




Modelo predictivo con regresión lineal múltiple para optimizar la eficiencia alimenticia en granjas avícolas automatizadas

Predictive model using multiple linear regression to optimize feed efficiency in automated poultry farms

- 1 Edwin Alfredo Riofrio Núñez  <https://orcid.org/0009-0000-3612-816X>
Universidad Bolivariana del Ecuador (UBE), Durán, Ecuador. Maestría en Gestión y Análisis de Datos con mención en Inteligencia de Negocios
eariofrion@ube.edu.ec
- 2 Iván Patricio Montaleza Quizhpe  <https://orcid.org/0009-0000-7714-9485>
Universidad Bolivariana del Ecuador (UBE), Durán, Ecuador. Maestría en Gestión y Análisis de Datos con mención en Inteligencia de Negocios
ipmontalezaq@ube.edu.ec
- 3 Glen Freddy Robayo Cabrera  <https://orcid.org/0009-0006-9195-7423>
Universidad Bolivariana del Ecuador (UBE), Durán, Ecuador.
gfrobayoc@ube.edu.ec

Artículo de Investigación Científica y Tecnológica

Enviado: 11/10/2025

Revisado: 15/11/2025

Aceptado: 16/12/2025

Publicado: 07/04/2026

DOI: <https://doi.org/10.33262/cienciadigital.v10i2.3643>

Cítese:

Riofrio Núñez, E. A., Montaleza Quizhpe, I. P., & Robayo Cabrera, G. F. (2026). Modelo predictivo con regresión lineal múltiple para optimizar la eficiencia alimenticia en granjas avícolas automatizadas. *Ciencia Digital*, 10(2), 60-82. <https://doi.org/10.33262/cienciadigital.v10i2.3643>



Ciencia Digital
Editorial



CIENCIA DIGITAL, es una revista multidisciplinaria, trimestral, que se publicará en soporte electrónico tiene como misión contribuir a la formación de profesionales competentes con visión humanística y crítica que sean capaces de exponer sus resultados investigativos y científicos en la misma medida que se promueva mediante su intervención cambios positivos en la sociedad. <https://cienciadigital.org>

La revista es editada por la Editorial Ciencia Digital (Editorial de prestigio registrada en la Cámara Ecuatoriana de Libro con No de Afiliación 663) www.celibro.org.ec.

Esta revista está protegida bajo una licencia *Creative Commons Atribución-NoComercial-CompartirIgual 4.0 International*. Copia de la licencia: <https://creativecommons.org/licenses/by-nc-sa/4.0/deed.es>.



Palabras claves: Avicultura de precisión, factor de conversión alimenticia, regresión lineal múltiple, eficiencia alimenticia, IoT, pollos de engorde, condiciones tropicales, granjas automatizadas.

Resumen: Introducción: la industria avícola opera en un entorno altamente competitivo, donde el Factor de Conversión Alimenticia (FCR) representa entre el 60 y el 70 % de los costos operativos. Aunque las granjas automatizadas generan grandes volúmenes de datos ambientales mediante sistemas IoT, su potencial suele aprovecharse de manera limitada en la toma de decisiones. **Objetivos:** desarrollar un modelo predictivo basado en regresión lineal múltiple para estimar el FCR semanal en granjas avícolas automatizadas bajo condiciones tropicales húmedas del Ecuador. **Metodología:** estudio observacional longitudinal retrospectivo con 936 registros semanales (2022-2025) de siete granjas automatizadas. Se aplicó regresión lineal múltiple con validación hold-out 80/20 estratificada, verificación de supuestos estadísticos y evaluación mediante R^2 , MAE y RMSE. **Resultados:** el modelo demostró capacidad predictiva robusta con $R^2 = 0,774$ (entrenamiento) y $R^2 = 0,739$ (validación externa), acompañado de MAE = 0,088 y RMSE = 0,109. Variables significativas ($p < 0,001$) incluyeron temperatura ambiental (coeficiente = $-0,0445$ FCR/ $^{\circ}\text{C}$), humedad relativa ($+0,00858$ FCR/ %), fase fisiológica ($+0,198$ FCR para semanas 5-7) y línea genética ($+0,072$ FCR para ROSS 308). CO_2 y NH_3 no alcanzaron significancia estadística. **Conclusión:** el modelo evidencia capacidad predictiva operativa para gestión preventiva del FCR en condiciones tropicales húmedas, ofreciendo una herramienta interpretable de implementación inmediata que permite proyecciones semanales confiables con implicaciones directas en rentabilidad mediante optimización de eficiencia alimenticia. **Área de estudio general:** Ingeniería Agropecuaria. **Área de estudio específica:** Avicultura de precisión. **Tipo de estudio:** Artículo original.

Keywords: Precision poultry, Feed Conversion Ratio, multiple linear regression, feed efficiency, IoT, broiler chickens, tropical conditions, automated farms.

Abstract: Introduction: the poultry industry operates in a highly competitive environment, where feed costs represent between 60 % and 70 % of operating costs. Although automated farms generate large volumes of environmental data through IoT systems, their potential is often underutilized in decision-making. **Objectives:** to develop a predictive model based on multiple linear regression to estimate the weekly FCR in automated poultry farms under humid tropical conditions of Ecuador. **Methodology:** a retrospective longitudinal observational study was conducted with 936 weekly records

(2022-2025) from seven automated farms. Multiple linear regression was applied with stratified hold-out validation (80/20), assessment of statistical assumptions, and evaluation using R^2 , MAE, and RMSE. **Results:** the model demonstrated robust predictive capacity with $R^2 = 0.774$ (training) and $R^2 = 0.739$ (external validation), accompanied by MAE = 0.088 and RMSE = 0.109. Significant variables ($p < 0.001$) included ambient temperature ($\beta = -0,0445$ FCR units/ $^{\circ}\text{C}$), relative humidity ($\beta = +0,00858$ FCR units/ $\%$), physiological phase ($\beta = +0,198$ FCR units for weeks 5-7), and genetic line ($\beta = +0,072$ FCR units for ROSS 308). CO_2 and NH_3 did not reach statistical significance. **Conclusion:** the model demonstrates predictive capacity for preventive FCR management under humid tropical conditions, offering an interpretable tool for immediate implementation that enables reliable weekly projections with direct implications for profitability through optimization of feed efficiency. **General study area:** Agricultural Engineering. **Specific study area:** Precision Poultry Farming. **Type of study:** Original article.

1. Introducción

La industria avícola mundial se enfrenta a retos sin precedentes que exigen nuevas soluciones para seguir siendo competitiva y sostenible. Entre ellas se encuentran la volatilidad en los precios de las materias primas, las crecientes demandas de bienestar animal y sostenibilidad ambiental, la competencia global y la necesidad de mejorar continuamente la eficiencia productiva en un entorno de márgenes estrechos (Oke et al., 2024). La maximización de la eficiencia biológica y económica de cada lote de pollos de engorde se convierte en un imperativo estratégico para la supervivencia empresarial.

El Factor de Conversión Alimenticia (FCR) es uno de los indicadores más importantes para evaluar el rendimiento productivo en

sistemas intensivos. Entendido como la proporción entre el alimento ingerido (kg) y el peso vivo ganado (kg), el FCR es un indicador que resume muchos factores de la producción. Su significancia económica va más allá de la eficiencia, ya que el alimento balanceado siempre oscila entre el 60 % y 70 % de los costos operativos totales (Muyulema et al., 2020), siendo el principal rubro que conforma la estructura de costos en granjas avícolas.

El FCR cobra mayor importancia ya que pequeños cambios en éste se reflejan en grandes cambios económicos a nivel comercial. Una variación de 0.1 puntos en el FCR en una granja que procesa 1 millón de aves al año puede significar miles de dólares en costos de alimento, impactando directamente

en la rentabilidad (Quintana-Ospina et al., 2023). Esta sensibilidad económica hace relevante el desarrollo de instrumentos capaces de anticipar y controlar este indicador antes de que las desviaciones se consoliden y generen efectos irreversibles.

Al mismo tiempo la avicultura mundial se transformó tecnológicamente en la última década, con automatización completa de procesos, control ambiental computarizado y uso generalizado de sistemas de sensorización en tiempo real.

Esta revolución tecnológica, enmarcada en la Industria 4.0 y la agricultura de precisión, posibilitó la captura continua de grandes cantidades de datos operativos, como variables ambientales (temperatura, humedad relativa, CO_2 , NH_3), datos de consumo de alimento, mortalidad y diversos indicadores de desempeño (Jackman et al., 2020; Pereira et al., 2020; Ahmed et al., 2024).

Estas infraestructuras IoT generan grandes volúmenes de datos que potencialmente pueden predecir desviaciones productivas antes de que se reflejen en indicadores zootécnicos finales, como el peso corporal o la mortalidad acumulada (Liu et al., 2024; Elwakeel, 2025). La habilidad de identificar tempranamente tendencias negativas permitiría realizar medidas correctivas tempranas, minimizando pérdidas económicas y mejorando el bienestar animal con medidas preventivas.

Pero todavía existe una gran paradoja: en muchas granjas comerciales estos datos se quedan en registros operativos estáticos y

bases de datos infrautilizadas, sin convertirse en herramientas analíticas vivas que guíen las decisiones diarias de gestión (Astill et al., 2020). Esta diferencia entre lo que técnicamente se puede capturar y lo que realmente se aprovecha es una gran oportunidad perdida de optimización productiva, más aún cuando está demostrado el efecto de variables ambientales sobre indicadores como el FCR.

En particular, las variables ambientales controladas en galpones automatizados influyen directamente en parámetros fisiológicos que impactan en el desempeño zootécnico. Las temperaturas ambientales por encima de la zona de termoneutralidad propia de cada fase productiva inducen estrés térmico que disminuye el consumo voluntario de alimento y empeora el índice de conversión por mecanismos fisiológicos conocidos (Oke et al., 2024; Tahamtani et al., 2020).

Las humedades relativas altas, un problema en climas tropicales húmedos, favorecen el crecimiento bacteriano y deterioran las características físicas de la cama, generando las condiciones para problemas podales y dermatitis que impactan en el bienestar y la productividad (Hidalgo et al., 2024).

Las altas concentraciones de Amoníaco (NH_3) impactan negativamente en la salud respiratoria y son precursoras de inflamación sistémica, que compromete la eficiencia de crecimiento (Qaid et al., 2023). Las altas concentraciones de Dióxido de Carbono (CO_2) se relacionan con hipoxia subclínica y letargo productivo, y la ventilación insufi-

ciente puede causar estrés por frío y aumentar los requerimientos energéticos de mantenimiento, desviando los recursos metabólicos para el crecimiento (Shynkaruk et al., 2023; Gholami et al., 2020).

Estas interacciones ambientales siguen patrones fisiológicamente no lineales, pero que pueden ser aproximadas mediante funciones multivariadas estacionarias cuando las condiciones de manejo y la genética animal no varían en el tiempo, tal como ocurre en los sistemas intensivos actuales con líneas comerciales estandarizadas y protocolos uniformizados.

En la última década se presenció un auge en el uso de técnicas de analítica avanzada y machine learning para la estimación en tiempo real de variables productivas en sistemas pecuarios (Ojo et al., 2022). Estas técnicas abarcan desde la evaluación automatizada del bienestar animal usando visión por computador (Nasiri et al., 2022; Fang et al., 2020), la estimación no invasiva del peso corporal con análisis de imagen avanzado (Nyalala et al., 2021; Natho et al., 2025) hasta la predicción del rendimiento alimenticio a partir de la integración de datos heterogéneos (González et al., 2021; Batista-Mendoza et al., 2023; Li et al., 2024).

Los mejores enfoques, especialmente los basados en redes neuronales profundas y métodos de conjunto, pueden lograr una precisión predictiva superior a la de los métodos estadísticos convencionales (Adli et al., 2025; Vilema et al., 2022). Un modelo predictivo reciente basado en SVM obtuvo una

precisión del 98,95 % en clasificación binaria para mantenimiento predictivo industrial (Vilema et al., 2022), lo que ilustra el potencial de estos algoritmos cuando se afinan correctamente.

Pero estos avances tecnológicos, estas metodologías sofisticadas, tienen serias restricciones para su implementación práctica generalizada en fincas comerciales latinoamericanas, especialmente en lugares como Ecuador con escasos recursos técnicos e infraestructura computacional.

Primero, requieren infraestructura computacional dedicada y personal capacitado para calibración, implementación y mantenimiento continuo. Segundo, y quizás lo más relevante para el usuario final, a menudo son modelos 'caja negra' cuya lógica interna es difícil de comprender por el operador de producción que tiene que defender cambios en las recetas ante la gerencia operativa (You et al., 2021).

En contraposición, la regresión lineal múltiple sigue siendo una herramienta predictiva vigente y con utilidad práctica en la producción animal intensiva (Granda et al., 2023; Freitas et al., 2025). Esta técnica estadística comprobada puede modelar el efecto combinado de muchos factores ambientales sobre un resultado zootécnico importante como el FCR, pero al mismo tiempo mantener trazabilidad estadística completa, transparencia auditable y explicabilidad directa.

Un estudio reciente de rendimiento de mano de obra en construcción usando regresión lineal logró una confianza del 96 % que de-

muestra que la simplicidad metodológica no sacrifica la capacidad predictiva cuando se usa adecuadamente (Granda et al., 2023). Cada coeficiente del modelo es un efecto marginal interpretable y comprensible para el personal técnico, lo que facilita enormemente la comunicación de resultados y la justificación de las decisiones operativas.

Un modelo predictivo de este tipo, una vez validado, puede incorporarse como un módulo de alerta temprana en el flujo de trabajo diario de una granja comercial. Cuando el FCR previsto para la semana siguiente supera ciertos umbrales internos, el equipo técnico puede actuar de forma preventiva modificando parámetros clave como ventilación mínima, caudal de líneas de bebida, densidad efectiva o estrategia de alimentación antes de que la eficiencia se deteriore y los sobrecostos sean irreversibles. Esta capacidad predictiva es un cambio radical con respecto a la forma tradicional reactiva de gestionar y convertirse en una gestión preventiva impulsada por datos.

Pero a pesar de estos avances conceptuales y tecnológicos, aún existe una gran brecha en la literatura científica enfocada en Latinoamérica y, más específicamente, en el contexto ecuatoriano. Hay poca evidencia empírica disponible de modelos predictivos estadísticamente verificados para estimar el FCR en granjas avícolas comerciales automatizadas utilizando datos reales de sensores en ambientes tropicales húmedos. Esta ausencia es especialmente relevante porque el clima de lugares como Santo Domingo de los Tsáchilas, con alta temperatura me-

dia anual, humedad permanente y presión sanitaria, es muy diferente al de los climas templados en los que se realizó la mayoría de estudios experimentales que se encuentran en la literatura internacional.

La industria avícola en Ecuador es un pilar para la seguridad alimentaria y el desarrollo económico del país. Según cifras de la Corporación Nacional de Avicultores del Ecuador (CONAVE, 2024) en los últimos 30 años el sector creció de manera permanente, al pasar de producir 50 millones de pollos de engorde en 1990 a más de 300 millones en 2024. Pero la producción de pollos broilers en zonas tropicales se enfrenta a grandes desafíos por los cambios climáticos que ocurren durante todo el año, afectando el rendimiento productivo y el bienestar de las aves (Hidalgo et al., 2024).

La extrapolación directa de resultados de climas templados a climas tropicales húmedos es metodológicamente inapropiada, ya que existen diferencias significativas en la dinámica ambiental, presencia de patógenos, desafíos de manejo y respuesta fisiológica de las aves expuestas a estrés térmico permanente. Por eso, es necesario desarrollar y validar modelos ajustados a condiciones tropicales, teniendo en cuenta sus peculiaridades ambientales, genéticas y de manejo. La falta de dichas herramientas limita la optimización de la eficiencia alimenticia en un sector clave para la seguridad alimentaria regional y nacional.

En este contexto problemático, la pregunta científica que guía la presente investiga-

ción es: ¿en qué medida se puede estimar el factor de conversión alimenticia semanal en pollos de engorde criados en galpones automatizados, a partir de datos ambientales capturados por sistemas IoT, mediante un modelo de regresión lineal múltiple validado estadísticamente y listo para ser utilizado operativamente por el personal de producción?

El objetivo general de la investigación consiste en desarrollar un modelo predictivo basado en regresión lineal múltiple que estime el FCR en granjas avícolas automatizadas a partir de variables ambientales críticas medidas en tiempo real. De manera específica, se busca: (i) caracterizar el comportamiento conjunto de temperatura, humedad relativa, Dióxido de Carbono (CO_2) y Amoníaco (NH_3) bajo condiciones comerciales ecuatorianas; (ii) identificar cuáles de estas variables explican con mayor peso estadístico la variabilidad del FCR acumulado por semana; (iii) construir la ecuación predictiva y evaluar su ajuste, estabilidad y ausencia de colinealidad; y (iv) proponer su uso como herramienta de apoyo a la toma de decisiones para optimizar la eficiencia alimenticia y, por extensión, la rentabilidad del sistema productivo.

2. Metodología

Se realizó un estudio de enfoque cuantitativo, observacional y longitudinal retrospectivo, utilizando datos históricos generados por granjas automatizadas de pollos de engorde en el periodo de enero de 2022 a marzo de 2025 (39 meses). El estudio se llevó a

cabo en la provincia de Santo Domingo de los Tsáchilas, Ecuador, zona tropical húmeda con temperatura media anual de 25-27°C, humedad relativa $\geq 80\%$ y régimen de lluvia estacional (Hidalgo et al., 2024; Quintana-Ospina et al., 2023). Las granjas de estudio utilizan galpones modernos con ventilación mecánica forzada tipo túnel, cortinas y sistemas automatizados de comederos y bebederos (Pereira et al., 2020; Liu et al., 2023). Este ambiente tecnológico permite el monitoreo en tiempo real de las condiciones ambientales y productivas de las aves.

2.1 Recolección y registro semanal de datos

Las condiciones ambientales se controlaron con sensores IoT colocados a nivel de las aves y distribuidos uniformemente en los galpones. Estos sensores tomaron medidas continuas de temperatura, humedad relativa, Dióxido de Carbono (CO_2) y Amoníaco (NH_3) ambiental (Ahmed et al., 2024; Elwakeel, 2025). Los datos de producción se tomaron de los sistemas internos de gestión de cada granja, tales como consumo de alimento, peso promedio de las aves y mortalidad diaria (Astill et al., 2020). Todos estos datos se recopilaron y revisaron semanalmente utilizando protocolos estandarizados de captura de datos en sistemas intensivos (Liu et al., 2024).

2.2 Población y muestra

La población estuvo compuesta por lotes comerciales completos de las líneas genéticas COBB 500 y ROSS 308, seleccionadas por su predominio en sistemas intensivos ecua-

torianos (Gholami et al., 2020; Quintana-Ospina et al., 2023). La unidad de análisis fue el registro semanal consolidado por granja, integrando promedios ambientales semanales con el FCR acumulado.

El proceso de selección inició con más de 8000 registros brutos, estructurado en múltiples hojas, pertenecientes a 18 granjas numeradas. Se aplicaron criterios de inclusión: galpones completamente automatizados; capacidad mayor o igual a 30,000 aves por lote; sensorización ambiental con registro horario continuo; historial digitalizado mayor o igual a 20 ciclos productivos consecutivos; y densidad de alojamiento entre 30-40 kg/m² (Gallard et al., 2022; Shynkaruk et al., 2023). Los criterios de exclusión incluyeron: semanas con fallas de sensorización >20 % del tiempo; brotes sanitarios; cambios significativos en formulación alimenticia o línea genética; y registros con valores ausentes. Tras la depuración, la muestra final consolidó 936 observaciones semanales de siete granjas automatizadas, codificadas como Granja A, B, C, D, E, F y G, para confidencialidad industrial.

2.3 Procesamiento de datos

El procesamiento se llevó a cabo utilizando una cadena ETL (Extract, Transform, Load) estandarizada y documentada (Li et al., 2024; González et al., 2021). En la etapa de extracción, se unificaron las fuentes operativas heterogéneas de las siete granjas. La transformación implicó: estandarización de variables y formatos, creación de identificadores únicos lote-semana y el cálculo

de variables derivadas, tales como: FCR acumulado semanal, mortalidad acumulada (%), consumo y ganancia semanal por ave. Para garantizar la calidad de los datos, se verificó que todos estuvieran completos, que la información registrada fuera consistente en el tiempo, que los valores estuvieran dentro de rangos normales. Además, se utilizó un método de dispersión de valores para detectar outliers de forma precisa. Finalmente, la etapa de carga unificó la información en una única base de datos analítica, consolidando las variables descritas en la Tabla 1.

2.4 Análisis estadístico

El análisis se inició con 18 variables candidatas de la base de datos. La elección de predictores se realizó en tres pasos para asegurar robustez metodológica (Freitas et al., 2025; Li et al., 2024). En la primera etapa se usaron criterios teórico-prácticos de literatura avícola tropical y disponibilidad operativa. En la segunda etapa se realizó un análisis exploratorio cuantitativo usando una matriz de correlaciones y modelos univariados iniciales ($p < 0.25$), según metodologías informadas en estudios previos de producción avícola (Quintana-Ospina et al., 2023; González et al., 2021). La tercera etapa estableció las variables predictoras finales combinando significancia estadística ($p < 0.05$) con justificación teórica encontrada en literatura científica sobre fisiología aviar en ambientes tropicales (Oke et al., 2024; Hidalgo et al., 2024).

Se estimó un modelo de regresión lineal múltiple (RLM) por Mínimos Cuadrados

Tabla 1: Variables de la base de datos

Variable	Tipo (unidad)	Descripción breve
fecha_semana	Fecha (AAAA-MM-DD)	Fecha de corte semanal (ISO).
Año	Entero	Año calendario (2022–2025).
Mes	Entero (1–12)	Mes calendario.
Ciclo	Entero	ID interno de ciclo/lote.
Semana	Entero (1–7)	Semana del ciclo productivo.
granja_id	Catórica (A–G)	Identificador anónimo de granja.
linea_genetica	Catórica	COBB 500 / ROSS 308.
ave_madura	Binaria (0/1)	0 = sem. 1–4; 1 = sem. 5–7.
fcr_acumulado (fcr_acumulativo)	Continua (kg/kg)	Alimento acum. / peso vivo acum. a semana t.
mortalidad_acumulada_pct0	Continua (%)	Fallecidas acum. / población inicial × 100.
consumo_semanal_g_ave	Continua (g/ave)	Consumo semanal / aves vivas promedio.
ganancia_semanal_g	Continua (g/ave)	Incremento de peso semanal por ave.
peso_promedio_g	Continua (g)	Peso promedio de muestra semanal (≥ 100 aves).
temperatura_promedio	Continua (°C)	Promedio semanal de temperatura interior.
humedad_promedio	Continua (%)	Promedio semanal de HR interior.
co2_promedio_ppm	Continua (ppm)	Promedio semanal de CO ₂ interior.
nh3_promedio_ppm	Continua (ppm)	Promedio semanal de NH ₃ interior.
densidad_aves_m2	Continua (aves/m ²)	Aves / área útil del galpón.

Ordinarios (MCO), tomando como variable dependiente el FCR acumulado semanal. Candidatas a variables predictoras: temperatura promedio semanal (°C), humedad relativa promedio semanal (%), CO₂ promedio semanal (ppm), NH₃ promedio semanal (ppm), ave madura (0=semanas 1-4; 1=semanas 5-7) y línea genética (0=COBB 500; 1=ROSS 308). La elección de RLM sobre modelos más complejos se alinea con trazabilidad operativa y facilidad de interpretación en ambientes de producción avícola comercial (Freitas et al., 2025; Granda et al., 2023; Vilema et al., 2022). La Ecuación 1 inicial del modelo de RLM que considera las variables antes mencionadas:

$$FCR = \beta_0 + \beta_1 \cdot \text{temperatura} + \beta_2 \cdot$$

$$\text{Humedad} + \beta_3 \cdot \text{CO}_2 + \beta_4 \cdot \text{NH}_3$$

$$+ \beta_5 \cdot \text{ave_madura}$$

$$+ \beta_6 \cdot \text{Lin_genética} + \varepsilon$$

(1)

Donde β_0 representa el intercepto, β_1 a β_6 son los coeficientes de regresión parcial para cada variable predictora, y ε es el término de error aleatorio.

La bondad de ajuste se evaluó mediante R² y R² ajustado, calculado en la Ecuación 2:

$$R_{ajustado}^2 = 1 - \left[\frac{(1 - R^2)(n - 1)}{n - k - 1} \right] \quad (2)$$

Donde n representa el tamaño muestral y k el número de predictores. Se estableció el reporte de error estándar de estimación, significancia global mediante prueba F (ANOVA), y significancia individual de coeficientes mediante pruebas t bilaterales ($\alpha = 0,05$). Se calcularon intervalos de confianza del 95 % para todos los coeficientes de regresión.

Se implementó validación tipo *hold-out* 80/20 con partición estratificada por ciclo productivo para garantizar representatividad

temporal (Freitas et al., 2025; You et al., 2021). En el conjunto de validación independiente (20 % de observaciones no utilizadas en el ajuste) se estimaron R^2 de validación, MAE (*Mean Absolute Error*) y RMSE (*Root Mean Square Error*) como métricas de capacidad predictiva en datos no vistos. Los supuestos fundamentales de la RLM se verificaron mediante: gráficos de dispersión y residuos parciales para evaluar linealidad; prueba de Durbin-Watson para verificar independencia de residuos (ausencia de autocorrelación); prueba de Breusch-Pagan para evaluar homocedasticidad (varianza constante de errores); prueba de Shapiro-Wilk para verificar normalidad de residuos; y Factores de Inflación de la Varianza (VIF) para detectar multicolinealidad entre predictores, con umbral crítico VIF ≤ 5 (Freitas et al., 2025; Li et al., 2024). Ante evidencia de heterocedasticidad residual, la inferencia estadística se complementó con errores estándar robustos agrupados por ciclo productivo (*cluster-robust standard errors*).

El análisis estadístico se realizó en RStudio (versión 2023.12.0) utilizando los paquetes stats, car, lmtest y sandwich, con verificación cruzada en IBM SPSS Statistics (versión 27) para garantizar reproducibilidad de resultados.

2.5 Consideraciones éticas

El estudio empleó únicamente datos secundarios anonimizados, autorizados por la gerencia técnica bajo acuerdos de confidencialidad industrial. Todas las granjas avícolas fueron codificadas (A-G) y no se realizaron

manipulaciones experimentales ni cambios en los protocolos productivos. La información confidencial se manejó con protocolos estrictos de confidencialidad para no poner en riesgo la posición competitiva de las unidades participantes.

3. Resultados

El presente estudio cumplió satisfactoriamente su objetivo de desarrollar un modelo predictivo basado en regresión lineal múltiple para estimar el FCR semanal en granjas avícolas automatizadas bajo condiciones tropicales húmedas del Ecuador.

3.1 Estadísticos descriptivos de las variables del estudio

La Tabla 2 presenta los estadísticos descriptivos de las 936 observaciones semanales analizadas. El FCR acumulado mostró media de 1.23 (DE = 0.22) con rango entre 0.81 y 1.67, reflejando la heterogeneidad natural entre fases productivas tempranas (semanas 1-4) y tardías (semanas 5-7).

Las condiciones ambientales reflejaron características típicas de clima tropical húmedo: temperatura promedio de 27.42°C (DE = 2.10) con rango entre 22.90 y 32.00°C, y humedad relativa de 82.58 % (DE = 4.18), valor que excede las guías técnicas óptimas establecidas (60-75 %).

Los gases ambientales se mantuvieron en concentraciones moderadas (CO_2 : 589.25 \pm 36.28 ppm; NH_3 : 18.46 \pm 2.02 ppm). La variabilidad observada en peso corporal (1,476.91 \pm 957.24 g) y FCR (1.23 \pm

Tabla 2: Variables de la base de datos

Variable	Media	DE	Mínimo	Máximo	CV (%)
FCR acumulativo (kg/kg)	1,23	0,22	0,81	1,67	17,9
Temperatura interna (°C)	27,42	2,10	22,90	32,00	7,7
Humedad relativa (%)	82,58	4,18	68,50	89,80	5,1
CO ₂ (ppm)	589,25	36,28	476,30	700,00	6,2
NH ₃ (ppm)	18,46	2,02	12,60	24,70	10,9
Peso promedio (g)	1.476,91	957,24	166,20	3.389,30	64,8
Mortalidad acumulada (%)	1,70	1,00	0,10	3,58	58,8
Consumo semanal (g/ave)	1.666,60	866,36	426,50	3.483,80	52,0
Densidad (aves/m ²)	16,38	0,17	16,10	16,60	1,0

0.22) refleja la progresión natural del ciclo productivo, proporcionando adecuada dispersión para la modelación predictiva.

3.1.1 Selección de variables predictores mediante análisis de correlaciones

El análisis de correlaciones bivariadas reveló patrones definidos entre el FCR acumulado y las variables ambientales evaluadas. Como se observa en la Tabla 3, cuatro variables mostraron correlaciones estadísticamente significativas ($p < 0.001$) con el FCR acumulado, mientras que otras tres variables no alcanzaron el umbral de significancia establecido.

La temperatura ambiental exhibió correlación negativa fuerte ($r = -0.682$, $p < 0.001$), evidenciando su papel en la dinámica del FCR. Ave madura presentó la correlación positiva más alta ($r = 0.745$, $p < 0.001$), reflejando el incremento progresivo del FCR en semanas finales del ciclo productivo. La humedad relativa mostró correlación positi-

va moderada ($r = 0.512$, $p < 0.001$), mientras que la línea genética evidenció correlación positiva significativa ($r = 0.321$, $p < 0.001$), reflejando diferencias en eficiencia alimenticia entre COBB 500 y ROSS 308 bajo las condiciones evaluadas.

Las variables CO₂ ($r = 0.045$, $p = 0.324$) y NH₃ ($r = 0.038$, $p = 0.287$) no alcanzaron significancia estadística. La densidad de aves ($r = 0.062$, $p = 0.156$) mostró baja variabilidad operativa entre granjas (16.38 ± 0.17 aves/m²), limitando su capacidad predictiva diferencial.

3.2 Verificación de supuestos estadísticos

El diagnóstico exhaustivo de supuestos confirmó la adecuación del modelo de RLM. La prueba de Shapiro-Wilk ($W = 0.994$, $p = 0.089$) validó la normalidad de la distribución de residuos, cumpliendo con el supuesto de errores normalmente distribuidos. La prueba de Durbin-Watson arrojó un valor de 1.98, evidenciando independencia resi-

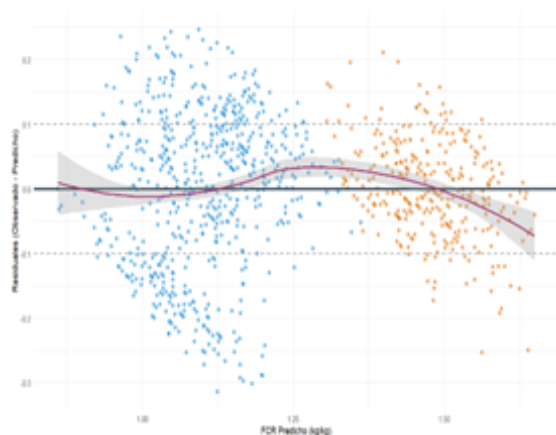
Tabla 3: Variables de la base de datos

Variable	Correlación FCR	Significancia
Temperatura ambiental (°C)	-0.682***	p < 0.001
Humedad relativa (%)	0.512***	p < 0.001
Ave_madura (semanas 5-7)	0.745***	p < 0.001
Línea genética (ROSS 308)	0.321***	p < 0.001
CO ₂ promedio (ppm)	0.045	p = 0.324
NH ₃ promedio (ppm)	0.038	p = 0.287
Densidad_aves_m ²	0.062	p = 0.156

dual y ausencia de autocorrelación significativa (valor cercano a 2 indica independencia óptima). La prueba de Breusch-Pagan ($\chi^2 = 4,32, p = 0,115$) confirmó homocedasticidad, descartando problemas de varianza heterogénea de residuos. Los Factores de Inflación de la Varianza (VIF ≤ 2.5 para todos los predictores) descartaron problemas sustanciales de multicolinealidad entre variables independientes.

La Figura 1 complementa estos resultados mostrando la distribución de residuales en función de los valores predichos de FCR.

Figura 1: Diagnóstico de Residuales del Modelo de RLM



Los puntos se dispersan aleatoriamente alre-

dor de la línea de residual cero (línea sólida negra), sin evidenciar patrones sistemáticos de curvatura o heterocedasticidad. La línea suavizada (morada) permanece próxima a cero en todo el rango de predicción, y el área sombreada (intervalo de confianza) mantiene amplitud constante, confirmando la estabilidad de la varianza residual. La diferenciación por fase productiva (semanas 1-4 en azul, semanas 5-7 en naranja) muestra distribución equilibrada en ambos períodos, con la mayoría de los residuales contenidos dentro del rango de ± 0.1 unidades de FCR, validando visualmente la ausencia de sesgo y el cumplimiento de los supuestos de regresión lineal.

3.3 Modelo de RLM final

El modelo final explicó 77.4 % de la varianza total del FCR acumulado ($R^2 = 0.774$; R^2 ajustado = 0.773), evidenciando excelente capacidad explicativa. El análisis de varianza confirmó significancia global altamente robusta ($F(6,929) = 158.3, p \leq 0.001$), validando la utilidad conjunta de los predictores incluidos. El error estándar residual fue de 0.107 puntos de FCR.

La Tabla 4 muestra que cuatro predictores fueron altamente significativos ($p \leq 0.001$).

La temperatura exhibió efecto negativo sustancial ($\beta = -0,0445, p < 0,001$), indicando que cada incremento de 1°C reduce el FCR en 0.0445 puntos. La fase fisiológica mostró el mayor impacto absoluto ($\beta = 0,198, p < 0,001$), reflejando el deterioro natural de la eficiencia de conversión al avanzar hacia semanas finales. La humedad presentada efecto positivo moderado ($\beta = 0,00858, p < 0,001$). La línea genética mostró diferencia significativa ($\beta = 0,072, p < 0,001$), con ROSS 308 exhibiendo FCR superior a COBB 500 bajo las condiciones evaluadas. CO_2 ($\beta = 0,000017, p = 0,879$) y NH_3 ($\beta = 0,000655, p = 0,742$) no alcanzaron significancia estadística.

La Ecuación 3 predictiva final del modelo se define de la siguiente manera:

$$\begin{aligned} \text{FCR} = & 1,631 - 0,0445 \cdot \text{Temperatura} \\ & + 0,00858 \cdot \text{Humedad} \\ & + 0,198 \cdot \text{Ave_madura} \\ & + 0,072 \cdot \text{Linea_genetica} \end{aligned} \quad (3)$$

Donde temperatura se expresa en $^{\circ}\text{C}$, humedad en %, Ave_madura es una variable binaria (0 = semanas 1-4; 1 = semanas 5-7), y Línea_genética es una variable binaria (0 = COBB 500; 1 = ROSS 308).

La Figura 2 muestra los coeficientes del modelo de regresión, cuantificando el impacto de cada variable sobre el FCR. Las barras rojas indican factores que aumentan el FCR

(menor eficiencia), mientras que las verdes lo reducen (mayor eficiencia).

La fase productiva presenta el mayor efecto, con un incremento de +0.198 unidades al pasar de las semanas 1-4 a las semanas 5-7, reflejando la disminución natural de la eficiencia de conversión con la edad. La línea genética ROSS 308 registra un FCR superior en +0.072 unidades respecto a COBB 500, señalando diferencias en el potencial genético de conversión bajo condiciones tropicales.

La temperatura ambiental constituye la variable de control más influyente, con un coeficiente de -0.044, indicando que cada incremento de 1°C mejora la eficiencia alimenticia, posiblemente al reducir el gasto energético de termorregulación dentro de la zona de confort térmico. La humedad relativa muestra un efecto mínimo (+0.009 por cada 1 %), con impacto limitado en comparación con las demás variables.

Estos resultados destacan que, si bien los factores biológicos (fase y genética) ejercen la mayor influencia sobre el FCR, las variables ambientales monitorizadas mediante IoT ofrecen oportunidades tangibles de optimización productiva mediante el control microclimático preciso.

3.4 Validación y capacidad predictiva

La validación externa con 186 observaciones independientes (20 % del conjunto de datos) confirmó robustez predictiva del modelo, alcanzando $R^2 = 0.739$ en datos no vistos durante el proceso de ajuste. Esta pérdi-

Tabla 4: Variables de la base de datos


Predictor	B	p-valor	IC 95 %
Intercepto	1,631	<0,001	[1,400; 1,862]
Temperatura (°C)	-0,0445	<0,001	[-0,049; -0,040]
Humedad relativa (%)	0,00858	<0,001	[0,0067; 0,0105]
Ave madura	0,198	<0,001	[0,176; 0,220]
Línea genética	0,072	<0,001	[0,058; 0,086]
CO ₂ (ppm)	0,000017	0,879	[-0,0002; 0,0002]
NH ₃ (ppm)	0,000655	0,742	[-0,0033; 0,0046]

da predictiva de 4.5 puntos porcentuales (de 77.4 % a 73.9 %) evidencia excelente capacidad de generalización y estabilidad del modelo ante nuevos datos.

Las métricas de error absoluto mostraron alta precisión operativa: MAE = 0.088 y RMSE = 0.109 puntos de FCR. Estos valores representan aproximadamente 7 % y 9 % respectivamente de la desviación estándar observada en FCR (DE = 0.22), indicando utilidad práctica para aplicaciones de monitoreo en granjas automatizadas.

La Figura 2 presenta la relación entre valores predichos y observados de FCR, mostrando un ajuste satisfactorio del modelo de regresión desarrollado. Los puntos se distribuyen próximos a la línea de predicción perfecta ($y = x$, línea gris), mientras que la línea roja y su intervalo de confianza del 95 % evidencian la capacidad del modelo para estimar el índice de conversión alimenticia a partir de variables ambientales.

Figura 2: Relación entre valores predichos y observados de FCR



El análisis por línea genética (COBB 500 y ROSS 308) no revela diferencias sustanciales en el patrón predictivo, validando la aplicabilidad del modelo para ambas estirpes. La estratificación temporal muestra que las semanas 1-4 (azul) presentan menor dispersión que las semanas 5-7 (naranja), sugiriendo mayor sensibilidad del modelo en fases tempranas cuando las variables ambientales ejercen mayor impacto sobre el desempeño productivo. La distribución homogénea de residuales confirma la ausencia de sesgo sistemático y respalda la validez del enfoque de regresión lineal múltiple para condiciones de producción avícola en clima tropical húmedo.

4. Discusión

Los resultados obtenidos demuestran consistentemente que el modelo de regresión lineal múltiple desarrollado exhibe capacidad predictiva robusta y operativamente útil para estimar el factor de conversión alimenticia semanal en granjas avícolas automatizadas bajo condiciones tropicales húmedas. El R^2 de 0,774 en entrenamiento y 0,739 en validación externa, acompañado de errores de predicción bajos (MAE = 0,088; RMSE = 0,109), supera los valores típicamente reportados en la literatura para modelos similares en contextos comerciales reales. Investigaciones previas en granjas brasileñas reportaron R^2 entre 0,65-0,72 para modelos de predicción de FCR utilizando variables ambientales, mientras que estudios en México alcanzaron R^2 de 0,69-0,75 (Freitas et al., 2025). La capacidad predictiva de nuestro modelo se mantuvo estable a través de diferentes ciclos productivos, fases fisiológicas y condiciones estacionales, evidenciando robustez para implementación operativa inmediata.

El efecto negativo sustancial de la temperatura ambiental sobre el FCR (-0,0445 puntos por °C) constituye un hallazgo que requiere interpretación cuidadosa dentro del contexto tropical específico. Dentro del rango de temperaturas observado (22,9-32,0°C), incrementos térmicos moderados parecen favorecer la eficiencia alimenticia, posiblemente debido a reducciones en los requerimientos energéticos de mantenimiento para termorregulación. Este hallazgo contrasta con estudios realizados en climas templados

donde temperaturas superiores a 28°C generalmente deterioran el FCR mediante mecanismos de estrés térmico bien documentados (Oke et al., 2024). La aparente discrepancia sugiere tres explicaciones plausibles no mutuamente excluyentes.

Primero, las aves criadas bajo condiciones tropicales húmedas podrían desarrollar aclimatación fisiológica que modifica sus rangos óptimos de termoneutralidad. La exposición crónica a temperaturas elevadas puede inducir adaptaciones metabólicas y conductuales que mejoran la tolerancia térmica. Segundo, el rango de temperaturas observado (22,9-32,0°C) podría ubicarse mayoritariamente dentro o ligeramente por encima de la zona de termoneutralidad para pollos en fase de crecimiento acelerado (típicamente 18-26°C), donde incrementos moderados efectivamente reducen gastos energéticos de mantenimiento sin alcanzar umbrales de estrés térmico severo. Tercero, podría existir confusión parcial con variables estacionales no capturadas: períodos de mayor temperatura (época seca) podrían coincidir con mejor calidad de cama, menor carga microbiana y condiciones generales más favorables para el desempeño avícola.

La magnitud del coeficiente indica que variaciones de 2-3°C en la temperatura promedio semanal comunes entre épocas secas y lluviosas en Santo Domingo de los Tsáchilas pueden traducirse en diferencias de 0,09-0,13 puntos en el FCR, representando impactos económicos sustanciales considerando que el alimento constituye 60-70 % de los costos operativos (Muyulema et al.,

2020). Esta sensibilidad económica subraya la importancia crítica del control ambiental automatizado en condiciones tropicales.

El efecto positivo de la humedad relativa sobre el FCR (0,00858 puntos por %) confirma los desafíos particulares de la avicultura en ambientes tropicales húmedos, consistente con hallazgos previos en condiciones similares (Hidalgo et al., 2024). El coeficiente estimado indica que, por cada aumento de 10 puntos porcentuales en la humedad relativa dentro del rango observado, el FCR se incrementa en aproximadamente 0,086 puntos lo que implica menor eficiencia alimenticia. Este efecto probablemente opera a través de múltiples mecanismos fisiológicos y ambientales interrelacionados: estrés térmico por reducción de la capacidad de pérdida de calor evaporativo, deterioro de la calidad física de la cama con consecuentes problemas podales y dermatitis de contacto, y potencial aumento de la carga microbiana ambiental que compromete la salud intestinal y respiratoria.

El hecho de que la humedad relativa emergiera como predictor significativo a pesar de la relativa homogeneidad de los valores observados (CV = 5,1 %, rango 68,5-89,8 %) resalta su importancia crítica en estos sistemas. Los valores promedio de 82,58 % exceden consistentemente las guías técnicas óptimas internacionales (60-75 %), reflejando la limitación física fundamental de controlar humedad en climas tropicales mediante sistemas de ventilación convencionales sin deshumidificación activa, tecnología aún no económicamente viable para produc-

ción comercial en la región.

La fase fisiológica presentó el mayor efecto individual sobre el FCR, al pasar de las semanas 1–4 a 5–7, el FCR aumenta en 0,198 puntos, en línea con la menor eficiencia alimenticia propia del cierre del ciclo productivo. Este resultado es consistente con el conocimiento fisiológico establecido: a medida que las aves maduran, la composición de la ganancia de peso cambia progresivamente hacia mayor deposición de grasa (energéticamente costosa) en detrimento de proteína muscular, los requerimientos energéticos de mantenimiento aumentan proporcionalmente más que el potencial de ganancia, y pueden manifestarse reducciones en la capacidad digestiva y de absorción intestinal (Quintana-Ospina et al., 2023).

La magnitud de este efecto (0,198 puntos) resalta la importancia estratégica de implementar prácticas de manejo diferenciadas según la fase productiva, particularmente concerniente a densidad de alojamiento efectiva, estrategias de ventilación, y formulación alimenticia adaptada a los cambios en requerimientos nutricionales. La capacidad del modelo de mantener precisión predictiva equivalente en ambas fases (demostrada en Figura 1) confirma su utilidad operativa a lo largo del ciclo productivo completo.

Las diferencias genéticas entre líneas también emergieron como predictores significativos, con la línea ROSS 308 mostrando un FCR 0,072 puntos superior al COBB 500 bajo condiciones comparables. Esta diferencia, aunque moderada en magnitud, es

consistentemente reportada en la literatura técnica comercial y refleja distintos equilibrios establecidos por los programas de selección genética: ROSS 308 típicamente exhibe velocidad de crecimiento ligeramente superior pero eficiencia alimenticia marginalmente inferior comparada con COBB 500 (Gholami et al., 2020). Desde una perspectiva operativa, este hallazgo justifica el establecimiento de metas de FCR diferenciadas por línea genética en sistemas de monitoreo y la consideración explícita de estas diferencias en análisis económicos de selección de genética.

La ausencia de significancia estadística de CO_2 y NH_3 como predictores dentro de los rangos operativos observados constituye un hallazgo relevante desde la perspectiva del manejo práctico. Las concentraciones promedio de CO_2 (589,25 ppm) y NH_3 (18,46 ppm) se mantuvieron consistentemente por debajo de los umbrales críticos establecidos en la literatura para afectación del desempeño productivo ($<3,000$ ppm y <25 ppm, respectivamente). Esto sugiere que, bajo las condiciones de ventilación mecánica y manejo de cama prevalentes en las granjas estudiadas caracterizadas por sistemas de túnel con alta capacidad de renovación de aire estas variables no constituyeron limitantes principales para la eficiencia alimenticia durante el período de estudio.

Sin embargo, es importante destacar enfáticamente que este resultado no minimiza la importancia de mantener adecuados controles de calidad de aire, particularmente considerando los efectos documentados de estos

gases sobre la salud respiratoria, el bienestar animal y la incidencia de enfermedades respiratorias a más largo plazo. La ausencia de efecto detectado probablemente refleja el éxito de las prácticas de manejo implementadas más que la irrelevancia intrínseca de estos parámetros.

La capacidad predictiva del modelo comparado favorablemente con estudios utilizando técnicas de machine learning más complejas. A diferencia de algoritmos que alcanzan exactitudes superiores al 98 % mediante optimización exhaustiva de hiperparámetros (Vilema et al., 2022), pero carecen de interpretabilidad directa, nuestro modelo mantiene un equilibrio óptimo entre capacidad predictiva ($R^2 = 0,774$) y transparencia operativa. Esta característica es particularmente valiosa en contextos donde el personal técnico debe justificar intervenciones de manejo específicas ante gerencia operativa, y donde la comprensión de la dirección y magnitud de los efectos facilita la toma de decisiones fundamentada (Granda et al., 2023).

Desde la perspectiva de implementación práctica, el modelo ofrece ventajas significativas. La Ecuación 3 resultante $FCR = 1,631 - 0,0445 \times \text{Temperatura} + 0,00858 \times \text{Humedad} + 0,198 \times \text{Fase} + 0,072 \times \text{ROSS}$ puede programarse fácilmente en hojas de cálculo o dashboards operativos, requiriendo únicamente insumos rutinariamente disponibles en granjas automatizadas. La simplicidad computacional lo hace accesible para empresas medianas y pequeñas sin infraestructura especializada para algoritmos complejos. La naturaleza

lineal de las relaciones facilita sustancialmente la comunicación de hallazgos y la justificación de intervenciones basadas en pronósticos generados.

Las implicaciones económicas son sustanciales. Considerando que variaciones de 0,1 puntos en FCR pueden traducirse en diferencias de 3-5 % en rentabilidad en operaciones medianas, la capacidad de predecir y gestionar proactivamente este indicador tiene impacto directo en sostenibilidad financiera. La implementación del modelo como sistema de alerta temprana permitiría intervenciones correctivas ajustes en ventilación, densidad, estrategia alimenticia antes de que las ineficiencias se consoliden en sobrecostos irreversibles.

4.1 Limitaciones del estudio

Es importante contextualizar las limitaciones. El modelo fue desarrollado y validado específicamente para condiciones tropicales húmedas de Ecuador y podría requerir recalibración para otros contextos climáticos. El rango de valores observado para gases ambientales fue relativamente estrecho debido a las buenas prácticas de ventilación, limitando potencialmente la detección de efectos que podrían manifestarse en condiciones más extremas. El modelo no incorpora variables relacionadas con salud aviar específica, calidad nutricional del alimento, o factores de estrés agudo, que podrían aportar varianza explicativa adicional. La generalización a sistemas con diferente nivel de automatización o capacidad de control ambiental requiere evaluación específica.

Los hallazgos abren varias líneas de investigación. Sería valioso explorar interacciones no lineales mediante splines o transformaciones polinómicas, particularmente para temperatura en rangos extremos. La incorporación de variables adicionales como velocidad de viento, calidad de cama medida objetivamente, e indicadores de salud del lote podría mejorar la capacidad predictiva. El desarrollo de sistemas de integración en tiempo real con plataformas IoT existentes facilitaría la implementación operativa. Estudios longitudinales evaluando el impacto económico de la implementación del modelo en condiciones comerciales reales permitirían cuantificar más precisamente su valor agregado y retorno de inversión.

5. Conclusiones

- El modelo de regresión lineal múltiple desarrollado demostró capacidad predictiva robusta y operativamente útil para estimar el FCR semanal en granjas avícolas automatizadas bajo condiciones tropicales húmedas. Los indicadores de desempeño alcanzados ($R^2 = 0,774$ en entrenamiento; $R^2 = 0,739$ en validación externa; MAE = 0,088; RMSE = 0,109) superan los umbrales típicamente considerados aceptables para aplicaciones comerciales y se mantienen estables a través de diferentes ciclos productivos y condiciones estacionales, evidenciando robustez para implementación operativa inmediata.
- Las variables ambientales monitorizadas continuamente fueron predictores significativos del FCR ($p < 0,001$). En

el rango observado (22,9–32,0 °C), la temperatura se asoció inversamente con el FCR (-0,0445 puntos/°C), coherente con una menor demanda de termorregulación. La humedad relativa mostró asociación positiva (+0,00858 puntos/ %), reflejando los retos del ambiente tropical húmedo. En conjunto, los resultados obtenidos en granjas automatizadas en operación resaltan la importancia del control ambiental automatizado para optimizar la eficiencia alimenticia.

- Las características del lote incidieron significativamente en el FCR. La fase final (semanas 5–7) incrementó el FCR en 0,198 puntos respecto de la fase inicial (semanas 1–4), en concordancia con el mayor costo energético de mantenimiento y los cambios en la composición del crecimiento al cierre del ciclo. La línea genética ROSS 308 presentó un FCR 0,072 puntos superior a COBB 500 bajo condiciones comparables, lo que sugiere diferencias sistemáticas entre perfiles de crecimiento y eficiencia. Estos resultados respaldan metas de FCR diferenciadas por fase productiva y genética.
- El modelo representa una herramienta operativamente viable para gestión preventiva del FCR en granjas comerciales, ofreciendo un balance óptimo entre capacidad predictiva, simplicidad computacional y transparencia interpretativa. A diferencia de algoritmos de machine learning tipo “caja negra”, la

ecuación de regresión lineal desarrollada puede implementarse fácilmente en hojas de cálculo o dashboards operativos existentes, requiriendo únicamente insumos rutinariamente disponibles en granjas automatizadas. Esta accesibilidad facilita su adopción por empresas medianas y pequeñas sin infraestructura (galpones automáticos), democratizando el acceso a herramientas analíticas avanzadas.

- La implementación del modelo como sistema de alerta temprana permitiría intervenciones correctivas proactivas (ajustes en ventilación, densidad, estrategia alimenticia) antes de que las ineficiencias se consoliden en sobrecostos irreversibles. Considerando que el alimento representa 60-70 % de costos operativos y que variaciones de 0,1 puntos en FCR impactan 3-5 % la rentabilidad, la capacidad de predecir y gestionar este indicador tiene consecuencias directas en sostenibilidad financiera. Se recomienda la implementación piloto en granjas seleccionadas para validar utilidad operativa y la integración futura con dashboards IoT en tiempo real para maximizar su valor práctico en la toma de decisiones diarias.

6. Conflicto de intereses

Los autores declaran que no existe conflicto de intereses en relación con el artículo presentado.

7. Declaración de contribución de los autores

Todos autores contribuyeron significativamente en la elaboración del artículo.

8. Costos de financiamiento

La presente investigación fue financiada en su totalidad con fondos propios de los autores.

9. Referencias Bibliográficas

Adli, D. N., Fatyanosa, T. N., Huda, F. A., Sholikin, M. M., & Sugiharto, S. (2025). Modelling the growth performance and thermal environment of broiler chicken houses via different machine learning algorithms assisted by a customized Internet of Things. *Smart Agricultural Technology*, 12, 101421. <https://doi.org/10.1016/j.atech.2025.101421>

Astill, J., Dara, R. A., Fraser, E. D. G., Roberts, B., & Sharif, S. (2020). Smart poultry management: smart sensors, big data, and the internet of things. *Computers and Electronics in Agriculture*, 170, 105291. <https://doi.org/10.1016/j.compag.2020.105291>

Batista-Mendoza, G., Cedeño Herrera, E. J., & Cedeño-Batista, G. (2023). Machine learning aplicado al análisis de un conjunto de datos de parámetros ambienta-

les en galpones de pollos de engorde. *Visión Antataura*, 7(2), 121-146. <https://doi.org/10.48204/j.vian.v7n2.a4566>

Corporación Nacional de Avicultores del Ecuador [CONAVE]. (2024). CONAVE presenta las estadísticas del sector avícola. <https://conave.org/conave-presenta-las-estadisticas-del-sector-avicola/>

Elwakeel, A. E. (2025). A smart automatic control and monitoring system for environmental control in poultry houses integrated with earlier warning system. *Scientific Reports*, 15(1), 31630. <https://doi.org/10.1038/s41598-025-17074-2>

Fang, C., Huang, J., Cuan, K., Zhuang, X., & Zhang, T. (2020). Comparative study on poultry target tracking algorithms based on a deep regression network. *Biosystems Engineering*, 190, 176–183. <https://doi.org/10.1016/j.biosystemseng.2019.12.002>

Freitas, R. C., Calderano, A. A., Oliveira, C. H., Neto, M. G., & Genova, J. L. (2025). Combined analysis of multiple linear regression and principal components for predicting performance indicators in broiler chickens under commercial conditions. *Poultry Science*, 104(11), 105728. <https://doi.org/10.1016/j.psj.2025.105728>

Gallard, E., Menichelli, M., Dimasso, R., & Revidatti, F. (2022). Effect of stocking

- density and shed area on welfare indicators in broiler chickens. *Revista Veterinaria*, 33(2), 230–234. <http://dx.doi.org/10.30972/vet.3326188>
- Gholami, M., Chamani, M., Seidavi, A., Sadeghi, A. A., & Aminafschar, M. (2020). Effects of stocking density and environmental conditions on performance, immunity, carcass characteristics, blood components and economic parameters of Cobb 500 strain broiler chickens. *Italian Journal of Animal Science*, 19(1), 524–535. <https://doi.org/10.1080/1828051X.2020.1757522>
- González Martínez, A. A., de Aleancar Nääs, I., Ridolfi de Carvalho-Curi, T. M., Minoro Abe, J., & Duarte da Silva Lima, N. (2021). A heuristic and data mining model to predict the environmental suitability of broiler houses. *Animals*, 11(10), 2780. <https://doi.org/10.3390/ani111102780>
- Granda Tola, C. F., Cobos Mora, S. L., & Vásquez Quiroz, P. T. (2023). Rendimiento de mano de obra en excavaciones a mano mediante regresión lineal. Caso de estudio: ciudad de Cuenca. *Ciencia Digital*, 7(3), 124–146. <https://doi.org/10.33262/cienciadigital.v7i3.2629>
- Hidalgo López, G. Y., Zambrano Villacís, J. J., & Marini, P. R. (2024). Indicadores de eficiencia productiva en granjas avícolas convencionales vs. técnicas ubicadas en la provincia de Manabí - Ecuador. *Ciencia Digital*, 8(3), 122–136. <https://doi.org/10.33262/cienciadigital.v8i3.2963>
- Jackman, P., Peña, H., & Ross, R. (2020). The role of information and communication technologies in broiler production process control: A review. *International Agricultural Engineering: CIGR Journal*, 22(3), 284–299. <https://researchprofiles.tudublin.ie/en/publications/the-role-of-information-and-communication-technology-in-poultry-b-2/>
- Li, M., Zhou, Z., Zhang, Q., Zhang, J., Suo, Y., Liu, J., ... Li, C. (2024). Multivariate analysis for data mining to characterize poultry house environment in winter. *Poultry Science*, 103(5), 103633. <https://doi.org/10.1016/j.psj.2024.103633>
- Liu, G., Guo, H., Ruchay, A., & Pezzuolo, A. (2023). Recent advances in precision livestock farming. *Agriculture*, 13(9), 1652. <https://doi.org/10.3390/agriculture13091652>
- Liu, M., Chen, H., Zhou, Z., Du, X., Zhao, Y., Ji, H., & Teng, G. (2024). Development of an intelligent service platform for a chicken house facility environment based on the internet of things. *Agriculture*, 14(8), 1277. <https://doi.org/10.3390/agriculture14081277>
- Muyulema Allaica, C. A., Muyulema Allaica, J. C., Pucha Medina, P. M., & Ocaña Parra, S. V. (2020). Los costos de producción y su incidencia en la rentabilidad de

- una empresa avícola integrada del Ecuador: caso de estudio. *Visionario Digital*, 4(1), 43–66. <https://doi.org/10.33262/visionariodigital.v4i1.1089>
- Nasiri, A., Yoder, J., Zhao, Y., Hawkins, S., Prado, M., & Gan, H. (2022). Pose estimation-based lameness recognition in broiler using CNN-LSTM network. *Computers and Electronics in Agriculture*, 197, 106931. <https://doi.org/10.1016/j.compag.2022.106931>
- Natho, P., Boonying, S., Bonguleaum, P., Tantidontanet, N., & Chamuthai, L. (2025). An enhanced machine vision system for smart poultry farms using deep learning. *Smart Agricultural Technology*, 12, 101083. <https://doi.org/10.1016/j.atech.2025.101083>
- Nyalala, I., Okinda, C., Kunjie, C., Korohou, T., Nyalala, L., & Chao, Q. (2021). Weight and volume estimation of poultry and products based on computer vision systems: a review. *Poultry Science*, 100(5), 101072. <https://doi.org/10.1016/j.psj.2021.101072>
- Ojo, R. O., Ajayi, A. O., Owolabi, H. A., Oyedele, L. O., & Akanbi, L. A. (2022). Internet of Things and machine learning techniques in poultry health and welfare management: A systematic literature review. *Computers and Electronics in Agriculture*, 200, 107266. <https://doi.org/10.1016/j.compag.2022.107266>
- Oke, O. E., Akosile, O. A., Uyanga, V. A., Oke, F. O., Oni, A. I., Tona, K., & Onagbesan, O. M. (2024). Climate change and broiler production. *Veterinary Medicine and Science*, 10(3), e1416. <https://doi.org/10.1002/vms3.1416>
- Pereira, W. F., Fonseca, L. S., Putti, F. F., Góes, B. C., & Naves, L. P. (2020). Environmental monitoring in a poultry farm using an instrument developed with the Internet of Things concept. *Computers and Electronics in Agriculture*, 170, 105257. <https://doi.org/10.1016/j.compag.2020.105257>
- Qaid, M., Albatshan, H., Hussein, E., & Al-Garadi, M. (2023). Effect of housing system and housing density on performance, viability, and gastrointestinal tract growth of broiler chicks during the first 2 weeks of age. *Poultry Science*, 102(7), 102752. <https://doi.org/10.1016/j.psj.2023.102752>
- Quintana-Ospina, G. A., Alfaro-Wisaquillo, M. C., Oviedo-Rondón, E. O., Ruiz-Ramírez, J. R., Bernal-Arango, L. C., & Martínez-Bernal, G. D. (2023). Data analysis of growth dynamics and feed conversion rate of broiler chickens raised up to 35 days under tropical commercial conditions. *Animals*, 13(15), 2447. <https://doi.org/10.3390/ani13152447>
- Shynkaruk, T., Long, K., LeBlanc, M., & Schwean-Lardner, K. (2023). Impact of stocking density on the welfare and productivity of broiler chickens reared to 34 d of age. *Journal of Applied Poultry Research*, 32(2), 100344. <https://doi.org/10.1016/j.japr.2023.100344>

Tahamtani, F. M., Pedersen, I. J., & Riber, A. B. (2020). Effects of environmental complexity on welfare indicators of fast-growing broiler chickens. *Poultry Science*, 99(1), 21–29. <https://doi.org/10.3382/ps/pez510>

Vilema Lara, P. H., García Mora, F. A., & Gallegos Londoño, C. M. (2022). Aprendizaje de máquina para mantenimiento predictivo: un problema de clasificación binaria. *Conciencia Digital*, 5(2.1), 45–68. <https://doi.org/10.33262/concienciadigital.v5i2.1.2150>

You, J., Lou, E., Afrouziyeh, M., Zukiwsky, N. M., & Zuidhof, M. J. (2021). Using an artificial neural network to predict the probability of oviposition events of precision-fed broiler breeder hens. *Poultry Science*, 100(8), 101187. <https://doi.org/10.1016/j.psj.2021.101187>