

Análisis comparativo de información nutricional de pollos de engorde con enfoque entre
modelos de lenguaje y tablas estándar Rostagno

David Alejandro Suárez Tarazona, Lesly Yuliana López Villamizar

Trabajo de Grado para Optar el Título de Zootecnista

Director

Herik Leonardo Cáceres Cáceres

Magister en Gestión de la Tecnología Educativa

Codirector

Heiner Leandro Tarazona García

Especialista en nutrición y alimentación animal

Universidad Industrial de Santander

Instituto de Proyección Regional y Educación a Distancia IPRED

Programa de Zootecnia

Bucaramanga

2024

Dedicatoria

Le dedico este trabajo y toda mi carrea universitaria a mi madre Yaddy Mayerly Villamizar por haberme apoyado cada una de mis locuras desde el día uno que quise entrar a la UIS hasta la maravillosa idea de viajar a Brasil, nunca haber perdido la fe en lo que puedo lograr y siempre sentirse orgullosa de mí y mis decisiones.

También dedico este proyecto a cada una de las personas que hicieron parte de mi vida en la universidad y mis agradecimientos infinitos a Málaga por haberme adoptado como parte de su comunidad y haberme hecho parte de tantas actividades en el municipio, que además de forjarme como profesional, forjaron mi personalidad y evolución humana. En mi cabeza quedan tantos nombres de personas que amé y fueron parte de mi día a día que nunca voy a olvidar.

Agradecimientos

Agradecemos principalmente al profesor Leonardo Avendaño que ya no es docente inscrito en la UIS, pero fue pionero de esta idea de trabajo de grado.

Agradezco y dedico mi progreso a cada uno de los profesores que me presionaron para que lograra mis objetivos, que se esforzaron por dar su tiempo y conocimientos, además, de tener mi total admiración: José Espinel, Jerson Estupiñán, Felipe Torres Ruda, Laura Álvarez, Julián Botero entre otros.

Y, por último, pero no menos importante Doña Nidia Ruda, nuestra más preciada reliquia Universitaria que además de haber sido parte de mi familia, fue vínculo esencial para ingresar a la UIS sede Málaga, fué apoyo fundamental durante tanto tiempo y me abrió las puertas de su casa y de su corazón.

Lesly Yuliana López

Agradezco primeramente a Dios por darme su bendición y permitir que este proyecto fuese una realidad. Al director y al codirector por brindarnos los conocimientos, darnos su apoyo y estar ahí siempre presentes durante el trabajo. Agradezco a cada docente por transmitir y aportar en mi vida el conocimiento que tengo. Agradezco a mi padre Rodolfo, mi madre Olga, mis hermanos y mi novia Tatiana que han creído en mí siempre, dándome ejemplo de superación y sacrificio y me han brindado su apoyo en este gran logro para mi vida. A mi tía Eloína por brindarme su apoyo de todas las formas desde el inicio hasta el final y en general a toda mi familia.

David Alejandro Suárez

Tabla de Contenido

	Pág
Introducción	12
1. Objetivos	14
1.1 Objetivo general	14
1.2 Objetivos específicos	14
2. Marco Referencial	15
2.1 Marco teórico	15
2.1.1 Evolución de la nutrición animal	15
2.1.2 Revolución digital en el sector agropecuario	16
2.2 Marco conceptual	17
2.2.1 Inteligencia artificial en la agricultura	17
2.2.2 Nutrición avícola	18
2.2.3 Valor nutricional de los alimentos	19
2.2.4 Procesamiento del lenguaje natural (PLN)	20
2.2.5 Modelos de lenguaje	21
2.2.6 Prompts	24
2.2.7 Atlas.ti	27
2.2.8 Diagrama Sankey	28
3. Metodología	28
3.1 Área de estudio	28

3.2	Extracción de información y respuestas del libro Tablas Brasileiras para aves y cerdos.	
	31	
3.3	Uso del software Atlas.ti.....	35
3.4	Análisis de contenido.....	39
3.5	Análisis de datos	41
3.5.1	Análisis entre intersecciones.....	44
3.5.2	Comparación con tablas brasileñas.....	45
4.	Resultados.....	47
5.	Conclusiones.....	51
	Referencias bibliográficas	54

Lista de Tablas

	Pág.
Tabla 1 Tipos de prompts	26
Tabla 2 Elaboración de prompts	29
Tabla 3 Requerimientos Nutricionales de Pollos de Engorde	31
Tabla 4 Listado de alimentos según Rostagno	32
Tabla 5 Corrección de temperatura según Rostagno	32
Tabla 6 Requerimientos y consumo de inicio a finalización de pollos de desempeño regular	33
Tabla 7 Relación de aminoácidos para estimar el consumo	34
Tabla 8 Requerimiento nutricional de pollos regular	35
Tabla 9 Intersección Rostagno con modelos de lenguaje	44
Tabla 10 Semejanzas de respuestas entre modelos	45
Tabla 11 Diferencias de respuestas entre modelos	46
Tabla 12 Resultados totales modelos de lenguaje y diario de Rostagno	50

Lista de Ilustraciones

	Pág.
Ilustración 1 Carpeta de diarios	36
Ilustración 2 Insertar proyecto	36
Ilustración 3 Agrupar documentos.....	37
Ilustración 4 Elaboración de citas y códigos.....	38
Ilustración 5 Categorización de códigos en grupos	39
Ilustración 6 Correlación diario Rostagno con grupos de códigos	40
Ilustración 7 Nodos entre códigos y Rostagno	41
Ilustración 8 Rostagno \cap Chatgpt	42
Ilustración 9 Rostagno \cap Gemini	43
Ilustración 10 Rostagno \cap Copilot	44
Ilustración 11 ChatGPT vs Rostagno.....	48
Ilustración 12 Copilot vs Rostagno.....	48
Ilustración 13 Gemini vs Rostagno.....	49

Glosario

Avícola: relativo a la cría y producción de aves domésticas, como pollos, gallinas y pavos, para obtener carne, huevos u otros derivados.

Clúster: en el análisis de datos es un conjunto de elementos similares que se agrupan. Es una técnica utilizada para descubrir patrones en datos

Desviación estándar: medida estadística que evalúa la dispersión de datos respecto a su medida.

Formulación: proceso mediante el cual es posible elaborar dietas nutricionales específicas para las aves, garantizando que se cubran sus necesidades alimenticias a lo largo de diversas etapas de producción.

Modelos de Lenguaje: herramientas impulsadas por inteligencia artificial, como ChatGPT, Gemini y Copilot, que emplean algoritmos sofisticados para generar recomendaciones nutricionales y mejorar la formulación de dietas.

Modelos: representaciones simplificadas de sistemas o procesos reales que permiten analizar, simular o predecir comportamientos en diferentes escenarios. En el texto, se refiere a los modelos de lenguaje basados en inteligencia artificial.

Nutricionales: relacionado con los nutrientes y la alimentación. En este caso, hace referencia a la formulación de dietas en el sector avícola, adaptadas a las necesidades específicas de los animales.

Precisión Nutricional: nivel de exactitud en la identificación y provisión de los nutrientes esenciales para asegurar un crecimiento, desarrollo y productividad óptimos de las aves, siendo crucial para la efectividad de las dietas formuladas.

Rigidez: falta de flexibilidad o capacidad de adaptarse a cambios o nuevas condiciones. En el contexto, describe cómo los enfoques tradicionales en la formulación de dietas limitan la adaptación a variaciones en el clima y materias primas.

Sankey: es una herramienta de visualización que muestra el flujo de valores de un conjunto a otro. Es útil para analizar el movimiento de información a lo largo del tiempo y para destacar las principales transferencias o flujos dentro de un sistema.

Sesgos algorítmicos: errores sistemáticos en los resultados de los modelos debido a los datos de entrenamiento deficientes.

Sostenibles: prácticas que satisfacen las necesidades actuales sin comprometer los recursos y posibilidades de las futuras generaciones. Aquí se refiere a la búsqueda de prácticas avícolas más responsables con el medio ambiente y los recursos.

Validación de datos: proceso para verificar la precisión y confiabilidad de los resultados generados.

Resumen

Título: Análisis comparativo de información nutricional de pollos de engorde con enfoque entre modelos de lenguaje y tablas estándar Rostagno*

Autor: David Alejandro Suárez Tarazona y Lesly Yuliana López Villamizar**

Palabras Clave: Modelo de lenguaje, nutrición, pollos, IA, Rostagno, Atlas.ti

Descripción: ¿es adecuado confiar en modelos de lenguaje o IA para el uso en producciones avícolas, en temas nutricionales y de formulación de dietas? Históricamente, este proceso se ha basado en tablas de composición y requerimientos nutricionales estandarizados, como las desarrolladas por Rostagno en Brasil. Sin embargo, la rigidez de estos enfoques limita su capacidad de adaptación a condiciones de cambio climático y la variación de materias primas disponibles. Con el aumento de la complejidad en el sector avícola y la creciente demanda de prácticas más sostenibles, se realizó un registro estandarizado para recopilar información de prompts aplicados a los modelos de lenguaje ChatGPT, Gemini y Copilot y se comparó la precisión frente a las tablas de Rostagno para la formulación de dietas en pollos de engorde. Se crearon en total 88 códigos de 214 citas dentro de 4 documentos o diarios que fueron unidos en 11 grupos. Utilizando análisis cualitativo y el software Atlas.ti, se evaluó la consistencia y precisión de las respuestas permitiendo identificar fortalezas y áreas de mejora de cada herramienta para obtener resultados adecuados frente a las tablas nutricionales de Rostagno. Los modelos mostraron diferencias significativas en la precisión y confiabilidad destacándose ChatGPT en precisión para formulaciones rápidas, mientras que Gemini fue más adecuado para análisis detallados. Copilot mostró utilidad limitada debido a las ambigüedades. ChatGPT y Gemini mostraron coincidencia promedio del 95% y 86% respectivamente con las tablas brasileras de Rostagno, mientras que Copilot presentó discrepancias mayores al 15 % en varios casos, particularmente en recomendaciones de aminoácidos esenciales. Además, poseen una solución favorable para la industria avícola, aportando información para la formulación de dietas en los diferentes procesos productivos teniendo en cuenta las características adecuadas que posee cada herramienta y los objetivos del usuario.

*Trabajo de grado

* Instituto de Proyección Regional y Educación a Distancia IPRED UIS. Director: Herik Leonardo Cáceres, Magister em Gestión de la Tecnología Educativa. Co-director: Heiner Leandro Tarazona García, Especialista em nutrición y alimentación animal.

Abstract

Title: Improving broiler diet formulation using language models: A comparison with Rostagno standards*

Author(s): David Alejandro Suárez Tarazona y Lesly Yuliana López Villamizar *

Key Words: Language model, nutrition, chickens, AI, Rostagno, Atlas.ti

Description: Is it appropriate to rely on language models or AI for use in poultry production, nutritional issues and diet formulation? Historically, this process has been based on standardized nutritional requirements and composition tables, such as those developed by Rostagno in Brazil. However, the rigidity of these approaches limits their ability to adapt to conditions of climate change and the variation in available raw materials. With the increase in complexity in the poultry sector and the growing demand for more sustainable practices, a standardized registry was carried out to collect information from prompts applied to the ChatGPT, Gemini and Copilot language models and the accuracy was compared against the tables of Rostagno for the formulation of diets in broiler chickens. A total of 88 codes were created from 214 quotes within 4 documents or diaries that were united into 11 groups. Using qualitative analysis and the Atlas.ti software, the consistency and precision of the responses was evaluated, allowing the identification of strengths and areas for improvement of each tool to obtain adequate results compared to Rostagno's nutritional tables. The models showed significant differences in precision and reliability, with ChatGPT standing out in precision for quick formulations, while Gemini was more suitable for detailed analysis. Copilot showed limited usefulness due to ambiguities. ChatGPT and Gemini showed average agreement of 95% and 86% respectively with the Brazilian Rostagno tables, while Copilot presented discrepancies greater than 15% in several cases, particularly in essential amino acid recommendations. In addition, they have a favorable solution for the poultry industry, providing information for the formulation of diets in the different production processes taking into account the appropriate characteristics that each tool has and the user's objectives.

*Degree Work thesis

* Institute for regional outreach and distance education IPRED UIS. Program Zootechnics.
Director: Herik Leonardo Cáceres. Co-director: Heiner Leandro Tarazona García.

Introducción

La formulación de dietas nutricionales en la producción avícola es un proceso fundamental que exige una identificación precisa de las necesidades alimenticias de las aves y un suministro adecuado de nutrientes a partir de las materias primas. Esta precisión es vital para asegurar un crecimiento, desarrollo y productividad óptimos de los animales. Tradicionalmente, las dietas se han elaborado basándose en investigaciones estandarizadas que consideran variables controladas, como temperatura y humedad, resultando en tablas de composición y requerimientos nutricionales, tales como las desarrolladas por Rostagno en Brasil. Aunque, estas tablas han sido cruciales en la práctica avícola, su rigidez puede limitar su aplicabilidad en un entorno en constante cambio (Grashorn, 2017). La creciente complejidad del sector avícola, junto con la diversidad de condiciones ambientales, ha planteado nuevos desafíos. Factores como el cambio climático, la fluctuación en los recursos de materias primas y la creciente demanda del mercado por productos más sostenibles requieren un enfoque más flexible y adaptativo en la formulación de dietas. Además, la presión para aumentar la eficiencia de la producción y garantizar el bienestar animal ha llevado a los productores a buscar soluciones más innovadoras (Janzen, 2023).

En este contexto, la emergencia de modelos de lenguaje y de inteligencia artificial (IA) representa una oportunidad revolucionaria para la formulación de dietas. Estos modelos son capaces de integrar datos de investigación y ofrecer recomendaciones personalizadas que se adaptan a diferentes climas y contextos productivos (Agtecher, 2022). Su habilidad para procesar grandes volúmenes de información y aprender de ella permite una personalización de las dietas según las necesidades específicas de los lotes de aves, mejorando la precisión nutricional. De la misma manera, la utilización de estos modelos puede facilitar la comunicación y la toma de decisiones en entornos educativos y profesionales, lo que refuerza su potencial en el ámbito agrícola (Alafnan et al., 2023; González-Atencio, 2023).

Este estudio plantea preguntas clave a los modelos de lenguaje, como ChatGPT, Gemini y Copilot, para igualar o incluso superar la precisión y fiabilidad de las tablas nutricionales tradicionales en la formulación de dietas. El objetivo es evaluar la efectividad de estos modelos como herramientas confiables, considerando su capacidad de adaptación a diversas condiciones productivas y su habilidad para responder a la dinámica cambiante del sector (González-González, 2023). La optimización de la formulación de dietas mediante la inteligencia artificial podría beneficiar a los productores, mejorando la eficiencia y sostenibilidad de la producción mientras se garantiza el bienestar animal. Esta investigación aborda la necesidad de modernizar las prácticas actuales de formulación de dietas, proponiendo soluciones prácticas y teóricas ante los desafíos contemporáneos en la producción avícola (Basantes, 2023; Grashorn, 2017).

El enfoque adoptado combina análisis cualitativos para evaluar la precisión y fiabilidad de los modelos de lenguaje, proporcionando un marco integral que permite abordar de manera efectiva el problema planteado y contribuir al avance en el campo de la nutrición avícola. La incorporación de modelos de lenguaje en este proceso promete no solo mejorar la formulación de dietas, sino también facilitar una comunicación más efectiva en la toma de decisiones, permitiendo una adaptación más ágil y eficiente a los cambios en el entorno productivo (González-Atencio 2023; Janzen, 2023).

1. Objetivos

1.1 Objetivo general

Evaluar la efectividad y coherencia de los modelos de lenguaje, como ChatGPT, Gemini y Copilot, en la creación de dietas nutricionales para la producción de pollo de engorde, analizando su exactitud y confiabilidad en comparación con las tablas nutricionales estándar Rostagno.

1.2 Objetivos específicos

Elaborar prompts específicos para cada uno de los modelos de lenguaje (ChatGPT, Gemini y Copilot) con el fin de obtener información precisa sobre los requerimientos nutricionales de los pollos de engorde, utilizando como referencia las tablas nutricionales del Departamento de Zootecnia de la Universidad Federal de Viçosa Rostagno.

Aplicar prompts creados en cada modelo de lenguaje, garantizando que se cumplan las especificaciones necesarias para la adecuada recopilación de resultados.

Analizar y comparar los datos obtenidos de cada modelo de lenguaje con las tablas nutricionales estándar.

Determinar la confiabilidad de los modelos y establecer cuál de ellos se puede recomendar.

2. Marco Referencial

2.1 Marco teórico

2.1.1 *Evolución de la nutrición animal*

La evolución de la nutrición animal ha transcurrido de métodos empíricos hacia enfoques científicos más rigurosos, fundamentados en la investigación y la experimentación. Inicialmente, la formulación de dietas se basaba en la experiencia y la observación directa, lo que limitaba su precisión y eficacia.

En Brasil, esta formulación dependía de la composición de alimentos y de datos nutricionales provenientes de referencias internacionales, especialmente de Estados Unidos y Europa. Ante esta situación, el Departamento de Zootecnia de la Universidad Federal de Viçosa (UFV) llevó a cabo una serie de experimentos destinados a crear tablas nutricionales para aves y cerdos, utilizando información recolectada localmente. El resultado de estos esfuerzos fue la publicación de su primera tabla en 1983. Posteriormente, se lanzaron ediciones sucesivas: la primera, en el 2000; la segunda, en el 2005; la tercera, en el 2011; la cuarta, en el 2017 y la quinta edición, en marzo del 2024, esta se basa en investigaciones recientes y ensayos realizados en laboratorio a condiciones medioambientales específicas para cada etapa productiva. Dichos desarrollos han contribuido significativamente a la mejora de la producción animal tanto en Brasil como en diferentes países tropicales de Suramérica, permitiendo la formulación de dietas más eficientes y económicas para aves y cerdos (Engormix, 2024).

Además, se ha introducido el uso de enzimas como sustitutos de los promotores de crecimiento. Estas enzimas ayudan a potenciar la actividad de las propias enzimas digestivas de los animales, dado que los ingredientes en las dietas suelen incluir celulosas, hemicelulosas y pectinas, que no son descompuestas de manera eficiente en los monogástricos (Shimada, 2003). Según Campaña (2010), los experimentos con dietas que presentan restricciones en proteína y energía, al

incorporar la enzima Avizyme, han mostrado mejoras en indicadores de productividad como el peso, el consumo de alimento y la conversión alimentaria, lo que resulta en beneficios significativos para la producción a un costo reducido.

2.1.2 Revolución digital en el sector agropecuario

2.1.2.1 Automatización de procesos. La incorporación de la tecnología ha transformado la agricultura mediante la automatización de una variedad de procesos, que van desde la recolección de datos hasta la toma de decisiones estratégicas. Con la evolución de la inteligencia artificial, su influencia en el sector agrícola se ha vuelto significativa, especialmente en la gestión de recursos, desde la planificación hasta la aplicación de fertilizantes. Esta optimización favorece un uso más eficaz de pesticidas, fertilizantes y agua, lo que resulta en beneficios económicos y una reducción del impacto ambiental relacionado con el uso excesivo de insumos (Calero, 2024). En la actualidad, América Latina y el Caribe cuentan con alrededor de 450 iniciativas enfocadas en la innovación tecnológica en el ámbito agrícola, con más de nueve sectores emergentes, la mayoría de los cuales se han desarrollado en los últimos cuatro años (Viton, 2019).

2.1.2.2 Uso de software en la formulación de dietas. Los sistemas informáticos se han convertido en herramientas esenciales para lograr un equilibrio nutricional en los animales, lo que a su vez contribuye a una mayor productividad en el sector agropecuario. La implementación de modelos de inteligencia artificial permite calcular dietas específicas para diversas especies, utilizando ingredientes comúnmente disponibles. Estos avances no solo optimizan la formulación de dietas, sino que también aumenta la capacidad en el uso de recursos y la sostenibilidad de la producción (Agtecher, 2022). Al integrar datos de diversas fuentes, estos sistemas pueden adaptarse a las variaciones en condiciones ambientales y necesidades nutricionales, ofreciendo recomendaciones personalizadas que favorecen el bienestar animal y la rentabilidad económica de los productores.

2.1.1.3 Emergencia de la inteligencia artificial. La inteligencia artificial ha transformado diversas industrias y su uso en la agricultura, especialmente en la nutrición animal, está en continuo aumento. Actualmente, las aplicaciones digitales de inteligencia artificial en el sector agrícola incorporan el manejo de cultivos, la gestión de plagas y enfermedades, el control de arvenses, la irrigación, la evaluación de suelos, la recopilación de datos para la sostenibilidad y el control de costos, así como soluciones específicas para el entorno rural. En el ámbito de la nutrición animal, esta tecnología se utiliza para analizar datos relacionados con la producción, el rendimiento de los animales y el consumo de alimentos, facilitando la identificación de indicadores y patrones necesarios para desarrollar dietas adaptadas a diferentes especies (Fernández, 2020).

2.2 Marco conceptual

2.2.1 Inteligencia artificial en la agricultura

A pesar que el empleo de modelos de lenguaje como ChatGPT en el ámbito de la investigación científica agropecuaria es todavía escasa, estos modelos han demostrado su capacidad para proporcionar información actualizada y útil. Los agricultores requieren estar al tanto de una gran variedad de temas, que incluyen finanzas, economía, biología y ventas (Agtecher, 2022; Janzen, 2023) señalan que la efectividad de estos modelos puede aumentar significativamente si se les proporciona un conjunto adecuado de datos de entrenamiento, lo que podría hacer que su aplicación en el sector agrícola sea más prometedora. Con la optimización del entrenamiento, se busca enriquecer las actividades realizadas en la agricultura. Por ejemplo, Uyeh et al. (2022) implementaron un sistema intuitivo que produce diversas combinaciones de respuestas, facilitando la modernización de los sistemas productivos agrícolas. Este algoritmo tiene el potencial de mejorar la toma de decisiones y, en consecuencia, aumentar la utilidad hasta en un 250%.

Investigaciones adicionales, han demostrado que es posible establecer sistemas de apoyo a la decisión mediante el uso de modelos que ofrecen herramientas eficaces y accesibles para la

producción de hortalizas, lo que permite mejorar el riego y la administración de nutrientes (González-Atencio, et al. 2023).

En lo que respecta al bienestar y la salud animal, Wilkinson et al., (2020) aplicaron el autómata y la inteligencia artificial para crear un modelo de manejo de pasturas, que equilibra el abastecimiento de alimento con las necesidades nutricionales diarias de los animales. Del mismo modo, Singh et al. (2021) llevaron a cabo una inspección que reveló que el uso de tecnologías de datos, en combinación con conocimientos de expertos y sensores avanzados, mejora de manera significativa las prácticas en la ganadería lechera.

Como se ha señalado, la utilización de algoritmos de aprendizaje en los modelos de lenguaje es crucial para avanzar en su aplicación. Reagan et al. (2022) utilizaron estos modelos para detectar enfermedades, como la leptospirosis en perros, logrando una eficiencia superior a la de los métodos de detección serológica convencionales. Además, Siche & Siche, (2023) realizaron un análisis bibliométrico organizado en tres clústeres sobre ChatGPT, presentando una lista de aplicaciones en el sector agropecuario. Esta integración de inteligencia artificial con evidencia científica sugiere que hay aplicaciones viables para su implementación en el campo, siempre que se garantice una disponibilidad adecuada de datos en términos de cantidad y calidad.

2.2.2 Nutrición avícola

Los requerimientos nutricionales de los pollos de engorde se establecen en función de sus rendimientos, los cuales varían según los distintos genotipos. Estos rendimientos se definen por el peso al sacrificio (en gramos), la edad comercial (en días) y el índice de conversión, tal como se indica en el trabajo de Siche & Siche (2023). La metionina es considerada el primer aminoácido limitante en la dieta de pollos de engorde, lo que hace que la investigación sobre sus requerimientos nutricionales se concentre en este nutriente.

En los monogástricos, como los pollos, los requerimientos se determinan mediante una combinación de proteína bruta y energía, a través de experimentos de dosis/respuesta. En estos

estudios, se incorpora metionina a una dieta base y se mide la respuesta en términos de ganancia diaria de peso (Campos, 2008). A partir de estos resultados, se utiliza un análisis de regresión para identificar el nivel óptimo de este aminoácido. Otra metodología es, la deducción factorial de los requerimientos de aminoácidos, que se basa en la composición nutricional del ave, aunque la información disponible en este ámbito es limitada. Investigaciones han demostrado que el contenido proteico promedio del cuerpo del ave es de alrededor de 186 g/kg. Además, las cantidades de metionina, lisina, treonina y triptófano en el cuerpo sin plumas son aproximadamente 2.5, 7.0, 3.9 y 1.0 g por cada 16 g de nitrógeno, respectivamente, siendo estos valores más bajos en las plumas. Asimismo, se considera crucial la relación entre los aminoácidos y la digestibilidad, que en los pollos de engorde se evalúa de manera más precisa mediante la digestibilidad ileal (Baker, 2008).

2.2.3 Valor nutricional de los alimentos

La evaluación de la disposición química y el contenido nutritivo de los alimentos es crucial para determinar de manera efectiva el contenido de nutrientes, lo cual es uno de los factores más relevantes en la nutrición animal (Carvalho et al., 2021). El entendimiento del valor nutricional de los alimentos utilizados en la alimentación animal no solo facilita la identificación de los nutrientes presentes, sino que también constituye un requisito fundamental para implementar prácticas de manejo que busquen aumentar la productividad animal (Genro & Orquis, 2009). La calidad alimentaria se traduce directamente en la producción por animal; por ello, realizar un análisis químico se transforma en una herramienta principal para equilibrar las dietas y optimizar la respuesta productiva (Bueno, 2017).

La determinación de la composición química mediante métodos tradicionales, comúnmente aplicados en laboratorios a nivel nacional, puede resultar costosa y demandar un tiempo considerable. No obstante, hay métodos alternativos, como la espectrometría de reflectancia en el infrarrojo cercano (NIRS), que utiliza el principio de emisión de radiación electromagnética y ha

sido reconocida como un enfoque eficaz para la evaluación química de alimentos y forrajes (Bueno, 2017). Al contar con una comprensión precisa de la composición química de los alimentos y los métodos adecuados para evaluar las necesidades nutricionales de los pollos, es posible avanzar hacia la formulación de dietas que satisfagan las necesidades específicas de cada animal, considerando su etapa fisiológica o su condición de vida (Gwendolyn, 2017)

2.2.4 Procesamiento del lenguaje natural (PLN)

El Procesamiento del Lenguaje Natural (PLN) es una subdisciplina de la inteligencia artificial (IA) que se enfoca en cómo las computadoras pueden interactuar con el lenguaje humano. Mediante el uso de algoritmos y modelos de aprendizaje automático, el PLN capacita las máquinas para comprender, analizar y producir texto de una manera que imita la comunicación humana (Rouhiainen, 2018). Esta habilidad resulta esencial para el análisis de grandes conjuntos de datos textuales, lo que facilita la toma de decisiones ya que identifica patrones y tendencias.

En la industria avícola, el PLN está transformando significativamente las prácticas de gestión en las granjas. La incorporación de tecnologías de inteligencia artificial (IA) permite mejorar la eficiencia y rentabilidad de las operaciones avícolas, al mismo tiempo contribuye con el impacto ambiental de la producción. Por ejemplo, sensores habilitados con IA pueden supervisar el comportamiento de los pollos, lo que facilita la detección temprana de enfermedades y mejora su salud (Park et al., 2022). Además, estos sistemas son capaces de regular la cantidad de alimento consumido, garantizando que los pollos reciban una nutrición adecuada, lo cual contribuye tanto a su bienestar como a la sostenibilidad ambiental.

La implementación del PLN en el sector avícola facilita la automatización de procesos analíticos, a la par que permite la elaboración de informes y recomendaciones que apoyan a los productores en la toma de decisiones más informadas. Esta integración de tecnologías avanzadas marca un avance significativo en la modernización de las prácticas agrícolas, subrayando la

relevancia de la IA y el PLN para optimizar la producción y gestionar de manera sostenible los recursos (Giraldo, 2023).

2.2.5 Modelos de lenguaje

Los modelos de lenguaje son sistemas avanzados diseñados para procesar el lenguaje natural, empleando vastas cantidades de datos para generar respuestas fundamentadas en patrones lingüísticos. Estos modelos analizan y comprenden el contexto, la sintaxis y el significado del texto, lo que permite a los usuarios tener una mayor conexión. La calidad de las respuestas que producen está intrínsecamente relacionada con la precisión y claridad del prompt o instrucción que reciben; cuanto más específico y bien estructurado sea el Prompt, mayor será la efectividad del modelo en la generación de una respuesta adecuada (Ortiz et al., 2024)

El progreso en los modelos de lenguaje ha sido significativo, comenzó con enfoques más simples que se basaban en reglas gramaticales y transiciones de palabras, hasta llegar a modelos complejos que utilizan redes neuronales profundas y técnicas de aprendizaje automático. Estos avances han permitido que los modelos sean capaces de captar matices de entonación, humor y contexto cultural, lo que los hace herramientas valiosas en diversas aplicaciones, desde la traducción automática hasta la exploración de sentimientos y la creación de contenido.

La implementación de modelos de lenguaje ha tenido un impacto notable en múltiples industrias, facilitando la automatización de tareas que requieren comprensión del lenguaje, como el servicio al cliente, la educación y la investigación. En el ámbito académico y profesional, su capacidad para sintetizar información y proporcionar respuestas a preguntas específicas colabora en la eficiencia de toma de decisiones y en la generación de conocimiento (Deng & Lin, 2022).

Sin embargo, la efectividad de estos modelos también plantea desafíos, especialmente en lo que respecta a la interpretación de información compleja o ambigua, así como a la posibilidad de sesgos inherentes en los datos utilizados para su entrenamiento. A medida que se desarrollan nuevas versiones y se refinan los algoritmos, es crucial continuar evaluando la ética y la precisión de los

modelos de lenguaje para asegurar que su uso beneficie a todos los usuarios de manera equitativa (González-González, 2023)

2.2.5.1 ChatGPT. Es un modelo de lenguaje creado por OpenAI que maneja la inteligencia artificial para interactuar en lenguaje natural. Apoyado en la arquitectura *Generative pre-trained transformer*, GPT, este modelo se entrena con grandes volúmenes de texto, lo que le permite originar respuestas acordes y relevantes a diversas preguntas. Su capacidad para asimilar y producir texto de manera fluida facilita conversaciones que imitan el estilo humano. Este proceso se lleva a cabo a través de un preentrenamiento y ajuste fino que le permite identificar patrones y contextos en el lenguaje (Koza, 2023)

En el área educativa, ChatGPT se expone como un recurso valioso que puede mejorar la calidad del aprendizaje. Al ofrecer explicaciones claras y ejemplos prácticos, puede trabajar como un tutor virtual, ayudando a los estudiantes a comprender conceptos complejos y potenciando su capacidad lingüística. La clasificación de prompts útiles para la enseñanza, explorada por Morales-Chan, (2023) destaca cómo el uso estratégico de este modelo puede enriquecer la experiencia educativa y facilitar el aprendizaje personalizado.

Sin embargo, es fundamental utilizar ChatGPT como una herramienta complementaria, ya que la interacción humana sigue siendo esencial en la educación. Los educadores aportan contextos y experiencias que un modelo de IA no puede ofrecer, lo que subraya el valor de un enfoque colaborativo entre la inteligencia artificial y la enseñanza tradicional (Cortes-Osorio, 2023).

A pesar de sus beneficios, el uso de ChatGPT también plantea cuestiones éticas significativas. La posibilidad de generar contenido impreciso o sesgado es una preocupación, dado que el modelo se basa en datos que pueden contener errores o prejuicios (Ortiz et al., 2024). Esto resalta la necesidad de que los usuarios desarrollen habilidades críticas para evaluar la información que reciben. Además, es crucial contemplar la privacidad y la seguridad de los datos en un contexto donde las interacciones pueden ser registradas y analizadas (Alafnan, 2023)

En resumen, ChatGPT representa un avance significativo en la interacción humano-máquina, especialmente en el ámbito educativo. Su utilización efectiva necesita un enfoque equilibrado que considere tanto sus capacidades como sus limitaciones, promoviendo un uso ético y responsable de la inteligencia artificial para enriquecer la experiencia educativa sin reemplazar la interacción humana fundamental. La incorporación de este modelo en la educación podría marcar una nueva era en la forma en que se instruye y se forma, siempre que se maneje con precaución (Dempere, 2023).

3.2.5.2 Gemini. Es una herramienta innovadora diseñada para implementar sistemas de diálogo de manera eficiente y casi instantánea, fundamentada en una base de datos que permite la generación de respuestas rápidas y precisas. Su desarrollo se orienta a optimizar la interacción del usuario, reduciendo el tiempo de uso de la aplicación y maximizando su rendimiento. Entre sus características más sobresalientes se encuentra la diversidad en los modos de diálogo, que abarcan desde la comunicación por voz mediante el reconocimiento de habla, hasta chat de texto e interacción a través de imágenes, entre otros (Cordoba et al., 2014)

Este enfoque versátil no solo enriquece la experiencia del usuario al facilitar diferentes formas de interacción, sino que también concede un acceso más intuitivo y dinámico a la información. La capacidad de Gemini para adaptarse a múltiples modalidades de comunicación potencia su aplicabilidad en diversos contextos, desde la atención al cliente hasta el ámbito del aprendizaje en línea. Asimismo, la integración de sistemas de diálogo como Gemini se alinea con las tendencias contemporáneas en inteligencia artificial, donde la interacción natural y la comprensión del lenguaje son fundamentales para crear experiencias más inmersivas y efectivas. Con el avance continuo de la tecnología, herramientas como Gemini poseen el potencial de transformar la manera en que los usuarios interactúan con los sistemas digitales, haciéndolos más accesibles y eficientes (Delgado,2024).

3.2.5.3 Copilot. Es una herramienta avanzada diseñada para facilitar la creación de código, desarrollada a partir de diversas bases de datos compiladas por sus creadores. Esta funcionalidad permite que el sistema interprete y procese el lenguaje humano en múltiples idiomas, lo que es crucial para ofrecer respuestas personalizadas que satisfagan las necesidades específicas de los usuarios (Torres, 2022). Su capacidad para generar sugerencias de código en tiempo real no solo optimiza el flujo de trabajo de los programadores, sino que también enriquece el proceso de aprendizaje al proporcionar ejemplos prácticos y contextualizados. De esta manera, la interacción entre el usuario y Copilot se transforma en un enfoque más dinámico de la programación, donde el asistente actúa como un colaborador que potencia la creatividad y la eficiencia en el desarrollo de software.

Además, el uso de Copilot refleja una tendencia creciente en el desarrollo de software, donde la inteligencia artificial se integra como un instrumento esencial para mejorar el rendimiento y la calidad del código. Al comprender el contexto de la tarea, Copilot puede ofrecer soluciones relevantes y efectivas, consolidándose como un recurso valioso para programadores de diversos niveles de experiencia. Con el avance continuo de la tecnología, el impacto de herramientas como Copilot en el ámbito de la programación seguirá expandiéndose, redefiniendo la manera en que se aborda el desarrollo de software.

2.2.6 Prompts

Los prompts desempeñan un papel esencial en la interacción con modelos de lenguaje, actuando como la base sobre la cual se generan las respuestas del sistema. Se puede definir un prompt como la entrada proporcionada al modelo, y su formulación tiene una repercusión directa en la calidad y relevancia de las respuestas obtenidas. La versatilidad en el uso de diferentes idiomas, como el inglés y el español, amplía las posibilidades de aplicación, pero también presenta desafíos considerables.

La eficacia de un prompt está intrínsecamente relacionada con la cantidad y claridad de la información que incluye. Un prompt que carezca de contexto o detalles relevantes es susceptible de generar respuestas insuficientes o inexactas, lo que puede resultar en malentendidos y en una reducción de la utilidad de las respuestas. Por ende, la habilidad para crear prompts eficaces se vuelve crucial para maximizar el potencial de los modelos de lenguaje (Koza, 2023)

Asimismo, es importante considerar que los prompts pueden estar influenciados por sesgos inherentes, dependiendo del algoritmo utilizado durante el entrenamiento del modelo. Estos sesgos pueden manifestarse en las respuestas generadas, afectando la calidad de la información proporcionada. Por ejemplo, si el modelo ha sido entrenado con datos que reflejan perspectivas limitadas o prejuicios, esto puede influir en las respuestas, perpetuando estereotipos o inexactitudes. Por tanto, es fundamental que los usuarios sean conscientes de estos factores al diseñar sus prompts, con el fin de mitigar los riesgos de sesgo y asegurar una comunicación más efectiva y precisa con el modelo.

En conclusión, tanto el diseño como la estructura de los prompts son elementos críticos que determinan la calidad de la interacción con los modelos de lenguaje. Al comprender cómo elaborar prompts claros y específicos, los usuarios pueden mejorar significativamente la calidad de las respuestas generadas, optimizando así el uso de estas herramientas en diversas áreas, desde la educación hasta la investigación y el desarrollo tecnológico.

3.2.6.1 Tipos de prompts. Según Morales-Chan, (2023) los diversos tipos de prompts pueden emplearse de manera estratégica para mejorar la eficacia de los resultados generados por los modelos de lenguaje. A continuación, se describen las categorías fundamentales:

Tabla 1*Tipos de prompts*

Tipo	Definición	Ejemplo
Secuenciales	Elaborar una conversación secuencial y lógica con el modelo de lenguaje que permita llegar a un objetivo específico.	Inicia dando la orden de ubicarse en un tema nacional de nutrición avícola; luego, se pide que mencione las características más esenciales para la elaboración de una dieta en la actualidad y por último que redacte una tabla nutricional con materias primas específicas y sus valores nutricionales.
Comparativo	Se busca que el modelo compare dos o más situaciones generando un análisis de cada cosa.	Se podría indicar que compare dos materias primas de origen proteico para establecer cual es mejor, o comparar que alimento tiene mayor digestibilidad o conversión alimenticio con otros.
Argumental	Se busca que el modelo genere un argumento a favor o en contra de un tema en particular, se hace una solicitud directa, pero utilizando información que nos proporciona anteriormente, es decir se genera una conversación de los temas que al final se quieren argumentar.	Se podría preguntar al modelo que argumente porque es importante la adición de minerales en la dieta de un pollo en fase de inicio o que argumente porque puede ser un problema la adición excesiva de minerales en fase final.

Tipo	Definición	Ejemplo
Perspectiva profesional	Uno de los tipos de prompts más prevalentes para generar dialogo con el modelo de lenguaje; se usa para que el modelo adopte el papel de un individuo o rol específico y describir un tema en un contexto específico dado.	Se sugiere que se le ordene actuar como (autor o profesión) y describe (tema), adicionando y un contexto establecido que se requiera. Como decirle que: actúe como especialista en nutrición de pollos y describe cuales son los puntos esenciales para la óptima nutrición de pollos de engorde en fase de inicio
Lista de deseos	Busca obtener repuestas específicas y relevantes del modelo de lenguaje. <i>"La estructura recomendada para prompts de lista de deseos es "Estoy buscando [opción/objeto/solución] con [requisito 1], [requisito 2] y [requisito 3]. ¿Podrías recomendar algunas ideas?"</i>	Una lista de deseos seria pedir al modelo que genere una lista de alimentos disponibles para pollos de engorde en clima trópico con niveles de nutrientes altos en energía, proteína y fibra.

Nota. Información tomada de (Mora, 2024; Rúgeles, 2001)

En conjunto, la aplicación de estos tipos de prompts permite a los usuarios maximizar la efectividad de los modelos de lenguaje, adaptando la interacción según el propósito deseado y la naturaleza del contenido requerido.

2.2.7 *Atlas.ti*

Es un software creado para procesar grandes volúmenes de información principalmente de origen cualitativo. De este modo se pueden analizar imágenes, videos, entrevistas, documentos escritos entre otros. Esta herramienta funciona inicialmente con importación de los datos, es decir teniendo listo o que se quiera llevar a estudio se puede importar desde una carpeta hecha en

computador pudiendo implementar diferentes formatos de archivos. Atlas.ti utiliza la codificación a porciones de texto relevantes o conceptos, de este modo se le asignan códigos, se pueden crear individualmente o el software de forma automática sugiere algunos (Cantero, 2014). Después de codificados los datos o bien llamadas citas se pueden crear redes conceptuales y de este modo reflejar la relación existente entre los códigos. Creando este relacionamiento se pueden identificar patrones en el texto, jerarquías o incluso conexiones. Si requieres agregar un comentario reflexión u opinión persona, el programa lo facilita.

Además, ofrece herramientas de búsqueda para poder encontrar palabras específicas, citas códigos de los documentos y también se puede relacionar con la IA para hacer preguntas sobre análisis de documentos. Atlas.ti genera diagramas, tablas de contingencia y nubes de palabras

2.2.8 Diagrama Sankey

Los diagramas Sankey son representaciones simbólicas formadas por nodos y flujos relacionados entre sí. Este tipo de diagrama posee como característica principal una anchura proporcional de los flujos y de los nodos a los valores que representan. Cada flujo se representa entre dos nodos, mostrando también la estructura y distribución del sistema representado. La representación gráfica generalmente es unidireccional, de izquierda a derecha y horizontal. En algunos casos aparecen realimentaciones, de forma que un flujo parte de un nodo posterior a un nodo anterior o al propio nodo (García, 2021, pág. 24).

3. Metodología

3.1 Área de estudio

El análisis se llevó a cabo en la Universidad Industrial de Santander, sede Málaga, utilizando modelos de lenguaje avanzados como ChatGPT, Gemini y Copilot. Se diseñó un registro estandarizado denominado 'diario de respuestas', que recopila información de los prompts aplicados a cada modelo de lenguaje. Posteriormente, estos datos fueron procesados y analizados

cuantitativamente utilizando el software Atlas.ti, enfocándose en la precisión y consistencia en comparación con las tablas de Rostagno. De este modo, se emplearon prompts estandarizados para evaluar la capacidad de cada modelo en el ámbito de la nutrición aviar teniendo en cuenta el tipo de prompt usado para cada uno.

Los prompts fueron diseñados meticulosamente para optimizar la eficacia de la información recabada, asegurando que abordaran aspectos críticos de la nutrición de pollos de engorde. El objetivo de los prompts es que resulten siendo preguntas eficientes para que los modelos generen respuestas específicas dependiendo de los tipos que existen.

Tabla 2

Elaboración de prompts

Tipo de Prompt	Prompt
Secuencial con perspectiva profesional	Actúe como zootecnista especialista en pollo de engorde. - ¿Según los requerimientos del pollo de engorde, cuantas dietas se necesitan y cuanto es su duración?
Argumental	Cuanto porcentaje de proteína requiere un pollo de engorde de desempeño regular del día 34 al 42
Argumental	Cuanta energía metabolizable requiere un pollo de engorde de desempeño regular del día 1 al 7
Argumental	Cuanto porcentaje de proteína requiere un pollo de engorde de desempeño medio del día 8 al 21 según las tablas brasileras de Rostagno
Argumental	Cuál es el requerimiento de la energía metabolizable en el pollo de engorde de desempeño medio del día 43 al 46 según las tablas brasileras de Rostagno
Comparativo y secuencial	Cuál es la diferencia de metionina entre un pollo de inicio hasta los 10 días y uno de levante hasta los 25 días. me puede dar porcentaje exacto de metionina?
Lista de deseos	Genera un listado de materias primeras esenciales y fáciles de obtener para balancear una dieta nutricional para pollos de engorde
De perspectiva profesional y secuencial	Desde este punto quiero que seas un experto en nutrición aviar. Ahora recomiéndame los alimentos con mejor digestibilidad en pollos de engorde. Con estos alimentos dame los porcentajes que se deben usar en cada una de las etapas
Argumental	Explica el porcentaje de conversión alimenticia de pollos de engorde de alto rendimiento

	Temperaturas sugeridas para la corrección del requerimiento de EM, en la formulación de dietas para pollos
Secuencial y argumental	Puedes evaluar el consumo diario de un pollo de engorde desde el día uno hasta el de sacrificio. Con este dato puedes calcular el consumo total de alimento de un pollo.
Argumental y lista de deseos	Dime cuales son los aminoácidos esenciales para pollos de engorde y de qué forma se pueden conseguir de manera comercial
De perspectiva profesional y argumental	Ahora eres especialista en nutrición aviar o zootecnista. Conociendo el manejo de la producción avícola. Cuál es el porcentaje de proteína que consume un pollo hembra a una temperatura promedio de 26°.

Nota: Datos obtenidos dentro de la investigación sobre los prompts utilizados en el desarrollo.

3.2 Extracción de información y respuestas del libro Tablas Brasileñas para aves y cerdos.**Tabla 3***Requerimientos Nutricionales de Pollo de Engorde***Lista de los Alimentos**

Alimento	Pag.	Alimento	Pag.
Aceite de Canola	41	Cítricos Pulpa	103
Aceite de Dendé	43	Coco, Harina	105
Aceite de Maíz	45	Galletería, Residuo	107
Aceite de Soja	47	Girasol, Harina	109
Albumina	49	Glicerina	111
Alga (<i>Spirulina platensis</i>)	51	Glucosa	113
Algarrobo Harina	53	Grasa de Aves	115
Algodón, Harina 30% PB	55	Grasa de Bovinos	117
Algodón, Harina 39% PB	57	Grasa de Cerdos	119
Algodón, Harina 43% PB	59	Grasa de Coco	121
Almidón	61	Lactosa	123
Arroz Salvado Desengrasado	63	Lecitina	125
Arroz, Salvado	65	Leche, Desnatada Polvo	127
Arroz, Quebrado	67	Leche, Integral Polvo	129
Avena, Grano	69	Leche, Suero Polvo	131
Azúcar	71	Leche, Suero Permeato	133
Babasu, Harina	73	Levadura, Cerveza	135
Babasu, Harina Amilácea	75	Levadura, Destilería Alc.	137
Batata Dulce, Harina	77	Maíz, Germen	139
Canola, Harina	79	Maíz, Gluten 21%PB	141
Caña de Azúcar, Jugo	81	Maíz, Gluten 60%PB	143
Caña de Azúcar, Melaza	83	Maíz, Grano 6,92%PB	145
Caña Melaza, Polvo	85	Maíz, Grano 7,86%PB	147
Carne Huesos H., 38% (35 - 40%)	87	Maíz, Grano 8,80%PB	149
Carne Huesos H., 43% (40 - 45%)	89	Maíz, Grano Alta Grasa	151
Carne Huesos H., 48% (45 - 50%)	91	Maíz, Grano Alta Lisina	153
Carne Huesos H., 52% (50 - 55%)	93	Maíz, Precocido	155
Carne Huesos H., 60%	95	Mandioca, Harina	157
Caseína	97	Mandioca, Integral Raspa	159
Cebada, Grano	99	Maní, Harina	161
Centeno, Grano	101	Maracuyá, Integral Pasta	163

Nota: tomado del libro de Rostagno, 2017 pag 39.

Tabla 4*Listado de alimentos según Rostagno*

Lista de los Alimentos (Cont.)			
Alimento	Pag.	Alimento	Pag.
Mijo, Grano	165	Soja, Harina 48%PB	203
Ouricuri, Harina	167	Soja, Integral Extrusada	205
Pan, Residuo	169	Soja, Integral Micronizada	207
Pastas Alimen., Residuo	171	Soja, Integral Tostada	209
Pescado, Harina 54%PB	173	Soja, Semi Integral Extr.	211
Pescado, Harina 61%PB	175	Soja, Semi Integral Tost.	213
Plumas, Harina 75%PB	177	Sorgo, Alto Tanino	215
Plumas, Harina 84%PB	179	Sorgo, Bajo Tanino	217
Plumas y Vísceras, Harina	181	Trigo, Germen	219
Ricino, Harina	183	Trigo, Gluten	221
Sangre, Eritrocitos	185	Trigo, Grano	223
Sangre, Harina	187	Trigo, Harina	225
Sangre, Plasma	189	Trigo, Harina Oscura	227
Soja, Cascara	191	Trigo, Residuo	229
Soja, Conc. Proteico	193	Trigo, Salvado	231
Soja, Aislado Proteico	195	Triticale, Grano	233
Soja, Harina 44%PB	197	Vísceras, Aves Harina	235
Soja, Harina 45%PB	199	Vísc. Aves Alta Gras Har.	237
Soja, Harina 46%PB	201	Vísceras, Cerdos Harina	239

Nota: tabla tomada del libro de Rostagno, 2017 pag 40.

Tabla 5*Corrección de temperatura según Rostagno*

Temperaturas sugeridas para corrección del requerimiento de EM		
Edad (días)	TN (°C)	Amplitud Térmica (°C)
22-33	23	18-28
34-56	20	16-27

Nota: tabla tomada del libro de Rostagno, 2017 pag 280.

Tabla 6*Requerimientos y consumo de inicio a finalización de pollos de desempeño regular*

Edad Días	Peso Medio Kg	Ganancia g/día	Req. Lis. Dig. g/día	Req. EM kcal/día ¹	Consumo g/día	Consumo Acumulado, g	Rel Lis/EM %/Mcal	Lis. Dig. Dieta, %
1	0,069	14,5	0,221	48,0	16,1	16	0,460	1,369
2	0,084	16,8	0,256	55,7	18,7	35	0,459	1,366
3	0,101	19,2	0,294	64,2	21,6	56	0,458	1,362
4	0,120	21,8	0,335	73,4	24,7	81	0,456	1,357
5	0,142	24,6	0,380	83,6	28,1	109	0,454	1,351
6	0,166	27,6	0,427	94,6	31,8	141	0,452	1,344
7	0,194	30,8	0,478	106,5	35,8	177	0,449	1,335
8	0,225	34,0	0,532	119,3	39,1	216	0,446	1,360
9	0,259	37,4	0,588	133,0	43,6	260	0,442	1,349
10	0,296	40,9	0,647	147,5	48,4	308	0,439	1,338
11	0,337	44,5	0,709	163,0	53,4	361	0,435	1,326
12	0,382	48,2	0,772	179,3	58,8	420	0,431	1,314
13	0,430	51,9	0,838	196,5	64,4	485	0,426	1,301
14	0,482	55,6	0,905	214,4	70,3	555	0,422	1,287
15	0,537	59,3	0,973	233,1	76,4	631	0,417	1,273
16	0,596	62,9	1,042	252,5	82,8	714	0,413	1,259
17	0,659	66,5	1,112	272,5	89,3	803	0,408	1,244
18	0,726	70,0	1,182	293,0	96,1	899	0,403	1,230
19	0,796	73,4	1,251	314,1	103,0	1002	0,398	1,215
20	0,869	76,7	1,320	335,5	110,0	1112	0,394	1,200
21	0,946	79,8	1,388	357,1	117,1	1230	0,389	1,186
22	1,026	82,8	1,455	379,0	120,3	1350	0,384	1,209
23	1,108	85,6	1,520	400,9	127,3	1477	0,379	1,194
24	1,194	88,2	1,583	422,8	134,2	1611	0,374	1,180
25	1,282	90,6	1,644	444,5	141,1	1752	0,370	1,165
26	1,373	92,8	1,702	465,9	147,9	1900	0,365	1,151
27	1,466	94,8	1,757	487,0	154,6	2055	0,361	1,137
28	1,560	96,6	1,809	507,6	161,1	2216	0,356	1,123
29	1,657	98,2	1,858	527,5	167,5	2383	0,352	1,109
30	1,755	99,5	1,903	546,8	173,6	2557	0,348	1,096
31	1,855	100,6	1,944	565,4	179,5	2737	0,344	1,083
32	1,955	101,6	1,981	583,1	185,1	2922	0,340	1,070
33	2,057	102,3	2,014	599,9	190,4	3112	0,336	1,057
34	2,159	102,7	2,043	615,7	192,4	3305	0,337	1,062
35	2,262	103,0	2,067	630,5	197,0	3502	0,333	1,049
36	2,365	103,1	2,088	644,2	201,3	3703	0,324	1,037
37	2,468	103,0	2,105	656,9	205,3	3908	0,320	1,025
38	2,571	102,8	2,117	668,4	208,9	4117	0,317	1,013
39	2,674	102,3	2,125	678,9	212,1	4329	0,313	1,002
40	2,776	101,7	2,130	688,2	215,1	4544	0,309	0,990
41	2,878	101,0	2,130	696,5	217,6	4762	0,306	0,979
42	2,979	100,1	2,128	703,6	219,9	4982	0,302	0,968
43	3,079	99,0	2,121	709,8	218,4	5200	0,299	0,971
44	3,178	97,9	2,112	714,9	220,0	5420	0,295	0,960
45	3,276	96,6	2,099	719,0	221,2	5641	0,292	0,949
46	3,372	95,2	2,083	722,2	222,2	5864	0,288	0,937
47	3,468	93,8	2,065	724,6	222,9	6087	0,285	0,926
48	3,561	92,2	2,044	726,0	223,4	6310	0,282	0,915
49	3,654	90,6	2,021	726,7	223,6	6534	0,278	0,904
50	3,744	88,9	1,996	726,7	223,6	6757	0,275	0,893
51	3,833	87,2	1,969	725,9	223,4	6980	0,271	0,881
52	3,920	85,4	1,940	724,5	222,9	7203	0,268	0,870
53	4,006	83,6	1,910	722,6	222,3	7426	0,264	0,859
54	4,090	81,7	1,878	720,1	221,6	7647	0,261	0,848
55	4,171	79,9	1,845	717,1	220,7	7868	0,257	0,836
56	4,251	78,1	1,813	714,5	219,8	8088	0,254	0,825

Nota: tabla tomada del libro de Rostagno, 2017 pág. 275

Tabla 7*Relación de aminoácidos para estimar el consumo*

Aminoácido		Fases			
		Pré inicial – Inicial 1 – 21 días		Crecimiento – Final 22 – 56 días	
		Dig.	Total	Dig.	Total
Lisina	%	100	100	100	100
Metionina	%	41	41	41	41
Metionina + Cisteína	%	74	74	74	74
Treonina	%	66	69	66	69
Triptófano	%	18	18	18	18
Arginina	%	107	105	107	105
Glicina + Serina	%	147	150	134	137
Valina	%	77	79	77	79
Isoleucina	%	67	67	68	68
Leucina	%	107	107	108	108
Histidina	%	37	37	37	37
Fenilalanina	%	63	63	63	63
Fenilalanina + Tirosina	%	115	115	115	115

Nota: tabla tomada del libro de Rostagno, 2017 pag 280.

Tabla 8

Requerimiento nutricional de pollos de engorde machos de desempeño regular-medio.

Edad	Días	1-7	8-21	22-33	34-42	43-46
Rango de Peso	Kg	0,04-0,19	0,22-0,95	0,96-2,06	2,16-2,98	3,08-3,37
Peso Medio	Kg	0,125	0,539	1,524	2,570	3,226
Ganancia	g/día	19,8	56,5	94,5	102,2	97,2
Lisina Digestible	g/día	0,306	0,930	1,764	2,106	2,104
Fósforo Disponible	g/día	0,108	0,310	0,555	0,615	0,597
Fósforo Digestible	g/día	0,095	0,272	0,508	0,564	0,549
Energía Metabolizable	kcal/día	69,63	225,8	494,2	664,8	716,5
Energía Metabolizable	kcal/kg	2,975	3,050	3,150	3,200	3,250
Energía Neta	kcal/kg	2350	2400	2470	2510	2550
Consumo	g/día	23,4	74,0	156,9	207,7	220,5
Nutriente						
Proteína Cruda Total	%	24,27	23,31	20,58	18,57	17,47
Proteína Cruda Digestible	%	21,94	21,09	18,61	16,79	15,79
Calcio	%	0,971	0,878	0,758	0,634	0,581
Fósforo Disponible	%	0,463	0,419	0,374	0,296	0,271
Fósforo Digestible	%	0,407	0,368	0,324	0,271	0,249
Potasio	%	0,597	0,598	0,599	0,593	0,593
Sodio	%	0,225	0,218	0,208	0,197	0,192
Cloro	%	0,202	0,194	0,183	0,172	0,166
Ácido Linoleico	%	1,091	1,075	1,056	1,027	1,015
Aminoácido Digestible						
Lisina	%	1,307	1,256	1,124	1,014	0,954
Metionina	%	0,536	0,515	0,461	0,416	0,038
Metionina + Cisteína	%	0,967	0,929	0,832	0,750	0,706
Treonina	%	0,863	0,829	0,742	0,669	0,630
Triptófano	%	0,235	0,226	0,202	0,183	0,172
Arginina	%	1,398	1,344	1,203	1,085	1,021
Glicina + Serina	%	1,921	1,846	1,506	1,359	1,278
Valina	%	1,006	0,967	0,865	0,781	0,735
Isoleucina	%	0,876	0,842	0,764	0,690	0,649
Leucina	%	1,398	1,344	1,214	1,095	1,030
Histidina	%	0,484	0,465	0,416	0,375	0,353
Fenilalanina	%	0,823	0,791	0,708	0,639	0,601
Fenilalanina + Tirosina	%	1,503	1,444	1,293	1,166	1,097
Nitrógeno Esencial Digestible	%	1,755	1,687	1,489	1,343	1,264
Aminoácido Total						
Lisina	%	1,441	1,384	1,239	1,118	1,052
Metionina	%	0,591	0,567	0,508	0,458	0,431
Metionina + Cisteína	%	1,066	1,024	0,917	0,827	0,778
Treonina	%	0,994	0,955	0,855	0,771	0,726
Triptófano	%	0,259	0,249	0,223	0,201	0,189
Arginina	%	1,513	1,453	1,301	1,174	1,104
Glicina + Serina	%	2,162	2,076	1,698	1,532	1,441
Valina	%	1,138	1,093	0,979	0,883	0,831
Isoleucina	%	0,965	0,927	0,843	0,760	0,715
Leucina	%	1,542	1,481	1,338	1,207	1,136
Histidina	%	0,533	0,512	0,459	0,414	0,389
Fenilalanina	%	0,908	0,872	0,781	0,704	0,663
Fenilalanina + Tirosina	%	1,657	1,592	1,425	1,286	1,210
Nitrógeno Esencial Total	%	1,942	1,865	1,647	1,486	1,398

Nota: tabla tomada del libro de Rostagno, 2017 pág. 290.

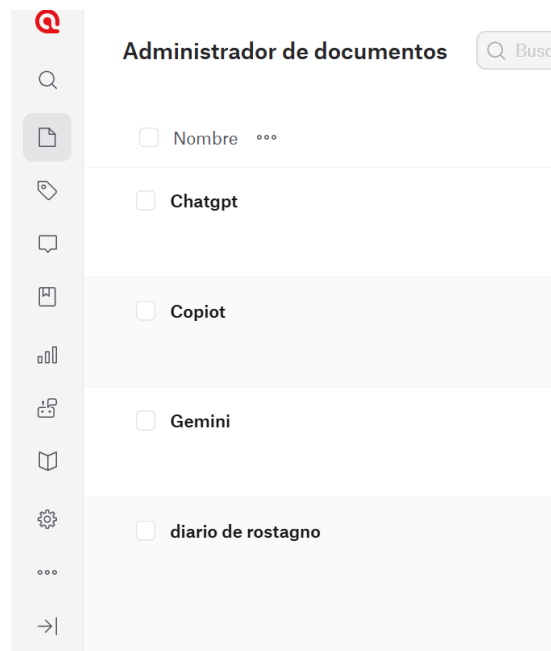
3.3 Uso del software Atlas.ti

Atlas.ti siendo un software de análisis cualitativo, se debe hacer un registro inicial para que genere una licencia de máximo 5 días, después de cumplidos estos días, se deberá comprar licencias para aumentar los días de uso.

Lo primero que se debe hacer es crear una carpeta con los documentos que vas a analizar (ilustración 1), después se añade un proyecto y se importa desde la carpeta de documentos.

Ilustración 1

Carpeta de diarios

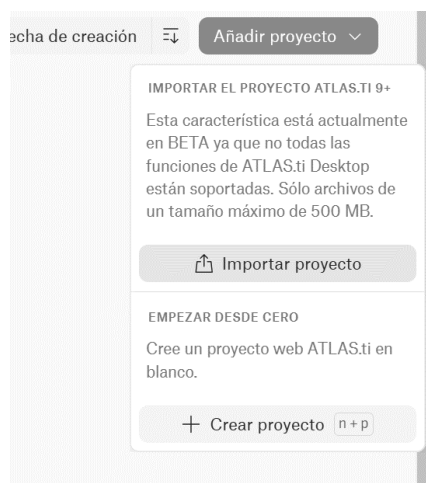


Cada uno de los documentos a importar, contiene las respuestas obtenidas por los modelos de lenguaje y las tablas brasileras de nutrición para aves y cerdos.

Estando dentro de la página web o habiendo descargado el aplicativo para Windows, se procede a iniciar con un nuevo proyecto, esto abrirá una página para introducir los documentos de análisis. Luego se procede a abrir el documento dentro del programa.

Ilustración 2

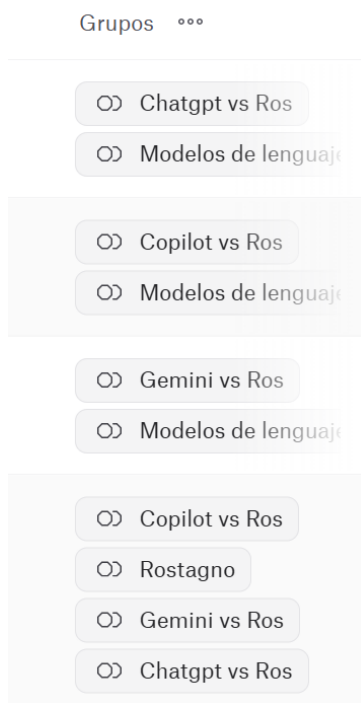
Insertar proyecto



Se importan los documentos en los que se va a trabajar.

Ilustración 3

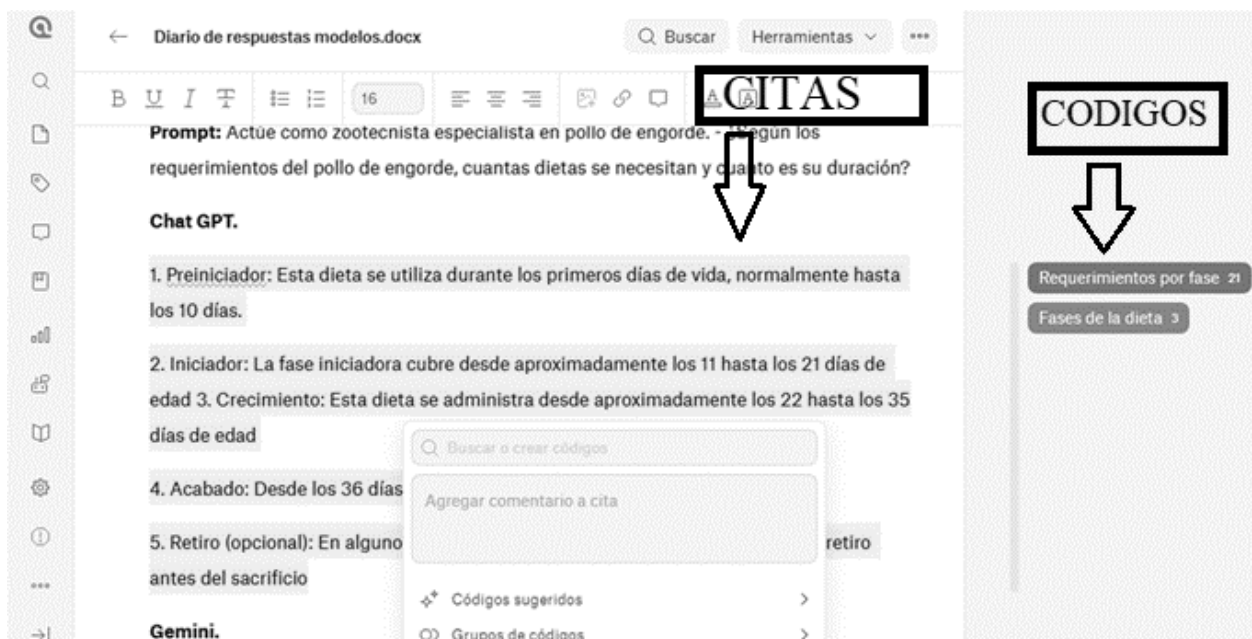
Agrupar los documentos



Abierto el documento se inicia la creación de las citas; estas citas son una porción de texto, que puede ser una línea, un párrafo o varios párrafos, es decir subrayar el texto y allí insertar la cita. Estas citas tienden a contener información relevante de la investigación para su posterior análisis. Para crear códigos descriptivos, los códigos son palabras o frases que se agregarán a cada una de las citas incluso si entre citas tienen algo en común se pueden repetir los códigos, estos solo agrupan citas que tengan similitudes, como dividirlos por temas.

Ilustración 4

Elaboración de citas y códigos



Después de crear citas y poner códigos a todas las citas en el documento, se procede a categorizar los códigos para crear grupos. Entonces, los grupos reunirán o separarán los códigos para tener una visión amplia del trabajo. A medida que se crean los grupos se puede fijar un color por título de este modo:

Ilustración 5*Categorización de códigos en grupos*

Administrador de códigos <input type="text" value="Buscar"/>			
<input type="checkbox"/> Nombre		Grupos	Citas
<input type="checkbox"/> acabado	●	Etapas o fases de desarrollo	9
<input type="checkbox"/> ajuste de lisina	●	VARIABLES DE AMINOÁCIDOS	1
<input type="checkbox"/> Algas	●	Salud anima y bienestar en la alimentacion	1
<input type="checkbox"/> Aminoacidos	●	VARIABLES DE AMINOÁCIDOS	10
<input type="checkbox"/> aminoacidos esenciales	●	VARIABLES DE AMINOÁCIDOS	4
<input type="checkbox"/> antioxidantes	●	Salud anima y bienestar en la alimentacion	1
<input type="checkbox"/> calculo de consumo	●	VARIABLES DE CONSUMO	3
<input type="checkbox"/> Calculo de indice de conversion alimenticia	●	VARIABLES DE CONVERSION ALIMENTICIA	1
<input type="checkbox"/> carbohidratos y azucares	●	Salud anima y bienestar en la alimentacion	1
<input type="checkbox"/> cereales y subproductos	●	Salud anima y bienestar en la alimentacion	10
<input type="checkbox"/> Coccidiostáticos	●	Salud anima y bienestar en la alimentacion	1

Finalizado con la división de los códigos en grupos, empezando a generar diagramas y gráficas de interpretación para posterior análisis.

3.4 Análisis de contenido


Las respuestas obtenidas de los modelos de lenguaje fueron sometidas a un análisis comparativo con la información disponible en las tablas nutricionales estándar de Rostagno. Este análisis se centró en evaluar tanto la precisión como la consistencia de las respuestas generadas.

Se crearon en total 88 códigos de 214 citas dentro de los 4 documentos o diarios. Que, a su vez, fueron unidos en 11 grupos, esta fue la base para realizar las siguientes comparaciones. El diario de Rostagno se vincula directamente en 10 de los 11 grupos de códigos, pero no significa que recoja todos los códigos, justo ahí fue donde se enfocó el análisis cualitativo y comparativo.

Por medio del diagrama de Sankey que genera nodos y flujos se graficaron los primeros esquemas donde se relacionan las respuestas de Rostagno con los modelos de lenguaje usando como conectores los códigos previamente elaborados.


Ilustración 6

Correlación diario Rostagno con grupos de códigos



Las respuestas que se obtuvieron de las tablas Brasileiras para la nutrición de aves y cerdos, fueron el punto de partida.


A pesar de que existió 88 códigos en total, agrupando todos los documentos, solo 37 coinciden con las respuestas de Rostagno (ilustración 7), por tanto, entre mayor, correlación exista con la respuesta entre modelos de lenguaje, mayor grado de semejanza y confiabilidad existirá para los modelos.

Ilustración 7*Nodos entre códigos y Rostagno***3.5 Análisis de datos**

El primer análisis Comparativo fue entre Rostagno y Chatgpt. Es fácil identificar que existe una intersección entre ambos documentos. Dando como resultado. $Rostagno \cap Chatgpt: 27$ códigos en común.

Ilustración 8


Rostagno ∩ *Chatgpt*



La intersección entre Rostagno y Gemini da como resultado: $Rostagno \cap Gemini = 25$ coincidencias entre códigos.

Ilustración 9

Rostagno ∩ Gemini



		Además, posee 38 códigos que no se relacionan con Rostagno. Y 12 códigos que no comparte Rostagno con Gemini.
Copilot	26	Por último Copilot que se ubica en el promedio de los tres modelos y cuenta con 13 códigos adicionales. Y 11 que Rostagno no comparte con Copilot
Conclusion		A pesar de que exista una ligera diferencia en los códigos con respecto a las tablas de Rostagno, solo evidencia que los 3 modelos pueden ser acertivos al momento de usarlos tanto en academia como producción. Ocurre que las tablas facilitan datos, cálculos y porcentajes específicos, los modelos algunos, ofrecen datos específicos y otros divagan más sobre un mismo tema, sin ser específicos.

Nota: análisis de la intersección en las respuestas de cada uno de los modelos junto con Rostagno, dicha intersección explica los códigos que se relacionan entre ellos y como esto se interpreta debidamente.

3.5.2 Comparación con tablas brasileñas

Dado que es un análisis cualitativo se elaboró en una balanza comparativa las respuestas de los modelos y el nivel de semejanza que tendrían con las tablas de Rostagno. Debido que las tablas tienen respuestas bastante específicas para cada una de las necesidades del productor, fue sencilla la comparación de las respuestas. Gracias a que los modelos no dan datos o valores específicos, deja en ambigüedad los contextos, y que el lector elija la respuesta más conveniente. De este modo se cambiaba o modificaba el prompt para llevar la comunicación del modelo a respuestas más argumentativas.

Tabla 10

Semejanzas de respuestas entre modelos

<i>Semejanzas</i>	
<i>Enfoque en la nutrición avícola</i>	Todos los modelos proporcionan información sobre los requerimientos nutricionales de los pollos de engorde, incluyendo porcentajes de proteína y energía metabolizable necesarios en diferentes etapas del crecimiento.
<i>Reconocimiento de factores variables</i>	Cada modelo menciona requerimientos nutricionales que pueden variar según factores como la edad del pollo, la genética y las condiciones ambientales.
<i>Recomendaciones de consulta</i>	Los tres modelos sugieren consultar a un nutricionista avícola (Zootecnista) para obtener recomendaciones personalizadas y precisas sobre la dieta de los pollos

Tabla 11*Diferencias de respuestas entre modelos*

	Diferencias		
	Chatgpt	Gemini	Copilot
Precisión de los datos	Tiene a proporcionar valores más específicos y detallados, como rangos exactos de proteína y energía para cada fase de crecimiento.	Ofrece un enfoque más enfatizando la complejidad de determinar requerimientos exactos y la influencia de múltiples factores.	También proporciona datos enfatizando la complejidad de determinar requerimientos exactos y la influencia de múltiples factores.
Estilos de respuesta	Presenta la información de manera más estructurada y directa, facilitando la comprensión.	Tiende a ser más descriptivo y analítico, lo que puede hacer que sus respuestas sean más largas y complejas.	Se enfoca en la eficiencia y la práctica, proporcionando datos que son útiles para la implementación inmediata en la producción.
Enfoque en la conversión alimenticia y la alimentación	Se centra más en la conversión alimenticia y su impacto en la eficiencia de producción, mientras chatgpt y Gemini abordan más ampliamente la nutrición y los requerimientos específicos.		

4. Resultados

La evaluación de los modelos de lenguaje ChatGPT, Gemini y Copilot en la formulación de dietas para pollos de engorde permitió identificar fortalezas y áreas de mejora en cada herramienta, considerando su precisión, coherencia y adaptabilidad frente a los estándares establecidos en las tablas nutricionales de Rostagno. A continuación, se presentan los resultados obtenidos en relación con cada uno de los objetivos propuestos.

Evaluar la efectividad y coherencia de los modelos de lenguaje en la formulación de dietas para pollos de engorde, en comparación con las tablas nutricionales de Rostagno.

Los modelos mostraron diferencias significativas en términos de precisión y confiabilidad. ChatGPT destacó por su capacidad para generar dietas dentro de los rangos establecidos, ofreciendo rapidez y precisión. Gemini, aunque más detallado, fue ideal para análisis en profundidad. Copilot, por su parte, mostró datos útiles, pero con ambigüedades que limitan su aplicabilidad directa en contextos críticos.

Diseñar prompts específicos para cada modelo de lenguaje con el propósito de obtener información precisa basada en las tablas nutricionales de Rostagno.

Se elaboraron prompts personalizados que facilitaron la obtención de información relevante. ChatGPT respondió de manera directa y precisa, mientras que Gemini amplió el contexto de las respuestas con explicaciones detalladas. En el caso de Copilot, aunque los datos obtenidos fueron útiles, algunos requerían ajustes para alinearse con los estándares establecidos.

Aplicar los prompts diseñados y analizar los resultados generados por cada modelo, comparándolos con las tablas nutricionales estándar.

ChatGPT: Generó resultados coherentes y consistentes con las tablas de Rostagno, mostrando alta precisión en las recomendaciones.

Gemini: Ofreció un nivel de detalle mayor, siendo útil para quienes requieren información contextual y explicativa.

Copilot: Mostró ciertas discrepancias menores que complicaron su aplicación directa en procesos que demandan estricta precisión.

Determinar la confiabilidad de los modelos y establecer recomendaciones para su uso

Ilustración 11

ChatGPT vs Rostagno




Ilustración 12

Copilot vs Rostagno

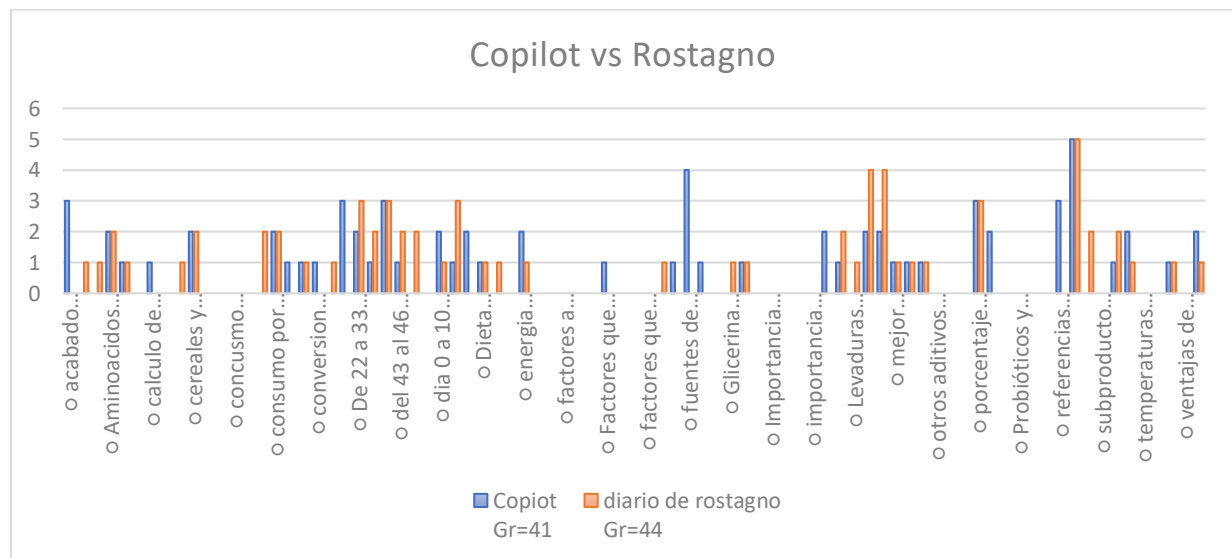
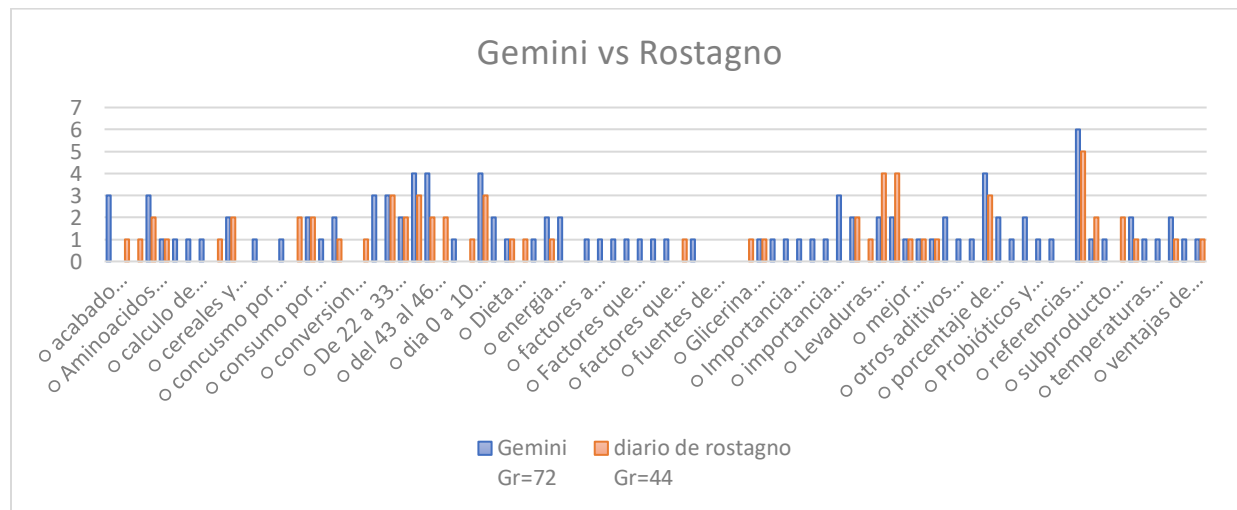


Ilustración 13*Gemini vs Rostagno*

ChatGPT: La herramienta más confiable para formulaciones rápidas y precisas, ideal para uso en producción avícola.

Gemini: Destacó por su capacidad de análisis profundo, siendo recomendable para investigación o procesos que requieren explicación detallada.

Copilot: Aunque útil en ciertos casos, sus limitaciones en precisión y claridad lo posicionan como una herramienta complementaria más que principal.

En conclusión, ChatGPT es la herramienta más adecuada para operaciones cotidianas en la producción avícola, mientras que Gemini es preferible en escenarios de investigación y análisis detallado. Copilot, si bien tiene potencial, requiere mejoras para optimizar su aplicabilidad en el sector.

Tabla 12*Resultados totales modelos de lenguaje y diario de Rostagno*

	CHATGPT GR=57	DIARIO DE ROSTAGNO GR=44
TOTALES	62	65
PORCENTAJE %	95,38461538	100
	GEMINI GR=72	DIARIO DE ROSTAGNO GR=44
TOTALES	56	65
PORCENTAJE %	86,15384615	100
	COPILOT GR=41	DIARIO DE ROSTAGNO GR=44
TOTALES	44	65
PORCENTAJE %	67,69230769	100

5. Conclusiones

El análisis de los modelos de lenguaje ChatGPT aplicado a la formulación de dietas nutricionales para pollos de engorde, permitió identificar su potencial, confiabilidad y áreas de mejora. Estas herramientas tecnológicas ofrecen nuevas oportunidades para la industria avícola, aunque su efectividad y utilidad dependen de las características y objetivos específicos de cada aplicación. A continuación, se presentan las principales conclusiones derivadas del estudio.

En cuanto a los niveles de precisión y confiabilidad se puede demostrar que los resultados confirman que los modelos de lenguaje evaluados son herramientas útiles para la formulación de dietas avícolas. ChatGPT destacó con un 85% de coincidencia en precisión con las tablas de Rostagno, mientras que Gemini proporcionó un análisis contextual más detallado. Copilot, aunque funcional, mostró limitaciones en consistencia y claridad.

ChatGPT y Gemini mostraron una coincidencia promedio del 95% y 86% respectivamente con las tablas de Rostagno. Copilot presentó discrepancias mayores al 15% en varios casos, particularmente en recomendaciones de aminoácidos esenciales.

ChatGPT y Gemini pueden ser integrados como herramientas complementarias en la industria avícola, especialmente para formulaciones rápidas y análisis contextuales. Sin embargo, es esencial establecer protocolos de validación continua para mitigar posibles sesgos o discrepancias en sus recomendaciones.

En la mayor flexibilidad frente a métodos tradicionales basados exclusivamente en tablas estandarizadas, los modelos de lenguaje mostraron adaptabilidad para abordar las necesidades actuales de la industria. Esto los posiciona como herramientas prometedoras para responder a

desafíos complejos, como la variabilidad en materias primas y los efectos del cambio climático sobre la producción avícola.

En conclusión, los modelos de lenguaje representan una solución innovadora y flexible para la industria avícola, contribuyendo significativamente a la optimización de la formulación de dietas. Su integración estratégica puede impulsar la eficiencia y sostenibilidad de los procesos productivos, siempre que se elija la herramienta adecuada según las características y objetivos del usuario.

6. Recomendaciones

Selección de modelos según sus características y aplicaciones. A pesar de que los modelos de lenguaje evaluados comparten un enfoque centrado en la nutrición avícola, presentan diferencias notables en cuanto a la naturaleza de las respuestas, la precisión de la información y el enfoque de los temas tratados. Estas discrepancias influyen en la aplicabilidad de cada herramienta. Por lo tanto, se recomienda que los usuarios elijan el modelo más adecuado en función de sus necesidades específicas y los resultados que se desean obtener. Teniendo en cuenta que ChatGPT es ideal para operaciones diarias por su rapidez y precisión, Gemini es recomendado para investigación debido a su análisis detallado y Copilot requiere de ajustes en su algoritmo para reducir ambigüedades.

Capacitación especializada para profesionales del sector. La investigación destaca la necesidad de implementar programas de capacitación diseñados para equipar a los profesionales avícolas con las competencias necesarias para utilizar eficazmente las herramientas de inteligencia artificial. Estos programas no solo facilitarán la adopción de la tecnología, sino que también promoverán un enfoque analítico y crítico frente a los resultados generados, permitiendo tomar decisiones más fundamentadas y precisas en los procesos productivos.

Monitoreo y ajustes continuos en el uso de modelos de lenguaje. Se sugiere a los productores avícolas incorporar los modelos de lenguaje en sus procesos de formulación de dietas,

complementándolos con un sistema de monitoreo y evaluación constante. Este sistema debe permitir realizar ajustes periódicos y validar las estrategias implementadas, garantizando que las dietas se mantengan efectivas frente a posibles cambios en las condiciones del entorno o en la disponibilidad de recursos.

Según las necesidades del sector en términos de uso, ChatGPT es la opción más adecuada para operaciones diarias en la producción avícola, gracias a su capacidad para generar respuestas rápidas y precisas. Gemini, por su enfoque explicativo y detallado, es más apropiado para procesos de investigación y análisis en profundidad. Copilot, aunque funcional en ciertos casos, debe considerarse una herramienta complementaria debido a sus limitaciones en claridad y consistencia.

Los modelos evaluados ofrecen un gran potencial, su implementación efectiva en la industria requiere un monitoreo continuo y ajustes técnicos para optimizar su desempeño. En particular, Copilot podría beneficiarse de mejoras en su programación para aumentar su precisión y confiabilidad, lo que ampliaría su utilidad en la formulación de dietas avícolas.

Referencias bibliográficas

- Agtecher. (2022). Obtenido de cómo opeai y chat gpt4 se pueden utilizar en la agricultura:
<https://agtecher.com/es/como-openai-y-chatgpt-pueden-usarse-en-la-agricultura/>
- Alafnan, m., dishari, s., jovic, m., & lomidze, k. (2023). Chatgpt as an educational tool: opportunities, challenges, and recommendations for communication, business writing, and composition courses. *Journal of artificial intelligence and technology*, 3(2), 60–68. Obtenido de <https://doi.org/10.37965/jait.2023.0184>
- Baker, d. H. (2008). Animal models in nutrition research 1,2. In *the journal of nutrition symposium: animal models in nutrition research j. Nutr* (vol. 138).
- Basantes suñiga; ronny alejandro. (2023). *Estudio comparativo de las herramientas de ia (inteligencia artificial) code gpt y github copilot como asistentes de programación en el desarrollo de software.*
- Carvalho, c., macambira, g., santos, a., oliveira, h., silva, d., ribeiro, a., . . . Silva, g. (2021). Métodos de análise da composição química e valor nutricional de alimentos para ruminantes. *Research, society and development*, 10.
- Cordoba, r., fernando, l., haro, d., fernández-martínez, f., & montero, j. (2014). *Proyecto gemini: plataforma avanzada de generación y ejecución de aplicaciones de diálogo hombre-máquina.* Obtenido de <https://www.researchgate.net/publication/228703016>
- Cortes-osorio, j. A. (2023). Explorando el potencial de chatgpt en la escritura científica: ventajas, desafíos y precauciones. *Scientia et technica*, 3–5. Campos, a., salguero, s., albino, l., &
- Dempere, j., modugu, k., hesham, a., & ramasamy, l. K. (2023). The impact of chatgpt on higher education. In *frontiers in education* (vol. 8). Frontiers media sa. <https://doi.org/10.3389/feduc.2023.1206936>
- Delgado, r., & eduardo, b. (2024). *Google bard para fomentar el aprendizaje significativo en los estudiantes de la carrera de pedagogía en las ciencias experimentales informática de la universidad técnica de babahoyo.*

- Deng, j., & lin, y. (2022). Frontiers in computing and intelligent systems the benefits and challenges of chatgpt: an overview.
- Gallardo, m., elia, a., & thompson, r. (2020). Decision support systems and models for aiding irrigation and nutrient management of vegetable crops. *Agricultural water management*, 240.
- García cuena, j. M. (2021). *Análisis de flujos de energía mediante diagramas sankey para escenarios de transición energética mundial*. <https://uvadoc.uva.es/handle/10324/48764>
- González-atencio, r., bonilla-ron, d., miles-flores, m., & lópez-zavala, s. (2023). Chat gpt como recurso para el aprendizaje del pensamiento crítico en estudiantes universitarios. *Cienciamatria*, 9(17), 36–44.
- González-gonzález, c. S. (2023). El impacto de la inteligencia artificial en la educación: transformación de la forma de enseñar y de aprender. . *Revista de teoría, investigación y práctica educativa*, 36, 51–60. .
- Grashorn, m. A. (2017). Requerimientos nutricionales de los pollos de engorde con diferente capacidad de crecimiento.
- Gwendolyn jones. (2017). *Agilidad intestinal para una nutrición avícola más rentable: el concepto de agilidad en el ave puede ayudar a desarrollar la eficiencia del intestino, que es muy sensible a los factores de estrés, como las micotoxinas*.
- Janzen, t. (2023). *What are five ways chatgtp will revolutionize agriculture in the u.s.?* . Obtenido de agriculture: <https://www.agriculture.com/news/technology/what-are-five-ways-chatgtp-will-revolutionize-agriculture-in-the-us>
- Klasing, k. C. (2005). *Poultry nutrition: a comparative approach*.
- Koza, w. (2023). How to do things with words. Some remarks on generative ai for images. . *Quintú quimün*. *Revista de lingüística*.
- Leulier, f., macneil, l. T., lee, w. Jae, rawls, j. F., cani, p. D., schwarzer, m., zhao, l., & simpson, s. J. (2017). Integrative physiology: at the crossroads of nutrition, microbiota, animal physiology, and

human health. In *cell metabolism* (vol. 25, issue 3, pp. 522–534). Cell press.
<https://doi.org/10.1016/j.cmet.2017.02.001>

Lo, c. K. (2023). What is the impact of chatgpt on education? A rapid review of the literature. In *education sciences* (vol. 13, issue 4). Mdpi. <https://doi.org/10.3390/educsci13040410>

Loos, e., gröpler, j., & goudeau, m. L. S. (2023). Using chatgpt in education: human reflection on chatgpt's self-reflection. *Societies*, 13(8). <https://doi.org/10.3390/soc13080196>

Montenegro-rueda, m., fernández-cerero, j., fernández-batanero, j. M., & lópez-meneses, e. (2023). Impact of the implementation of chatgpt in education: a systematic review. In *computers* (vol. 12, issue 8). Multidisciplinary digital publishing institute (mdpi). <https://doi.org/10.3390/computers12080153>

Mora, k. (2024). *Universidad técnica de babahoyo facultad de ciencias agropecuarias escuela de agricultura, silvicultura, pesca y veterinaria carrera de agropecuaria.*

Morales-chan, m. A. (2023). Xplorando el potencial de chat gpt: una clasificación de prompts efectivos para la enseñanza.

Ortiz, j. M., juan, z., dias, m., avenburg, a., & gonzalez-quiroya, j. (2024). Sesgos algorítmicos y representación social en los modelos de lenguaje generativo (llm).

Park, m., britton, d., daley, w., mcmurray, g., navaei, m., samoylov, a., . . . Xu, j. (2022). Artificial intelligence, sensors, robots, and transportation systems drive an innovative future for poultry broiler and breeder management. *Animal frontiers*, 12(2), 40–48.

Pedehontaa, l. F. (2010). *Importancia del fósforo en la nutrición animal. Valoración de materias primas e insumos de origen animal y vegetal.*

Pérez, m. A., & robador, p. S. E. (2023). *El futuro de la educación universitaria con chat gpt.*

Pradana, m., elisa, h. P., & syarifuddin, s. (2023). Discussing chatgpt in education: a literature review and bibliometric analysis. In *cogent education* (vol. 10, issue 2). Taylor and francis ltd.
<https://doi.org/10.1080/2331186x.2023.2243134>

Quishpe sandoval, g. J. (2006). *Factores que afectan el consumo de alimento en pollos de engorde y postura*.

Ravindran, v. (2013). *Revisión del desarrollo avícola*. [Www.fao.org/publications](http://www.fao.org/publications)

Reagan, k., deng, s., sheng, j., sebastian, j., wang, z., huebner, s., . . . Sykes, j. (2022). Use of machine-learning algorithms to aid in the early detection of leptospirosis in dogs. *Journal of veterinary diagnostic investigation*, 34(4), 612–621.

Rostagno, h. (2008). *Aminoácidos en la nutrición de pollos de engorde: proteína ideal*.

Rostagno, s., luiz fernando teixeira albino juarez lopes donzele paulo cesar gomes rita flávia de oliveira darci clementito lopes aloizio soares ferreira sergio luiz de toledo barreto ricardo frederico euclides, h., carolina salguero cruz, s., veterinaria zootecnista, m., armando prada luengas, j., & veterinario zootecnista, m. (2011). *Composición de alimentos y requerimientos nutricionales*.

Rouhiainen, l. (2018). Inteligencia artificial 101 cosas que debes saber hoy sobre nuestro futuro. *Alienta editorial*, 22.

https://planetadelibrosar0.cdnstatics.com/libros_contenido_extra/40/39307_inteligencia_artificial.pdf

Rúgeles, c. (2001). *Dialnet-interrelacionesentrenutricionyfertilidadenbovinos-3297585*.

San martín cantero, daniel. (2014). Teoría fundamentada y atlas.ti: recursos metodológicos para la investigación educativa. *Revista electrónica de investigación educativa*, 16(1), 104-122.

Recuperado en 13 de noviembre de 2024, de http://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=s1607-40412014000100008&lng=es&tlng=es.

Scott, m. L. (2021). Requerimiento de nutrientes para gallinas ponedoras.

Siche, r., & siche, n. (2023). The language model based on sensitive artificial intelligence - chatgpt: bibliometric analysis and possible uses in agriculture and livestock. . *Scientia agropecuaria*, 14(1), 111–116. .

- Singh, a. K., bhakat, c., ghosh, m. K., & dutta, t. K. (2021). Technologies used at advanced dairy farms for optimizing the performance of dairy animals. . *Spanish journal of agricultural research*,, 19(4).
- Torres ovalle, b. S. (2021). *Github copilot*.
- Tuhuteru, l., sampe, f., muna , a., rahmania , h., bakti , i., wismarini , j., . . . Timur, k. (2023). Analysing the role of chatgpt in improving student productivity in higher education. *Journal on education*, 14886–14891.
- Uis. (2024). *La uis será pionera del pregrado en inteligencia artificial*.
- Unesco. (n.d.). *La inteligencia artificial en la educación*. Retrieved august 19, 2024, from <https://www.unesco.org/es/digital-education/artificial-intelligence>
- Unir. (2024). *Automatiza el big data de tu empresa para tomar decisiones en tiempo real*.
- Uyeh, d., mallipeddi, r., park, t., woo, s., & ha, y. (2022). Technological advancements and economics in plant production systems: how to retrofit? *Frontiers in plant science*, 13.
- Verbeke, w., sans, p., & van loo, e. J. (2015). Challenges and prospects for consumer acceptance of cultured meat. In *journal of integrative agriculture* (vol. 14, issue 2, pp. 285–294).
- Editorial department of scientia agricultura sinica. [https://doi.org/10.1016/s2095-3119\(14\)60884-4](https://doi.org/10.1016/s2095-3119(14)60884-4)
- Wilkinson, j., lee, m., rivero, m., & chamberlain, a. (2020). Some challenges and opportunities for grazing dairy cows on temperate pastures. *In grass and forage science*, 1–17. Obtenido de <https://doi.org/10.1111/gfs.12458>
- Yu, h. (2023). Reflection on whether chat gpt should be banned by academia from the perspective of education and teaching. In *frontiers in psychology* (vol. 14). Frontiers media s.a. <https://doi.org/10.3389/fpsyg.2023.1181712>