

Evaluación de variables agronómicas asociadas al rendimiento productivo del arroz (*Oryza sativa* L.)

Evaluation of agronomic variables associated with the productive performance of rice (*Oryza sativa* L.)

Genesis Patricia Quimiz Tumbaco¹ <https://orcid.org/0009-0007-7818-7927>

Mairett Yuri Rodríguez Balza² <https://orcid.org/0000-0002-3177-6456>

mairett.rodriguez@interoc.biz

¹ Dirección de Posgrado, Universidad Politécnica Estatal del Carchi, Tulcán – Ecuador.

*Correspondencia: genesis.quimiz@upec.edu.ec

RESUMEN

El estudio evaluó variables agronómicas asociadas al rendimiento del arroz en Ecuador y Perú mediante un enfoque estadístico comparativo. Se analizaron 664 observaciones provenientes de ensayos en bloques completos al azar. Se aplicaron estadística descriptiva, regresión lineal múltiple, modelos mixtos y análisis de componentes principales (PCA). En Ecuador, el modelo lineal explicó el 56.7 % de la variabilidad, identificando como factores clave la altura de planta, el número de macollos y el tipo de material genético. En Perú, el modelo inicial presentó bajo poder explicativo ($R^2 = 0.094$); sin embargo, al controlar la heterogeneidad estructural se evidenciaron relaciones más robustas entre las variables agronómicas y el rendimiento. Los modelos basados en PCA no superaron al modelo lineal clásico en capacidad predictiva. Se concluye que el rendimiento depende del contexto agroecológico y que los modelos lineales constituyen herramientas más eficientes para su explicación bajo condiciones de variabilidad controlada.

Palabras clave: arroz; rendimiento; regresión lineal; modelos mixtos; análisis comparativo.

ABSTRACT

This study evaluated agronomic variables associated with rice yield in Ecuador and Peru using a comparative statistical approach. A total of 664 observations from randomized complete block trials were analyzed. Descriptive statistics, multiple linear regression, mixed models, and principal component analysis (PCA) were applied. In Ecuador, the linear model explained 56.7% of yield variability, identifying plant height, tiller number, and genetic material as key factors. In Peru, the initial model showed low explanatory power ($R^2 = 0.094$); however, after controlling structural heterogeneity, stronger relationships between agronomic variables and yield were observed. PCA-based models did not outperform the classical linear model in predictive capacity. It is concluded that yield depends on the agroecological context and that linear models are more efficient under conditions of controlled variability.

Keywords: rice; yield; linear regression; mixed models; comparative analysis.

Recibido: 05/04/2026

Aceptado: 06/05/2026

INTRODUCCIÓN

El arroz Zewdu et al., (2020) constituye uno de los cultivos más relevantes a nivel global, al representar la base alimentaria de más de 3.500 millones de personas y desempeñar un papel estratégico en la seguridad alimentaria mundial (FAO, 2023). En América Latina, la demanda de consumo interno, se configura como un eje dinamizador de la economía rural, contribuyendo a la generación de empleo y a la reducción de la pobreza en zonas agrícolas (Cordero & Manzaneda, 2021). En el caso ecuatoriano, el cultivo de arroz presenta una alta importancia socioeconómica; sin embargo, los sistemas productivos aún enfrentan limitaciones estructurales que inciden directamente en su eficiencia y sostenibilidad (Boletín Situacional Arroz, 2024; Diaz et al., 2025). A pesar de su relevancia, persiste una brecha significativa entre el rendimiento potencial y el rendimiento observado en campo, lo que evidencia la necesidad de profundizar en el análisis de los factores que condicionan la productividad. Esta problemática no es exclusiva del Ecuador, se manifiesta en diversos sistemas agrícolas de la región, donde las condiciones edafoclimáticas, el manejo agronómico y la adopción tecnológica influyen de manera diferenciada en los resultados

productivos (Guzman, 2026; Navarrete, 2025). En este contexto, comprender los determinantes del rendimiento agrícola se convierte en un desafío clave para garantizar la estabilidad productiva frente a escenarios de cambio climático y presión sobre los recursos naturales.

Desde una perspectiva agronómica, el rendimiento del arroz es el resultado de una compleja interacción entre el genotipo y el ambiente, donde intervienen múltiples variables de carácter morfofisiológico. Rasgos como el número de macollos efectivos, la longitud de la panícula y el peso de mil granos constituyen componentes fundamentales en la determinación del rendimiento final (Nachiketa et al., 2023). No obstante, la expresión de estos atributos presenta una alta plasticidad, lo que implica que su comportamiento puede variar significativamente en función de las condiciones locales. En este sentido, la estabilidad del rendimiento depende en gran medida de la capacidad de adaptación de las variedades a entornos específicos, pudiendo un mismo material genético mostrar desempeños contrastantes en diferentes zonas agroecológicas (Zewdu et al., 2020).

En los últimos años, la literatura científica ha cuestionado la suficiencia de los enfoques tradicionales de análisis, basados en evaluaciones univariadas, para explicar la complejidad de los sistemas productivos. En su lugar, se ha promovido el uso de metodologías multivariadas que permitan capturar la interdependencia entre variables y ofrecer una visión más integral del fenómeno productivo (Olivoto & Lúcio, 2020). Entre estas herramientas, los modelos AMMI han demostrado ser eficaces para analizar la interacción genotipo-ambiente y descomponer las fuentes de variación en ensayos agrícolas (Bocianowski et al., 2024). Asimismo, los modelos lineales mixtos han ganado relevancia por su capacidad para manejar estructuras de datos jerárquicas y separar efectos fijos y aleatorios con mayor precisión (Oberpriller et al., 2022; West et al., 2022). A pesar de los avances metodológicos, aún existe una limitada integración de estos enfoques en estudios comparativos que aborden simultáneamente diferentes contextos productivos en la región andina. Esta carencia restringe la posibilidad de generar inferencias robustas sobre los determinantes estructurales del rendimiento y dificulta la formulación de estrategias agrícolas adaptadas a realidades diversas.

En este marco, la presente investigación tiene como objetivo analizar los determinantes del rendimiento del arroz en Ecuador y Perú mediante un enfoque estadístico comparativo que integra modelos de regresión lineal múltiple, modelos mixtos y técnicas de reducción de dimensionalidad.

Se plantea como supuesto central que la consideración de la interdependencia entre variables agronómicas permite mejorar la capacidad explicativa de los modelos tradicionales, aportando mayor precisión y parsimonia en la interpretación de los resultados.

METODOLOGÍA Y MÉTODOS

El estudio adoptó un enfoque cuantitativo de tipo comparativo, orientado a analizar los determinantes del rendimiento del cultivo de arroz en Ecuador y Perú a partir de información proveniente de ensayos agrícolas estructurados. La variable dependiente fue el rendimiento expresado en $\text{kg}\cdot\text{ha}^{-1}$, mientras que las variables independientes correspondieron a atributos agronómicos como el número de panículas por m^2 , el promedio de macollos y la altura de planta en ambos países, incorporándose adicionalmente la esterilidad y el tipo de material genético en el caso de Ecuador. De igual manera, se consideraron variables estructurales como la localidad y el bloque experimental, este último modelado como efecto aleatorio en el caso peruano, y variables fitosanitarias que fueron integradas en análisis exploratorios de tipo multivariado.

El procesamiento de los datos se realizó en el entorno estadístico R, siguiendo un flujo de trabajo que incluyó la depuración, estandarización y validación de las bases de datos. Se trabajó exclusivamente con registros completos para los análisis multivariados, lo que implicó una reducción del tamaño muestral inicial debido a la presencia de datos faltantes. La detección de valores atípicos se efectuó mediante inspección gráfica, priorizando la consistencia de los datos para los modelos posteriores. No se aplicaron métodos de imputación, lo cual se reconoce como una limitación del estudio.

El análisis estadístico se desarrolló en diferentes niveles. En primer lugar, se realizó un análisis descriptivo del rendimiento, considerando medidas de tendencia central y dispersión para caracterizar la variabilidad productiva en función de la localidad y el material genético. Posteriormente, se empleó regresión lineal múltiple para evaluar la relación entre las variables agronómicas y el rendimiento, permitiendo estimar el efecto simultáneo de múltiples predictores sobre una variable continua, enfoque ampliamente utilizado en modelamiento estadístico aplicado (Ansarifar et al., 2021; Sohil et al., 2022). Se verificaron los supuestos básicos del modelo mediante análisis de residuos y evaluación de multicolinealidad.

Con el fin de considerar la posible estructura jerárquica de los datos, en el caso de Perú se ajustó un modelo lineal mixto incorporando el bloque como efecto aleatorio, enfoque ampliamente utilizado en el análisis de ensayos multiambiente y datos con estructura anidada en investigación agronómica (Argaw et al., 2025). Sin embargo, la varianza asociada a este componente resultó marginal, indicando una contribución limitada de la estructura experimental sobre la variabilidad del rendimiento. De manera complementaria, se aplicó un análisis de componentes principales (PCA) como técnica de reducción de dimensionalidad, con el propósito de explorar patrones de covariación entre variables agronómicas y fitosanitarias, así como identificar estructuras latentes que pudieran influir en el comportamiento productivo.

En última instancia, se desarrolló una comparación entre los modelos lineales tradicionales y aquellos basados en componentes principales, utilizando criterios de ajuste como el coeficiente de determinación, el error cuadrático medio y los criterios de información. Para garantizar la comparabilidad de los resultados, todos los modelos fueron estimados sobre subconjuntos equivalentes de datos completos en cada país. Esta estrategia permitió contrastar enfoques explicativos directos frente a aproximaciones multivariadas, proporcionando una visión más integral de los determinantes del rendimiento en contextos agroecológicos diferenciados.

RESULTADOS

Los análisis se realizaron a partir de bases consolidadas de ensayos experimentales correspondientes al ciclo agrícola 2024–2025, considerando 216 observaciones en Ecuador distribuidas en tres localidades y 448 en Perú en quince localidades.

Estadística descriptiva

En Ecuador, el rendimiento presentó variabilidad moderada entre localidades, con valores medios que oscilaron entre 6 446 y 7 601 kg·ha⁻¹. Guayas registró el mayor rendimiento promedio, seguido de Yaguachi y Babahoyo. El coeficiente de variación se mantuvo entre 8.8 % y 13.4 %, lo que sugiere un sistema productivo relativamente estable y con variabilidad controlada entre ambientes, evidenciando condiciones agronómicas relativamente homogéneas dentro del sistema analizado.

Tabla 1

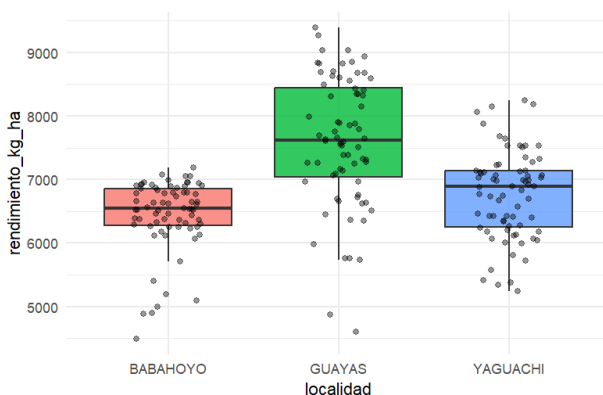
Rendimiento (kg·ha⁻¹) por localidad en Ecuador

Localidad	n	Media	SD	CV (%)
Chilcal Alto	24	6856	548	7.99
El Marañón	28	9623	743	7.72
Ferreñafe	44	8403	1411	16.8

Fuente: Elaboración propia

Figura 1

Distribución del rendimiento por localidad en Ecuador (boxplot con jitter)



Fuente: Elaboración propia

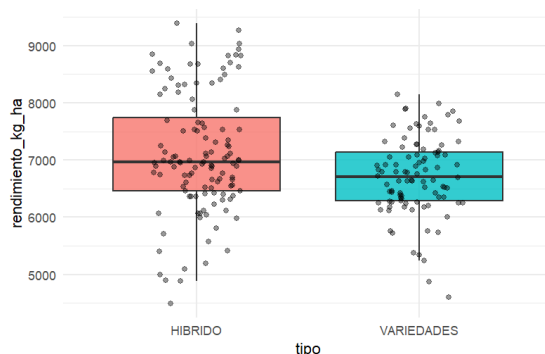
En relación con el tipo de material genético, los híbridos mostraron mayor rendimiento promedio y mayor variabilidad en comparación con las variedades, evidenciando una posible ventaja productiva asociada a su uso. Este comportamiento sugiere que, aunque los híbridos presentan mayor potencial productivo, también pueden ser más sensibles a las condiciones ambientales, lo que influye en la estabilidad del rendimiento.

Tabla 2. *Rendimiento ($kg \cdot ha^{-1}$) por tipo de material genético en Ecuador*

Localidad	n	Media	SD	CV (%)
Chilcal Alto	24	6856	548	7.99
El Marañón	28	9623	743	7.72

Fuente: Elaboración propia

Figura 2. Rendimiento según tipo de material genético en Ecuador



Fuente: Elaboración propia

En Perú, se observó una alta heterogeneidad productiva entre localidades, con valores extremos que van desde 5 608 hasta 14 861 $\text{kg}\cdot\text{ha}^{-1}$, evidenciando una mayor variabilidad estructural del sistema productivo en comparación con Ecuador. Esta amplitud sugiere la presencia de condiciones agroecológicas y de manejo diferenciadas, lo que podría incidir en la estabilidad del rendimiento y en la capacidad explicativa de los modelos estadísticos.

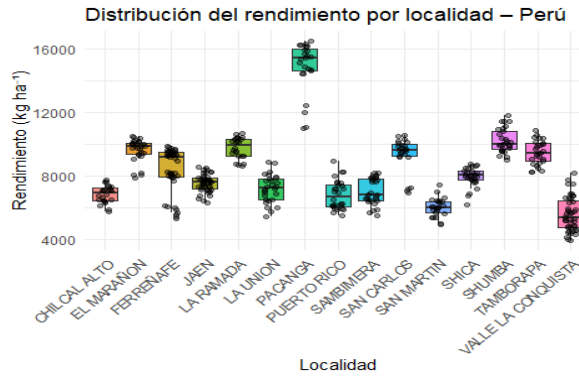
Tabla 3. Rendimiento ($\text{kg}\cdot\text{ha}^{-1}$) por localidad en Perú

Localidad	n	Media	SD	CV (%)
Chilcal Alto	24	6856	548	7.99
El Marañón	28	9623	743	7.72
Ferreñafe	44	8403	1411	16.8
Jaén	44	7570	542	7.17
La Ramada	24	9784	662	6.77
La Unión	28	7211	881	12.2
Pacanga	24	14861	1619	10.9
Puerto Rico	28	6827	906	13.3
Sambimera	28	7040	847	12
San Carlos	24	9353	1096	11.7
San Martín	24	6041	586	9.7
Shica	28	7942	603	7.6
Shumba	28	10244	763	7.45
Tamborapa	28	9474	745	7.86

Valle La Conquista	44	5608	1075	19.2
--------------------	----	------	------	------

Fuente: Elaboración propia

Figura 3. Distribución del rendimiento por localidad en Perú



Fuente: Elaboración propia

Regresión lineal y modelo mixto

En Ecuador, el modelo de regresión lineal múltiple fue estadísticamente significativo ($p < 0.001$) y explicó el 56.7 % de la variabilidad del rendimiento, evidenciando una capacidad explicativa moderada-alta en comparación con sistemas agrícolas más heterogéneos.

Tabla 4. Modelo de regresión lineal múltiple en Ecuador

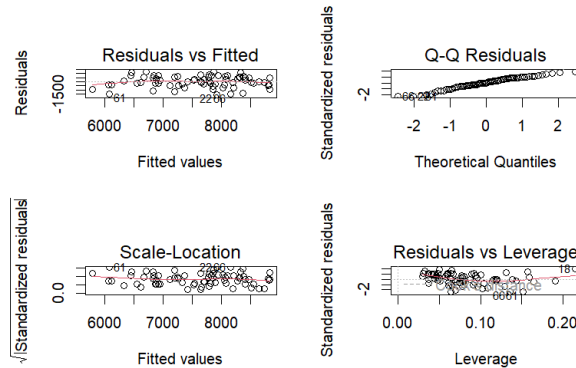
Localidad	n	Media	SD	CV (%)
Chilcal Alto	24	6856	548	7.99
El Marañón	28	9623	743	7.72
Ferreñafe	44	8403	1411	16.8
Jaén	44	7570	542	7.17
La Ramada	24	9784	662	6.77
La Unión	28	7211	881	12.2

Fuente: Elaboración propia

$R^2 = 0.567$ / R^2 ajustado = 0.534

En el modelo de regresión lineal múltiple estimado para Ecuador se incluyeron como variables predictoras el número de panículas por m², el promedio de macollos, la altura de planta, la esterilidad y el tipo de material genético. Los resultados evidenciaron que no todas las variables contribuyen de manera significativa al rendimiento. En particular, la altura de planta y el promedio de macollos mostraron efectos estadísticamente significativos con relación inversa al rendimiento, mientras que el tipo de material genético también presentó un efecto relevante, indicando menores rendimientos en variedades respecto a híbridos. Por el contrario, el número de panículas por m² no evidenció asociación significativa, y la esterilidad mostró una tendencia marginal. En conjunto, estos resultados evidencian que no todos los componentes agronómicos influyen de manera uniforme sobre el rendimiento, resaltando la complejidad del sistema productivo.

Figura 4. Diagnósticos del modelo en Ecuador



Fuente: Elaboración propia

En Perú, el modelo lineal fue significativo, pero presentó bajo poder explicativo ($R^2 \approx 0.09$), reflejando una mayor complejidad estructural del sistema productivo. El modelo mixto no aportó mejoras, ya que la varianza del bloque fue prácticamente nula, lo que indica que la estructura experimental no explicó variabilidad adicional relevante.

Tabla 5. Modelo de regresión lineal múltiple en Perú

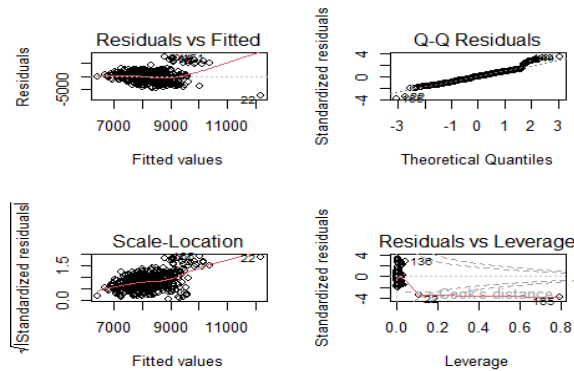
Variable	β	Error estándar	t	p
Intercepto	1889.47	955.6	1.98	0.049
Panículas m ²	1.16	1.08	1.07	0.285
Promedio macollos	98.99	26.38	3.75	<0.001
Altura planta	38.31	6.94	5.52	<0.001

Fuente: Elaboración propia

$R^2 = 0.094$

En este caso, el promedio de macollos y la altura de planta se asociaron positivamente con el rendimiento, mientras que el número de panículas no mostró efecto significativo. Estos resultados contrastan con los obtenidos en Ecuador, lo que sugiere que los determinantes del rendimiento no son consistentes entre contextos productivos, reforzando la influencia de factores locales y la heterogeneidad agroecológica.

Figura 5. Diagnósticos del modelo en Perú

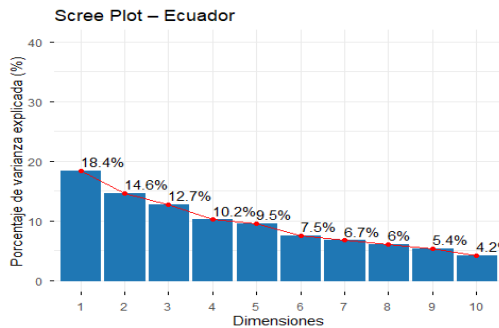


Fuente: Elaboración propia

Análisis de Componentes Principales

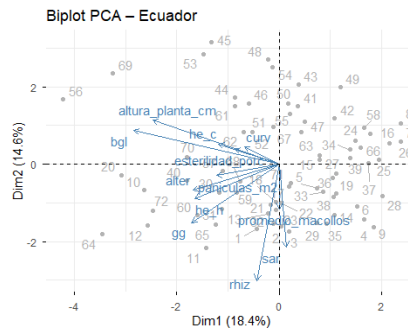
En Ecuador, los dos primeros componentes explicaron el 33.0 % de la varianza total, mientras que en Perú alcanzaron el 52.7 %, evidenciando una mayor estructura multivariada en este último. Esto sugiere que, en Ecuador, una proporción importante de la variabilidad no es capturada por las principales dimensiones del sistema.

Figura 6. Scree plot Ecuador



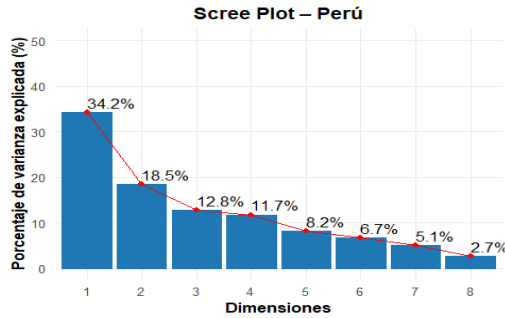
Fuente: Elaboración propia

Figura 7. Biplot Ecuador



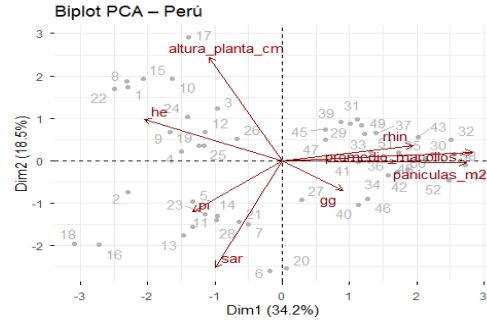
Fuente: Elaboración propia

Figura 8. Scree plot Perú



Fuente: Elaboración propia

Figura 9. Biplot Perú



Fuente: Elaboración propia

La regresión basada en componentes principales mostró menor capacidad explicativa en Ecuador ($R^2 = 0.460$) y en Perú ($R^2 = 0.671$), en comparación con los modelos lineales clásicos, lo que indica que la reducción de dimensionalidad no mejora necesariamente la predicción del rendimiento en estos sistemas.

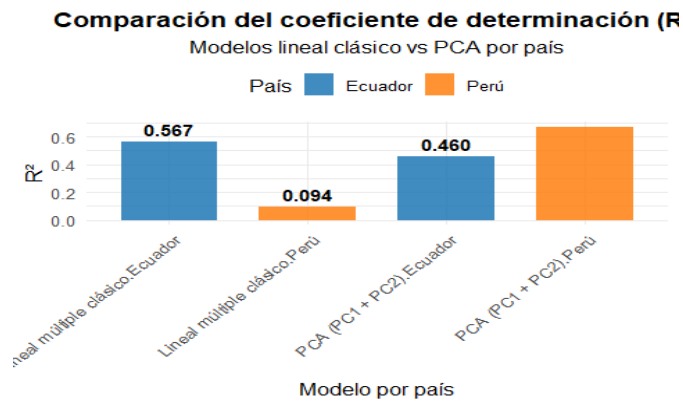
Comparación de modelos

Tabla 6. Comparación de modelos

País	Modelo	n	R ²	RMSE	AIC	BIC
Ecuador	Lineal	72	0.567	668	1154.95	1170.89
Ecuador	PCA	72	0.46	746	1164.84	1173.95
Perú	Lineal	52	0.769	1382.6	909.7	919.4
Perú	PCA	52	0.671	1649.9	926	933.9

Fuente: Elaboración propia

Figura 10. Comparación del coeficiente de determinación (R²)



Los resultados evidenciaron que, en ambos países, el modelo lineal clásico presentó mejor desempeño en términos de ajuste y parsimonia frente al modelo basado en componentes principales. Aunque el PCA permitió identificar patrones estructurales, su incorporación no mejoró la capacidad predictiva del modelo. Estos resultados sugieren que, en contextos agrícolas aplicados, los modelos lineales tradicionales continúan siendo herramientas robustas para la explicación del rendimiento.

DISCUSIÓN

El presente estudio analizó los determinantes agronómicos del rendimiento del arroz en Ecuador y Perú mediante un enfoque comparativo que integró modelos lineales y técnicas multivariadas. Los resultados permitieron contrastar la hipótesis planteada, evidenciando que, aunque los métodos multivariados identifican patrones de covariación entre variables, no necesariamente mejoran la capacidad explicativa ni la parsimonia frente a los modelos lineales clásicos cuando se trabaja bajo condiciones comparables de tamaño muestral (Olivoto & Lúcio, 2020).

En Ecuador, el modelo lineal explicó una proporción moderada de la variabilidad del rendimiento ($R^2 = 0.567$), identificando como variables relevantes la altura de planta, el promedio de macollos y el tipo de material genético. Estos resultados coinciden con lo reportado por Nachiketa et al., (2023), quienes destacan el papel de los componentes morfoestructurales como determinantes directos del rendimiento. La relación negativa observada entre altura y rendimiento sugiere posibles efectos asociados al acame o a una asignación menos eficiente de biomasa, coherente con estudios de interacción genotipo-ambiente que evidencian variabilidad en la expresión de rasgos productivos (Zewdu et al., 2020).

En Perú, el modelo lineal reestimado bajo condiciones comparables mostró un mayor coeficiente de determinación ($R^2 = 0.769$), lo que indica que las variables agronómicas mantienen relaciones consistentes con el rendimiento cuando se controla la heterogeneidad estructural. El bajo ajuste observado inicialmente sobre el total de observaciones sugiere que la variabilidad entre localidades influye significativamente en la estabilidad de los modelos, lo cual ha sido señalado en estudios sobre sistemas agrícolas heterogéneos (Navarrete, 2025).

El análisis de componentes principales permitió identificar estructuras de covariación, especialmente en Perú, donde los primeros componentes concentraron una mayor proporción de la varianza total. No obstante, estos patrones no se tradujeron en una mejora del desempeño

predictivo, ya que los modelos basados en componentes presentaron menores niveles de ajuste. Este resultado es consistente con lo señalado por Olivoto & Lúcio, (2020), quienes destacan el valor de los enfoques multivariados para comprender la estructura de los ensayos agrícolas, aunque su aplicación no garantiza una mejora en la capacidad predictiva. Asimismo, estudios recientes sobre interacción genotipo-ambiente han evidenciado que la complejidad estructural del sistema no siempre se traduce en mayor precisión en los modelos (Bocianowski et al., 2024).

Asimismo, el modelo lineal mixto no evidenció aportes significativos de la estructura de bloques, lo que sugiere que la variabilidad del rendimiento está mayormente explicada por efectos fijos agronómicos, en concordancia con lo señalado por West et al., (2022) y Oberpriller et al., (2022) en relación con la limitada contribución de efectos aleatorios en contextos con baja variabilidad entre grupos. Desde una perspectiva comparativa, las diferencias observadas entre países reflejan la influencia de condiciones agroecológicas diferenciadas; sin embargo, los patrones generales de asociación entre variables y rendimiento se mantienen relativamente consistentes.

Entre las principales limitaciones se destaca la reducción del tamaño muestral en los análisis multivariados debido a la presencia de datos faltantes, así como la ausencia de técnicas de imputación y diagnósticos más robustos de influencia. En términos aplicados, los resultados sugieren que los modelos lineales constituyen herramientas eficaces para el análisis del rendimiento en sistemas arroceros, mientras que las técnicas multivariadas aportan principalmente valor exploratorio más que predictivo.

CONCLUSIONES

El presente estudio permitió identificar los principales determinantes agronómicos asociados al rendimiento del arroz en sistemas productivos de Ecuador y Perú mediante un enfoque estadístico comparativo. En ambos países, los modelos lineales clásicos evidenciaron asociaciones significativas entre variables morfoestructurales y rendimiento, destacándose particularmente la altura de planta y el promedio de macollos como predictores consistentes. En Ecuador, el rendimiento estuvo influenciado negativamente por incrementos en la altura de planta y el número de macollos, así como por el tipo de material genético, lo que sugiere que la arquitectura vegetal y la selección varietal constituyen factores determinantes en la productividad. En Perú, las variables agronómicas mostraron relaciones lineales robustas con el rendimiento cuando se

controló la heterogeneidad estructural, alcanzando un alto coeficiente de determinación bajo condiciones comparables.

La aplicación del análisis de componentes principales permitió identificar estructuras latentes de covariación, particularmente más concentradas en el sistema peruano; sin embargo, su incorporación como predictores no mejoró el desempeño frente a los modelos lineales tradicionales, evidenciando que la reducción dimensional no implica necesariamente mayor capacidad explicativa cuando existen relaciones lineales directas sólidas. En términos metodológicos, los resultados resaltan la importancia de comparar enfoques estadísticos bajo condiciones equivalentes de tamaño muestral para evitar interpretaciones sesgadas. Desde una perspectiva aplicada, se concluye que la optimización del rendimiento puede abordarse eficazmente mediante el manejo de variables agronómicas específicas, sin requerir modelos multivariados complejos, aunque futuras investigaciones podrían incorporar técnicas de imputación, análisis de influencia robusta y modelos no lineales para explorar relaciones adicionales no capturadas por el enfoque lineal clásico.

REFERENCIAS BIBLIOGRÁFICAS

- Ansarifar, J., Wang, L., & Archontoulis, S. V. (2021). An interaction regression model for crop yield prediction. *Scientific reports*, *11*(1), 17754.
- Argaw, T., Fenta, B. A., Zegeye, H., Azmach, G., & Funga, A. (2025). Multi-environment trials data analysis: Linear mixed model-based approaches using spatial and factor analytic models. *Frontiers in Research Metrics and Analytics*, *10*, 1472282.
- Bocianowski, J., Nowosad, K., & Rejek, D. (2024). Genotype-environment interaction for grain yield in maize (*Zea mays* L.) using the additive main effects and multiplicative interaction (AMMI) model. *Journal of Applied Genetics*, *65*(4), 653-664. <https://doi.org/10.1007/s13353-024-00899-4>
- Boletín Situacional Arroz 2024*. (s. f.). Recuperado 20 de marzo de 2026, de <https://online.fliphtml5.com/ijia/moji/>
- Cordero Flores, P., & Manzaneda Delgado, F. (2021). [Http://www.scielo.org.bo/scielo.php?script=sci_abstract&pid=S2409-16182021000100003&lng=es&nrm=iso&tlng=es](http://www.scielo.org.bo/scielo.php?script=sci_abstract&pid=S2409-16182021000100003&lng=es&nrm=iso&tlng=es). *Revista de Investigación e Innovación* Revista Cubana de Educación Superior Vol. 45 (2026) RNPS 2418 ISSN 2518-2730

Agropecuaria y de Recursos Naturales, 8(1), 3-16.
<https://doi.org/10.53287/xivu8492oe20n>

- Díaz Ponce, S. L., Castillo Vélez, M. J., Domínguez Andrade, J. M., & Espinel Martínez, R. L. (2025). *Análisis de la adopción de innovaciones alineadas a la bioeconomía en la agricultura campesina arroceras de los cantones Daule y Santa Lucía del Ecuador* [Thesis, ESPOL.FCSH]. <http://www.dspace.espol.edu.ec/handle/123456789/67600>
- FAO. (2023). *World Food and Agriculture – Statistical Yearbook 2023*. FAO; <https://openknowledge.fao.org/handle/20.500.14283/cc8166en>
- Guzmán Casallas, L. G. (2026). *Desafíos en el cultivo de maíz amarillo en la Orinoquia colombiana y su relación con la conservación del suelo*. <https://repository.unad.edu.co/handle/10596/78596>
- Nachiketa, Singh, V., & Soni, B. (2023). Growth and Yield of Rice (*Oryza sativa* L.) under Agro-climatic Zone of Prayagraj, India. *International Journal of Environment and Climate Change*, 13(8), 1096-1100. <https://doi.org/10.9734/ijec/2023/v13i82048>
- Navarrete Ordóñez, M. (2025). *Medición integral de productividad agrícola en sistemas socioecológicos*. <https://hdl.handle.net/1992/75943>
- Oberpriller, J., De Souza Leite, M., & Pichler, M. (2022). Fixed or random? On the reliability of mixed-effects models for a small number of levels in grouping variables. *Ecology and Evolution*, 12(7), e9062. <https://doi.org/10.1002/ece3.9062>
- Olivoto, T., & Lúcio, A. D. (2020). metan: An R package for multi-environment trial analysis. *Methods in Ecology and Evolution*, 11(6), 783-789. <https://doi.org/10.1111/2041-210X.13384>
- Sohil, F., Sohali, M. U., & Shabbir, J. (2022). An introduction to statistical learning with applications in R: By Gareth James, Daniela Witten, Trevor Hastie, and Robert Tibshirani, New York, Springer Science and Business Media, 2013, \$41.98, eISBN: 978-1-4614-7137-7. *Statistical Theory and Related Fields*, 6(1), 87-87. <https://doi.org/10.1080/24754269.2021.1980261>
- West, B. T., Welch, K. B., & Galecki, A. T. (2022). *Linear mixed models: A practical guide using statistical software*. Chapman and Hall/CRC.

<https://api.taylorfrancis.com/content/books/mono/download?identifierName=doi&identifierValue=10.1201/9781003181064&type=googlepdf>

Zewdu, Z., Dessie, A., Worede, F., Atinaf, M., Berie, A., Tahir, Z., Kinfu, H., & Bitew, M. (2020). Agronomic performance evaluation and yield stability analysis of upland rice (*Oryza sativa* L.) varieties using AMMI and GGE biplot. *Plant*, 8(4), 87-92.

Conflicto de intereses

La autora declara que no existe conflicto de interés

Contribución de autoría.

Genesis Patricia Quimiz Tumbaco: Conceptualización. Investigación. Metodología. Administración del proyecto. Recursos. Redacción, revisión y edición.

Mairrett Yuri Rodríguez Balza: Curación de datos. Análisis formal. Adquisición de fondos. Investigación. Metodología. Software. Supervisión. Validación. Visualización.