

# Modelo Integrado de Predicción de Peso y Optimización de Cosecha en la Industria Avícola

Enfocado en la reducción de costos y el cumplimiento del mix de oferta

Luisa Fernanda Giraldo C. y Juan Sebastián Guzmán G.

fernandagiraldo21@gmail.com, juanguzgira@gmail.com

**Resumen** - Este proyecto desarrolla un modelo integrado que combina la predicción del peso de pollos de engorde y la optimización del proceso de cosecha, con el objetivo de minimizar los costos de alimentación y garantizar el cumplimiento de los rangos de peso exigidos por el mercado. La iniciativa se enmarca en una empresa del sector avícola, donde la planificación eficiente es clave para mejorar la rentabilidad y satisfacer la demanda de aves clasificadas como pequeñas, medianas o grandes.

En una primera fase, se construyó un modelo de regresión polinómica de grado 3, ajustado para dos grupos de edad: aves menores o iguales a 38 días, y aves de 39 días en adelante. El modelo alcanzó un RMSE de 0.129 kg ( $R^2=0.3388$ ) para el primer grupo, y un RMSE de 0.1963 kg ( $R^2=0.8119$ ) para el segundo, lo que permitió capturar con mayor precisión la evolución del peso en el tiempo.

Posteriormente, se diseñó un modelo de optimización basado en programación matemática, empleando las predicciones de peso como insumo. El modelo fue capaz de planificar la cosecha óptima en 12 días operativos del horizonte de planeación (2 Semanas), respetando las restricciones de demanda por categoría de peso y evitando el sacrificio de aves con peso fuera de especificación. Los resultados muestran el potencial de la integración analítica para mejorar la toma de decisiones operativas en la industria avícola.

**Índice de Términos** - Avicultura, Modelado predictivo, Optimización matemática, Regresión polinómica

**Keywords:** Broiler weight prediction, Harvest planning, Mathematical optimization, Polynomial regression

# I. Introducción

De acuerdo con la Federación Nacional de Avicultores de Colombia, el consumo de carne de pollo en el país superó los 35 kg per cápita en 2023 y mantiene una tendencia ascendente en la última década, consolidándose como la principal fuente de proteína animal en el país (Fenavi, 2024). Para atender esa demanda, las grandes integradoras avícolas –entre ellas una de las compañías líderes del sector que se toma como caso de estudio en este trabajo– operan cadenas altamente sincronizadas que van desde la producción de huevo fértil hasta la distribución del producto procesado.

El eslabón más sensible de esa cadena es la cosecha (beneficio) de pollos de engorde. Escoger qué lote sacrificar, en qué fecha y desde qué galpón implica balancear cuatro frentes:

1. Entregar el mix de pesos que exige el mercado (aves pequeñas, medianas y grandes);
2. Evitar que las aves sobrepasen el rango comercial;
3. Respetar ventanas operativas (barridas parciales, tiempos mínimos entre cosechas);
4. Contener los costos de alimentación, que representan entre el 70 % y el 80 % del costo total.

Cada semana coexisten cientos de lotes con edades y velocidades de crecimiento distintas. Sacrificar antes de tiempo compromete la oferta futura; sacrificar tarde incrementa el consumo de alimento y genera sobrepesos. Además, la decisión se toma por galpón completo, no ave por ave, lo que añade rigidez. En la práctica, la empresa necesita fijar su plan de beneficio con al menos 4–6 semanas de anticipación y, para ello, debe proyectar con precisión el peso futuro de cada lote.

Este estudio plantea una solución analítica integrada compuesta por:

- Un modelo de predicción de peso basado en regresiones polinómicas por rangos de edad, que incorpora edad, sexo y tipo de galpón, y entrega estimaciones diarias de peso.
- Un modelo de optimización de cosecha formulado en programación entera mixta, que usa esas predicciones para determinar el calendario de beneficio que minimiza costos de alimentación y satisface el mix de mercado bajo las restricciones operativas reales.


## Justificación

La planificación de la cosecha en la industria avícola representa uno de los procesos más sensibles y estratégicos dentro de la cadena de suministro, especialmente en empresas de gran escala, donde las decisiones deben considerar simultáneamente aspectos biológicos, operativos, económicos y comerciales.

En este contexto, la toma de decisiones sobre qué aves cosechar y en qué momento impacta directamente en la eficiencia del uso del alimento, la disponibilidad de producto para el mercado, el cumplimiento de especificaciones de peso y la capacidad operativa de las plantas de beneficio. Una mala decisión en la cosecha puede desencadenar efectos en cadena como sobrecostos de alimentación, incumplimientos con clientes, pérdida de producto, congestión operativa o desabastecimiento.

Esta decisión implica encontrar un balance delicado: si se cosechan aves antes de tiempo, se compromete el suministro futuro de aves medianas y grandes; si se espera demasiado, las aves pueden exceder el rango de peso comercial, generando sobrecostos de alimentación y pérdida de valor en el mercado.

El problema radica en que, al decidir qué galpones sacrificar en un día determinado, se afecta inevitablemente la oferta disponible en los días siguientes. Cada ave que hoy es clasificada como “pequeña”, mañana podría alcanzar la categoría “mediana” o incluso “grande”, si se sigue alimentando. Sin embargo, el crecimiento continuo también implica un aumento en los costos diarios, y el riesgo de que el peso sobrepase los límites aceptables por los clientes. Este desafío cobra aún más relevancia al considerar la distribución de la demanda del mercado, donde se privilegia un mix específico de categorías de peso y tipo de ave (ver **Fig. 1**).



**Fig. 1.** Participación porcentual del mercado según tipo y categoría de pollo. Esta figura resalta la preferencia del mercado por el pollo blanco, con una distribución específica entre aves pequeñas, medianas y grandes, y una participación significativa del pollo campesino

A pesar de su complejidad, el proceso de cosecha suele apoyarse principalmente en la experiencia acumulada del equipo técnico y estratégico. Si bien este conocimiento es valioso, la ausencia de herramientas cuantitativas que integren predicciones individuales de peso, demanda del mercado y restricciones operativas puede limitar la capacidad de anticipación y optimización en la toma de decisiones.

Este trabajo de grado cobra especial importancia al proponer una herramienta analítica integrada, compuesta por:

- Modelo de predicción de peso de las aves de engorde, que considera variables claves como edad, sexo, tipo de galpón y granja, permitiendo estimar con mayor precisión la evolución del peso en el tiempo.
- Modelo de optimización de cosecha, que toma como insumo las predicciones de peso para definir, semana a semana, qué galpones cosechar, minimizando costos y cumpliendo con los requisitos de peso del mercado (aves pequeñas, medianas y grandes), así como con restricciones operativas como ventanas de cosecha y barridas parciales.

El desarrollo del planteamiento abordado en este trabajo, busca para la empresa caso de estudio:

- Reducir los costos de alimentación, al evitar que aves permanezcan más tiempo del necesario en engorde.
- Aumentar la precisión en la planificación operativa, anticipando escenarios productivos y logísticos.
- Mejorar el cumplimiento del plan de ventas, entregando aves dentro de los rangos de peso requeridos.
- Facilitar la toma de decisiones estratégicas, basadas en información cuantitativa, trazable y proyectada.

Además, esta propuesta puede servir como punto de partida para replicar o escalar la metodología a otras regiones o sistemas de producción, adaptándola a contextos con condiciones similares. En suma, el trabajo no solo responde a una necesidad real de la empresa, sino que también aporta valor académico y aplicado, al proponer un enfoque integrado, cuantitativo y contextualizado a las particularidades de la producción avícola en Colombia.

## Estado del arte

La aplicación de herramientas analíticas en la industria avícola ha evolucionado notablemente en las últimas décadas, a medida que la complejidad de la cadena de suministro y las presiones del mercado exigen una planificación más precisa y eficiente. La investigación de operaciones ha aportado significativamente en áreas como la programación de cosecha, asignación de recursos, control de inventarios y logística, especialmente mediante el uso de modelos de programación lineal entera mixta (MILP) y enfoques heurísticos o metaheurísticos (Mula et al., 2010; Perea et al., 2019).

Un ejemplo destacado es el trabajo de Solano-Blanco et al. (2020), desarrollado en el contexto colombiano con la Universidad de los Andes, donde se plantea un modelo MILP para coordinar la producción y el sacrificio de aves, incorporando restricciones de capacidad, bioseguridad y cumplimiento de demanda. Aunque sus resultados evidencian mejoras en rentabilidad y eficiencia, el modelo se basa en pesos fijos para la toma de decisiones, sin considerar la incertidumbre o variabilidad real del crecimiento animal.

Por otro lado, estudios como los de Boonmee et al. (2015) y Brevik et al. (2020) han aplicado modelos de optimización en diferentes eslabones de la industria, desde la logística del transporte de aves hasta la asignación de producción en entornos de múltiples granjas. Sin embargo, comparten una limitación importante: el uso de entradas agregadas o promedios poblacionales, que no reflejan la variabilidad intra-lote ni el crecimiento diferenciado por condiciones biológicas y ambientales.

En el campo de la predicción del peso, la literatura ha estado dominada por modelos de tipo biológico, como los de Gompertz, Logístico o Richards, que ajustan curvas de crecimiento poblacional a partir de parámetros fisiológicos (Zuidhof et al., 2014; Oliveira et al., 2021). Aunque útiles para entender patrones generales, estos modelos tienden a perder precisión cuando se requiere estimar el peso individual de un lote específico en un entorno operativo, especialmente cuando no se consideran variables como sexo, tipo de galpón, densidad poblacional o clasificación zootécnica.

Estudios más recientes han comenzado a incorporar técnicas de aprendizaje automático y regresión multivariable para predecir peso con mayor granularidad (Zanin et al., 2022), pero su vinculación directa con modelos de optimización para la planificación operativa aún es limitada.

Frente a esta brecha, el presente trabajo propone una integración novedosa entre un modelo de predicción de peso, basado en regresiones polinómicas segmentadas por rangos de edad, y un modelo MILP de optimización de cosecha. Esta combinación representa una contribución original tanto en el plano metodológico como aplicado, al permitir decisiones más precisas y adaptadas a la dinámica real del crecimiento avícola. En el contexto colombiano, y particularmente en la empresa abordada, esta propuesta responde directamente a la necesidad de alinear la producción con la demanda comercial, reducir sobrecostos alimenticios, y planificar bajo escenarios reales de operación y variabilidad biológica.

En la siguiente tabla (Tabla 1) se presenta un resumen de algunos estudios relevantes en el área de planificación y optimización en la industria avícola. Se destacan sus enfoques principales, las limitaciones identificadas en cada caso y la forma en que el presente trabajo contribuye a superar dichas limitaciones en un contexto aplicado

<b>Autor(es) y Año</b>	<b>Enfoque Principal</b>	<b>Limitaciones Relevantes</b>	<b>Contribución del Presente Trabajo</b>
Solano-Blanco et al. (2020)	Modelo MILP para planificación integrada de producción y sacrificio	Ausencia de predicción individualizada del peso	Integra predicción de peso y optimización de cosecha en contexto real
Boonmee et al. (2015)	Optimización logística en producción avícola (Tailandia)	Usa datos agregados sin modelar variabilidad biológica	Incorpora variabilidad de crecimiento para decisiones tácticas
Brevik et al. (2020)	Planificación óptima de sacrificio bajo restricciones de capacidad	Considera pesos fijos, sin modelo de crecimiento predictivo	Optimiza cosecha con predicciones ajustadas a granja y sexo
Zuidhof et al. (2014)	Modelado biológico del crecimiento de pollos con curvas de Gompertz	No aplicable directamente a decisiones operativas	Aplica predicción práctica segmentada por rangos de edad
Oliveira et al. (2021)	Comparación de funciones de crecimiento (Gompertz y Logística)	Enfocado en análisis comparativo más que predictivo aplicado	Adapta enfoque polinómico a contexto colombiano real
Zanin et al. (2022)	Predicción de peso usando machine learning y sensores	No vincula predicción con modelos de optimización operativa	Conecta modelos predictivos con programación matemática de cosecha

**Tabla 1.** Comparación de estudios relevantes sobre modelos en la industria avícola.

## Objetivo General:

Desarrollar un modelo integrado que combine la predicción del peso de pollos de engorde y la optimización de cosecha, con el fin de minimizar los costos de alimentación y garantizar el cumplimiento de las especificaciones de peso del mercado, permitiendo una mejor planificación en la empresa caso de estudio de la industria avícola.

## Objetivos Específicos:

1. Construir un modelo de predicción de peso de pollos de engorde que permita estimar el peso de las aves en una edad determinada.
2. Diseñar un modelo de optimización de cosecha, basado en programación matemática, que determine el día óptimo de sacrificio de cada lote de aves, minimizando los costos de alimentación y asegurando el cumplimiento de los rangos de peso exigidos por el mercado (aves pequeñas, medianas y grandes).
3. Integrar la predicción de peso como insumo clave en el modelo de optimización, permitiendo una planificación dinámica y ajustada a la variabilidad de crecimiento de las aves.

## II. Materiales y métodos

Este estudio se desarrolló en tres fases principales: (1) construcción del modelo de predicción de peso, (2) diseño del modelo de optimización de cosecha y (3) integración de ambos modelos para generar planes de cosecha eficientes. Cada fase responde a los objetivos específicos del proyecto.

### Fase 1: Modelo de predicción de peso

**Objetivo:** Estimar el peso futuro de los pollos de engorde en función de variables productivas, biológicas y ambientales, mediante un modelo de regresión multivariable.

#### Actividades:

- Recolección y consolidación de datos históricos de producción incluyendo variables como:
  - Edad del ave al momento del beneficio.
  - Sexo.
  - Granja de origen.
  - Tipo de galpón (controlado vs. Tradicional).
  - Peso real registrado previo al beneficio.
- Análisis exploratorio de datos (EDA) para comprender la distribución de variables, presencia de valores atípicos, correlaciones y comportamiento del peso a lo largo del tiempo.

- Revisión y selección de variables (featuring) mediante análisis estadístico, pruebas de significancia y análisis de interacción entre variables.
- Construcción y evaluación de múltiples modelos de regresión (lineales, polinómicos, segmentados) para capturar la relación entre edad y peso.
- Evaluación del desempeño mediante métricas como RMSE y  $R^2$ , y ajuste final del modelo tras analizar residuos y errores sistemáticos.
- Selección del modelo con mejor capacidad predictiva y análisis de residuos para validar supuestos.

## Fase 2: Integración de los modelos

**Objetivo:** Incorporar las predicciones de peso generadas por el modelo de regresión como insumo clave del modelo de optimización de cosecha, permitiendo una planificación dinámica y adaptada a la evolución real del peso de las aves.

### Actividades:

- Transformación de las predicciones de peso a un formato estructurado por galpón, sexo y día para alimentar el modelo de optimización.
- Vinculación directa entre las salidas del modelo predictivo y los parámetros del modelo MILP, en particular el parámetro de peso estimado  $W_{g,p,s,d}$ .
- Validación del flujo de información entre modelos mediante escenarios de prueba.

## Fase 3: Modelo de optimización de cosecha

**Objetivo:** Determinar, para cada día del horizonte de planificación, qué galpones deben ser cosechados, minimizando los costos de alimentación y cumpliendo con las restricciones operativas y comerciales del sistema.

### Actividades:

- Formulación del modelo como un problema de programación entera mixta (MILP).
- Definición de variables de decisión, parámetros y restricciones, incluyendo:
  - Ventanas mínimas entre barridas por galpón
  - Capacidad de planta de beneficio
  - Cumplimiento de proporciones del mix por categoría de peso
  - Penalización por desviaciones respecto a la demanda deseada
- Implementación del modelo en Python utilizando Pyomo como entorno de modelado algebraico.
- Utilización del solver Gurobi para la resolución de instancias del modelo.
- Análisis de resultados obtenidos a partir de un horizonte de planificación de 18 días, validando su aplicabilidad práctica en el contexto real de la empresa.
- Generación de reportes, distribución del mix y cumplimiento de la demanda, con posibilidad de ajuste por cambios en parámetros o escenarios futuros.

## Metodología

Para abordar el problema planteado en este trabajo de grado, se adopta la metodología CRISP-DM (Cross-Industry Standard Process for Data Mining), ampliamente reconocida por ofrecer un marco estructurado y flexible para proyectos de análisis de datos. Esta metodología consta de seis fases iterativas, que van desde la comprensión del negocio hasta el despliegue de la solución.

La elección de CRISP-DM responde a su capacidad para integrar el conocimiento del negocio con técnicas analíticas avanzadas, garantizando una preparación rigurosa de los datos, un análisis coherente y una implementación alineada con los objetivos del proyecto.



Fig. 2. Metodología CRISP-DM para proyectos de ciencia de datos

A continuación, se detallan las fases:

### Comprensión del negocio

Este estudio se enmarca en la industria avícola, donde el beneficio de pollos representa una decisión crítica que afecta la eficiencia operativa, el cumplimiento con el mercado y los costos asociados al alimento. La necesidad de anticipar el momento óptimo de sacrificio motivó el desarrollo de una solución analítica integrada que combina predicción de peso y optimización de cosecha. Desde el inicio, se identificó que proyectar el peso futuro de las aves era un insumo clave para sustentar decisiones logísticas y económicas.

### Comprensión de los datos

Con el acompañamiento de expertos operativos, se identificaron las principales fuentes de información

interna. Se realizó un análisis exploratorio para conocer la estructura, periodicidad y confiabilidad de las variables disponibles. Esta etapa también permitió priorizar variables relevantes como edad, sexo, tipo de galpón, y ubicación de la granja, las cuales inciden directamente en el comportamiento del peso y su variabilidad.

## Preparación de los datos

### Modelo de proyección de pesos

Se consolidó un conjunto de datos históricos a partir de múltiples fuentes internas relacionadas con la producción avícola. Esta fase incluyó actividades como:

- Limpieza de registros incompletos, atípicos o inconsistentes
- Análisis de la distribución de variables relevantes
- Codificación de variables categóricas
- Segmentación por rangos de edad para capturar cambios en el comportamiento del crecimiento.

El objetivo fue construir un dataset confiable y representativo que sirviera como base para entrenar modelos de predicción del peso de las aves.

### Estructuración de datos para el modelo de optimización

A partir de las predicciones generadas por el modelo de peso, se construyeron las estructuras necesarias para alimentar el modelo de optimización de cosecha. Esta etapa comprendió:

- Generación de un dataset proyectado a 4 semanas con pesos diarios estimados por lote
- Levantamiento de parámetros clave del sistema productivo, incluyendo capacidades semanales de planta, demanda por categoría, restricciones operativas (ventanas entre cosechas, barridas parciales), y la definición del conjunto de galpones a evaluar.

Estas transformaciones permitieron adaptar los datos predictivos al lenguaje y lógica del modelo MILP, facilitando una integración coherente entre predicción y decisión.

## Modelado

Se exploraron distintos enfoques de regresión para la predicción del peso, evaluando opciones como regresión lineal, modelos polinómicos segmentados y modelos multivariados. El mejor desempeño se logró con un modelo polinómico de grado 3, ajustado por rangos de edad ( $\leq 38$  y  $\geq 39$  días) e incluyendo variables como sexo, granja y tipo de galpón. Este modelo sirvió como insumo para el desarrollo posterior de un modelo de optimización formulado en programación entera mixta (MILP), que define qué galpones cosechar cada día, minimizando el costo de alimentación y cumpliendo con restricciones reales.

## Evaluación

Para el modelo predictivo, se emplearon métricas como  $R^2$ , RMSE y MAE, complementadas con análisis de residuos y validación cruzada. Para el modelo de optimización, se utilizaron métricas de desempeño como el costo total del plan, el cumplimiento del mix de mercado y la cantidad de días con solución factible. Además, se verificó la consistencia con la lógica operativa y se usaron solvers como CBC y Gurobi para garantizar la eficiencia en la resolución del modelo.

## Despliegue

Aunque su implementación definitiva queda fuera del alcance de este trabajo, se propone su socialización dentro de la empresa como base para futuras pruebas piloto. Los resultados obtenidos demuestran el potencial del enfoque integrado como herramienta de apoyo a la planificación, y sientan las bases para su adopción escalable en escenarios productivos reales.

## Marco Teórico

### 1. Predicción de Peso en Pollos de Engorde

#### 1.1 Importancia de la Predicción de Peso

La predicción precisa del peso corporal en pollos de engorde es esencial para optimizar la programación del sacrificio, mejorar la eficiencia alimentaria y maximizar la rentabilidad. Modelar el crecimiento permite anticipar el momento óptimo de beneficio, ajustándose a las demandas del mercado y reduciendo costos operativos (Khadem, Shamsuzzoha, & Piya, 2017).

#### 1.2 Modelos de Crecimiento

El crecimiento de los pollos sigue una curva sigmoidea que puede representarse mediante modelos matemáticos como el de Gompertz, ampliamente utilizado en estudios avícolas (Duan-Yai, Young, Lisle, & Coutts, 1999). Este tipo de modelo permite estimar parámetros clave como el peso final, la ganancia diaria de peso y el punto de inflexión, facilitando decisiones sobre el manejo zootécnico y el momento de beneficio.

#### 1.3 Variables que Afectan el Crecimiento y la Predicción de Peso

Diversos factores influyen en la evolución del peso corporal en pollos de engorde, lo que hace necesario considerar múltiples variables al construir modelos predictivos. Según Zuidhof et al. (2014), el crecimiento no es homogéneo y depende de factores biológicos como el sexo, la línea genética (con diferencias en tasas de crecimiento entre razas comerciales) y condiciones ambientales como temperatura, densidad de población, ventilación y manejo nutricional. Estos elementos afectan tanto el ritmo como la forma de la curva de crecimiento.

Entre las principales variables utilizadas en la literatura se encuentran:

- Edad del ave: Es la variable temporal base, pues el peso corporal sigue una evolución sigmoidea a lo largo del tiempo.
- Sexo: Machos y hembras difieren en su velocidad de crecimiento y eficiencia alimenticia.
- Línea genética: Diferentes estirpes comerciales (ej. Ross, Cobb, Hubbard) tienen curvas de crecimiento distintas por diseño genético.
- Condiciones ambientales: Temperatura, humedad, ventilación y calidad del aire afectan el metabolismo y la conversión alimenticia.
- Densidad de población: Altas densidades pueden generar estrés, reducir el acceso al alimento y frenar el crecimiento.
- Programa nutricional: Cambios en el tipo y calidad del alimento impactan directamente la ganancia diaria de peso.
- Granja o tipo de alojamiento: Captura prácticas específicas de manejo, bioseguridad y control sanitario.
- Factores sanitarios: Presencia de enfermedades subclínicas o vacunación pueden alterar la curva esperada.
- Interacciones entre variables: Por ejemplo, la interacción entre temperatura y densidad puede potenciar efectos negativos en el crecimiento.

## **2. Optimización del Beneficio en la Producción Avícola**

### **2.1. Fundamentos de la Optimización**

La optimización en sistemas productivos avícolas busca maximizar el beneficio económico, considerando múltiples restricciones como la capacidad de sacrificio, los recursos logísticos y la variabilidad del mercado. A través de la formulación matemática del problema, es posible estructurar modelos que determinen estrategias de producción más rentables y sostenibles (Khadem et al., 2017).

### **2.2. Modelos de Optimización en la Industria Avícola**

Modelos como la Programación Lineal Entera Mixta (MILP) han sido utilizados para optimizar redes de suministro avícolas, logrando reducciones de inventario, mejoras en la eficiencia operativa y un mejor cumplimiento de la demanda (Relex Solutions, 2024). Estos modelos integran la planificación de producción, distribución y venta, adaptándose a los cambios dinámicos en los precios y la oferta.

### **2.3. Avicultura de Precisión**

La avicultura de precisión se basa en la recolección y análisis de datos en tiempo real mediante sensores, sistemas de visión e inteligencia artificial. Esto permite tomar decisiones informadas sobre alimentación, salud animal y programación de sacrificio. Su implementación se traduce en mejoras significativas en productividad, bienestar animal y sostenibilidad (PLOS ONE, 2024).

### III. Resultados y hallazgos

En esta sección se presentan los principales hallazgos del estudio, organizados en tres fases. La Fase 0 corresponde a la exploración de datos, la cual fue fundamental para comprender el comportamiento de las variables asociadas al peso de las aves y orientar la construcción del modelo de predicción. A partir de estos análisis, se identificaron patrones relevantes por sexo, edad y tipo de estructura de cría. La Fase 1 describe los resultados obtenidos con el modelo de proyección de pesos, incluyendo su desempeño predictivo y ajuste frente a datos reales. Finalmente, la Fase 2 expone los resultados del modelo de optimización, evaluando su capacidad para generar planes de cosecha más eficientes y alineados con las necesidades productivas y del mercado.

#### Fase 0: Análisis exploratorio de datos

El análisis exploratorio de datos (EDA) permitió comprender las características fundamentales de los registros disponibles, evaluar la calidad de la información y detectar patrones relevantes para el modelamiento posterior. A continuación, se describen los principales hallazgos:

##### 1. Relación entre Edad y Peso promedio

El primer análisis se centra en visualizar la relación entre la edad de sacrificio de los pollos (en días) y su peso promedio (en kilogramos). Esta relación puede observarse en la Fig 3, en esta gráfica, cada punto representa un viaje (camión) cargado de aves, y el valor registrado corresponde al peso promedio de los pollos transportados en ese lote.

Se conservaron únicamente los datos comprendidos entre 25 y 52 días de edad y pesos entre 1 kg y 5 kg, rangos definidos como operativamente válidos para el plan de cosecha según el conocimiento del negocio. La tendencia general muestra un aumento progresivo del peso conforme incrementa la edad, con mayor dispersión en edades avanzadas, lo que refleja la variabilidad natural en los procesos de engorde. Sin embargo, se puede apreciar una amplia dispersión de los datos.

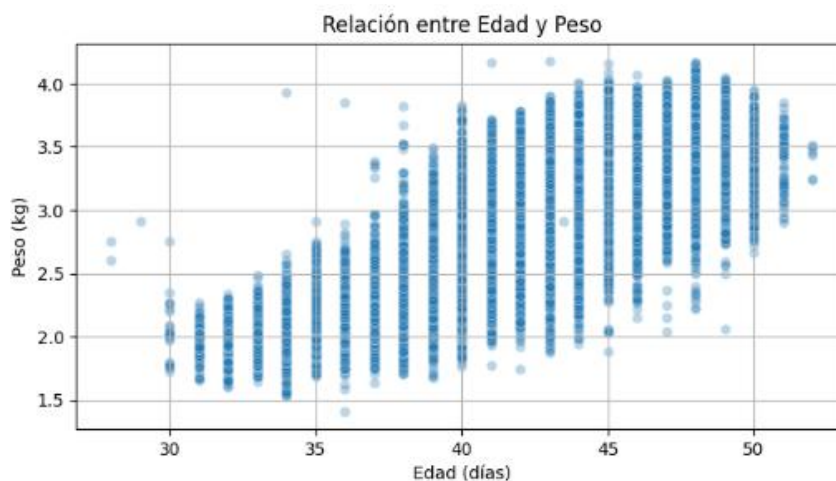


Fig. 3. Relación entre la edad del ave y su peso corporal, para el dataset evaluado.

## 2. Distribución del peso de las aves

El histograma de la variable peso (Fig 4) revela una distribución bimodal, con dos picos de alta frecuencia alrededor de los 2,1 kg y 3,2 kg. Esta bimodalidad sugiere la existencia de dos poblaciones dentro del sistema productivo, probablemente relacionadas con las diferencias en el sexo de las aves y sus tiempos de crecimiento. La presencia de dos picos bien definidos respalda esta hipótesis, reflejando decisiones operativas diferenciadas para machos y hembras.

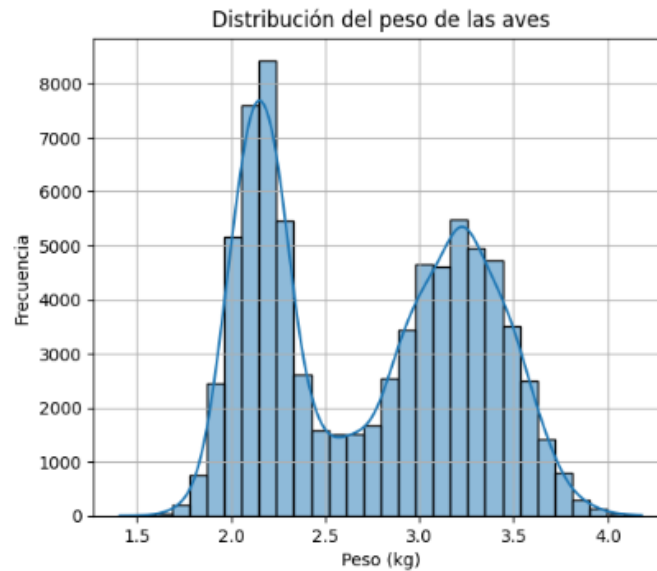


Fig. 4. Distribución de frecuencias del peso de las aves en el dataset.

## 3. Curvas de crecimiento por sexo

En la curva de crecimiento promedio por sexo se puede observar cómo varía el peso de las aves a lo largo del tiempo según el sexo declarado. Los machos (M) muestran consistentemente un peso superior, seguidos por las aves de sexo mixto (MX) y, finalmente, las hembras (H). La diferencia de peso entre los sexos tiende a acentuarse con el paso de los días, lo que refuerza la hipótesis de que el sexo tiene un efecto estructural en la ganancia de peso.

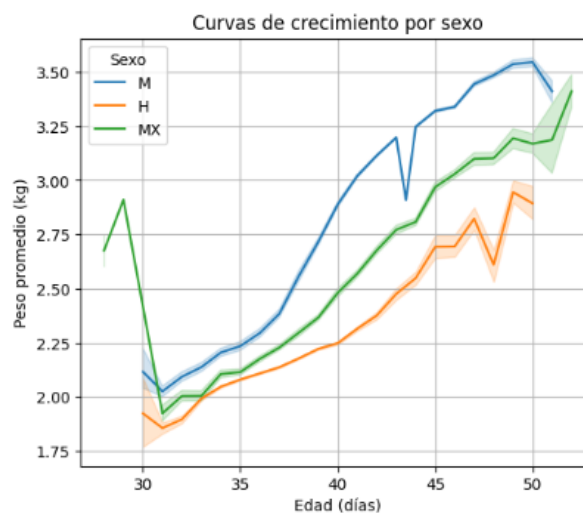


Fig. 5. Curvas de crecimiento promedio por sexo de las aves

#### 4. Curvas de crecimiento por tipo de estructura

Se construyeron curvas de crecimiento diferenciadas por tipo de estructura de galpón (Tradicional vs. Controlado) y por sexo. En general, las aves criadas en galpones de tipo controlado presentan una tendencia a alcanzar mayores pesos promedio, especialmente en los machos. Esta diferencia, aunque más tenue, también es observable en hembras y mixtos. El resultado refuerza la hipótesis de que el tipo de estructura puede tener un impacto positivo sobre el desempeño zootécnico, al ofrecer condiciones ambientales más estables.

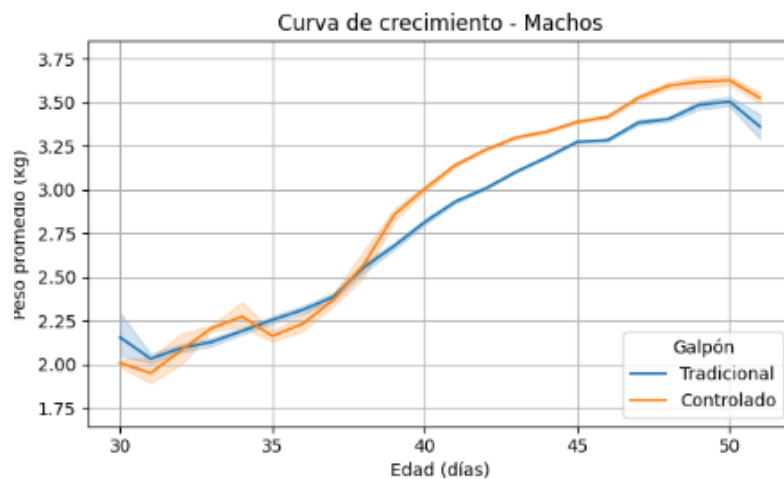


Fig. 6. Curva de crecimiento de machos según tipo de estructura de Galpón

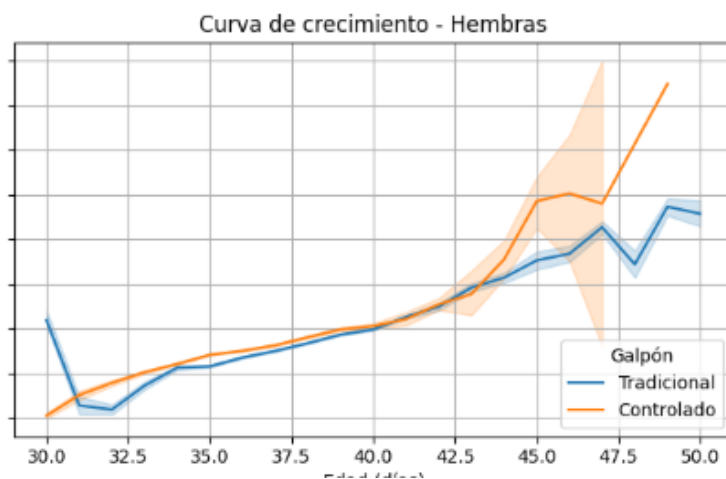


Fig. 7. Curva de crecimiento de hembras según tipo de estructura de Galpón




Fig. 8. Curva de crecimiento sexo mixto según tipo de estructura de Galpón

## 5. Distribución del ADG por estructura

El análisis del ADG (Average Daily Gain - Ganancia Diaria Promedio) mediante diagramas de caja muestra que los galpones de tipo controlado no solo logran mayores valores medianos de ganancia diaria, sino que también presentan una mayor dispersión. Esto sugiere un mejor desempeño productivo, aunque con algo más de variabilidad. Los valores atípicos presentes en ambas estructuras podrían estar ligados a factores no controlados en el lote (problemas sanitarios, calidad de alimento, entre otros).




Fig. 9. Distribución de la ganancia diaria de peso (ADG) según tipo de galpón.

## 6. Evolución del ADG por año y estructura

Finalmente, el análisis del ADG por año y tipo de estructura permite observar que, de forma consistente entre 2023 y 2025, los galpones controlados mantienen un mejor desempeño en comparación con los

tradicionales. Además, los galpones tradicionales presentan una mayor variabilidad en los resultados, lo que podría traducirse en una menor predictibilidad en la producción y planificación de cosechas.

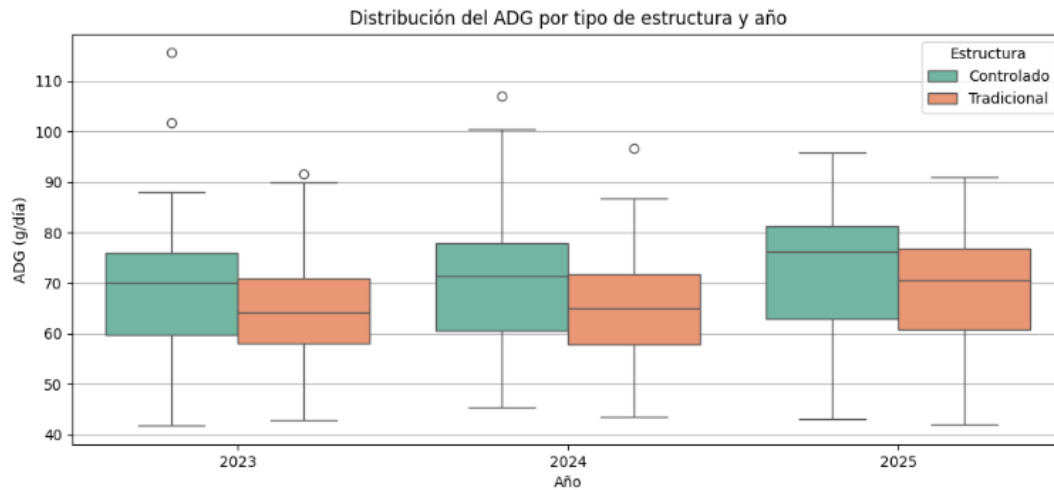


Fig. 10. Distribución de la ganancia diaria de peso (ADG) por tipo de galpón y año.

## 7. Curva de ADG por edad y tipo de estructura

Este gráfico representa la evolución de la ganancia diaria de peso (ADG) en función de la edad de las aves, diferenciando entre estructuras de tipo Tradicional y Controlado. Hasta aproximadamente los 37 días, ambas curvas presentan un comportamiento similar, con valores cercanos de ADG. Sin embargo, a partir de esa edad, se evidencia una divergencia más clara: las aves criadas en galpones Controlados logran mantener una ganancia diaria superior, mientras que en los galpones Tradicionales el ADG tiende a estancarse o disminuir ligeramente. Esta diferencia resalta el impacto que pueden tener las condiciones ambientales controladas sobre el desempeño productivo, especialmente en etapas avanzadas del engorde.




Fig. 11. Curvas de ganancia diaria de peso (ADG) por edad y tipo de galpón.

## Fase 1: Modelo de predicción de peso

Para el desarrollo del modelo de predicción del peso de las aves, se llevaron a cabo múltiples iteraciones que permitieron evaluar distintas combinaciones de variables y estructuras del modelo. Se probaron modelos de regresión lineal y polinómica, incorporando variables como edad, sexo y tipo de galpón, así como sus interacciones. Tras analizar el desempeño de los modelos en distintos rangos de edad, se seleccionó como modelo final una regresión polinómica de grado 3, segmentada por rangos de edad ( $\leq 38$  días y  $\geq 39$  días), ya que logró capturar de manera más precisa la curvatura del crecimiento. Este modelo alcanzó un RMSE de 0.1290 kg y un  $R^2$  de 0.3388 para edades tempranas, y un RMSE de 0.1963 kg y un  $R^2$  de 0.8119 para edades mayores, mostrando una mejora sustancial en la precisión de la predicción en etapas críticas del ciclo productivo.

A continuación, se describen los enfoques más relevantes evaluados y sus respectivas conclusiones.

### 1. Modelo de Regresión Lineal

El primer modelo evaluado fue una regresión lineal simple con las variables independientes: Edad, Sexo y Tipo de Estructura. Este modelo alcanzó un  $R^2$  de 87.09%, lo cual sugiere que explica una gran parte de la variabilidad del peso. No obstante, su desempeño fue insatisfactorio en la práctica: en edades tempranas (30 a 35 días), las predicciones se alejaban considerablemente de los valores reales. Este sesgo es crítico en contextos productivos, ya que en esta etapa se toman decisiones claves. Se concluye que un alto  $R^2$  no garantiza precisión a lo largo de todo el rango de edad, por lo que este modelo fue descartado.




Fig. 12. Comparación entre peso real y predicho por regresión lineal según edad y sexo y tipo de estructura de granja.

### 2. Regresión Lineal incluyendo la Clasificación de la Granja

En un segundo intento, se incorporó una variable categórica adicional que clasifica a las granjas según su rendimiento histórico. Esta modificación mejoró ligeramente el desempeño del modelo ( $R^2 = 88.7\%$ ), pero persistió el mismo patrón: a edades tempranas, las predicciones seguían mostrando errores importantes. Por tanto, a pesar del incremento marginal en  $R^2$ , el modelo no logró resolver la limitación principal.

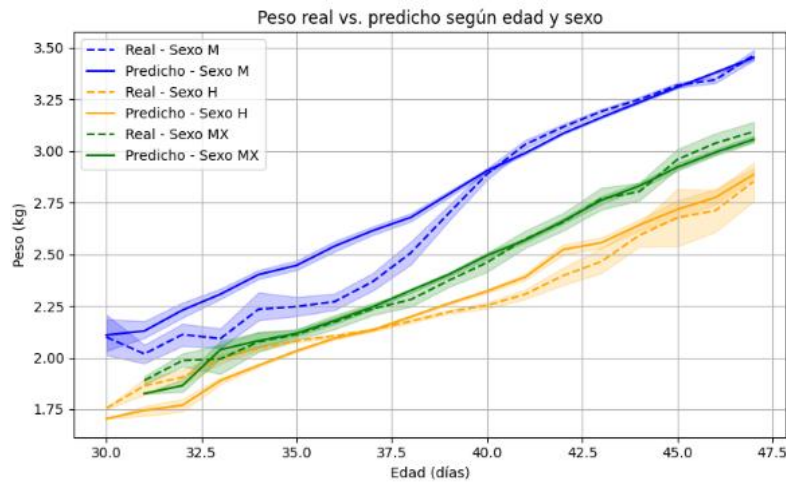


Fig. 13. Comparación entre peso real y predicho por regresión lineal según edad y sexo , tipo de estructura de granja y clasificación de granja.

### 3. Regresión Lineal con filtro por años recientes

Se repitió el modelo anterior incluyendo únicamente información a partir del año 2024. Esta decisión se basó en los hallazgos del análisis exploratorio de datos, donde se evidenció que la ganancia diaria de peso (ADG) ha aumentado progresivamente año a año, por lo cual no era conveniente incluir datos históricos que ya no reflejan el contexto actual de producción. Con este ajuste, se observó una mejora en el desempeño del modelo, alcanzando un  $R^2$  de 98.45%. Sin embargo, el modelo continuó fallando en la predicción del peso en edades tempranas, lo que indica que la limitación no está únicamente en los datos, sino en la forma en que se está especificando el modelo.

Esto motivó la exploración de modelos polinómicos, que permitieran capturar de forma más flexible la relación no lineal entre la edad del ave y su peso.




Fig. 14. Comparación entre peso real y predicho por regresión lineal según edad y sexo , tipo de estructura de granja y clasificación de granja/ datos posteriores a 2024.

#### 4. Modelo Polinómico de Grado 3 (con separación por rangos de edad)

Finalmente, se implementó un modelo polinómico de grado 3, considerando los términos AGE, AGE<sup>2</sup> y AGE<sup>3</sup>, junto con las variables categóricas Sexo, Estructura y Clasificación\_Granja. Adicionalmente, se dividió el conjunto de datos en dos rangos de edad: aves con edad menor o igual a 38 días, y aves con edad mayor o igual a 39 días, entrenando un modelo distinto para cada grupo.

Los resultados fueron los siguientes:

- **Para edad ≤ 38 días**

RMSE: 0.1290 kg

R<sup>2</sup>: 0.3388

- **Para edad ≥ 39 días**

RMSE: 0.1963 kg

R<sup>2</sup>: 0.8119

Aunque el R<sup>2</sup> para edades tempranas es relativamente bajo, el modelo ajusta mejor el comportamiento real del peso en este rango, a diferencia de los modelos anteriores. Por esta razón, este enfoque fue seleccionado como el modelo final, ya que permite una mejor predicción práctica a lo largo de todo el rango de edad, como se evidencia en la gráfica comparativa entre pesos reales y predichos.

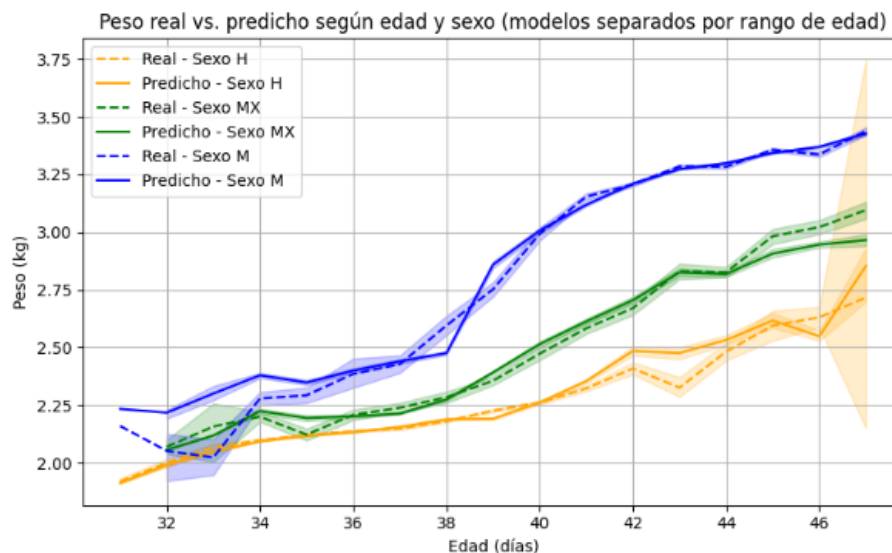


Fig. 15. Comparación entre peso real y predicho por regresión polinómica grado 3 según edad y sexo, tipo de estructura de granja y clasificación de granja/ datos posteriores a 2024.

#### Limitaciones modelo de predicción de pesos

A pesar de que el modelo final presenta un buen desempeño general, es importante reconocer ciertas limitaciones que condicionan su aplicabilidad y precisión. A continuación, se resumen los principales aspectos a tener en cuenta:

- **Rango de edad limitado:** El modelo fue entrenado para edades entre 30 y 47 días, rango en el que operativamente se toman decisiones de sacrificio. Su aplicación fuera de este rango no es recomendable.
- **Evolución del desempeño productivo:** Como se evidenció en el análisis exploratorio, la ganancia diaria de peso (ADG) ha aumentado en los últimos años. Por esto, se recomienda recalcular el modelo periódicamente con datos recientes para mantener su precisión.
- **Datos históricos excluidos:** Se descartaron registros anteriores a 2024 por reflejar condiciones menos representativas del desempeño actual.
- **Falta de variables complementarias:** El modelo no incluye factores como genética, manejo zootécnico o condiciones ambientales, que podrían explicar parte de la variabilidad no capturada.

## Fase 2: Modelo de optimización de cosecha

### Planteamiento del modelo

Una vez comprendido los datos y generado las predicciones de pesos, se procede con la definición y formulación matemática del problema de optimización, como lo definimos a continuación

#### 1. Conjuntos

*G:* Conjunto de granjas

*P<sub>g</sub>:* Conjunto de galpones en la granja *g*

*S:* Conjunto de sexos – {MACHO, HEMBRA}

*D:* Conjunto de días del horizonte de planificación

*T:* Conjunto de tipos de pollo – {CAMPESINO, BLANCO}

*C:* Conjunto de categorías de peso – {PEQUEÑO, MEDIANO, GRANDE}

*W:* Conjunto de semanas del horizonte

#### 2. Parámetros

*N<sub>g,p,s</sub>:* Número de aves por grupo (granja *g*, galpón *p*, sexo *s*)

*W<sub>g,p,s,d</sub>:* Peso promedio proyectado del grupo en el día *d* en kg

*ADG<sub>g,p,s,d</sub>:* Ganancia diaria de peso del grupo ( $\frac{kg}{día}$ )

*Tipo<sub>g,p,s</sub>:* Tipo de pollo del grupo (CAMPESINO o BLANCO)

*CAT<sub>g,p,s,d</sub>:* Categoría de peso asignada (PEQUEÑO, MEDIANO O GRANDE)

*Q<sub>t,c,d</sub>:* Demanda deseada de aves del tipo *t* y categoría *c* para el día *d*

*T<sub>w</sub>:* Total deseado de aves beneficiadas en la semana *w*

*tol:* Tolerancia semanal de desviación con respecto a la demanda

*TolDia:* Tolerancia diaria de desviación con respecto a la demanda

*TolDiaCamp:* Tolerancia diaria de desviación con respecto a la demanda para el pollo CAMPESINO

### 3. Variables de decisión

$$x_{(g,p,s,d)}$$

$\in \{0, 1\}$ : Toma el valor de 1 si el grupo  $(g, p, s)$  se cosecha el día  $d$ , 0 en caso contrario

Esta variable se declara solo en los índices  $(g,p,s,d)$  que disponen de datos válidos de peso y categoría.

### 4. Función objetivo

Maximizar la ganancia diaria total de peso cosechado:

$$MAX Z = \sum_{g,p,s,d} ADG_{g,p,s,d} \cdot x_{g,p,s,d} - M_{penal} \cdot \sum_{g,p,s,d} (d_{fin} - d) \cdot x_{g,p,s,d}$$

Se maximiza la suma de las ADG de los grupos cosechados y se resta una penalización proporcional a cuántos días se posponga la cosecha, para evitar acumular aves al final del horizonte.

### 5. Restricciones

→ R1. Cosecha única por grupo:

$$\sum_{d \in D} x_{g,p,s,d} \leq 1 \quad \forall g, p, s$$

Cada grupo (granja–galpón–sexo) puede cosecharse como máximo una vez en todo el horizonte.

→ R2. Cumplimiento del mix diario con tolerancia:

$$(1 - Tol_t) \cdot Q_{t,c,d} \leq \sum_{g,p,s} N_{g,p,s} \cdot x_{g,p,s,d} \leq (1 + Tol_t) \cdot Q_{t,c,d}$$

donde  $Tol_t = TolDiaCamp$  si  $t = CAMPESINO$ , y  $TolDia$  en otro caso.

Asegura que el número de aves cosechadas de cada tipo  $t$  y categoría  $c$  esté dentro de los márgenes de tolerancia por día.

→ R3. Prioridad de hembras sobre machos en un mismo galpón:

$$x_{g,p,MACHO,d} \leq 1 - \sum_{d'=d-4}^{d-1} x_{g,p,HEMBRA,d'} \quad \forall d \geq 5$$

Los machos sólo pueden beneficiarse al menos cuatro días después que las hembras del mismo galpón.

→ R5. Total semanal con tolerancia:

$$(1 - tol) \cdot TOT_w \leq \sum_{d \in sem(w)} \sum_{g,p,s} N_{g,p,s} \cdot x_{g,p,s,d} \leq (1 + tol) \cdot TOT_w$$

Controla el total de aves beneficiadas por semana.

→ R6. Peso máximo no superado:

$$\text{Si } W_{g,p,s,d} \geq 3,5 \text{ kg} \Rightarrow x_{g,p,s,d} = 1$$

Obliga a cosechar cualquier grupo que alcance 3,5 kg o más para evitar sobrepeso excesivo.

→ R7. Promedio semanal de peso en pollo campesino:

$$\sum_{d \in \text{sem}(w)} \sum_{g,p,s \in \text{Camp}} N_{g,p,s} \cdot W_{g,p,s,d} \cdot x_{g,p,s,d} \geq 3 \cdot \sum_{d \in \text{sem}(w)} \sum_{g,p,s \in \text{Camp}} N_{g,p,s} \cdot x_{g,p,s,d}$$

Garantiza que el peso promedio cosechado de pollos CAMPESINO sea al menos 3 kg cada semana.

El problema de programación de la cosecha se formuló como un **modelo entero-mixto lineal (MILP)** cuya función objetivo maximiza la ganancia diaria de peso (ADG) y penaliza las desviaciones con respecto al programa de demanda.

La instancia completa incluyó:

Elemento	Cantidad
Variables binarias $x_{(g,p,s,d)}$	5 145
Restricciones	403
Horizonte de planeación	12 Días Operativos
Grupos (granja-galpón-sexo) considerados	245
Grupos cosechados (x=1 en la solución)	205

**Tabla 2.** Dimensión del modelo MILP y resumen de la solución óptima

El modelo se resolvió con Gurobi 12.0.2 bajo licencia académica, ejecutándose en Google Colab (CPU Intel® Xeon® 2.20 GHz, 2 hilos). Tras la presolve, el problema se redujo a 1 793 variables binarias y 294 restricciones. Gurobi encontró la solución óptima en 60,8 s, con un *optimality gap* final de 0,010 %.

## Principales hallazgos

- **Plan de cosecha:** se programó el beneficio de 205 lotes a lo largo del horizonte, cumpliendo la demanda diaria y semanal para las categorías pequeño-mediano-grande sin generar aves fuera de especificación de peso.
- **Objetivo alcanzado:** la función objetivo obtuvo un valor de 13 831,02, equivalente a la maximización del ADG neto sujeto a las restricciones operativas (prioridad de hembras, límites de peso  $\leq 3,5$  kg, ventanas de 4 días entre sexos, etc.).
- **Balance temporal:** el modelo desplazó la cosecha de lotes con mayor potencial de crecimiento hacia los días finales y adelantó aquellos que ya excedían el peso máximo permitido, logrando un uso más homogéneo de la capacidad de la planta.
- **Robustez de la solución:** el plan cumple dentro de las tolerancias definidas tanto el mix diario por tipo / categoría como los totales semanales; todas las restricciones activas se satisfacen exactamente. Pequeñas desviaciones presentes, que fueron permitidas por las tolerancias definidas, podrían reducirse en desarrollos futuros afinando la función objetivo o añadiendo penalizaciones específicas

Estos resultados demuestran que la integración predictiva (modelo polinómico de peso) y prescriptiva (MILP) genera planes operativos factibles y computacionalmente eficientes. Al maximizar la ganancia diaria de peso (ADG) en la función objetivo, el modelo prioriza lotes con mejor desempeño, les permite más días de crecimiento y, por ende, eleva el indicador de rendimiento en campo. Esta mejora se traduce en menores costos de alimentación, que suponen alrededor del 70 % del costo total de engorde, lo que hace que la propuesta sea especialmente atractiva desde el punto de vista económico y aporte una herramienta robusta para la toma de decisiones de corto plazo en la industria avícola.

## Alcances y proyecciones del modelo

- **Homogeneidad diaria de beneficio**  
El siguiente paso consiste en suavizar la curva de sacrificio diario: incorporar penalizaciones o restricciones de nivelación de carga que fuercen a que el número de aves beneficiadas sea lo más constante posible entre días. Esto facilitará la programación de turnos y el uso estable de la planta.
- **Horizonte de planeación extendido**  
Una vez se logre la homogeneidad, el modelo puede ampliarse de los 12 días operativos actuales a horizontes de 3 a 6 semanas. Ello multiplicará los índices ( $g, p, s, d$ ), incrementando tanto las variables binarias como las restricciones, requiriendo así, explorar técnicas avanzadas de descomposición y aceleración (p. ej., rolling-horizon, Lagrangiano, Benders), junto con heurísticas de arranque rápido y warm-starts basados en la solución del día anterior.

- **Despliegue operativo**

Con un horizonte ampliado y tiempos de cómputo controlados, se podría realizar despliegue del modelo dentro del sistema de planificación de la empresa, de modo que la optimización se ejecute de forma rutinaria y respalde las decisiones diarias de beneficio y logística

Estos alcances persiguen no sólo reforzar la robustez técnica del modelo, sino transformarlo en una herramienta de decisión diaria que establezca la producción, reduzca costos y escale junto con las necesidades de la operación avícola.

Los hallazgos presentados demuestran la viabilidad del modelo propuesto y abren la puerta a futuras mejoras y escalabilidad operativa

## IV. Conclusiones

- La predicción del peso de las aves mediante regresión polinómica segmentada por rangos de edad demostró ser una herramienta útil para capturar la no linealidad del crecimiento, especialmente en el rango a partir del día 39 de edad de las aves, donde se observó un ajuste considerablemente mejor ( $R^2$ : 0.81).
- El análisis exploratorio fue clave para identificar patrones diferenciados según el sexo, tipo de galpón y edad, lo cual permitió construir un modelo más realista y alineado con las dinámicas productivas.
- A pesar de su buen desempeño del modelo de proyección de pesos, dentro del rango de interés operativo (30–47 días), el modelo presenta limitaciones relacionadas con la exclusión de variables como genética o manejo zootécnico y componentes nutricionales, y requiere actualizaciones periódicas para reflejar mejoras productivas recientes.
- La integración temprana del modelo de predicción como input del modelo de optimización representa un avance significativo frente a enfoques basados únicamente en experiencia o valores promedio. Esta integración permite una toma de decisiones más ajustada a la realidad biológica de los lotes.
- El modelo de optimización formulado como MILP, que emplea las proyecciones de peso como entrada, resolvió 5100 variables binarias en un horizonte de 12 días operativos, y alcanzó el óptimo global en unos 61 s con un gap  $< 0,01$  %; la solución respeta todas las restricciones de mezcla diaria, totales semanales, prioridad de sexo y límites de peso dentro de las tolerancias definidas, demostrando su viabilidad y robustez para la planificación operativa.
- Al maximizar la ganancia diaria de peso, el modelo selecciona lotes con mejor desempeño zootécnico y, por ende, reduce el costo de alimentación que representa cerca del 70 % del costo total de engorde a la vez que satisface la demanda por categoría; su estructura modular facilita extender el horizonte, incorporar nuevas restricciones logísticas y desplegar la herramienta dentro de los sistemas de planificación existentes para soportar decisiones diarias basadas en datos.

# REFERENCIAS

1. **Boonmee, C., Arthan, S., & Boonmee, P.** (2015). Poultry production and logistics optimization: A case study in Thailand. *International Journal of Production Economics*, 170, 602–612. <https://doi.org/10.1016/j.ijpe.2015.06.027>
2. **Brevik, H., Magnus, J. R., & Paap, R.** (2020). Optimal slaughter planning under capacity constraints in broiler production. *European Journal of Operational Research*, 285(3), 1077–1090.
3. **Fenavi.** (2024). *Resultado y expectativa avícola 2023-2024* (Boletín No. 393). Federación Nacional de Avicultores de Colombia. [https://fenavi.org/wp-content/uploads/2024/01/Fenaviquin\\_ed3932024.pdf](https://fenavi.org/wp-content/uploads/2024/01/Fenaviquin_ed3932024.pdf)
4. **Mula, J., Pedro, D., Díaz-Madroño, M., & Vicens, E.** (2010). Mathematical programming models for supply chain production and transport planning. *European Journal of Operational Research*, 204(3), 377–390. <https://doi.org/10.1016/j.ejor.2009.09.008> researchgate.net
5. **Solano-Blanco, R., Guevara, C., & Calderón, J.** (2020). *Integrated planning for poultry supply chains: A MILP approach* [Tesis de maestría, Universidad de los Andes]. Repositorio Uniandes. <https://repositorio.uniandes.edu.co/handle/1992/50728>
6. **Zanin, A., Bittencourt, A., & Pereira, M.** (2022). Machine learning models for broiler weight prediction using sensor data. *Computers and Electronics in Agriculture*, 196, 106913. <https://doi.org/10.1016/j.compag.2022.106913>
7. **Zuidhof, M. J., Schneider, B. L., Carney, V. L., Korver, D. R., & Robinson, F. E.** (2014). Growth, efficiency, and yield of commercial broilers from 1957, 1978, and 2005. *Poultry Science*, 93(12), 2970–2982. <https://doi.org/10.3382/ps.2014-04291>