envejecimiento. Se evidencia un desacople sistemático entre la temperatura de la receta (setpoint estable en 76–77 °C) y la temperatura real del arroz (modos 70–72 °C), con un offset de ~4–7 °C. Este sesgo sugiere pérdidas térmicas, efectos de carga/ventilación y rezagos de control que impiden la convergencia al setpoint y amplifican la dispersión de resultados.

El quebrado de ingreso es el principal predictor del quebrado de salida (correlación muy alta), por lo que mantener calidad de entrada consistente y políticas de recepción/selección robusta es condición necesaria para minimizar el daño mecánico y estabilizar la conformidad. El compromiso tiempo–temperatura observada (relación negativa entre setpoint y duración) indica decisiones operativas coherentes con la física del proceso, pero su aplicación no estandarizada contribuye a variabilidad; formalizar bandas de receta condicionadas por humedad/quebrado de ingreso reducirá dispersiones entre lotes.

El modelo OLS para tiempo de receta ($R^2=0,65$; $MAE=4,46$ h; $MSE=26,9$ h²) es útil a nivel operativo para recomendar setpoints y planificar capacidad, aunque persisten errores puntuales; incorporar variables de carga/flujo de aire y estrategias no lineales podría mejorar la precisión. Operativamente, se recomienda cerrar el lazo de control de temperatura con sensórica calibrada, verificación de ubicación/aislamiento térmico y lógica PLC con alarmas de error estacionario, más un checklist de liberación por lote (humedad y quebrado objetivo).

Referencias Bibliográficas

1. Andrade, R., Urioste, S., Lourido, D., Vergara, J. D., Marín, D., Loaiza, K., Moná, A., García, C., Graterol Matute, E. J., & Labarta, R. (2022). Rice Observatory: Monitoring survey and open access data for the rice sector version 1.0. *Rice Observatory*.
2. Belt, W. (2020). *Algoritmos y estructuras de datos en Python Un enfoque ágil y estructurado* (A. Molina, Ed.; Primera). UADER.
3. Cabezón Gutiérrez, S., & Blas Zurro, J. I. de. (2014). *Control de Calidad en la Producción Industrial*. <http://uvadoc.uva.es/handle/10324/13153>
4. Condor, E. E., & Rocca, M. A. (2020). *Algoritmos resueltos con Python* (Vol. 1). EIDEC. <https://doi.org/10.34893/6kbn-5a63>
5. Cuatrecasas, L. (2005). *Gestión Integral de la Calidad: Implantación, Control y Certificación* (X. Jordi, Ed.; Tercera). Planeta DeAgostini Profesional y Formación. https://www.academia.edu/34412668/Gesti%C3%B3n_Integral_de_la_Calidad_Llu%C3%A1Ds_Cuatrecasas
6. Deng, Y., & Lyu, Q. (2020). Establishment of evaluation and prediction system of comprehensive state based on big data technology in a commercial blast furnace. *ISIJ International*, 60(5), 898-904. <https://doi.org/10.2355/isijinternational.ISIJINT-2019-545>
7. Diego, M., Sergio, U., Roberto, C., Marcelo, C., Paulina, P., Daggan, A., Ricardo, L., & Robert, A. (2021). Caracterización del sector arrocero en Ecuador 2014-2019: ¿Está cambiando el manejo del cultivo? *Centro Internacional de Agricultura Tropical (CIAT); Fondo Latinoamericano para Arroz de Riego (FLAR); Ministerio de Agricultura y Ganadería (MAG) de Ecuador; Instituto Nacional de Investigaciones Agropecuarias (INIAP) de Ecuador*, 58. <https://cgspace.cgiar.org/bitstream/handle/10568/113781/Marin%20et%20al%20202021%20BI OCIAT%20--%20Caracterizacion%20arroz%20Ecuador%202014%202019.pdf?sequence=1&isAllowed=y>
8. Dorf, R., & Bishop, R. (2005). *Sistema de control moderno*. PEARSON EDUCACION, S.A.
9. Fuentes, R. (2015). *Análisis de variables múltiples*. <https://revistachilenadeanestesia.cl/analisis-de-variables-multiples/>
10. Hernández-Pedrera, C., & Da Silva-Portofilipe, F. (2016). Aplicación del control estadístico de procesos (CEP) en el control de su calidad. *Tecnología Química*, XXXVI(1), 130-145. <https://www.redalyc.org/articulo.oa?id=445543786011>



11. IICA. (2022). *Guía para la elaboración de diagramas de flujo de los procesos institucionales.* Instituto Interamericano de Cooperación para la Agricultura.
12. INEN. (2014). GRANOS Y CEREALES. ARROZ PILADO. REQUISITOS. En *INSTITUTO ECUATORIANO DE NORMALIZACION.* https://www.normalizacion.gob.ec/buzon/normas/nte_inen_1234-1.pdf
13. Infoagro. (2019). *El Cultivo del Arroz.* <https://www.infoagro.com/herbaceos/cereales/arroz.htm>
14. Jeong, J. H., Woo, J. H., & Park, J. G. (2020). Machine Learning Methodology for Management of Shipbuilding Master Data. *International Journal of Naval Architecture and Ocean Engineering*, 12, 428-439. <https://doi.org/10.1016/j.ijnaoe.2020.03.005>
15. Manobanda, W. G., Castro, D. S., Vallejo, H. V., & Carrera, C. F. (2019). *MEJORAMIENTO CONTINUO DE PROCESOS DE CALIDAD* (Primera). Grupo Compás.
16. Núñez, M., & Sarmiento, A. R. (2014). Metodología para el Estudio de Procesos de Producción de Bienes y Servicios: Optimizando el Uso de Recursos. *Revista Expresión Tecnológica. IUTC*, 3(2), 86. <http://bdigital.ula.ve/storage/pdf/expretecno/v3n2/art05.pdf>
17. Ochoa Sangrador, C., Molina Arias, M., & Ortega Páez, E. (2023). *Análisis multivariante. Regresión lineal múltiple.* <http://www.evidenciasenpediatria.es>
18. Pinciroli, M., Ponzio, N. Raquel., & Salsamendi, Mait. (2015). *El arroz: alimento de millones.* D - Editorial de la Universidad Nacional de La Plata. http://www.faa.unicen.edu.ar/archivos/Arroz_Alimento_de_millones.pdf
19. Plan V. (2021, octubre 21). *Ecuador: la eterna batalla por el precio del arroz.* <https://www.planv.com.ec/historias/sociedad/ecuador-la-eterna-batalla-el-precio-del-arroz>
20. Rojo, J. M. (2017). *Regresión lineal múltiple.* http://humanidades.cchs.csic.es/cchs/web_UAE/tutoriales/PDF/Regresion_lineal_multiple_3.pdf
21. Romero, J. V. (2019). *Aprende Python desde cero a experto.* Leanpub. <http://leanpub.com/aprende-python>
22. Sadiku, M. N. O., Ashaolu, T. J., Ajayi-Majebi, A., & Musa, S. M. (2020). Big Data in Food Industry. *International Journal Of Scientific Advances*, 1(3). <https://doi.org/10.51542/ijscia.v1i3.5>



23. Saikrishna, A., Dutta, S., Subramanian, V., Moses, J. A., & Anandharamakrishnan, C. (2018). Ageing of rice: A review. *Journal of Cereal Science*, 81, 161-170. <https://doi.org/10.1016/j.jcs.2018.04.009>
24. Silos Cordoba. (2021). *Almacenamiento del arroz para proteger su calidad :Recomendaciones para el almacenamiento del arroz en un silo metálico*. <https://gandariaspain.com/es/blog-es/almacenaje-de-grano/recomendaciones-para-el-correcto-almacenamiento-del-arroz-en-un-silo-metalico/>
25. Uribe Gómez, J. (2021). *Fundamentos de control estadístico de procesos para gestores y administradores tecnológicos*. <https://doi.org/10.22430/9789585122352>
26. Weichert, D., Link, P., Stoll, A., Rüping, S., Ihlenfeldt, S., & Wrobel, S. (2019). A review of machine learning for the optimization of production processes. *International Journal of Advanced Manufacturing Technology*, 104(5-8), 1889-1902. <https://doi.org/10.1007/s00170-019-03988-5>
27. Zhu, X., Yang, J., Huang, Q., & Liu, T. (2022). A Review on Pollution Treatment in Cement Industrial Areas: From Prevention Techniques to Python-Based Monitoring and Controlling Models. En *Processes* (Vol. 10, Número 12). MDPI. <https://doi.org/10.3390/pr10122682>

Conflictos de intereses:

Los autores declaran que no existe conflicto de interés posible.

Financiamiento:

No existió asistencia financiera de partes externas al presente artículo.

Agradecimiento:

N/A

Nota:

El artículo no es producto de una publicación anterior.