

UNIVERSIDAD NACIONAL DE SAN ANTONIO ABAD DEL CUSCO

FACULTAD DE AGRONOMIA Y ZOOTECNIA

ESCUELA PROFESIONAL DE ZOOTECNIA



TESIS

**ANÁLISIS DEL COMPORTAMIENTO PRODUCTIVO Y DE LA
CURVA DE LACTACIÓN EN EL GANADO BOVINO LECHERO
CRIADO EN LA GRANJA K'AYRA**

PRESENTADO POR:

Br. KORAIMA HEIDY CARREÑO SAIRE.

**PARA OPTAR TÍTULO PROFESIONAL
DE INGENIERO ZOOTECNISTA.**

ASESOR:

Ing. Ph.D. GONZALO WLADIMIR
GONZALES APARICIO

CUSCO - PERÚ

2025



Universidad Nacional de San Antonio Abad del Cusco

ANEXO 1 INFORME DE SIMILITUD

El que suscribe, el Asesor Ing. PhD. Gonzalo Wladimir Gonzales Aparicio, quien aplica el software de detección de similitud al trabajo de investigación/tesis titulada: "ANÁLISIS DEL COMPORTAMIENTO PRODUCTIVO Y DE LA CURVA DE LACTACIÓN EN EL GRANADO BOVINO LECHERO CRIADO EN LA GRANJA K'AYRA" presentado por: KORAIMA HEIDY CARREÑO SAIRE con DNI Nro.: 77808976 presentado por: _____ con DNI Nro.: _____ para optar el Título Profesional/ Grado Académico de INGENIERO ZOOTECNISTA

Informo que el trabajo de investigación ha sido sometido a revisión por 03 veces, mediante el software similitud, conforme al Artículo 6° del Reglamento para Uso del Sistema de Detección de Similitud en la UNSAAC y de la evaluación de originalidad se tiene un porcentaje de (NUEVE) 9 % de similitud.

Evaluación y acciones del reporte de coincidencia para trabajos de investigación conducentes a grado académico o título profesional, tesis

Porcentaje	Evaluación y Acciones	Marque con una (X)
Del 1 al 10%	No sobrepasa el porcentaje aceptado de similitud.	X
Del 11 al 30%	Devolver al usuario para las subsanaciones.	
Mayores a 31%	El responsable de la revisión del documento emite un informe al inmediato jerárquico, conforme al reglamento, quien a su vez eleva el informe al Vicerrectorado de Investigación para que tome las acciones correspondientes; sin perjuicio de las sanciones administrativas que correspondan de acuerdo a ley.	

Por tanto, en mi condición de Asesor, firmo el presente informe en señal de conformidad y adjunto la primera página del reporte del Sistema de Detección de Similitud.

Cusco, 19 de AGOSTO de 2025


Firma

Post firma: Ing. PhD. Gonzalo Wladimir Gonzales Aparicio

Nro. de DNI: 41285829

ORCID del Asesor: 0000-0002-4682-6591

Se adjunta:

1. Reporte Generado por el Sistema de Detección de Similitud. TURNITIN. oid:27259:484580038
2. Enlace del Reporte Generado por el Sistema Detección de Similitud:
<https://unsaac.turnitin.com/viewer/submissions/oid:27259:484580038?locale=es-MX>

KORAIMA CARREÑO

ANÁLISIS DEL COMPORTAMIENTO PRODUCTIVO Y DE LA CURVA DE LACTACIÓN EN EL GANADO BOVINO LECHERO CR...

 Universidad Nacional San Antonio Abad del Cusco

Detalles del documento

Identificador de la entrega

trn:oid:::27259:484580038

Fecha de entrega

19 ago 2025, 9:15 a.m. GMT-5

Fecha de descarga

19 ago 2025, 9:33 a.m. GMT-5

Nombre de archivo

KORAIMA TESIS FAZ EP ZOOTECNIA.pdf

Tamaño de archivo

1.9 MB

122 Páginas

36.201 Palabras

190.881 Caracteres

9% Similitud general

El total combinado de todas las coincidencias, incluidas las fuentes superpuestas, para ca...

Filtrado desde el informe

- Bibliografía
- Texto citado
- Texto mencionado
- Coincidencias menores (menos de 11 palabras)

Exclusiones

- N.º de coincidencias excluidas

Fuentes principales

- 8%  Fuentes de Internet
- 5%  Publicaciones
- 7%  Trabajos entregados (trabajos del estudiante)

Marcas de integridad

N.º de alertas de integridad para revisión

-  **Caracteres reemplazados**
161 caracteres sospechosos en N.º de páginas
Las letras son intercambiadas por caracteres similares de otro alfabeto.
-  **Texto oculto**
17 caracteres sospechosos en N.º de páginas
El texto es alterado para mezclarse con el fondo blanco del documento.

Los algoritmos de nuestro sistema analizan un documento en profundidad para buscar inconsistencias que permitirían distinguirlo de una entrega normal. Si advertimos algo extraño, lo marcamos como una alerta para que pueda revisarlo.

Una marca de alerta no es necesariamente un indicador de problemas. Sin embargo, recomendamos que preste atención y la revise.

DEDICATORIA

Este trabajo es dedicado especialmente a mis queridos padres, Natalia Saire Quispe y Aquilino Carreño Carbajal, por confiar en mí, por su apoyo incondicional y sus buenos consejos, son mi mayor motivación e inspiración para salir adelante, es por ellos el motivo de mi esfuerzo.

A mis tíos, Jorge Saire, Henry Saire, y mi primo Kevin Saire, que siempre estuvieron a mi lado, dándome fuerzas y palabras de aliento para continuar.

A la memoria de mi padrastro, Sr. Ulises Andrade Yabarrena. Aunque ya no esté físicamente, sé que estaría orgulloso de mis logros. Gracias por tu apoyo, que ha sido fuente de inspiración constante.

A mi mascota Queen, que pinto mi mundo de tricolor

A mis amigos y familiares que me acompañaron en todo este transcurso de mi vida

AGRADECIMIENTOS

Expreso mi profundo y sincero agradecimiento:

A Dios por la vida de mis padres y por bendecirme cada día, permitiendo disfrutar de mis logros.

A la Universidad Nacional de San Antonio Abad del Cusco, así como a los distinguidos docentes de la Escuela Profesional de Zootecnia por su excelencia y dedicación las cuales han sido fundamentales en mi formación como profesional.

A mi asesor el Ing. PhD. Gonzalo Wladimir Gonzales Aparicio, por su apoyo, paciencia y tiempo dedicado. Gracias por compartir sus conocimientos y experiencias.

A los trabajadores de la granja Kayra, que me han apoyado brindándome un espacio e hicieron fácil el proceso de colección de datos.

ÍNDICE

DEDICATORIA	i
AGRADECIMIENTOS.....	ii
GLOSARIO DE TÉRMINOS	x
RESUMEN	xi
ABSTRACT.....	xii
I. INTRODUCCIÓN.....	1
II. PROBLEMA OBJETO DE ESTUDIO	2
2.1 DEFINICIÓN DEL PROBLEMA DE INVESTIGACIÓN	2
2.2 PREGUNTAS DE INVESTIGACIÓN.....	3
2.2.1 PREGUNTA GENERAL	3
2.2.2 PREGUNTAS ESPECÍFICAS.....	3
III. OBJETIVOS Y JUSTIFICACIÓN	4
3.1 OBJETIVOS.....	4
3.1.1 OBJETIVO GENERAL	4
3.1.2 OBJETIVOS ESPECÍFICOS.....	4
3.2 JUSTIFICACIÓN	4
IV. HIPOTESIS	6
4.1 HIPÓTESIS DE INVESTIGACIÓN	6
4.1.1 HIPÓTESIS GENERAL	6
4.1.2 HIPÓTESIS ESPECÍFICAS	6
V. MARCO TEÓRICO.....	7
5.1 ANTECEDENTES DE LA INVESTIGACION	7
5.1.1 ANTECEDENTES INTERNACIONALES	7
5.1.2 ANTECEDENTES NACIONALES	8
5.1.3 ANTECEDENTES LOCALES.....	9

5.2	COMPORTAMIENTO PRODUCTIVO DEL GANADO BOVINO LECHERO.....	10
5.2.1	VARIABLES QUE INFLUYEN EN LA PRODUCCIÓN DE LECHE	10
5.2.2	PARÁMETROS PRODUCTIVOS	12
5.2.3	MÉTODOS PARA MEDIR EL RENDIMIENTO PRODUCTIVO DEL GANADO LECHERO	14
5.3	CURVA DE LACTACIÓN.....	14
5.3.1	CURVA DE LACTACIÓN EN EL GANADO BOVINO.....	15
5.3.2	FACTORES QUE AFECTAN LA FORMA Y DURACION DE LA CURVA DE LACTACIÓN.....	15
5.3.3	CURVA DE LACTACIÓN PARA LA GESTIÓN EFICIENTE DE LA PRODUCCIÓN LECHERA.....	17
5.4	MÉTODOS PARA MODELAR Y ANALIZAR LA CURVA DE LACTACIÓN	19
5.4.1	MODELOS MATEMÁTICOS	20
5.4.2	MODELOS EMPÍRICOS.....	21
5.4.3	MÉTODOS ESTADÍSTICOS.....	21
VI.	MATERIALES Y MÉTODOS.....	23
6.1	LUGAR DEL EXPERIMENTO.....	23
6.1.1	UBICACIÓN GEOGRÁFICA.....	23
6.1.2	CARACTERÍSTICAS DE LA UNIDAD DEL ESTUDIO	23
6.1.3	DURACIÓN DEL ESTUDIO.....	24
6.2	MATERIALES	24
6.2.1	FICHAS TÉCNICAS DE REGISTROS DE PRODUCCIÓN	24
6.2.2	MATERIAL DE OFICINA.....	24
6.2.3	MATERIAL DE CAMPO	25
6.2.4	EQUIPOS.....	25

6.3	TIPO DE INVESTIGACIÓN.....	25
6.4	DESCRIPCIÓN DE LA INVESTIGACIÓN.....	26
6.5	MÉTODOS PARA LA COLECTA DE INFORMACIÓN.....	26
6.6	VARIABLES DE ESTUDIO.....	26
6.6.1	VARIABLES EXPLICATIVAS	26
6.6.2	VARIABLES RESPUESTAS	27
6.7	MÉTODOS PARA EL ANÁLISIS DE DATOS COLECTADOS.....	27
6.7.1	EVALUACIÓN DE LA PRODUCCIÓN DE LECHE POR CAMPAÑA Y NÚMERO DE LACTACIÓN DEL GANADO BOVINO LECHERO CRIADO EN LA GRANJA K'AYRA	27
VII.	RESULTADOS Y DISCUSIÓN.....	29
7.1	PRODUCCIÓN DE LECHE REAL Y ESTANDARIZADA	29
7.1.1	PRODUCCIÓN DE LECHE REAL SEGÚN GRUPO RACIAL..	29
7.1.2	PRODUCCIÓN DE LECHE REAL POR NÚMERO DE LACTANCIA	31
7.1.3	PRODUCCIÓN ESTANDARIZADA A 305 DÍAS POR GRUPO RACIAL	33
7.1.4	PRODUCCIÓN ESTANDARIZADA A 305 DÍAS POR NÚMERO DE LACTANCIA.....	35
7.1.5	COMPORTAMIENTO DE LA CURVA DE LACTACIÓN PROMEDIO POR GRUPO RACIAL.....	37
7.2	EDAD AL PRIMER PARTO (EPP) E INTERVALO ENTRE PARTOS (IEP).....	38
7.2.1	INTERVALO ENTRE PARTOS POR GRUPO RACIAL	38
7.2.2	INTERVALO ENTRE PARTOS Y EDAD AL PRIMER PARTO POR NÚMERO DE LACTANCIA.....	40
7.2.3	EDAD AL PRIMER PARTO E INTERVALO ENTRE PARTOS SEGÚN RAZA Y NÚMERO DE LACTANCIA	43

7.3	AJUSTE DE LA CURVA DE LACTACIÓN SEGÚN MODELOS MATEMÁTICOS	46
7.3.1	AJUSTE DE MODELOS MATEMÁTICOS A LA PRIMERA LACTANCIA	46
7.3.2	AJUSTE DE MODELOS EN LA SEGUNDA Y LA TERCERA LACTANCIA A MÁS	49
7.3.3	COMPARACIÓN DE MODELOS MATEMÁTICOS	55
VIII.	CONCLUSIONES.....	57
IX.	RECOMENDACIONES	58
X.	BIBLIOGRAFÍA.....	59
XII.	ANEXOS	67

ÍNDICE DE TABLAS

Tabla 1. Requerimientos nutricionales de vacas lecheras en producción....	16
Tabla 2. Producción real de leche y promedio por día de lactación, considerando los diferentes grupos poblacionales evaluados	30
Tabla 3. Producción real de leche y promedio por día considerando el número de lactación en vacas primíparas y vacas multíparas en la unidad de producción de vacunos de K'ayra.....	32
Tabla 4. Producción estandarizada de leche y promedio por 305 días de lactación, considerando los diferentes grupos poblacionales evaluados en la unidad de producción de vacunos de K'ayra	34
Tabla 5. Producción estandarizada de leche y promedio por día considerando el número de lactación en vacas primíparas y vacas multíparas en la unidad de producción de vacunos de K'ayra.....	36
Tabla 6. Comparativo del intervalo entre partos (días) entre los diferentes grupos poblacionales evaluados en la unidad de producción de vacunos de K'ayra	38
Tabla 7. Comparativo del intervalo entre partos considerando el número de lactación en vacas primíparas y vacas multíparas en la unidad de producción de vacunos de K'ayra	41
Tabla 8. Edad al primer parto e intervalo entre partos en vacas Holstein e Híbridos, considerando el número de lactación en vacas primíparas y vacas multíparas en la unidad de producción de vacunos de K'ayra.....	44
Tabla 9. Comparación de modelos de curva de lactación para la primera lactación del rebaño evaluado en la unidad de producción de vacunos de K'ayra.	48
Tabla 10. Comparación de modelos de curva de lactación para la segunda lactación en la unidad de producción de vacunos de K'ayra	52
Tabla 11. Comparación de modelos de curva de lactación para la tercera lactancia a más en la unidad de producción de vacunos de K'ayra	53

ÍNDICE DE FIGURAS

Figura 1. Representación referencial de las curvas de lactación según número de lactancia en bovinos lechero (Lopez et al., 2020)	18
Figura 2. Curvas de lactación ajustadas de producción promedio diaria de leche según grupo poblacional de vacas criadas en el centro agronómico de K'ayra	37
Figura 3. Curvas de lactancia ajustadas por los modelos Wood, Wilmink, ECN y Dave, en vacas de primera lactancia del rebaño evaluado en la unidad de producción de vacunos de K'ayra.....	47
Figura 4. Curvas de lactancia ajustadas por los modelos Wood, Wilmink, ECN y Dave en vacas de segunda lactancia, en el rebaño evaluado en la unidad de producción de vacunos de K'ayra.....	50
Figura 5. Curvas de lactancia ajustadas por los modelos Wood, Wilmink, ECN y Dave en vacas de tercera lactancia a más, en el rebaño evaluado en la unidad de producción de vacunos de K'ayra	51
Figura 6. Gráficas del análisis comparativo de los entre modelos matemáticos evaluados en la unidad de producción de vacunos de K'ayra	55

ÍNDICE DE ANEXOS

Anexo 1. Modelo de comandos empleados en el procesamiento de datos en el Rstudio para el “Primero objetivo”	68
Anexo 2. Modelo de comandos empleados en el procesamiento de datos en el Rstudio para el “segundo objetivo”	91
Anexo 3. Modelo de comandos empleados en el procesamiento de datos en el Rstudio para el “Tercer objetivo”	98
Anexo 4. Registros productivos y reproductivos de campo de los hatos evaluados.....	116
Anexo 5. Formato de colección de datos de producción diaria para su incorporación al programa de Rstudio	117
Anexo 6. Panel fotográfico de las unidades evaluadas y la colección de leche	118

GLOSARIO DE TÉRMINOS

AIC	: Criterio de Información de Akaike.
BIC	: Criterio de Información Bayesiano.
CL	: Curva de Lactancia.
DS	: Desviación Estándar.
ECN	: Modelo Exponencial con Corrección Lineal Negativa.
EPP	: Edad al Primer Parto.
IBR	: Rinotraqueitis Infecciosa Bovina.
IEP	: Intervalo Entre Partos.
MIDAGRI	: Ministerio de Desarrollo Agrario y Riego.
MMNL	: Modelos Mixtos No Lineales.
MNL	: Modelos No Lineales.
NRC	: National Research Council (Consejo Nacional de Investigación).
NSC	: Número de Servicios por Concepción.
R o Rstudio	: Entorno de desarrollo para el lenguaje R.
RNA	: Redes Neuronales Artificiales.
TC	: Tasa de Concepción.
VBP	: Valor Bruto de Producción.

RESUMEN

Este estudio analizó el comportamiento productivo y la curva de lactación en ganado bovino lechero de la granja K'ayra, ubicada en el distrito de San Jerónimo, provincia de Cusco, Perú. El objetivo fue determinar la producción de leche por campaña y por número de lactación, evaluar los principales indicadores reproductivos (EPP e IEP) y modelar la curva de lactación mediante funciones matemáticas para identificar el modelo de mejor ajuste. Se recopilaron y analizaron 60 registros productivos y reproductivos de vacas Holstein, Brown Swiss e híbridas correspondientes al periodo 2017–2024. La investigación fue de tipo descriptiva, con enfoque retrospectivo-prospectivo. Se aplicaron análisis de varianza para la comparación de promedios y se ajustaron los modelos matemáticos de Wood, Wilmink, ECN y Dave a la producción estandarizada a 305 días, utilizando criterios estadísticos como R^2 , AIC, BIC y RMSE para la selección del mejor modelo. Los resultados mostraron diferencias significativas en la producción real de leche entre grupos raciales ($p < 0.05$), sin diferencias en la duración de lactancia ni en la producción estandarizada ($p > 0.05$). La edad promedio al primer parto fue de 40 meses y el intervalo entre partos de 572 días, valores superiores a los óptimos técnicos, lo que refleja limitaciones en el manejo reproductivo. El modelo ECN presentó el mejor ajuste para todas las categorías, describiendo de forma precisa el pico y la persistencia de la producción. En conclusión, la evaluación integral de la producción y la curva de lactación constituye una herramienta esencial para optimizar la eficiencia, la rentabilidad y el bienestar animal en sistemas lecheros de zonas interandinas como el Cusco.

Palabras clave: curva de lactación, comportamiento productivo, producción estandarizada, ganado bovino lechero, modelos matemáticos.

ABSTRACT

This study analyzed the productive performance and lactation curve of dairy cattle at the K'ayra farm, located in the district of San Jerónimo, province of Cusco, Peru. The objective was to determine milk production by season and by lactation number, evaluate the main reproductive indicators (AFC and CI), and model the lactation curve using mathematical functions to identify the best-fitting model. Sixty productive and reproductive records from Holstein, Brown Swiss, and crossbred cows corresponding to the period 2017–2024 were collected and analyzed. The research was descriptive in nature, with a retrospective-prospective approach. Analysis of variance was applied to compare means, and the mathematical models of Wood, Wilmink, ECN, and Dave were fitted to milk production standardized to 305 days, using statistical criteria such as R^2 , AIC, BIC, and RMSE to select the best model. The results showed significant differences in actual milk production between breed groups ($p < 0.05$), with no differences in lactation length or standardized production ($p > 0.05$). The average age at first calving was 40 months and the calving interval was 572 days, values above the technical optimum, reflecting limitations in reproductive management. The ECN model showed the best fit for all categories, accurately describing the peak and persistence of production. In conclusion, the comprehensive evaluation of production and the lactation curve is an essential tool to optimize efficiency, profitability, and animal welfare in dairy systems in inter-Andean areas such as Cusco.

Keywords: lactation curve, productive performance, standardized production, dairy cattle, mathematical model.

I. INTRODUCCIÓN

El sector ganadero, en particular la producción lechera, desempeña un rol primordial en la economía y la garantía alimentaria de varios países del mundo. En este sentido, la investigación del comportamiento productivo y la curva de lactación en el ganado bovino lechero se presenta como un área de investigación crucial para comprender y mejorar la eficiencia de la producción lechera.

El centro agronómico K'ayra, situado en el distrito de San Jerónimo – provincia de Cusco, se destaca como un referente en la cría y producción de ganado bovino lechero y es por ello que es un escenario idóneo para hacer un examen detallado del comportamiento productivo de sus animales, así como para estudiar la curva de lactación a lo largo del tiempo.

Según el Compendio Estadístico Perú 2023 del INEI, la producción de leche fresca en Cusco creció de 106 028 toneladas en 2018 a 138766 toneladas en 2022. Este incremento del 30.8% en apenas cinco años refleja un impulso significativo en el sector lechero regional (INEI, 2023). Estos estudios exigen la optimización de la eficiencia y sostenibilidad del sector ganadero.

Es esencial conocer la curva de lactación en una producción de ganado bovino lechero para una gestión eficiente de recursos y de economía, porque proporcionaría datos claves para poder optimizar la producción, salud, reproducción y el bienestar del ganado, además de que se podrán tomar decisiones relevantes de la eficiencia, rentabilidad y sostenibilidad de la explotación ganadera.

En esta investigación, tuvo como propósito examinar el desempeño productivo del ganado bovino lechero en el centro agronómico K'ayra, centrándose en la producción láctea y en la evolución de la curva de lactación a lo largo de las diferentes etapas de la lactancia. Para ello, se recopilaron datos sobre la producción de la leche generada por cada vaca.

II. PROBLEMA OBJETO DE ESTUDIO

2.1 DEFINICIÓN DEL PROBLEMA DE INVESTIGACIÓN

La ganadería lechera tiene roles fundamentales dentro de la garantía alimenticia y económica de muchas comunidades. Sin embargo, la eficiencia y sostenibilidad del rendimiento lácteo en el ganado bovino dependen de una comprensión profunda del comportamiento productivo y de la curva de lactación. En un contexto específico del ganado bovino lechero, es importante abordar este tema para optimizar la producción y enfrentar los desafíos que puedan surgir.

En diferentes países de bajo desarrollo, el estudio de la curva de lactación es muy escaso, por ello identificar el comportamiento productivo en un establo lechero es de suma importancia para poder analizar la situación, tomar decisiones y mejorar la producción.

Cada vez es mayor el número de empresas ganaderas y un número creciente de vacas por establo. En el Perú se produce 2'066,125 TM de leche fresca anualmente. Constituyendo el 5% del total del VBP (valor bruto producción agrícola), el ganado vacuno es la segunda especie más relevante del sector específico ganadero (MIDAGRI, 2017).

El centro agronómico K'ayra, ubicado en la provincia de Cusco tiene condiciones de manejo, nutrición, ambiental, además de una población bovina, que son referenciales a otras unidades productivas ganaderas existentes en los valles interandinos de la sierra de Perú. En esta unidad productiva existen factores que pueden influir significativamente en el rendimiento productivo del ganado bovino lechero.

Esta investigación busca conocer la característica de la producción lechera y curva de lactación que puede dar un indicador referencial del desempeño productivo de otros rebaños ubicados en ambientes geográficos similares a los de la granja K'ayra.

2.2 PREGUNTAS DE INVESTIGACIÓN

2.2.1 PREGUNTA GENERAL

¿Cuál es el comportamiento productivo y de la curva de lactación en el ganado bovino lechero en el centro agronómico K'ayra?

2.2.2 PREGUNTAS ESPECÍFICAS

- a. ¿Cuál es el volumen de producción de leche por campaña y número de lactación del ganado bovino lechero criado en el centro agronómico K'ayra?
- b. ¿Cuál es el periodo de intervalos entre partos del ganado bovino lechero criado en el centro agronómico K'ayra?
- c. ¿Cuál es el comportamiento de la curva de lactación del ganado bovino lechero del centro agronómico K'ayra?

III. OBJETIVOS Y JUSTIFICACIÓN

3.1 OBJETIVOS

3.1.1 OBJETIVO GENERAL

Evaluar el comportamiento productivo y la curva de lactación del ganado bovino lechero criado en el centro agronómico K'ayra.

3.1.2 OBJETIVOS ESPECÍFICOS

- a. Determinar la producción de leche por campaña y número de lactación del ganado bovino lechero criado en el centro agronómico K'ayra.
- b. Determinar el periodo de intervalos entre partos del ganado bovino lechero criado en el centro agronómico K'ayra.
- c. Modelar el comportamiento de la curva de lactación del ganado bovino lechero del centro agronómico K'ayra, mediante modelos matemáticos.

3.2 JUSTIFICACIÓN

La producción lechera representa una actividad fundamental para la seguridad alimentaria y el desarrollo económico de las comunidades altoandinas del Cusco, donde el ganado bovino constituye una fuente clave de ingresos y nutrición. Sin embargo, la eficiencia y sostenibilidad de este sector dependen de una comprensión profunda del comportamiento productivo y de la curva de lactación de los animales, así como de la identificación de los factores que inciden en la cantidad y calidad de la leche producida. Por ello, este estudio se justifica en la necesidad de generar información local y actualizada que permita optimizar la gestión de los hatos en ambientes interandinos, caracterizados por condiciones ambientales, nutricionales y de manejo particulares.

El análisis detallado del comportamiento productivo y de la curva de lactación en el ganado bovino lechero del centro agronómico K'ayra permitirá identificar los principales factores que limitan o potencian la producción, sirviendo como referencia para otras unidades productivas de la región. Los resultados proporcionarán herramientas objetivas para el diseño de estrategias de manejo

alimenticio, reproductivo y sanitario, ajustadas a las condiciones locales, y contribuirán al desarrollo de modelos de predicción que faciliten la toma de decisiones en la gestión ganadera. De este modo, el estudio beneficiará directamente a los productores al ofrecer alternativas para incrementar la productividad y rentabilidad, y aportará información valiosa para la comunidad científica y las autoridades, promoviendo la sostenibilidad y competitividad del sector lechero regional

IV. HIPOTESIS

4.1 HIPÓTESIS DE INVESTIGACIÓN

4.1.1 HIPÓTESIS GENERAL

El comportamiento productivo repercute en la curva de lactación en el ganado bovino lechero criado en el centro agronómico K'ayra.

4.1.2 HIPÓTESIS ESPECÍFICAS

- a.** La producción de leche por campaña y por número de lactación del ganado bovino lechero criado en el centro agronómico K'ayra, es similar entre estos.
- b.** El periodo de intervalos entre partos del ganado bovino lechero criado en el centro agronómico K'ayra es diferente entre grupos y excede el óptimo de un sistema productivo tecnificado.
- c.** El comportamiento de la curva de lactación del ganado bovino lechero del centro agronómico K'ayra, se puede adecuar a modelos matemáticos usados para evaluar la curva de lactación.

V. MARCO TEÓRICO

5.1 ANTECEDENTES DE LA INVESTIGACION

5.1.1 ANTECEDENTES INTERNACIONALES

Aguilar (2021) en su investigación, tuvo como objetivo principal medir el rendimiento productivo en el cruce alternado entre ganado lechero, en Costa Rica. En su investigación se evaluaron nueve razas mediante la función de Wood (1967). Se compararon las tendencias de rendimiento entre los grupos raciales utilizando análisis estadístico. Se observó que ciertos cruces presentaron rendimientos superiores y otros persistencia y rendimientos bajos además de que se obtuvo disparidades importantes en el periodo de la lactancia y la producción lechera entre los cruces. Se destacaron ciertos cruces por su buen rendimiento y persistencia moderada. Las medidas de productividad al máximo de lactancia y su continuidad fueron determinantes para la producción total y diaria de leche, finalmente se sugirió que al elegir las vacas se seleccionen aquellas con alta capacidad de producción.

Apaza *et al.* (2016) en su artículo evaluó parámetros en vacas lecheras en condiciones de establo o libertad que detallan la curva de producción. Veinte vacunos que estaban en su tercera parte de gestación y eran el resultado del cruce entre Holstein y Criollo, fueron seleccionados para el estudio, 14 alojadas en establo y 6 libres sin alojamiento. Se evaluó la producción de leche desde el nacimiento hasta el secado natural de las vacas. Su dieta estaba compuesta principalmente por pastizales naturales en forraje verde, paja y heno. Los resultados muestran que fue diferente a los que se tenía en el 2001 donde la producción se tornaba en 10 kg por día y en la experimentación las vacas de establo produjeron 10.6 kg por día y un total de 3242.68 kg por campaña, mientras que las no estabuladas tuvieron producción promedio de 8.6 kg y un total de 2621.87 kg por campaña. La propuesta del modelo Wood (1967) demostró ser efectivo en el estimado de la producción láctea en el municipio de Achacachi - La Paz, para identificar la producción de leche en vacunos de cruce y ver los valores que caracterizan el patrón en las zonas de altura.

Shangñay *et al.* (2020) tuvieron como propósito, realizar una evaluación económica de la producción láctea, entre 2014 y 2018. Durante este análisis, se registró diariamente la producción de leche; estos datos fueron analizados teniendo en cuenta los impactos ambientales en la generación de leche durante diversas lactancias. El análisis implicó calcular los días de lactancia ajustados en función a la producción por semanas, considerando el estándar de 305 días de lactancia establecido por la National research council (NRC). Además de esto, se evaluó el volumen total de leche producida en kg por lactancia. Los resultados revelaron que la producción a los 305 días por lactancia fue inferior en vacas que tuvieron su primera lactación, con una producción promedio de 2675.37 L/campaña, en contraste en su sexta lactancia, que alcanzaron una producción promedio de 5160.90 L/campaña. Esta disparidad refleja tanto la madurez fisiológica y reproductiva de los animales, además de la capacidad genética para la productividad de leche. Además, se pudo observar un aumento significativo durante el proceso de producción lechera a medida que las vacas alcanzaban su plena capacidad productiva, lo que sugiere una mayor eficiencia en la sexta lactancia. Este hallazgo resalta la relación directa entre la productividad láctea y la madurez física de las vacas.

5.1.2 ANTECEDENTES NACIONALES

Vásquez *et al.* (2021) en su trabajo usaron modelos mixtos no lineales (MMNL) y modelos no lineales (MNL) para, modelar la curva de lactancia mantenidas en una granja de cría intensiva entre 2007 y 2013. Se examinaron 22173 conjuntos de datos que registraban la producción de leche (en kg) durante controles quincenales, abarcando 1302 lactancias y 668 vacas Holstein. Se emplearon diversos enfoques matemáticos, incluyendo los de Wood, Brody, Wood y Wilmink, examinando tanto MNL mixtos como enfoques del MMNL. Tras aplicar criterios de información como el método de Akaike (AIC) y el Bayesiano (BIC), se determinó que los MMNL ofrecían una superior adecuación para describir a 305 días la curva de producción. El enfoque mixto de Wood fue el más adecuado para la primera parición, mientras que el enfoque mixto de Wilmink fue óptimo para las pariciones subsiguientes. Además, el número de lactancia se utilizó para determinar la producción máxima, los días hasta la producción máxima, el porcentaje de rendimiento durante la lactancia y la producción total a los 305 días.

Crisologo (2020) en su investigación tuvo como objetivo principal establecer los patrones de producción láctea en el ganado de raza Holstein a través del enfoque de Wood, realizada en La Libertad. Se enfocó en examinar cómo la frecuencia de la lactancia, el momento del parto afectan el rendimiento productivo. Se recopilaron y examinaron datos de generación láctea en intervalos de dos semanas entre el 2015 y 2018. Durante tres intervalos continuos: enero-abril, mayo-agosto y septiembre-diciembre. Se tomaron en cuenta un total de 5330 registros de producción de vacas entre una, dos o más de tres lactancias. Se descubrió que las vacas que parían entre septiembre y diciembre, así como entre enero y abril, mostraban una producción diaria promedio más baja a lo largo de todo el período, en comparación con aquellas que parían entre mayo y agosto. Además, se observó que las temperaturas elevadas impactaban negativo en la productividad, disminuía la persistencia de la producción láctea debido a una rápida caída en las curvas de producción y acortaba el período de máxima producción. Para mantener curvas de producción de leche se agruparon los partos durante épocas de temperaturas más bajas, contrarrestando los efectos adversos del calor experimentado por las vacas durante el verano.

5.1.3 ANTECEDENTES LOCALES

Pando (2022) en su investigación tuvo como objetivo principal analizar el impacto de la producción láctea en el crecimiento sostenible de un total de 73 rebaños en las comunidades de Varonia, Anansaya, Sutech, Nihuacalla, Huatacalla, Mayumbamba, Limacpata, Matarapampa Y Chiwakurpay, todas ubicadas en Paruro, en el año 2021. Señalo que el sistema de producción láctea tuvo un porcentaje medio del 67.0%, confirmando su hipótesis descriptiva. En cuanto a la variable de crecimiento sostenible, el promedio esta entre el 62.5%, corroborando la hipótesis descriptiva. Además, se obtuvo una relación significativa entre la producción lechera y la sostenibilidad del desarrollo en los aspectos económicos, sociales y ambientales, con un nivel de significación estadística.

En comparación con los métodos de registro estándar, se pueden utilizar métodos de registro alternativos para estandarizar la actividad de lactancia materna durante 305 días. La elección de cada método de contabilidad de la producción de leche depende del número de animales en el establo, el personal responsable del método

de contabilidad, los costos de recopilación, análisis y procesamiento de datos, la infraestructura de ordeño y la tecnología de cada establo (Veramendi, 2021).

5.2 COMPORTAMIENTO PRODUCTIVO DEL GANADO BOVINO LECHERO

El comportamiento productivo del ganado es un aspecto fundamental en la industria láctea, ya que determina la calidad y cantidad de lácteos que se genera. Este comportamiento se ve influenciado por una serie de características hereditarias, ambientales, nutricionales y de manejo.

5.2.1 VARIABLES QUE INFLUYEN EN LA PRODUCCIÓN DE LECHE

Los variables o factores importantes que inciden en la producción láctea son:

a. Alimentación de calidad

La alimentación es fundamental e incide significativamente en la producción y en la salud del ganado bovino. La primera señal de desequilibrio nutricional es la disminución en la producción láctea. El estado de carne del animal puede indicar si la alimentación proporcionada cumple con los requisitos de producción o de mantenimiento. Se ha observado que algunos ganaderos se conforman con ofrecer a los animales solo una fracción de lo que necesitan en su ración diaria, incumpliendo así con el estándar requerido. Por ello, es crucial preocuparse por la cantidad y la calidad de alimentos voluminosos proporcionados a los animales cada día, especialmente durante la época de sequía (Alba, 2015).

b. Condiciones climáticas

El impacto de la temperatura es un elemento vital que afecta tanto la ingesta de agua y alimento como el porcentaje de concepción, además de la composición láctea y producción. Las vacas lecheras logran su producción máxima en temperaturas que varían entre 4 y 21 °C; sin embargo, temperaturas superiores a 24 °C causa un bajo consumo de alimentos y consecuentemente, en la producción láctea. las vacas suelen experimentar menos estrés en climas templados en comparación con climas extremos, lo que puede mejorar su productividad. Además de la temperatura, otros factores como la altitud, la radiación, la lluvia, la humedad, y el viento también influyen en el consumo de alimentos del ganado, estos

fenómenos pueden tener efectos indirectos por sus impactos en la disponibilidad y calidad nutritiva del forraje (Sheen y Risco, 2002).

c. Frecuencia del ordeño

En el ganado lechero, es fundamental que la ubre sea evaluada regularmente para asegurar una producción óptima de leche. El acúmulo de leche en los alvéolos y depósitos de la ubre puede causar presión e impedir la secreción adecuada de leche. Por lo tanto, el ordeño frecuente de las vacas maximiza el proceso de producción láctea (Alvarado *et al.*, 2019).

d. Gestación

Generalmente, al final de la gestación, existe una disminución en la producción láctea, esto podría deberse a que los nutrientes destinados al desarrollo fetal aumentan, aunque otra explicación más convincente apunta hacia cambios en la producción hormonal. Se estima que solo se destina entre un 1% y 2% de los requerimientos diarios de la vaca al desarrollo fetal, y la producción podría estar altera por la producción hormonal ya que se libera excesivo estrógeno y progesterona en la sangre del animal, afectando negativamente la producción láctea (Sheen y Risco, 2002).

e. Manejo

El manejo integral del ganado lechero, que abarca la alimentación, sanidad, bienestar animal, reproducción y rutina de ordeño, es esencial para optimizar la producción y calidad de la leche. Una gestión adecuada de estos factores permite que las vacas expresen su potencial productivo, mientras que deficiencias en la nutrición, el ambiente o la sanidad pueden traducirse en una menor producción y mayores problemas de salud y reproducción (Bednarski y Kupczynski, 2024)

f. Infraestructura

La infraestructura y el nivel de tecnificación de las unidades de producción lechera influyen directamente en la calidad composicional, higiénica y sanitaria de la leche. Un mayor grado de modernización en el diseño de establos y equipos de ordeño

está asociado con mejoras sustanciales en la higiene del producto y la salud del hato (Sandoval Monzón *et al.*, 2023)

5.2.2 PARÁMETROS PRODUCTIVOS

Los parámetros productivos son relevantes reflejando la eficiencia y rendimiento del rebaño. Algunos de los parámetros más importantes son:

a. Producción promedio de leche por vaca

Este parámetro evalúa la cantidad de leche generada por cada vaca durante un intervalo específico. Es fundamental para evaluar la eficiencia productiva individual y del rebaño en su conjunto (Ossa, 1997).

b. Tasa de crecimiento del rebaño

Este indicador nos muestra cómo cambia el tamaño del rebaño a lo largo del tiempo y las etapas que se distinguen por su propia velocidad o ritmo de crecimiento (Posada *et al.*, 2011).

c. Eficiencia reproductiva

Una forma para evaluar la eficiencia reproductiva de los rebaños lecheros se hace mediante el uso de parámetros reproductivos, uno de ellos es el intervalo entre partos (IEP) que es el tiempo promedio entre dos partos sucesivos. Otro parámetro reproductivo es tasa de concepción (TC) el cual es el porcentaje de vacas que logran quedar preñadas tras un intento de inseminación artificial y otro indicador sería el número de servicios por concepción (NSC) (Sandoval, 2019).

Un IEP adecuado en rebaños lecheros está en torno a 12-13 meses (Aidar *et al.*, 1986), además una TC adecuada está en torno a 65-70% para vacas en primer servicio y de 50-60% en vacas de segundo parto a más (Vera, 2017).

d. Producción de sólidos de leche

Entre los factores ambientales que afectan al porcentaje de sólidos totales, abarcan la edad de la vaca, la temperatura del entorno, la salud de la vaca y la gestión de la alimentación. Entre todos estos factores, la gestión de la alimentación es la que

más impacta en los constituyentes de la leche, especialmente en la grasa (Campabadal, 2013).

e. Eficiencia alimentaria

La conexión entre la alimentación y la producción láctea es esencial. La eficacia en el consumo de alimentos es fundamental a la hora de menguar los costes de producción y la eficiencia nutricional es descrita como la cantidad de leche producida por cada unidad de materia seca ingerida (Viña, 2018).

f. Mortalidad y morbilidad

Altas tasas de morbilidad y mortalidad pueden afectar negativamente la producción y la rentabilidad. La mortalidad entre las vacas lecheras constituye un problema tanto en términos de pérdidas financieras ya que existe disminución de la producción y trabajo adicional, como del sufrimiento animal o eutanasia, un aumento de mortalidad de vacas puede indicar una salud y bienestar subóptimos (Thomsen *et al.*, 2004).

g. Calidad de la leche

La calidad láctea, se describe como un producto no adulterado ni alterado sino integro, y libre de calostro, obtenido a través de un ordeño completo y continuo de hembras domésticas en buen estado de salud y adecuadamente alimentadas. Una baja calidad puede afectar la comercialización y el valor del producto. Existen métodos de evaluación para la calidad de la leche y se pueden dividir en tres categorías: análisis sensorial, análisis fisicoquímico y análisis sanitario (Campabadal, 2013).

h. Consumo de agua

Un suministro adecuado de agua es crucial para la producción de leche y su bajo consumo puede revelar problemas de salud o estrés en los animales. La leche, compuesta en un 87% por agua, depende completamente de este compuesto. Además, el agua juega un papel vital en los procesos de desinfección del material y equipo de ordeño, limpieza y refrigeración, procesos fundamentales para garantizar la calidad láctea (Campabadal, 2013).

5.2.3 MÉTODOS PARA MEDIR EL RENDIMIENTO PRODUCTIVO DEL GANADO LECHERO

La obtención de mayor volumen de leche de alta calidad por vaca al año, con el menor costo posible, es el indicador que resume los resultados de una lechería eficiente. La productividad de una lechería está determinada principalmente por su tasa de natalidad que es el vínculo entre los nacimientos que ocurren en un rebaño en un año y el promedio de hembras adultas presentes expresado en porcentaje, el intervalo entre partos es el tiempo en días en que ocurre en promedio un parto en cada hembra adulta en la lechería y se establece como el inverso de la natalidad, la producción anual por vaca es la leche producida por una vaca en su periodo de lactancia con estos datos se podría hacer el reemplazo de vacas a eliminar y la proporción de vacas lecheras que es el porcentaje de vacas que están en producción con respecto al total de las vacas, en este proceso el porcentaje debe ser lo más alto posible para la eficiencia del sistema (Castro Ramírez, 2002).

5.3 CURVA DE LACTACIÓN

Es el patrón de producción de leche de la vaca desde el momento del parto hasta el final de la lactancia donde se muestra cómo la producción puede variar, alcanzando un pico máximo en algún punto y luego disminuyendo gradualmente. La forma esta influenciada por varios factores y su representación gráfica es esencial para los productores de leche, ya que les permite comprender y gestionar eficazmente la producción láctea en sus rebaños además de que proporciona información y de acuerdo a ello se optimiza la alimentación, el manejo y otros aspectos del cuidado del ganado lechero, su objetivo radica en maximizar la producción de láctea, preservando el bienestar y seguridad de las vacas (Silvestre *et al.*, 2006).

En cuanto a la manipulación de la lactación, se ha observado que la exposición de vacas a períodos de luz crecientes, denominados fotoperíodos, puede incrementar la producción láctea. Por ejemplo, las vacas expuestas a un régimen de 16 horas de luz producen de 6 a 10% más de leche que aquellas sometidas a fotoperíodos inversos. Aunque los mecanismos precisos por los cuales la luz afecta la lactación aún no se comprenden completamente, es probable que impliquen la regulación hormonal (Bradley, 2020).

5.3.1 CURVA DE LACTACIÓN EN EL GANADO BOVINO

Para describir cómo se desarrolla la producción láctea, se estudia la curva de lactancia (CL) en tres etapas: 1) fase inicial o fase ascendente; 2) pico de producción o punto máximo; 3) fase descendente; y al finalizar vendría el periodo seco donde cesa la producción y se permite la regeneración del tejido mamario (Landete, 2000).

Periodo de persistencia: Característica de la curva de lactación que indica la capacidad de la vaca para mantener la producción después del pico. No es una fase, sino una medida del ritmo de descenso de la producción a lo largo del tiempo. (Díaz García, 2019)

Periodo de transición: que comprende desde cuatro semanas antes hasta cuatro semanas después del parto, es crítica para el desempeño lechero. Durante este periodo se producen cambios hormonales y metabólicos importantes; un manejo nutricional adecuado minimiza enfermedades como cetosis e hipocalcemia, y es clave para asegurar una lactancia saludable y eficiente (García Casillas *et al.*, 2012)

5.3.2 FACTORES QUE AFECTAN LA FORMA Y DURACION DE LA CURVA DE LACTACIÓN

Están determinados por una variedad de factores:

a. Genética

Diferentes razas de animales lecheros tienen características genéticas específicas las que influyen en la producción láctea y algunas tienen mayor capacidad de producción, además, la genética determina la capacidad inherente de una vaca para producir leche. La selección genética puede mejorar la producción a lo largo de las generaciones, por ello, es importante tener en cuenta que no se transfieren completamente su genética, sino una selección al azar que representa la mitad de sus características genéticas (Reyes *et al.*, 2020).

b. Alimentación

La nutrición adecuada es esencial para una buena producción de leche. Una dieta equilibrada y rica en nutrientes, incluidos proteínas, grasas y minerales, puede

influir en la calidad láctea y cantidad producida, también es necesario ajustar la dieta a lo largo del ciclo de lactancia, considerando las necesidades específicas en diferentes etapas, puede afectar la curva de lactación (Viña, 2018).

Tabla 1. Requerimientos nutricionales de vacas lecheras en producción

Nutriente	Unidad	Vaca 600 kg, 20 kg leche/día	Vaca 500 kg, 15 kg leche/día
Energía neta de lactancia	Mcal/día	33.0	28.0
Materia seca	kg/día	19.5	16.5
Proteína bruta	% MS	16.0	15.5
FDN (fibra detergente neutro)	% MS	28-32	30-33
FDA (fibra detergente ácido)	% MS	18-20	19-21
Calcio	g/día	120	90
Fósforo	g/día	80	60
Magnesio	g/día	30	22
Sodio	g/día	40	30
Potasio	g/día	150	120
Azufre	g/día	24	18

Fuente: Adaptado de NRC, 2021 (National Academies of Sciences, 2021)

c. Manejo

Un manejo apropiado durante y posterior al parto, tendrá un efecto sumamente beneficioso en la salud y bienestar de la vaca, por ende, en su producción de leche. en la sierra, el ordeño manual es el más utilizado, por su bajo costo y adaptabilidad, aunque presenta mayores riesgos de contaminación y menos eficiencia (Napolitano *et al.*, 2020). El ordeño mecánico mejora la calidad y rapidez del proceso, pero requiere inversión, energía eléctrica y capacitación, asimismo, la frecuencia y la técnica empleadas en el ordeño pueden influir en cuanta leche se produce y el tiempo de duración de la producción (Amos *et al.*, 2016).

d. Salud animal

La presencia de enfermedades, como mastitis que reduce el volumen y la calidad de leche debido a la inflamación mamaria, y demás condiciones de salud, puede

afectar negativamente la producción láctea y verse reflejada en la curva de lactación (FAO, 2013).

e. Factores ambientales

Las condiciones climáticas influyen significativamente en la producción lechera en zonas altoandinas. Durante la temporada de lluvias, la mayor disponibilidad y calidad de forrajes favorecen mayores volúmenes de leche y una lactancia más prolongada, a diferencia de la época seca, donde el rendimiento se ve limitado (Quispe *et al.*, 2016)

En vacas Brown Swiss del altiplano cusqueño (Velille), la producción de leche es mayor durante la época de lluvias (hasta 14.5 L/vaca/día) gracias a una mejor oferta forrajera, mientras que en la época seca disminuye significativamente. La altitud y la estacionalidad climática influyen directamente en el rendimiento del hato (Condori y Gonzales, 2025)

f. Manejo reproductivo

La escasa eficacia reproductiva puede llevar a la inseminación de las vacas poco después del parto, lo que resulta en bajos índices de concepción y en una disminución en la cantidad de leche producida, especialmente en aquellas vacas de alta producción, identificadas como aquellas que quedan preñadas en los primeros intentos (Hernández, 2016).

5.3.3 CURVA DE LACTACIÓN PARA LA GESTIÓN EFICIENTE DE LA PRODUCCIÓN LECHERA

El análisis de la curva de lactancia permite entender la actividad fisiológica de la vaca durante su etapa de producción láctea además de que proporciona un resumen preciso de los niveles de la leche producida, los cuales son influenciados por la eficacia biológica y genética del bovino, así como por las condiciones de manejo específicas durante un periodo dado (Shagñay *et al.*, 2020).




Figura 1. Representación referencial de las curvas de lactación según número de lactancia en bovinos lechero (Lopez et al., 2020)

a. Alimentación y su efecto sobre la curva de lactación

La curva de lactación proporciona información sobre la cantidad láctea producida por la vaca y ayuda a entender a los productores a optimizar la producción, estableciendo metas realistas. El factor más crucial está relacionado con la necesidad de alimentar a las vacas conforme a sus requerimientos nutricionales. Estos requisitos cambian según el nivel de producción, el peso del animal y el periodo de lactancia en la que estén los animales, si se entienden estos conceptos, se puede diseñar una ración optima, equilibrando adecuadamente la proporción de concentrado y forraje (Pando, 2022).

b. Manejo reproductivo y monitoreo de salud

El manejo reproductivo está estrechamente relacionado con la curva de lactación, lo que permite programar adecuadamente la inseminación artificial y la mejorar la eficiencia productiva, para ello es necesario sincronizar los nacimientos con los picos de producción y aplicar estrategias genéticas enfocadas a mejorar la producción sin comprometer la salud animal (Cuatrín, 2009).

Un intervalo de entre partos y el aumento entre días abiertos reduce la eficiencia reproductiva y la producción de leche por ciclo (Moncada, 2021). En la sierra peruana, este problema supera los 450 días debido a deficiencia nutricionales y

problemas de salud, además, se acorta la vida productiva de la vaca y aumenta los descartes por baja fertilidad (Rodríguez *et al.*, 2019)

c. Mejora de la calidad genética del rebaño

Anteriormente, las vacas se clasifican principalmente por su producción de leche y rentabilidad, pero hoy en día también se prioriza las características reproductivas y de salud para reducir costos y mejorar el bienestar animal (Reyes López *et al.*, 2009).

La Holstein se destaca por su alta producción de leche en ambientes controlados como la costa peruana, pero es sensible al estrés ambiental. Sin embargo, el Brown Swiss, produce menos leche, con mejor calidad, y es adaptable a exigentes condiciones de la sierra, mostrando mayor rusticidad y estabilidad productiva (Quispe *et al.*, 2016).

5.4 MÉTODOS PARA MODELAR Y ANALIZAR LA CURVA DE LACTACIÓN

Según Buxade (1996), al examinar las curvas reales de lactación se ven variaciones significativas en la duración y el contenido de leche entre las vacas por su gran potencial de productividad en comparación a otras.

Es necesario modelar la curva de lactación y estandarizar la generación láctea para poder comparar varios animales criados en distintos entornos. Las etapas que establecen la forma de la curva, se ven influenciadas por variables tanto ambientales como hereditarias. Se pueden utilizar funciones matemáticas que calculan los niveles de producción a lo largo del tiempo para analizar la trayectoria de la lactancia (Trejo *et al.*, 2024).

Recientemente, ha habido un notable avance en la capacidad computacional en granjas lecheras, lo que ha facilitado el registro automático de la producción diaria. Esto ha permitido la generación de datos sobre las curvas de lactancia y la comparación de los parámetros de estas curvas para decidir cómo gestionarlas (Ramírez Cano, 2017).

5.4.1 MODELOS MATEMÁTICOS

Con el pasar de los años, se han creado nuevos modelos matemáticos, además de Wood y Wilmink, ya que estos solo se adaptan a ciertos casos y limitadas condiciones, y por ello se aumentaron nuevas investigaciones donde se aumentan más modelos que tienen mayor precisión, una mejor representación del pico de producción, más adaptación a sistemas modernos y amplían su base de datos, y al tener todo esto también se mejora en la interpretación de la persistencia de lactancia

a. Modelo de Wood

Modelo utilizado en una función matemática para describir la curva de lactación. Puede ajustarse a los datos observados y proporcionar parámetros que caracterizan la producción de leche a lo largo del tiempo (Wood, 1967).

Un estudio realizado por Ossa *et al.* (1997) en vacas mestizas de un sistema de doble propósito en el Caribe colombiano demostró que el modelo de Wood puede describir adecuadamente la curva de lactancia en condiciones tropicales. El modelo alcanzó un alto coeficiente de determinación ($R^2 = 0.88$), estimando una producción máxima de 6.25 L diarios alrededor del día 48 posparto.

b. Wilmink

Este modelo permite analizar la persistencia y variaciones en la producción lechera mediante parámetros específicos que reflejan estas fases de la curva de lactación (Wilmink, 1987).

En un estudio realizado por Trejo *et al.*, (2024) donde se aplicó el modelo de Wilmink para describir curvas de lactancia en vacas Holstein bajo condiciones intensivas, mostrando el mejor ajuste estadístico frente a otros modelos clásicos. Los autores concluyeron que Wilmink es una herramienta eficaz para predecir producción de leche, grasa y proteína, facilitando la toma de decisiones en manejo lechero.

c. Modelo exponencial con corrección lineal negativa

El modelo exponencial con corrección lineal negativa (ECN) describe curvas de lactancia capturando el crecimiento exponencial, y mejora el ajuste en la caída progresiva, este modelo refleja con mayor precisión el comportamiento de una curva de lactación (Rodríguez *et al.*, 2005)

Mamani (2023) evaluó modelos de curvas de lactancia en vacas Brown Swiss y encontró que el modelo parabólico exponencial es eficaz para describir patrones complejos sin pico definido, ofreciendo una estimación precisa de la producción total. Este modelo es útil para mejorar el manejo y selección genética en sistemas lecheros

d. Modelo de Dave

El modelo de Dave es una función cuadrática usada para describir curvas de lactancia, capturando el ascenso al pico y el descenso posterior (Adediran *et al.*, 2012)

5.4.2 MODELOS EMPÍRICOS

a. Modelo de tasa de decrecimiento exponencial

Este enfoque asume que la producción de leche disminuye exponencialmente con el tiempo (Macciotta *et al.*, 2005).

e. Modelo de splines cúbicos

Utiliza curvas suaves para conectar puntos de datos y proporciona una representación más flexible de la curva de lactación (Fox, 2002).

5.4.3 MÉTODOS ESTADÍSTICOS

a. Análisis de varianza (ANOVA)

Puede utilizarse para comparar la leche producida en diferentes períodos de amamantamiento y evalúa la significancia de las diferencias, comprende técnicas de estadística útiles cuando existen dos o más grupos que precisan ser examinados, medidos y que varían en característica (Dagnino, 2014).

f. Regresión lineal y no lineal

Estos métodos estadísticos permiten ajustar modelos a los datos observados y analizar la relación entre las variables, describen el comportamiento de un sistema (Rivas, 1993).

g. Redes neuronales artificiales (RNA)

Pueden utilizarse para modelar la curva de lactación, ya que estas redes son capaces de capturar patrones complejos y no lineales en los datos (Castañeda *et al.*, 2024).

h. Métodos bayesianos

Permiten modelar los datos de acuerdo a parámetros y proporcionar intervalos de credibilidad para las estimaciones de la curva de lactación. Es común combinar varios enfoques para obtener precisión de la curva de lactación en animales, presentando resultados de forma natural e intuitiva. (Abraira, 2005)

VI. MATERIALES Y MÉTODOS

6.1 LUGAR DEL EXPERIMENTO

La investigación se efectuó en la unidad de producción de ganado vacuno de la Escuela profesional de Zootecnia, ubicado en el centro agronómico K'ayra en el distrito de San Jerónimo, provincia y región Cusco.

6.1.1 UBICACIÓN GEOGRÁFICA

Región: Cusco

Provincia: Cusco

Distrito: San Jerónimo

Lugar: Centro Agronómico K'ayra

Los límites son:

- Norte: Vía de evitamiento
- Oeste: Río Huanacauire
- Sur: Zona Mesapata, Chacaqyoc, Rumitaqayoc y Churumoqo
- Este: Fundo Leticia y Zona Sillkina

Las coordenadas UTM son:

- Latitud: -13.558976418661953
- Longitud: -71.87632441520691

Fuente: Google Earth, (2024)

6.1.2 CARACTERÍSTICAS DE LA UNIDAD DEL ESTUDIO

La unidad de estudio presenta las características siguientes:

La población de bovinos lecheros que comprenden las razas de, Holstein, híbrido, y Brown Swiss, de 1,2,3,4,5 lactaciones y está conformado por una población de 60 vacas de las cuales 4 son Brown Swiss (6.67%), 40 son Holstein (66.67%) y 16 son híbridas (26.67%), se obtuvo un total de 120 registros individuales de producción correspondientes a 60 vacas. En la unidad de producción de vacunos evaluada, en promedio entran de 30 a 32 vacas en producción cada mes, representando la diversidad genética y productiva del ganado lechero.

En el presente estudio, el término “híbridos” se utiliza conforme a la denominación registrada en los libros de producción y reproducción de la granja K’ayra, que constituyen la fuente principal de los datos analizados. Debido a la naturaleza retrospectiva de la investigación y a las limitaciones de los registros históricos, generalmente solo se consigna la raza materna, siendo esta mayoritariamente Holstein en los primeros partos. Sin embargo, a partir del siguiente parto, la descendencia de estas vacas suele aparecer registrada simplemente como “híbrido”, sin especificar la raza del padre ni el porcentaje de hibridación. Este patrón se repite en generaciones sucesivas, de modo que los animales identificados como “híbridos” pueden ser producto de cruces entre vacas de origen Holstein y padres de raza no registrada, o bien entre otros animales previamente denominados “híbridos”, sin que se cuente con información precisa sobre su composición racial. Por lo tanto, en el contexto de este trabajo, “híbrido” hace referencia a vacas cuyo origen racial es mixto o indefinido, limitándose la información disponible a la nomenclatura consignada en los registros de la granja.

6.1.3 DURACIÓN DEL ESTUDIO

El estudio se desarrolló durante seis meses del año 2025 que comprenden las etapas de elaboración de proyecto, recopilación y sistematización de datos, análisis estadístico, elaboración de documento de tesis. Pero señalando también que la recopilación de datos fue entre los años 2017, 2018, 2019, 2020, 2021, 2022, 2023 y 2024

6.2 MATERIALES

Los materiales utilizados en la investigación fueron los siguientes:

6.2.1 FICHAS TÉCNICAS DE REGISTROS DE PRODUCCIÓN

Se incluyeron formularios, libros, hojas de cálculo de registro para anotar datos específicos de cada bovino, incluyendo detalles sobre la edad, volumen de producción lechera, número de lactación, raza, fecha de inicio de lactación y otros factores relevantes.

6.2.2 MATERIAL DE OFICINA

- Libros de producción de leche de los bovinos

- Libro de nacimientos
- Lapicero, lápiz y borrador
- Laptop
- Papelería, folders

6.2.3 MATERIAL DE CAMPO

El material de campo necesario para la investigación incluyó las siguientes herramientas y equipos para realizar observaciones, recopilar datos, estos fueron:

- Libretas de campo
- Equipos de protección personal (EPP)
- Cámara fotográfica y de video

6.2.4 EQUIPOS

Los equipos que se utilizaron en la investigación fueron los siguientes:

- Ordeñadora mecánica por vacío tipo balde al piso
- Balanzas de pesaje mecánica de resorte tipo gancho

6.3 TIPO DE INVESTIGACIÓN

La investigación es de tipo básica, con ella se busca incrementar conocimientos acerca del comportamiento productivo y la curva de lactación en el ganado bovino lechero criado, también se puede clasificar como descriptiva ya que no se modificaron variables de estudio, ni se asignaron unidades experimentales a tratamientos; se evaluó la información existente considerando los factores que intervienen sobre las variables respuestas. Considerando la colecta de información preexistente, la investigación se puede clasificar como retrospectiva en parte ya que se tomó información registrada en los libros de producción de la unidad de producción de vacunos de leche, correspondientes a los años 2017, 2018, 2019, 2020, 2021, 2022 y 2024, y en parte fue prospectiva, ya que se recopiló información para completar los datos de producción de algunos animales que formaron parte de la evaluación.

6.4 DESCRIPCIÓN DE LA INVESTIGACIÓN

Se analizó la información referida a los registros de producción del ganado bovino lechero, a fin de evaluar la campaña de lactación y el comportamiento de la curva de lactación que expresan los animales criados en la unidad de estudio.

Para el estudio se tomaron datos de producción por vacunos y por diferentes razas que existen o que existieron en el centro agronómico K'ayra, que hayan entrado o estado en producción durante el periodo de año del 2017 hasta el 2024, estos datos fueron transferidos a una hoja de cálculo, para ser ordenados según código del vacuno, raza, número de lactancia, fecha de inicio de lactancia, época y su producción, con esta información se podrá generar las curvas de lactación, considerando factores que pudieran afectar estas, como son la raza, el año de lactación la estación del año, el número de lactación y otros que pudieran incluirse. Una vez realizado este proceso se analizaron estadísticamente y mediante un software

6.5 MÉTODOS PARA LA COLECTA DE INFORMACIÓN

Para la siguiente investigación, se utilizaron fichas técnicas de registros de producción preexistentes

Para completar lactaciones de algunas vacas, se siguió efectuando el registro productivo de estas hasta concluir la lactación correspondiente.

La información referida a las fechas de parición de las vacas también se fue recuperando a partir de los registros de reproducción de la unidad de producción de vacunos estudiada, con ello se pudo obtener la información de intervalo entre partos y corroborar las fechas de inicio de las lactaciones.

6.6 VARIABLES DE ESTUDIO

6.6.1 VARIABLES EXPLICATIVAS

- Año (2017, 2018, 2019, 2020, 2021, 2022, 2023, 2024)
- Estación (lluvias, secas)
- Número de lactación (1,2,3,4,5)
- Raza (Holstein, Híbrido "grupo poblacional", Brown Swiss)

6.6.2 VARIABLES RESPUESTAS

- Intervalo entre partos
- Duración de campaña real
- Volumen de producción por campaña real
- Volumen de producción de leche por campaña estandarizada a 305 días

6.7 MÉTODOS PARA EL ANÁLISIS DE DATOS COLECTADOS

Los modelos empleados son cuatro que más se ajustan a las curvas de lactación. Esto permitirá identificar patrones, calcular la persistencia de la lactancia y comparar las curvas entre diferentes animales.

6.7.1 EVALUACIÓN DE LA PRODUCCIÓN DE LECHE POR CAMPAÑA Y NÚMERO DE LACTACIÓN DEL GANADO BOVINO LECHERO CRIADO EN LA GRANJA K'AYRA

Para este caso objetivo se usó estadística descriptiva a fin de poder determinar datos promedios valores mínimos y máximos, así como desviaciones estándar, en función de las razas Brown Swiss, Holstein e híbrido, así como del número de lactación y promedios en función de los años de evaluación.

Además, se emplearon técnicas de estadísticas de tipo inferencial a fin de poder determinar el análisis de varianza, para ello primero se determinó la normalidad de los datos usando el teste de Kolmogorov Smirnov y la homogeneidad de varianza usando el test de Bartlett y el test de Levene. Para el análisis de varianza se empleó el siguiente modelo aditivo lineal:

$$y_{ijk} = \mu + NL_i + A_j + E_k + e_{ijk}$$

Donde:

y_{ijk} = volumen de producción

μ = media

NL_i = número de lactación

A_j = año

E_k = estación

e_{ijk} = residual

Además, se efectuó la prueba de comparación múltiple de medias de Tukey, a fin de identificar las diferencias entre grupos considerados.

El análisis estadístico se hizo con el lenguaje de programación R v4.2 y el entorno de trabajo Rstudio

VII. RESULTADOS Y DISCUSIÓN

7.1 PRODUCCIÓN DE LECHE REAL Y ESTANDARIZADA

7.1.1 PRODUCCIÓN DE LECHE REAL SEGÚN GRUPO RACIAL

En cuanto a la evaluación por razas, en la Tabla 2 se presenta información sobre el comportamiento productivo de las vacas Brown Swiss, Holstein e híbrido, se analizaron diferentes parámetros como la producción real por campaña, la producción media diaria y el número de lactación

En cuanto a la producción real por campaña, el grupo poblacional híbrido, tuvo un mayor promedio en producción con 4303.98 kg por campaña, seguidos de los Holstein con 3950.25 kg por campaña y finalmente el Brown Swiss con 3268.73 kg por campaña siendo estos promedios diferentes entre razas ($p < 0.05$), se observó, además, una alta variabilidad dentro de cada grupo, en la desviación estándar en las tres razas, que puede deberse a condiciones de manejo dentro del rebaño.

En cuanto a la producción media por día, estos valores fueron mucho más similares ya que estadísticamente no se encontró diferencias significativas ($p > 0.05$) teniendo así a la raza Holstein con un promedio de producción de 11.95 kg/día, seguida de las vacas híbridas, con una producción promedio de 11.06 kg/día, y el Brown Swiss que con una producción promedio de 11.40 kg/ día.

Tabla 2. Producción real de leche y promedio por día de lactación, considerando los diferentes grupos poblacionales evaluados

Parámetro evaluado	Unidad	Grupo poblacional evaluado		
		Brown Swiss	Holstein	Hibrido
Lactaciones evaluadas	Cantidad	6	96	27
Producción real por campaña (kg)	Prom $\pm$ DS	3268.73 $\pm$ 2445.07c	4011.77 $\pm$ 1990.44b	4303.98 $\pm$ 1976.12a
	(min – max)	1566.5 – 8078.1	837.3 – 9193.9	1021.7 – 8032.5
Producción media por día (kg)	Prom $\pm$ DS	11.40 $\pm$ 2.50a	11.95 $\pm$ 2.25a	11.06 $\pm$ 1.88a
	(min – max)	9.44 – 14.84	7.18 – 18.16	6.96 – 15.65
Duración de la lactación (días)	Prom $\pm$ DS	275.17 $\pm$ 155.84a	330.49 $\pm$ 151.10a	385.19 $\pm$ 173.03a
	(min – max)	160 – 561	106 - 837	117 – 725

Leyenda: Prom = promedio, DS = Desviación estándar, letras diferentes en la misma fila indican diferencias estadísticas (p<0.05)

La duración de lactancia en los diferentes grupos muestra una dispersión considerable, teniendo a los híbridos con 385 días de producción promedio, la Holstein con 330 días de producción promedio y las Brown Swiss con 275 días de producción promedio, aunque estas diferencias no son significativas ($p>0.05$) ya que los rangos de variación son muy amplios, observándose rango que van desde los 106 a 837 en las vacas Holstein, esto es algo que indica problemas relacionados a las prácticas de manejo del rebaño, número de partos o condiciones sanitarias (Calero *et al.*, 2022).

7.1.2 PRODUCCIÓN DE LECHE REAL POR NÚMERO DE LACTANCIA

En la Tabla 3 se muestran los resultados adquiridos al considerar la producción de leche por campaña, media diaria y duración de la lactancia, según el número de lactación (de primera a quinta).

En cuanto a la evaluación por número de lactación en la Tabla 3 se muestran que la producción real por campaña, se incrementó desde la primera lactancia (3625.06 ± 2000.46 kg/campaña real) hasta la cuarta lactancia presentando esta última, un promedio de 4640.25 ± 1718.74 kg / lactancia, lo que corrobora que las vacas incrementan su rendimiento con el aumento de la edad y la cantidad de partos, debido al mayor desarrollo físico y de la glándula mamaria, el resultado concuerda con lo señalado por Pallete *et al.* (2023), las vacas llegan a su máxima producción de leche entre la tercera y cuarta lactancia, lo cual concuerda con lo contemplado en el presente estudio. Además, se registran periodos largos de producción como es el caso de la 4ta lactancia con 385 días en la duración de la lactancia, en contraste, la lactancia más corta se registró en la quinta parición, con un promedio de 293 días. Asimismo, las primeras lactancias también presentaron menores días de producción, lo que podría atribuirse a su inmadurez mamaria, manejo reproductivo, o alimentación.

Tabla 3. Producción real de leche y promedio por día considerando el número de lactación en vacas primíparas y vacas multíparas en la unidad de producción de vacunos de K'ayra.

Parámetro evaluado	Unidad	Número de lactación				
		1	2	3	4	5
Lactaciones evaluadas	Cantidad	44	43	26	14	2
Producción real por campaña (kg)	Prom ± DS	3625.06±2000.46b	4156.38±2004.02 ^a	4258.72±2095.94a	4640.25±1718.74a	3516.05±3057.32b
	(min – max)	1005.3 - 8682.00	837.3 – 9193.90	1379.5 – 8032.50	2351.0 – 6945-61	1354.2 – 5677.90
Producción media por día (kg)	Prom ± DS	11.01 ± 2.35b	12.03 ± 2.00ab	12.36 ± 2.23a	12.10 ± 1.78ab	10.93 ± 3.17b
	(min – max)	6.96 – 17.34	7.18 – 15.65	8.16 – 18.16	9.58 – 16.10	8.68 – 13.17
Duración de la lactación (días)	Prom ± DS	319.32 ±154.43 ^a	343.86 ±164.28 ^a	344.65 ±161.94a	385.28 ±139.68a	293.50 ±194.46a
	(min – max)	114 – 757	106 – 837	124 – 667	164 - 638	156 - 431

Leyenda: Prom = promedio, DS = Desviación estándar, letras diferentes en la misma fila indican diferencias estadísticas (p<0.05)

Se puede observar que en la cuarta lactancia la capacidad productiva es alta, y estos datos concuerdan con las evidencias que señalan un punto máximo de rendimiento en este periodo, la segunda y tercera lactancia también tienen un buen desempeño, lo que sugiere una consolidación productiva desde el segundo parto (Pallete *et al.*, 2023)

El descenso de producción en la quinta lactancia se puede deber a diferentes factores, fisiológicos, susceptibilidad o enfermedades (IBR, mastitis, brucelosis, etc.), sin embargo, al tener escaso número de animales con esta lactación (dos registros), limita la generalización de los resultados.

En cuanto a la producción media diaria se observaron valores altos desde la segunda lactancia, el promedio alto es la tercera lactancia con 12.36 ± 2.23 kg/día promedio, seguida de la segunda lactancia con 12.03 ± 2.00 kg/día y la cuarta con 12.10 ± 1.78 kg/día, siendo estos tres promedios estadísticamente similares entre sí, y más que los promedios diarios obtenidos en la primera y quinta lactancias, en ese sentido, Statham (2023) indica que vacas que son primerizas requieren de energía para su desarrollo mamario y su crecimiento corporal lo cual reduce la eficiencia de la producción

7.1.3 PRODUCCIÓN ESTANDARIZADA A 305 DÍAS POR GRUPO RACIAL

En la Tabla 4 se presenta la producción estandarizada de leche a 305 días, comparando los diferentes grupos raciales como son los Brown Swiss, Holstein e híbridos, todos ellos evaluados en la granja K'ayra.

En cuanto a la evaluación de la producción estandarizada por razas en la Tabla 4 los resultados fueron notorios en la raza Holstein con un promedio de producción de 3312.09 kg por campaña, seguida del híbrido con 3131.54 kg de producción por campaña y el Brown Swiss con 2839.7 kg de producción por campaña siendo estos promedios similares entre razas ($p > 0.05$), aunque estos resultados favorecen a la raza Holstein, también es notorio la presencia de un amplio rango de variabilidad, esto puede deberse a las diferentes condiciones de manejo en el aspecto reproductivo.

.

Tabla 4. Producción estandarizada de leche y promedio por 305 días de lactación, considerando los diferentes grupos poblacionales evaluados en la unidad de producción de vacunos de K'ayra

Parámetro evaluado	Unidad	Grupo poblacional evaluado		
		Brown Swiss	Holstein	Hibrido
Lactaciones evaluadas	Cantidad	6	96	27
Producción estandarizada (305 días) por campaña (kg)	Prom $\pm$ DS (min – max)	2839.7 $\pm$ 1525.78a 1566.5 – 5716.9	3312.09 $\pm$ 1194.40a 837.3 – 5872.9	3131.54 $\pm$ 1023.79a 1021.7 – 4181.8
Producción media estandarizada por día (305 días) (kg)	Prom $\pm$ DS (min – max)	12.18 $\pm$ 3.79a 9.44 – 18.74	12.49 $\pm$ 2.64a 7.18 – 19.26	11.55 $\pm$ 2.06a 6.96 – 15.65

Leyenda: Prom = promedio, DS = Desviación estándar, letras diferentes en la misma fila indican diferencias estadísticas ($p < 0.05$)

Respecto a la producción media estandarizada los resultados fueron homogéneos, el Holstein lidera con un promedio de producción diaria de 12.49 kg/día, seguida del Brown Swiss con un promedio de producción diaria de 12.18 kg/día, y los híbridos con un promedio de producción diaria de 11.55 kg/día, siendo estos promedios similares ($p>0.05$), este parámetro es de suma importancia porque permite estimar el rendimiento diario a una curva de lactación estandarizada de 305 días

Al analizar los resultados de producción estandarizada se puede ver resultados superiores en la raza Holstein, en comparación con las demás razas evaluadas, este comportamiento productivo es consistente con lo que señala Pallete et al. (2023), quienes indican que el alto potencial genético de las vacas Holstein está estrechamente relacionado con su capacidad productiva, manifestándose de forma significativa cuando se manejan en condiciones tecnificadas adecuadas

7.1.4 PRODUCCIÓN ESTANDARIZADA A 305 DÍAS POR NÚMERO DE LACTANCIA

En la Tabla 5 se exponen los valores de producción estandarizada por campaña y por día, de acuerdo con el número de lactancia, mostrando el comportamiento productivo desde la primera hasta la quinta lactancia.

En cuanto a la evaluación por número de lactancia, la producción estandarizada por campaña a 305 días, se muestra los resultados de la evaluación realiza. Se observa una tendencia creciente desde la primera lactancia hasta la cuarta lactancia, alcanzando su máximo expresión productiva en la cuarta lactancia y en la quinta lactancia se evidencia un descenso en los niveles productivos, posiblemente atribuidos al desgaste fisiológico asociado a sus edades avanzadas.

Respecto a la producción media diaria estandarizada, se logra observar que la tercera lactancia presenta mayor rendimiento con 13.04 ± 2.44 kg/día promedio, la primera lactación con 11.32 ± 2.69 kg/día promedio y la quinta lactancia con 11.66 ± 4.21 kg/día promedio presentan menores promedios diarios.

.

Tabla 5. Producción estandarizada de leche y promedio por día considerando el número de lactación en vacas primíparas y vacas multíparas en la unidad de producción de vacunos de K'ayra.

Parámetro evaluado	Unidad	Número de lactación				
		1	2	3	4	5
Lactaciones evaluadas	Cantidad	44	43	26	14	2
Producción estandarizada (305 días) por campaña (kg)	Prom ± DS (min – max)	2938.01±1221.28a 1005.3 – 5872.90	3372.18±1087.35a 837.3 - 5716.90	3400.31±1237.98a 1379.5 - 5596.40	3646.27±931.91a 2351.0 - 5327.31	2909.15±2199.03a 1354.2 - 4464.10
Producción media estandarizada por día (305 días) (kg)	Prom ± DS (min – max)	11.32±2.69b 6.96 - 19.26	12.62±2.42ab 7.18 - 18.74	13.04 ± 2.44a 8.16 – 18.35	12.92 ± 2.32ab 9.58 – 17.47	11.66± 4.21ab 8.68 – 14.64

Leyenda: Prom = promedio, DS = Desviación estándar, letras diferentes en la misma fila indican diferencias estadísticas (p<0.05)

Los resultados alcanzados indican que tanto el número de lactancia como la edad influyen en el rendimiento productivo, tal como lo indican Vázquez *et al.* (2021), al respecto, las vacas en su tercera lactancia alcanzan un equilibrio fisiológico óptimo entre el desarrollo corporal, la madurez funcional del aparato mamario y la eficiencia metabólica, lo cual conduce a una mayor productividad, con respuestas hormonales favorables, caracterizadas por una mayor actividad de prolactina, somatotropina, cortisol, insulina y hormonas tiroideas, que en conjunto optimizan la síntesis y eyección de leche, lo que explica los valores observados

7.1.5 COMPORTAMIENTO DE LA CURVA DE LACTACIÓN PROMEDIO POR GRUPO RACIAL

Finalmente, se presenta la Figura 2, que ilustra las curvas de lactación ajustadas de producción promedio diaria de leche para cada grupo racial, observando sus picos de producción y el patrón de persistencia en el tiempo.




Figura 2. Curvas de lactación ajustadas de producción promedio diaria de leche según grupo poblacional de vacas criadas en el centro agronómico de K'ayra

Se observa que las diferentes razas analizadas tienen sus picos de producción entres los 30 y 50 días, comentado por Wood (1967) quien indica que la producción máxima se alcanza entre los 40 y 60 días posparto

Tras el pico de producción se inicia un descenso progresivo, evidenciando el proceso de persistencia en cada raza y a partir de los 400 a 500 días la producción se estabiliza alrededor de los 9 a 10 L por día

El comportamiento del grupo de los Híbridos, muestran fluctuaciones marcadas, su nivel es casi comparable a los del Holstein, lo que respalda su potencial productivo en condiciones de altitud. Según Cardona *et al.*, (2023), los cruzamientos entre Holstein y demás razas que son adaptadas a climas con altas temperaturas mejoran su eficiencia alimentaria y toleran las condiciones ambientales sin comprometer su volumen de producción lo que sugiere que los híbridos pueden mantener una alta productividad en estos entornos

7.2 EDAD AL PRIMER PARTO (EPP) E INTERVALO ENTRE PARTOS (IEP)

7.2.1 INTERVALO ENTRE PARTOS POR GRUPO RACIAL

En la Tabla 6 se observan los resultados alcanzados sobre el intervalo entre partos (IEP) en las diferentes razas evaluadas en la unidad de producción de vacunos de la granja K'ayra. Esta información resulta clave para entender la eficiencia reproductiva según la base genética de los animales.

Tabla 6. Comparativo del intervalo entre partos (días) entre los diferentes grupos poblacionales evaluados en la unidad de producción de vacunos de K'ayra

Parámetro Evaluado	Unidad	Grupo poblacional evaluado		
		Brown Swiss	Holstein	Hibrido
Lactaciones Evaluadas	Cantidad	3	66	16
Intervalo entre partos (días)	Prom ± DS (min – max)	479.00±31.43a 457-515	633.20±299.71a 318-2217	604.25±177.61 ^a 356-925

Leyenda: Prom = promedio, DS = Desviación estándar, letras diferentes en la misma fila indican diferencias estadísticas (p<0.05)

En cuanto a la evaluación del intervalo entre partos (IEP) por razas, en la Tabla 6, se presenta los datos divididos en diferentes razas (Brown Swiss, Holstein e híbrido). Se observó que la raza Brown Swiss presentó un intervalo promedio de 479.00 ± 31.43 días, mientras que en las vacas Holstein el intervalo fue de 633.20 ± 299.71 días, asimismo en el grupo vacas híbridadas, el intervalo fue de 604.25 ± 177.61 días. El análisis estadístico muestra que no existen diferencias significativas entre estos promedios ($p > 0.05$), en cuanto al grupo de vacas Brown Swiss tiene un número de registros evaluados inferior a los demás grupos, esto se debe a los escasos de animales de la raza en el rebaño.

No obstante, Arana *et al.*, (2006) registraron un intervalo parto-primer servicio promedio de 118 días y un intervalo parto-concepción de 171 días en vacas del valle del Mantaro, atribuyendo estas prolongaciones a dificultades en la detección del celo y limitaciones nutricionales, asimismo, Evaristo y Echevarría (1999) encontraron que la condición corporal y la eficiencia en la detección del celo influyen significativamente en el intervalo parto-primer servicio en sistemas intensivos de Lima, con un promedio de 99 días para este parámetro. Estos resultados indican que mantener un IEP dentro de este rango contribuye a optimizar la producción y reproducción en sistemas lecheros de la sierra peruana.

Se puede destacar que los resultados reflejados en la presente investigación expresan una alta prolongación del intervalo entre partos, cuyos intervalos están en promedio de los 572 días, muy fuera de lo ideal para la producción eficiente, estos pueden estar ligados a factores interrelacionados como, deficiente detección de celo, retraso en cuanto a la implementación de los servicios de inseminación, deficiencias en el manejo post parto, deficiencias en el control sanitario.

La comparación entre resultados obtenidos y los parámetros ideales, indican que se requiere una mejora en cuanto al manejo del rebaño en términos de incrementar la capacidad reproductiva, ya que los días abiertos forman parte del IEP. Según Cañete *et al.* (2024) un IEP que es muy extendido, disminuye significativamente la producción anual de leche, esto porque al extenderse su producción, también disminuye la cantidad de lactancias que puede completar en su vida útil. La prolongación observada en cuanto a días de producción, no solo afecta a la productividad de la vaca, sino, también a la rentabilidad del sistema productivo,

afectando la reposición de animales, disminuye el aprovechamiento de recursos y reduce los ingresos económicos resultantes de esta actividad.

7.2.2 INTERVALO ENTRE PARTOS Y EDAD AL PRIMER PARTO POR NÚMERO DE LACTANCIA

La Tabla 7 complementa los hallazgos anteriores al mostrar el comportamiento del IEP y EPP (edad al primer parto) según el número de lactancia. Este enfoque permite identificar patrones de eficiencia reproductiva a lo largo de la vida productiva de las vacas.

Tabla 7. Comparativo del intervalo entre partos considerando el número de lactación en vacas primíparas y vacas multíparas en la unidad de producción de vacunos de K'ayra

Parámetro evaluado	Unidad	Número de lactación				
		Vacas primíparas	Vacas multíparas			
		EPP	2	3	4	5
Lactaciones evaluadas	Cantidad	44	42	26	14	2
EPP e IPP	Prom ± DS	1209.55±319.83	618.38±198.28b	614.38±237.16b	552.57±235.49b	498.50±74.25b
	(min – max)	523-1972	318-1150	346-1188	329-1083	446-551

Leyenda: EPP=Edad al primer parto, IEP=Intervalo entre partos, Prom = promedio, DS = Desviación estándar, letras diferentes en la misma fila indican diferencias estadísticas (p<0.05)

En cuanto a la evaluación del IEP diferenciados por el número de lactancia en la Tabla 7 se observa que las vacas de segunda a quinta lactancia se encuentran en un rango de 498.50 a 618.38 días, siendo estadísticamente similares entre si ($p>0.05$) con una tendencia a disminuir, conforme avanza el número de lactancia, no obstante, dichos valores son superiores al intervalo entre partos (IEP) considerado como óptimo que se sitúa entre 365 a 420 días, lo cual es recomendado para explotaciones lecheras eficientes. La disminución de días en el IEP según van avanzando las lactancias, podría explicarse como una adaptación reproductiva, aunque se debe considerar también la amplia variabilidad reflejada en las desviaciones estándar registradas.

Respecto a los resultados presentados para la primera lactancia, se visualiza información referida a la edad al primer parto (EPP) de 1209.55 días (40.32 meses), este valor corresponde al promedio de días desde el nacimiento a la primera parición. Por lo cual no se compararon con los promedios de otras lactaciones. Se empleo este parámetro (EPP), debido a la ausencia de datos específicos del primer servicio o el primer intento de inseminación, dada la limitación de datos disponibles sobre fechas de inseminación o servicios de monta en el rebaño estudiado, se trabajó con datos con los que, si se contaban, y ello limita la interpretación de resultados importantes. Sin embargo, fue posible contar el parámetro importante que es el intervalo entre el nacimiento y la primera parición, conocido como edad al primer parto o “EPP”, este dato es importante, ya que da un indicador sobre el inicio de la vida reproductiva. Al respecto, se espera que este lapso de tiempo se encuentre ente 25 y 28 meses (750 – 840 días) en vacas lecheras en los Estados Unidos (Hare *et al.*, 2006), aunque para el caso de Cajamarca en Perú, se vio que la EPP varía entre 29 y 34 meses siendo menor para el caso de las vacas Jersey (29.1 ± 0.8 meses) respecto de vacas Holstein y Brown Swiss (33.1 ± 1.2 y 34.3 ± 1.2 meses, respectivamente) (Ruiz *et al.*, 2023). También se tiene un parámetro comparable a la EPP que es la edad al primer servicio (EPS) de inseminación o monta, respecto a este último parámetro, Condori y Gonzales, (2025) reportaron en vacas Brown Swiss en Velille - Cusco, una EPS la cual está situado en un rango de entre 613.8 y 729.7 días en promedio y que implicaría una EPP de se situaría entre 883 y 1000 días y, aun así, estos son menores a los observados en el presente estudio. En ese sentido el promedio para la EPP, observados en las vacas

pertenecientes al rebaño de la unidad de producción de vacunos de la EP Zootecnia – UNSAAC, es más alto que lo observado en rebaños comerciales norte americanos y también en rebaños criados en condiciones de valles interandinos de la sierra de Perú. Esto implica un inicio de la vida productiva que es tardío, lo cual tiene repercusión en la vida productiva de las vacas lecheras, finalmente, se considera que una edad ideal al primer parto debe situarse entre los 24 meses de vida de la vaca (Schultz *et al.*, 2023) y los hallazgos obtenidos en el presente estudio demuestran retrasos considerables, y esto implica pérdidas económicas por el costo que se hace en el proceso de recría, además de la reducción en la vida productiva de las vacas

Hay que también considerar que la falta de registros reproductivos precisos en sistemas de producción que tienden a ser sistematizados, constituye limitaciones para un análisis reproductivo riguroso (Vásquez, 2021).

Por otro lado, el IEP que constituye un indicador importante para evaluar la eficiencia reproductiva y económica en la producción de leche, con los resultados de la presente investigación, presentan valores altos. Según Valera (1996), un IEP habitual se sitúa entre 365 a 450 días para garantizar un adecuado ritmo de partos y mantener la rentabilidad del sistema. La prolongación del IEP, puede asociarse en fallas de la detección de celo, deficiente manejo postparto, retrasos en el reinicio de la actividad ovárica, deficiencias nutricionales, como lo indicaba Torres (2020), que estas deficiencias en el manejo reproductivo, sumadas a la falta de programas sistemáticos de monitoreo reproductivo, contribuyen a extender el IEP, lo que afecta de manera adversa la productividad y rentabilidad de los sistemas lecheros.

7.2.3 EDAD AL PRIMER PARTO E INTERVALO ENTRE PARTOS SEGÚN RAZA Y NÚMERO DE LACTANCIÓN

A continuación, en la Tabla 8 se detallan los resultados para vacas Holstein e Híbrido según número de lactancia, lo cual permite evaluar el comportamiento reproductivo comparativo entre razas y dentro de ellas según la experiencia reproductiva.

Tabla 8. Edad al primer parto e intervalo entre partos en vacas Holstein e Híbridos, considerando el número de lactación en vacas primíparas y vacas múltiparas en la unidad de producción de vacunos de K'ayra

Grupo poblacional evaluado	N° de lactancias	Lactaciones evaluadas	EPP e IEP
		Cantidad	Prom $\pm$ DS (min – max)
Holstein	EPP	30	1219.33 $\pm$ 292.29a 536-1767
	2	32	619.00 $\pm$ 205.58b 318-1150
	3	19	624.90 $\pm$ 205.58b 346-1188
	4	12	574.67 $\pm$ 247.11b 329-1083
	5	2	498.50 $\pm$ 7425b 446-551
Hibrido	EPP	11	1087 $\pm$ 305.63 ^a 523-1731
	2	8	655.25 $\pm$ 185.64b 442-925
	3	6	597.67 $\pm$ 164.18b 418-829
	4	2	420.00 $\pm$ 90.51b 356-484

Leyenda: EPP=Edad al primer parto, IEP=Intervalo entre partos, Prom = promedio, DS = Desviación estándar, letras diferentes en la misma fila indican diferencias estadísticas ($p < 0.05$)

En cuanto al intervalo entre partos en la raza Holstein según el número de lactaciones evaluadas en la Tabla 8, a partir de la segunda lactancia los valores se estabilizan, teniendo en la segunda lactancia 619.00 $\pm$ 205.58 días, en la tercera lactancia 624.90 $\pm$ 205.58 días, en la cuarta lactancia 574.67 $\pm$ 247.11 días y en la quinta lactancia 498.50 $\pm$ 7425 días, el análisis estadístico muestra que no existen diferencias significativas entre estos datos ($p > 0.05$)

Idealmente los partos recomendados en los bovinos Holstein son entre los 365 y 400 días asegurando un parto por año (Cañete, 2024). En este caso, los resultados encontrados exceden el rango por más de 200 días en las lactaciones evaluadas, este desfase implica periodos prolongados en la inactividad reproductiva, además

del aumento en los días abiertos y pérdidas económicas asociadas con menos eficiencia productiva.

En cuanto al IEP del grupo de vacas híbridas según el número de lactaciones en la Tabla 8, los valores son notoriamente altas, con 655.25 ± 185.64 días en la segunda lactación, 597.67 ± 164.18 días en la tercera lactación y 420.00 ± 90.51 días en la cuarta lactación, el análisis estadístico muestra que no existe diferencias significativas entre estos datos ($p > 0.05$).

Sin embargo, Calderon *et al.*, (2017) en ganados cruzados en la región de la selva obtuvo IEP de 317 a 540 días, una diferencia muy marcada en cuanto a lo obtenido en los presentes resultados, donde la cuarta lactancia apenas y se acerca a los rangos normales, debiendo esto resultados a problemas en manejo reproductivo, calidad genética, condiciones ambientales.

Por su parte Fernández (2020) demostró en sus estudios que los rebaños con un débil control reproductivo presentan intervalos promedio de hasta 600 días, mientras aquellos que tienen programas reproductivos intensivos, reducen intervalos menores a 400 días, esto evidencia la importancia de un manejo reproductivo adecuado para mejorar la eficiencia reproductiva y productiva en sistemas bovinos.

Entonces, los resultados indican que los intervalos tan extensos comprometen gravemente la rentabilidad del sistema lechero, cada mes adicional sin preñez representa un descenso directo en la producción anual de leche y mayores costos al alimentar animales que no producen, al tener también una DS de más de 200 días sugiere problemas en la detección de celos, inseminaciones artificiales fallidas, deficiencias de nutrición, enfermedades no controladas.

La alimentación influencia demasiado en la edad de la pubertad en las vacas, en sistemas intensivos en la costa con dietas balanceadas, las vacas Holstein alcanzan la pubertad a los 10 a 11 meses y entran en servicio a los 14 meses, mejorando la eficiencia productiva (Aguilar Zavaleta, 2018). En cambio, en los sistemas intensivos en la sierra, la alimentación en base de pasturas y suplementación variable las vacas alcanzan la pubertad a los 17 meses y el primer servicio a los 19 meses (Paytán Paccori, 2021). Los hallazgos en el presente

estudio corroboran un retraso en la edad al primer parto, por ende, su edad al primer servicio, atribuibles a deficiencias nutricionales.

No obstante, las enfermedades reproductivas como la brucelosis, leptospirosis y neosporosis afectan la fertilidad y productividad del ganado bovino en la sierra peruana, provocando abortos, infertilidad y disminución en la producción de leche. Rivera *et al.* (2004) reportaron la presencia de estos agentes infecciosos en bovinos del trópico peruano, destacando que *Brucella sp.* y *Leptospira sp.* son causantes esporádicos de abortos en zonas como Lima, Arequipa y el Mantaro. Según, el Servicio Nacional de Sanidad Agraria (SENASA, 2023) la brucelosis continúa siendo una de las principales enfermedades que afectan la reproducción y la eficiencia productiva del ganado bovino en el Perú.

7.3 AJUSTE DE LA CURVA DE LACTACIÓN SEGÚN MODELOS MATEMÁTICOS

7.3.1 AJUSTE DE MODELOS MATEMÁTICOS A LA PRIMERA LACTANCIA

En la Figura 3 se muestran los distintos modelos matemáticos (Wood, Wilmink, ECN y Dave) usados para ajustar la curva de lactancia en vacas durante su primera lactancia, mostrando cómo varía la producción diaria de leche a lo largo de los 305 días.




Figura 3. Curvas de lactancia ajustadas por los modelos Wood, Wilmink, ECN y Dave, en vacas de primera lactancia del rebaño evaluado en la unidad de producción de vacunos de K'ayra

Lo más relevante es que todos los modelos predicen un pico de producción muy temprano, alrededor de los primeros 20 días, seguido de un descenso progresivo, aunque con diferencias notables en la magnitud y el ritmo de esa caída. El modelo ECN estima un pico superior a los 16 kg diarios, mientras que los modelos Wood y Wilmink lo sitúan por debajo de los 14 kg. Estas discrepancias entre modelos se intensifican conforme avanza la lactancia, particularmente tras los 100 días, lo que puede tener un impacto directo en la planificación del manejo nutricional y reproductivo del hato. Además, la rapidez con la que la producción de leche disminuye tras el pico inicial subraya la importancia de un manejo óptimo en las primeras semanas para sostener la productividad.

Tabla 9. Comparación de modelos de curva de lactación para la primera lactación del rebaño evaluado en la unidad de producción de vacunos de K'ayra.

Indicadores estadísticos	Unidad	Modelos matemáticos			
		Wood	Wilmink	ECN	Dave
AIC	Adimensional	58,639.19	58,502.44	19,712.17	58,592.68
BIC	Adimensional	58,668.44	58,539.01	19,737.02	58,621.93
R²	Proporción	0.0207	0.0329	0.1964	0.0248
RME	kg/día	3.414	3.392	3.501	3.407
Día de pico	Día	8	10	9	21
Producción pico	kg/día	12.37	12.52	15.99	12.41
Producción total 305 días	kg	3,522.13	3,521.06	3,926.36	3,519.74

Leyenda. R²=coeficiente de determinación. RMSE=error cuadrático. AIC=Criterio de información de Akaike. BIC=criterio de información bayesiano, ECN= exponencial con corrección lineal negativa

En la Tabla 9 se observan los resultados de los cuatro modelos matemáticos (Wood, Wilmink, exponencial con corrección lineal negativa y Dave) evaluados para describir el comportamiento de la curva de lactación en vacas de primera lactancia, utilizando la producción de leche diaria estandarizada hasta los 305 días. En esta tabla también se muestran los resultados del análisis del desempeño de cada modelo con base en los indicadores estadísticos (r^2 , RMSE, AIC, BIC), criterios que son utilizados en la literatura científica para comparar calidad de ajustes de cada uno de estos modelos.

Se observó un mejor ajuste con el modelo exponencial con corrección lineal negativa, con un R² (0.1964) lo que indica mayor explicación en la variabilidad de la producción lechera diaria, además estimo un pico de producción de 15.99 kg a los 9 días de lactancia registrada y 3926.36 kg/campaña proyectada. Estos resultados pueden atribuirse a que este modelo incorpora explícitamente la fase del ascenso y del declive de la curva, importante en vacas primerizas, donde la persistencia es menor y es muy variable en el pico de producción (Vásquez *et al.*, 2021). El menor RMSE (3.39 kg) fue obtenido por el modelo de Wilmink, seguido de los modelos Dave (3.40 kg) y Wood (3.41 kg). Si bien la diferencia

entre ellos es mínima, este indicador sugiere que el modelo de Wilmink ofrece una mayor precisión en la estimación diaria de la producción de leche.

Respecto al criterio de información de Akaike (AIC) y al bayesiano (BIC), el modelo exponencial con corrección lineal negativa (ECN) también presentó los valores más bajos (AIC = 19712.17; BIC = 19737.02), lo que indicaría una mejor eficiencia del modelo, considerando el equilibrio entre ajuste y complejidad. Entre los modelos clásicos, el de Wilmink nuevamente se posicionó como el más eficiente (AIC = 58502.44; BIC = 58539.01), lo que refuerza su aplicabilidad práctica y robustez estadística.

En cuanto a la comparación general, el modelo ECN puede considerarse más útil para describir la forma biológica general de la primera lactancia del rebaño estudiado, especialmente en estudios de persistencia y pico, mientras que el modelo de Wilmink resulta más apropiado cuando se desea una mayor precisión de estimación diaria.

Finalmente, la elección del modelo adecuado para describir la curva de lactancia tiene implicancias directas en la gestión de la producción lechera. Un modelo que refleje una mejor precisión permitirá una mejor planificación de la alimentación, el manejo y la selección genética. En este caso el modelo ECN ofrece una herramienta buena para optimizar la producción en la unidad de producción de vacunos estudiada.

7.3.2 AJUSTE DE MODELOS EN LA SEGUNDA Y LA TERCERA LACTANCIA A MÁS

En cuanto a la evaluación de la segunda y tercera (a más) lactancia del rebaño evaluado, también se emplearon los cuatro modelos matemáticos antes descritos, siguiendo los criterios aplicados para la primera lactación (R^2 , RMSE, AIC y BIC).

Respecto a la segunda lactancia observado en la Figura 4, se revelan diferencias en la forma en que los modelos matemáticos representan la curva de lactancia en vacas de segunda lactancia, en ese sentido, mientras que los modelos ECN y Dave capturan con precisión un ascenso progresivo y un pico productivo alrededor del día 9, coherente con el comportamiento productivo de este rebaño,

el modelo de Wood muestra un comportamiento anómalo al ubicar el máximo en el primer día, lo cual distorsiona la interpretación biológica. Esta comparación evidencia que no todos los modelos responden igual frente a datos reales, destacando la importancia de elegir adecuadamente el método de ajuste para representar fielmente la dinámica lechera. Además, la gráfica evidencia que, en vacas adultas, la persistencia y el mantenimiento de la producción a lo largo del ciclo son más homogéneos, lo que puede traducirse en una mayor eficiencia económica para la lechería.




Figura 4. Curvas de lactancia ajustadas por los modelos Wood, Wilmink, ECN y Dave en vacas de segunda lactancia, en el rebaño evaluado en la unidad de producción de vacunos de K'ayra

En la Figura 5 se observan las curvas de lactación del grupo de tres a más lactaciones lo que realmente salta a la vista es la consistencia y la cercanía entre las predicciones de todos los modelos a lo largo de los 350 días de lactancia. A diferencia de lo que suele ocurrir en vacas jóvenes, aquí los picos de producción son muy similares y se alcanzan rápidamente, rozando los 16 Kg diarios, pero lo más relevante es la estabilidad y la superposición de las curvas durante la fase de descenso.




Figura 5. Curvas de lactancia ajustadas por los modelos Wood, Wilmink, ECN y Dave en vacas de tercera lactancia a más, en el rebaño evaluado en la unidad de producción de vacunos de K´ayra

Esta similitud sugiere que, A partir de la tercera lactancia, las vacas alcanzan una madurez fisiológica que hace su producción más predecible y estable, independientemente del modelo utilizado. Este momento es clave en el ciclo productivo, ya que la vaca consolida su capacidad productiva y responde mejor a las condiciones ambientales y nutricionales. Esta información es útil para optimizar el manejo, enfocándose en la salud y longevidad del animal para mantener la estabilidad productiva. Para los productores, esto permite planificar mejor la alimentación, reproducción y gestión del hato, reduciendo errores en la estimación de la producción. Además, la gráfica evidencia que, en vacas adultas, la persistencia y el mantenimiento de la producción a lo largo del ciclo son más homogéneos.

Tabla 10. Comparación de modelos de curva de lactación para la segunda lactación en la unidad de producción de vacunos de K´ayra

Indicadores estadísticos	Unidad	Modelos matemáticos			
		Wood	Wilmink	ECN	Dave
AIC	Adimensional	60,097.18	59,988.21	19,712.17	60,022.90
BIC	Adimensional	60,126.52	60,024.87	19,737.02	60,052.23
R²	Proporción	0.1714	0.1795	0.1964	0.1768
RME	kg/día	3.452	3.435	3.501	3.441
Día de pico	Día	22	8	9	21
Producción pico	kg/día	14.90	15.31	15.99	15.06
Producción total	kg	3,812.47	3,814.91	3,926.36	3,814.36
305 días					

Leyenda.: R²=coeficiente de determinación. RMSE=error cuadrático. AIC=Criterio de información de Akaike. BIC=criterio de información bayesiano. ECN= exponencial con corrección lineal negativa

En la Tabla 10 muestran los resultados estadísticos de la segunda lactación y en la Tabla 11 se muestran los resultados del grupo de vacas de tercera a más lactancia, donde se muestra que el modelo ECN continúa destacando como el más explicativo, al registrar el mayor valor de R² = 0.20 y 0.19 segunda y tercera lactancia, respectivamente, aunque su error (RMSE = 3.501) fue apenas superior al de los otros modelos. Este patrón concuerda con la información proporcionada por Macciotta *et al.* (2005), quienes señalaron que este tipo de modelos resulta más efectivo en representar curvas de lactancia en animales que ya han superado su primera lactación, debido a una curva más definida y predecible. Por su parte, el modelo de Wilmink tuvo el menor RMSE (3.435) y un R² cercano (0.1795), lo que lo posiciona como un modelo competitivo en términos de predicción ajustada.

En términos de predicción, los modelos Wilmink y Dave fueron los más destacados, ambos con un RMSE de 3.44 kg, indicando menor error promedio en la estimación de la producción diaria. Esta precisión resulta especialmente útil para la gestión individual de vacas y toma de decisiones sobre alimentación o descarte.

Tabla 11. Comparación de modelos de curva de lactación para la tercera lactancia a más en la unidad de producción de vacunos de K'ayra

Indicadores Estadísticos	Unidad	Modelos matemáticos			
		Wood	Wilmink	ECN	Dave
AIC	Adimensional	19,736.45	19,721.13	19,712.17	19,712.17
BIC	Adimensional	19,761.30	19,752.20	19,737.02	19,737.02
R²	Proporción	0.1911	0.1949	0.1964	0.1964
RME	kg/día	3.513	3.505	3.501	3.501
Día de pico	Día	1	7	9	9
Producción pico	kg/día	16.14	15.86	15.99	15.99
Producción total 305 días	kg	3,925.42	3,924.02	3,926.36	3,926.36

Leyenda: R²=coeficiente de determinación. RMSE=error cuadrático. AIC=Criterio de información de Akaike. BIC=criterio de información bayesiano. ECN= exponencial con corrección lineal negativa

En cuanto a la Tabla 11 el modelo de Wood estimó una producción máxima desde el primer día de lactancia, lo cual es biológicamente improbable y sugiere un ajuste deficiente para vacas en tercera lactancia o posteriores. Este tipo de comportamiento ha sido también cuestionado por Vásquez *et al.* (2021), ya que concluyeron que el modelo de Wood tiende a sobreestimar el inicio de la curva en vacas multíparas bajo condiciones de altura, produciendo curvas con picos artificialmente tempranos. Por el contrario, los modelos Wilmink y ECN alcanzaron la producción máxima en los días 7 y 9, respectivamente.

En términos de producción máxima, el modelo ECN predijo un pico de producción de 15.99 kg/día, el más alto entre los modelos, seguido de Wilmink con 15.31 kg/día. Este comportamiento es coherente con lo observado en vacas multíparas, donde el pico de producción suele alcanzarse tempranamente (7 a 10 días) y es más elevado que en la primera lactancia. Además, estimó una producción acumulada de 3,926.36 kg en 305 días, superando al resto de modelos, lo cual sugiere una mayor capacidad para capturar la evolución completa de la lactancia, incluyendo fases iniciales, pico y descenso progresivo, este resultado concuerda con lo reportado por Vásquez *et al.* (2021), evaluaron modelos no lineales y lineales mixtos para describir la curva de lactancia en

vacas Holstein en el Valle de Huaura, encontrando que el modelo de Wilmink fue el que mejor se ajustó a vacas con segundo y tercer parto, donde indican que la mayor producción en lactancias posteriores también está acompañada de curvas más amplias y sostenidas, donde modelos tipo compartimental o de crecimiento retardado muestran mejor desempeño.

Por el contrario, el modelo de Wood mostró el menor desempeño en todos los indicadores. Aunque históricamente ha sido ampliamente usado en estudios de curvas de lactancia (Wood, 1967), su capacidad para representar adecuadamente los cambios en producción en vacas multíparas parece limitada bajo condiciones reales y en altitudes como las de la región Cusco.

Finalmente, se puede afirmar que el modelo ECN es el más adecuado para describir la curva biológica completa (forma, pico, declive), mientras que el modelo de Wilmink se mantiene como la mejor opción cuando se requiere eficiencia y precisión para predicción práctica.

7.3.3 COMPARACIÓN DE MODELOS MATEMÁTICOS




Figura 6. Gráficas del análisis comparativo de los entre modelos matemáticos evaluados en la unidad de producción de vacunos de K'ayra

En la Figura 6 se presenta la comparación integral de los cuatro modelos matemáticos (Dave, ECN, Wilmink y Wood) para el ajuste de la curva de lactancia en vacas, diferenciando su desempeño en la primera, segunda y tercera o más lactancias mediante los criterios estadísticos AIC, BIC, R^2 y RMSE. En conjunto, estos resultados sugieren que el modelo ECN es preferible para describir la curva de lactancia en las primeras lactancias por su eficiencia estadística y capacidad explicativa, mientras que en lactancias posteriores la elección del modelo puede basarse en otros criterios prácticos, ya que el desempeño entre ellos tiende a igualarse. Esta información es fundamental para la selección del modelo más apropiado según el grupo de animales y los objetivos específicos del análisis en estudios de producción lechera.

VIII. CONCLUSIONES

- Las vacas híbridas y Holstein, mostraron mayor producción real que las Brown Swiss ($p < 0.05$), sin diferencias significativas en cuanto a duración de la lactancia ($p > 0.05$), en cuanto a la evaluación por número de lactación del ganado, se observó diferencias significativas en la producción real ($p < 0.05$) y con respecto a la producción estandarizada a 305 días no se observaron diferencias entre grupos raciales ($p > 0.05$). Además, la mayor productividad general, se observó en la tercera y cuarta lactancia.
- La edad al primer parto (EPP) del rebaño evaluado, fue superior a 40 meses, sin observarse diferencias significativas entre razas, además, con respecto al intervalo entre partos (IEP) se observaron promedios prolongados siendo este de 572 días como promedio general sin diferencias entre lactaciones ($p > 0.05$).
- El modelo Exponencial con crecimiento negativo (ECN) mostró el mejor ajuste global para la curva de lactancia, especialmente en vacas de primera y segunda lactancia y el modelo de Wilmink ofreció una mayor precisión del promedio de producción diaria. En vacas de tercera lactancia o más, las diferencias entre modelos son menores, permitiendo una elección flexible según el objetivo.

IX. RECOMENDACIONES

- Se recomienda implementar un programa de fortalecimiento de registros de información productiva, para facilitar el análisis sistemático de los datos para identificar y corregir posibles factores que generen problemas en la producción leche por parte del rebaño.
- Se recomienda establecer protocolos estrictos de manejo reproductivo y sanitario, para favorecer el inicio de vida reproductiva a edad más temprana a fin de reducir la edad al primer parto y reducir el intervalo entre partos hasta lograr parámetros adecuados para rebaños de vacas lecheras.
- Realizar investigaciones para determinar el efecto de los problemas sanitarios y la detección celos e inseminación de vacas, sobre el intervalo entre partos.
- Se recomienda utilizar el modelo ECN para estudios de persistencia y análisis biológico de la curva de lactancia, en vacas primerizas, y emplear el modelo de Wilmink y ECN cuando se requiera mayor precisión en la predicción diaria para la gestión individual y planificación de la alimentación en vacas en producción
- Implementar programas de capacitación continua para el personal encargado del manejo y ordeño, enfatizando buenas prácticas de higiene, bienestar animal y registro de datos productivos, a fin de mejorar la calidad y cantidad de leche producida.
- Fomentar el uso de indicadores productivos estandarizados (litros/vaca/día, persistencia de lactancia, tasa de concepción) para comparar el rendimiento de la granja con estándares nacionales e internacionales, y establecer metas de mejora continua.

X. BIBLIOGRAFÍA

Abraira, V. (2005). Inferencia Estadística Bayesiana. Revista de Medicina de Familia SEMERGEN, 18-20.

Adediran, S., Ratkowsky, D., & Donaghy, D. (2012). Evaluación comparativa de un nuevo modelo de curva de lactancia para vacas lecheras Holstein-Friesian alimentadas con pasto. Journal of Dairy Science, 5344-5356.

Aguilar Zavaleta, L. (2018). Comportamiento de los Parámetros reproductivos de un Hato lechero de raza Holstein Friesian, criado de forma intensiva durante el periodo 2014, Pacasmayo - La Libertad. Universidad Nacional de Trujillo, 1-70.

Aguilar, R. (2021). Análisis del comportamiento de curvas de lactancia típicas de diferentes cruces raciales de bovinos de leche en condiciones de Trópico Húmedo. Turrialba, Costa Rica: Centro Agronómico Tropical de Investigación y enseñanza. División de Educación. Programa de Maestría.

Aidar, S., Giannoni, M., & Ramos, A. (1986). Efectos genéticos del ambiente sobre la duracion de intervalo de partos de bovinos mestisos holandeses. Sociedad Brasileira de zootecnistas, 468-474.

Alba Gómez, L. O. (2015). La reproducción de la hembra bovina en Cuba. Cuba: Editorial Universitaria.

Ali, T., & Schaeffer, L. (1987). Contabilidad de las covarianzas en los rendimientos de leche del día de la prueba en vacas lecheras. Revista Canadiense de Ciencia Animal, 637-644.

Alvarado, W., Gonzales, J., Quilcate, C., Saucedo, J., & Bardales, J. (2019). Factores de prevalencia de mastitis cubclinica en vacas lecheras del distrito de Florida, Region Amazonas, Peru. Revista de Investigaciones Veterinarias del Peru, 923-931.

Amos, H., Kiser, T., & Loewenstein, M. (1985). Influence of milking frequency on productive and reproductive efficiencies of dairy cows. Journal of Dairy Science, 1046-1051. doi:10.3168/jds.S0022-0302(85)80880-8

Apaza Huallpa, Y., Loza Murguia, M. G., Rojas Pardo, A., & Achu Nina, C. (2016). Determinación del comportamiento de la curva de lactancia y producción lechera

del ganado Mestizo del Altiplano de la Provincia Omasuyos Departamento de La Paz. *Selva Andina Anim Sci.*, 77-86.

Arana, C., Echevarría, L., & Segura, J. (2006). Factores que afectan el intervalo parto-primer servicio y primer servicio-concepción en vacas lecheras del Valle del Mantaro durante la época lluviosa. *Revista de Investigaciones Veterinarias del Perú*, 108-113.

Arias, R., Mader, T., & Escobar, P. (2008). Factores climáticos que afectan el desempeño productivo del ganado bovino de carne y leche. *Archivos de medicina veterinaria*, 7-22.

Bednarski, M., & Kupczynski, R. (2024). Factores que afectan la productividad y la calidad de la leche, y la salud de las vacas lecheras. *Animals*, 14-24.

Bradley G, K. (2020). Cunningham. Fisiología Veterinaria. Ámsterdam, Países Bajos: Elsevier Health Sciences.

Buxade, C. (1996). Producción vacuna de leche y carne. *Zootecnia Tomo VII*. Madrid: Ediciones Mundi-Prensa.

Calderon León, T., Chirinos Peinado, D., & Castro Bedriñana, J. (2017). Parámetros Reproductivos del Ganado Nellore en la Selva Central del Peru (2000-2007). *Revista de Investigaciones Veterinarias del Peru*, 230-239.

Calero Vaca, G. M., Jiménez Yáñez, S. F., Almeida Lopez, F. A., Maldonado Arias, D. F., & Toalombo Vargas, P. A. (2022). Parámetros productivos y reproductivos del hato lechero Brown Swiss ubicada en un clima andino. *Polo del conocimiento*, 1739-1780.

Campabadal, C. (2013). Factores que afectan el contenido de sólidos en leche. *Universidad de Costa Rica*, 67-90.

Cañete, V., Vernay, H., Biga, P., Lammoglia, V., & Marini, P. (2024). Conception calving interval and its impact on the production and productive . *Biologia Agropecuaria Tuxpan*, 115-124.

Cardona Cifuentes, D., Londono Gil, M., & Echeverri Zuluaga, J. (2017). Evaluación comparativa de parámetros productivos en diferentes cruces de ganado Blanco -

Orejinegro con Holstein. Corpoica Cienc Tecnol Agropecuaria, Mosquera (Colombia), 513-527.

Castañeda Sanchez, W. A., Polo Escobar, B. R., & Vega Huincho, F. (2024). Redes neuronales artificiales: Una medicion de aprendizaje de pronosticos como demanda potencial. Universidad, Ciencia y Tecnologia, 51-59.

Castro Ramírez, A. (2002). Ganadería de leche. Costa Rica: Editorial Universidad Estatal a Distancia.

Condori, J. L., & Gonzales, G. W. (2025). Estructura poblacional y parámetros productivos y reproductivos de ganado Brown Swiss criados en Cusco, Perú. Revista de Investigaciones Veterinarias del Perú, 36(2). doi:<https://doi.org/10.15381/rivep.v36i2.28554>

Crisologo Carranza, R. L. (2020). Determinación de la curva de lactancia en ganado vacuno Holstein en el establo “San José” S.A.C., Virú - La Libertad. (págs. 11-25). Cajamarca, Peru: Tesis para optar el titulo profesional de Ingeniero Zootecnista.

Cuatrin, A. (2009). Curva de Producción y Composición de Leche Bovina. Biblioteca Central (FAUBA) de Buenos Aires, 75-79.

Dagnino, J. (2014). Bioestaditica y Epidemiologia. Revista Chilena de Anestecia, 306-310.

Diaz Garcia, R. S. (2019). Somatotropina bovina y persistencia de la curva de producción láctea en vacas Holstein. Tesis para optar el título profesional de ingeniero zootecnista (págs. 5-37). Huacho, Peru: Universidad Nacional José Faustino Sanchez Carrion.

Escalante Fernandez, K. (2020). Evaluación del comportamiento productivo y reproductivo en ganado lechero mestizo y sus creuces con gyr lechero, considerando las epocas del año en tropico humedo. UNIVERSIDAD NACIONAL AGRARIA DE LA SELVA, 1-64.

Evarsito, R., & Echevarría, L. (1999). FActores que afectan el intervalo parto primer servicio en vacas lecheras de crianza intensiva. Revista De Investigaciones Veterinarias Del Perú, 22-26.

FAO. (2013). Impact of mastitis in small scale dairy production systems. Organizacion de las Naciones Unidad para la Alimentacion y la Agricultura, 8-100.

Fox, J. (2002). Apendice de regresion no paramétrica de un complemento de R y S-PLUS para la regresion aplicada. C.A. sage, 1-50.

García Casillas, A. C., & Montiel Ramos, L. A. (2012). El periodo de transición de la vaca lechera. Sociedades Rurales, Producción y Medio Ambiente (UAM Xochimilco), 1-22.

Google Earth. (28 de abril de 2024). Granja K´ayra (UNSAAC). Obtenido de https://earth.google.com/web/search/Kayra+r%c3%ado+san+Jer%c3%b3nimo,+Cusco/@-13.55779265,-71.8752871,3215.91533764a,574.60532219d,35y,-0h,0t,0r/data=CiwiJgokCT_dwVyopqK_Ec9hIU2zvjrAGQipETcM1kvAIV6LRu2YaVfAQgIIAToDCgEwQgIIAEoNCP_____wEQAA

Hare, E., Norman, H., & Wrigth, J. (2006). Trends in Calving Ages and Calving Intervals for Dairy Cattle. Journal Dairy Scienci, 365-370.

Hernandez Ceron, J. (2016). Fisiologica clinica de la reproduccion en bovinos lecheros. Universidad Nacional Autonoma de Mexico, 17-95.

Herrera Delgado, A. D. (2022). Tecnificación del procesamiento de productos lácteos en la granja Kayra - Cusco. 2020. Tesis optar al título profesional de Licenciado en Administración (págs. 12-37). Cusco, Perú: Universidad Nacional De San Antonio Abad Del Cusco.

Japan International Cooperation Agency. (2007). FISIOLOGÍA DE LA LACTACIÓN. Japan Cooperation, 67-85.

Landete Castillejos, T. (2000). La capacidad de los modelos matematicos para describir la forma de las cruvas de lactancia. Journal of Animal Science, 3010-3013.

Lopez, P., Rearte, W., & de la Sota, R. (2020). Herramienta Informática para el Análisis de Progenie. Innovación y Desarrollo Tecnológico y Social. ResearchGate, 2-11.

Macciotta, N., Vicario, D., & Cappio-Borlino, A. (2005). Detection of different shapes of lactation curve for milk yield in dairy cattle by empirical mathematical models. American Dairy Science Association, 1178–1191.

Mamani Choque, G. (2023). Modelos matemáticos para estimar curvas de lactancia en vacunos brown swiss del Centro Experimental Chuquibambilla, Puno. Universidad nacional del Altiplano, 1-30.

MINAGRI. (2017). Sistema integrado de estadísticas agrarias. Anuario estadístico de producción agrícola y ganadera . Lima : Ministerio de Agricultura y Riego.

Moncada, G. (2021). FACtores que alteran el intervalo entre partos (iep) en las hembras bovinas. ResearchGate, 1-5.

Napolitano, F., Gabriela Marcela, M., Aldo, B., & Adolfo, A. (2020). Advantages and disadvantages of manual and mechanical milking systems: productivity, animal welfare and productivity. El búfalo de agua en Latinoamérica, hallazgos recientes, 1-1500.

National Academies of Sciences, E. a. (2021). Nutrient Requirements of Dairy Cattle (8th rev. ed.). The National Academies Press, 20.

Ossa, G., Torrenegroza, L., & Alvarado, L. (1997). Determinacion de la curva de lactacion en vacas mestizas de un hato de doble propoósito en la Regio del Caribe de Colombia. Ciencia y Tegnologia Agropecuaria, 54-57.

Pallete, A., García, M., Cespedes, P., & Rodríguez, Z. (2023). PROductividad lechera en vacas holstein de la cuenca de lima – Perú. Anales Cientificos, 68-83.

Pando, W. (2022). Sistema de producción de leche y desarrollo sostenible en comunidades campesinas del distrito de Paruro, 2021. Cusco: Universidad Andina del Cusco. Tesis presentado para optar el grado academico de Doctor en medio ambiente y desarrollo sostenible.

Paytan Paccori, A. (2021). Época de parto y su relación con el desempeño productivo y reproductivo de vacas Holstein criadas en sistema intensivo en un establo de la cuenca lechera de Majes. Universidad Peruana Cayetano Heredia, 1-27.

Posada, S., Rosero, R., Rodríguez, N., & Costa, A. (2011). Estimación de parámetros de curvas de crecimiento de ganado Nellore criado en confinamiento. Revista MVZ Córdoba, 2701-2710.

Quispe, J., Belizario, C., Apaza, Z., Maquera, Z., & Quisocala, V. (2016). Desempeño productivo de vacunos Brown Swiss en el altiplano peruano. *Revista de Investigacion Altoandina*, 411-422.

Ramirez Cano, O. (2017). Caracterizacion de curvas de lactancia para produccion y componentes de leche e bovinos Jersey. *Universidad Autonoma Chapingo*, 2-64.

Reyes Lopez, O., Castillo Juárez, H., & Montaldo, H. (2009). Covarianzas genéticas y fenotípicas para días abiertos y características de la curva de lactancia en vacas Holstein en el norte de México. *Universidad Metropolitana-Xochimilco. Mexico*, 343-354.

Rivas, G. (1993). Regresion no lineal. *Revista Colombiana de Estaditica*, 90-100.

Rivera, H., Benito, A., Ramos, O., & Manchego, A. (2004). Prevalencia de enfermedades de impacto reproductivo en bovinos de la estacion experimental de tropico del centro de investigacion IVITA. *Revista de Investigacion Veterinaria del Peru*, 120-126.

Rodriguez, L., Ara, M., Huaman , H., & Echevarría , L. (2005). Modelos de ajuste para curvas de lactación de vacas en crianza intensiva en la cuenca de Lima. *Revista de Investigaciones Veterinarias del Perú*, 1-12.

Rodriguez, L., Pozo, A., Sobero, B., Loza, J., Axel, A., & Jorge, J. (2019). Eficiencia productiva y reproductiva sobre la clasificación de vacas en el centro de producción de allpachaka, Ayacucho 3550 msnm. *Unidad de Investigación e Innovación en Ciencias Agrarias*, 33-44.

Ruiz Figueroa, E., Alvarado Malca, E., & Bueno Cabrera, W. (2023). Indices reproductivos en vacunos Brown Swiss, Jersey y Holstein en altura – cooperativa Atahualpa Jerusalén – Cajamarca. *Catedra Villareal*, 94-102.

Sandoval Giron, V. M. (2019). Evaluacion de parametros peoductivos y reproductivos en ganado de leche en hacienda playones, Flavio Alfaro Ecuador. *Universidad Nacional de Agricultura*, 23-28.

Sandoval Monzón, R., Cevallos Ampuero, J., Ferrari Gabilondo, G., Montenegro Vega, M., & Ruiz Garcia, L. (2023). Efecto del nivel de tecnificación de los establos lecheros de la provincia de Lima sobre la calidad composicional, higiénica y

sanitaria de la leche. Revista de investigación veterinaria del Perú, 1-15. doi:<https://doi.org/10.15381/rivep.v34i4.25499>

Schultz, M., Capelli, A., & Sanchez, S. (2023). Análisis de la edad al primer parto en el desempeño productivo y reproductivo en la primera lactancia de vacas Holstein en un sistema intensivo de Argentina. Revista veterinaria, 48-54.

SENASA. (2023). Brucella spp en leche cruda de bovino, Peru. Lima: SENASA PERU.

Shagñay, S., Arias, L., & Vaca, S. (2020). La evaluación de las curvas de producción lechera de las vacas Holstein Friesian en la estación experimental Tunshi Espoch. Ciencia Digital, 85-96.

Sheen, S., & Risco, A. (2002). Factores que afectan la producción de leche en vacas de doble propósito en trópico húmedo- Pucallpa. Revista de Investigación Veterinaria del Perú, 25-29.

Silvestre, A., Petim-Batista, F., & Colaço, J. (2006). La precisión de siete funciones matemáticas en el modelado de curvas de lactancia del ganado lechero pasadas en registros del día de prueba de diferentes esquemas. Journal of dairy science, 1813-1821. doi:10.3168/jds.S0022-0302(06)72250-0

Statham, J. (Marzo de 2023). Nutrición para la reproducción en el ganado vacuno. Obtenido de Manual de MSD (Manual de Veterinaria).

Thomsen, P., Kjeldsenc, A., & Hans, S. (30 de 01 de 2004). Mortalidad (incluida la eutanasia) entre las vacas lecheras danesas (1990-2001). Medicina Veterinaria Preventiva, 62, 19-33.

Torres Aburto, V. (2020). Análisis costo beneficio de la implementación de tecnologías para la mejora de parámetros reproductivos y productivos en bovinos en el trópico húmedo. Universidad Veracruzana, 1-147.

Trejo, L., Ruiz, F., Toledo, H., Duran, M., & Garcia, A. (2024). Modelación de curvas de lactancia para producción de leche, grasa y proteína, y evaluación de factores que las afectan en ganado Holstein en México. Revista Mexicana de Ciencias Pecuarias, 483-500.

Valera. (1996). Productividad de Vacas Holstein en la cuenca lechera de Lima y la magnitud de algunos Factores Ambientales que lo afectan. Universidad Nacional Agraria La Molina, 1-99.

Vasquez, A., Garcia, M., Sessarego, E., & Chagray, N. (2021). Modelación de la curva de lactación en vacas Holstein de un establo en el valle de Huaura, Perú. Revista de Investigacion Veterinaria Perú.

Vera Cedeño, J. A. (2017). Efectos del celo y el tratamiento con GnRH sobre la tasa de concepcion en programas de inseminacion artificial y transferencia de embriones bovinos. Universidad nacional de Cordoba, 48-64.

Veramendi Nina, F. H. (2021). Estandarizacion de la produccion de leche mediante metodos alternativos al registro estandar en vacunos lecheros. Universidad Cientifica del Sur, 34-35.

Viña Señarís, C. (2018). Eficiencia alimentaria en vacas de leche: su importancia y cómo mejorarla. NutriNews, 118-124.

Wilmink, J. (1987). Adjustment of test-day milk, fat and protein yield for age, season and stage of lactation. Livestock Production Science,, 335-348.

Wood, P. (1967). Algebraic Model of the Lactation Curve in Cattle. Nature 216, 164–165.

XII. ANEXOS

Anexo 1. Modelo de comandos empleados en el procesamiento de datos en el Rstudio para el “Primero objetivo”

SCRIPT (Producción real)

```
# Preparación de los datos
# Lectura de datos
library(car)
library(emmeans)
library(psych)
library(nortest)
library(readxl)
datos <- read_excel("D:/Users/Usuario/Documents/MIO/TESIS/EDICION/koraima/DATOS1.xlsx")
View(datos)
head(datos)
str(datos)
datos$CODIGO <- as.factor(datos$CODIGO)
datos$RAZA <- as.factor(datos$RAZA)
datos$INT_PART <- as.numeric(datos$INT_PART)
datos$N_LACT <- as.factor(datos$N_LACT)
datos$M_PARTO <- as.factor(datos$M_PARTO)
datos$ESTACION <- as.factor(datos$ESTACION)
datos$D_LACT <- as.numeric(datos$D_LACT)
datos$MES_YEAR <- as.factor(datos$MES_YEAR)
#attach(datos)
is.data.frame(datos)
#
# GENERAR SUB CONJUNTOS
LACT1<-subset(datos, N_LACT == "1")
LACT2<-subset(datos, N_LACT == "2")
LACT3<-subset(datos, N_LACT == "3")
LACT4<-subset(datos, N_LACT == "4")
LACT5<-subset(datos, N_LACT == "5")
#
#PRUEBA DE NORMALIDAD
boxplot(datos$PROM_REAL~datos$N_LACT)
#TEST DE SHAPIRO-WILKS
shapiro.test(LACT1$D_LACT)
shapiro.test(LACT2$D_LACT)
shapiro.test(LACT3$D_LACT)
shapiro.test(LACT4$D_LACT)
#shapiro.test(LACT5$D_LACT)
#
#PRUEBA DE KOLMOGOROV SMIRNOV
lillie.test(LACT1$PROM_REAL)
lillie.test(LACT2$PROM_REAL)
lillie.test(LACT3$PROM_REAL)
lillie.test(LACT4$PROM_REAL)
#lillie.test(LACT5$PROM_REAL)
#
#PRUEBA DE HOMOGENEIDAD DE VARIANZA "FLIGNER-KIILLEN Y LEVENNE"
fligner.test(datos$PROM_REAL ~ datos$N_LACT)
leveneTest(datos$PROM_REAL ~ datos$N_LACT,center = "median")
#
bartlett.test(datos$PROM_REAL~datos$N_LACT)
#
#modelo
MODELO1 <- aov(datos$PROM_STAND ~ datos$RAZA + datos$N_LACT + datos$MES_YEAR)
summary.lm(MODELO1)
#
#ANALISIS DE VARIANZA
anova(MODELO1)
#
#PRUEBA DE TUKEY usando libreria agricola
library(agricolae)
outhSD <-HSD.test(MODELO1, "datos$RAZA",console=TRUE)
outhSD <-HSD.test(MODELO1, "datos$N_LACT",console=TRUE)
outhSD <-HSD.test(MODELO1, "datos$MES_YEAR",console=TRUE)

#
#EVALUACION GRAFICA DE NORMALIDAD DE RESIDUOS DEL MODELO
#
qqnorm(MODELO1$residuals)
qqline(MODELO1$residuals)
par(mfrow = c(1,2))
plot(MODELO1, which = 1:4)
```

```

#
#normalidad de residuos
shapiro.test(MODELO1$residuals)

RESULTADOS

> # Preparación de los datos
> # Lectura de datos
> library(car)
> library(emmeans)
> library(psych)
> library(nortest)
> library(readxl)
> datos <- read_excel("D:/Users/Usuario/Documents/MIO/TESIS/EDICION/koraima/DATOS1.xlsx")
> View(datos)
> head(datos)
# A tibble: 6 × 10
  CODIGO RAZA INT_PART N_LACT M_PARTO ESTACION D_LACT MES_YEAR PROM_REAL PROM_STAND
  <dbl> <chr> <dbl> <dbl> <chr> <chr> <dbl> <chr> <dbl> <dbl>
1 1510 HO 759 2 abril LLUVIA 272 Abr_2017 4088. 4088.
2 1510 HO 1010 3 diciembre LLUVIA 362 Dic_2019 4445. 4079.
3 1535 HO 2217 2 marzo LLUVIA 386 Mar_2022 5089. 4484.
4 1547 HO 833 2 noviembre LLUVIA 149 Nov_2018 1498. 1498.
5 1547 HO 346 3 octubre SEQUIA 362 Oct_2019 5345. 4939.
6 1547 HO 546 4 abril LLUVIA 402 Abr_2021 6470. 5056.
> str(datos)
tibble [129 × 10] (S3: tbl_df/tbl/data.frame)
 $ CODIGO : num [1:129] 1510 1510 1535 1547 1547 ...
 $ RAZA : chr [1:129] "HO" "HO" "HO" "HO" ...
 $ INT_PART : num [1:129] 759 1010 2217 833 346 ...
 $ N_LACT : num [1:129] 2 3 2 2 3 4 5 2 3 2 ...
 $ M_PARTO : chr [1:129] "abril" "diciembre" "marzo" "noviembre" ...
 $ ESTACION : chr [1:129] "LLUVIA" "LLUVIA" "LLUVIA" "LLUVIA" ...
 $ D_LACT : num [1:129] 272 362 386 149 362 402 431 372 136 364 ...
 $ MES_YEAR : chr [1:129] "Abr_2017" "Dic_2019" "Mar_2022" "Nov_2018" ...
 $ PROM_REAL : num [1:129] 4088 4445 5089 1498 5345 ...
 $ PROM_STAND: num [1:129] 4088 4079 4484 1498 4939 ...
> datos$CODIGO <- as.factor(datos$CODIGO)
> datos$RAZA <- as.factor(datos$RAZA)
> datos$INT_PART <- as.numeric(datos$INT_PART)
> datos$N_LACT <- as.factor(datos$N_LACT)
> datos$M_PARTO <- as.factor(datos$M_PARTO)
> datos$ESTACION <- as.factor(datos$ESTACION)
> datos$D_LACT <- as.numeric(datos$D_LACT)
> datos$MES_YEAR <- as.factor(datos$MES_YEAR)
> #attach(datos)
> is.data.frame(datos)
[1] TRUE
> # GENERAR SUB CONJUNTOS
> LACT1<-subset(datos, N_LACT == "1")
> LACT2<-subset(datos, N_LACT == "2")
> LACT3<-subset(datos, N_LACT == "3")
> LACT4<-subset(datos, N_LACT == "4")
> LACT5<-subset(datos, N_LACT == "5")
> #
> #PRUEBA DE NORMALIDAD
> boxplot(datos$PROM_REAL~datos$N_LACT)
> #TEST DE SHAPIRO-WILKS
> shapiro.test(LACT1$D_LACT)
Shapiro-Wilk normality test
data: LACT1$D_LACT
W = 0.934, p-value = 0.01442
> shapiro.test(LACT2$D_LACT)
Shapiro-Wilk normality test
data: LACT2$D_LACT
W = 0.92295, p-value = 0.006718
> shapiro.test(LACT3$D_LACT)
Shapiro-Wilk normality test
data: LACT3$D_LACT
W = 0.94284, p-value = 0.157
> shapiro.test(LACT4$D_LACT)
Shapiro-Wilk normality test
data: LACT4$D_LACT
W = 0.96495, p-value = 0.8029
> #shapiro.test(LACT5$D_LACT)
> #PRUEBA DE KOLMOGOROV SMIRNOV

```

```

> lillie.test(LACT1$PROM_REAL)
      Lilliefors (Kolmogorov-Smirnov) normality test
data:  LACT1$PROM_REAL
D = 0.095169, p-value = 0.4056
> lillie.test(LACT2$PROM_REAL)
      Lilliefors (Kolmogorov-Smirnov) normality test
data:  LACT2$PROM_REAL
D = 0.10871, p-value = 0.2279
> lillie.test(LACT3$PROM_REAL)
      Lilliefors (Kolmogorov-Smirnov) normality test
data:  LACT3$PROM_REAL
D = 0.12812, p-value = 0.3326
> lillie.test(LACT4$PROM_REAL)
      Lilliefors (Kolmogorov-Smirnov) normality test
data:  LACT4$PROM_REAL
D = 0.15014, p-value = 0.5325
> #lillie.test(LACT5$PROM_REAL)
> #
> #PRUEBA DE HOMOGENEIDAD DE VARIANZA "FLIGNER-KIILLEN Y LEVENNE"
> fligner.test(datos$PROM_REAL ~ datos$N_LACT)
      Fligner-Killeen test of homogeneity of variances
data:  datos$PROM_REAL by datos$N_LACT
Fligner-Killeen:med chi-squared = 1.1176, df = 4, p-value = 0.8915
> leveneTest(datos$PROM_REAL ~ datos$N_LACT,center = "median")
Levene's Test for Homogeneity of Variance (center = "median")
      Df F value Pr(>F)
group  4  0.1855 0.9456
      124
> #
> bartlett.test(datos$PROM_REAL~datos$N_LACT)
      Bartlett test of homogeneity of variances
data:  datos$PROM_REAL by datos$N_LACT
Bartlett's K-squared = 1.0411, df = 4, p-value = 0.9035
> #
> #modelo
> MODELO1 <- aov(datos$PROM_REAL ~ datos$RAZA + datos$N_LACT + datos$MES_YEAR)
> summary.lm(MODELO1)
Call:
aov(formula = datos$PROM_REAL ~ datos$RAZA + datos$N_LACT + datos$MES_YEAR)
Residuals:
      Min       1Q   Median       3Q      Max
-2966.7  -996.9    0.0   874.3  3299.6
Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)      4013.3     1279.1   3.138  0.00257 **
datos$RAZAH0         919.3     1081.1   0.850  0.39831
datos$RAZAH0 HIBRIDO  1342.6     1136.2   1.182  0.24173
datos$N_LACT2         765.2     599.2   1.277  0.20624
datos$N_LACT3        1656.2     712.2   2.325  0.02323 *
datos$N_LACT4        1391.9     805.3   1.728  0.08873 .
datos$N_LACT5         301.0     1563.6   0.192  0.84797
datos$MES_YEARAbr_2020  -612.6     2235.8  -0.274  0.78498
datos$MES_YEARAbr_2021 -1553.4     1638.3  -0.948  0.34662
datos$MES_YEARAbr_2023 -1093.7     2226.7  -0.491  0.62497
datos$MES_YEARAgo_2019 -1073.2     2121.3  -0.506  0.61464
datos$MES_YEARAgo_2021  -868.2     1445.6  -0.601  0.55026
datos$MES_YEARAgo_2023 -1066.7     1433.6  -0.744  0.45956
datos$MES_YEARDic_2019  -931.7     1642.2  -0.567  0.57246
datos$MES_YEARDic_2020 -4049.2     1354.9  -2.989  0.00397 **
datos$MES_YEARDic_2021 -1895.6     1668.1  -1.136  0.26004
datos$MES_YEARDic_2022  2704.5     1685.5   1.605  0.11351
datos$MES_YEARDic_2023 -1530.4     2235.8  -0.684  0.49614
datos$MES_YEAREne_2017  -276.5     2121.3  -0.130  0.89670
datos$MES_YEAREne_2021 -3209.4     1362.8  -2.355  0.02160 *
datos$MES_YEAREne_2022 -2403.7     1752.6  -1.372  0.17500
datos$MES_YEAREne_2023 -2756.3     1209.5  -2.279  0.02602 *
datos$MES_YEARFeb_2017   964.8     2121.3   0.455  0.65078
datos$MES_YEARFeb_2021 -2344.6     1685.5  -1.391  0.16902
datos$MES_YEARFeb_2022 -1968.2     2071.7  -0.950  0.34565
datos$MES_YEARFeb_2023  -791.6     1668.1  -0.475  0.63674
datos$MES_YEARJul_2020 -4586.8     2163.7  -2.120  0.03790 *
datos$MES_YEARJul_2021 -1031.4     1642.2  -0.628  0.53219
datos$MES_YEARJul_2022 -1874.8     2163.7  -0.866  0.38946
datos$MES_YEARJul_2023 -4999.1     2163.7  -2.310  0.02410 *
datos$MES_YEARJun_2018 -2405.6     2071.7  -1.161  0.24987
datos$MES_YEARJun_2020 -2142.0     2121.3  -1.010  0.31640
datos$MES_YEARJun_2021  -379.2     1642.2  -0.231  0.81814

```

```

datos$MES_YEARJun_2022 -2133.7      1457.2    -1.464    0.14802
datos$MES_YEARJun_2023 -3927.3      2121.3    -1.851    0.06873 .
datos$MES_YEARMar_2019  -813.1      1271.6    -0.639    0.52485
datos$MES_YEARMar_2021 -4549.4      1682.1    -2.705    0.00875 **
datos$MES_YEARMar_2022 -1102.3      1638.3    -0.673    0.50349
datos$MES_YEARMar_2023  -970.3      1168.1    -0.831    0.40927
datos$MES_YEARMay_2017  -752.6      2071.7    -0.363    0.71759
datos$MES_YEARMay_2018  1039.6      1404.4     0.740    0.46183
datos$MES_YEARMay_2019  1176.1      2071.7     0.568    0.57222
datos$MES_YEARMay_2020 -3203.1      1433.6    -2.234    0.02896 *
datos$MES_YEARMay_2021 -3273.1      2130.9    -1.536    0.12945
datos$MES_YEARMay_2023 -2703.1      1292.2    -2.092    0.04043 *
datos$MES_YEARNov_2017  -231.6      2121.3    -0.109    0.91340
datos$MES_YEARNov_2018 -4200.0      2071.7    -2.027    0.04679 *
datos$MES_YEARNov_2019 -1934.0      1452.2    -1.332    0.18766
datos$MES_YEARNov_2020  -884.8      2130.9    -0.415    0.67935
datos$MES_YEARNov_2021 -1680.8      1678.8    -1.001    0.32051
datos$MES_YEARNov_2022  3496.1      2071.7     1.688    0.09636 .
datos$MES_YEARNov_2023 -3871.3      1642.2    -2.357    0.02147 *
datos$MES_YEAROct_2017 -2488.1      2071.7    -1.201    0.23417
datos$MES_YEAROct_2018 -1680.8      1615.7    -1.040    0.30211
datos$MES_YEAROct_2019 -2026.1      1732.1    -1.170    0.24645
datos$MES_YEAROct_2020 -2512.3      2071.7    -1.213    0.22970
datos$MES_YEAROct_2021 -3973.5      2171.2    -1.830    0.07189 .
datos$MES_YEAROct_2022  -678.8      1373.1    -0.494    0.62274
datos$MES_YEAROct_2023 -1886.4      1277.1    -1.477    0.14454
datos$MES_YEARSet_2017  -1522.7      2163.7    -0.704    0.48414
datos$MES_YEARSet_2019   621.1      2171.2     0.286    0.77574
datos$MES_YEARSet_2020 -4267.1      1661.7    -2.568    0.01258 *
datos$MES_YEARSet_2021 -2614.1      2121.3    -1.232    0.22233
datos$MES_YEARSet_2022 -2777.5      2226.7    -1.247    0.21680
datos$MES_YEARSet_2023 -1515.2      2226.7    -0.680    0.49865
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
Residual standard error: 1834 on 64 degrees of freedom
Multiple R-squared:  0.5807, Adjusted R-squared:  0.1615
F-statistic: 1.385 on 64 and 64 DF, p-value: 0.09758
> #
> #ANALISIS DE VARIANZA
> anova(MODELO1)
Analysis of Variance Table
Response: datos$PROM_REAL
          Df    Sum Sq Mean Sq F value    Pr(>F)
datos$RAZA      2    5526818  2763409   0.8218  0.44423
datos$N_LACT     4   14652257  3663064   1.0893  0.36939
datos$MES_YEAR  58  277933325  4791954   1.4250  0.08372 .
Residuals      64  215212083  3362689
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> #
> #PRUEBA DE TUKEY usando libreria agricola
> library(agricolae)
> outHSD <-HSD.test(MODELO1, "datos$RAZA",console=TRUE)
Study: MODELO1 ~ "datos$RAZA"
HSD Test for datos$PROM_REAL
Mean Square Error: 3362689
datos$RAZA, means
      datos.PROM_REAL      std      r      se      Min      Max      Q25      Q50      Q75
BS          3268.733 2445.066   6 748.6308 1566.5 8078.1 1876.300 2428.30 3171.250
HO          4011.767 1990.437  96 187.1577  837.3 9193.9 2540.025 3757.35 5105.225
HO HIBRIDO    4303.981 1976.118  27 352.9080 1021.7 8032.5 2536.450 4527.60 5659.400
Alpha: 0.05 ; DF Error: 64
Critical Value of Studentized Range: 3.393297
Groups according to probability of means differences and alpha level( 0.05 )
Treatments with the same letter are not significantly different.
      datos$PROM_REAL groups
HO HIBRIDO    4303.981      a
HO          4011.767      a
BS          3268.733      a
> outHSD <-HSD.test(MODELO1, "datos$N_LACT",console=TRUE)

Study: MODELO1 ~ "datos$N_LACT"
HSD Test for datos$PROM_REAL
Mean Square Error: 3362689
datos$N_LACT, means
      datos.PROM_REAL      std      r      se      Min      Max      Q25      Q50      Q75
1          3625.061 2000.462  44 276.4503 1005.3 8682.00 1778.775 3505.80 4837.600

```

```

2      4156.383 2004.022 43  279.6463  837.3 9193.90 2729.900 3734.20 5194.600
3      4258.723 2095.936 26  359.6306 1379.5 8032.50 2147.050 4369.05 5458.825
4      4640.251 1718.741 14  490.0939 2351.0 6945.61 3000.525 4494.60 6248.008
5      3516.050 3057.318  2 1296.6666 1354.2 5677.90 2435.125 3516.05 4596.975

Alpha: 0.05 ; DF Error: 64
Critical Value of Studentized Range: 3.969792
Groups according to probability of means differences and alpha level( 0.05 )
Treatments with the same letter are not significantly different.
  datos$PROM_REAL groups
4      4640.251      a
3      4258.723      a
2      4156.383      a
1      3625.061      a
5      3516.050      a
> outHSD <-HSD.test(MODELO1, "datos$MES_YEAR",console=TRUE)

> #
> #EVALUACION GRAFICA DE NORMALIDAD DE RESIDUOS DEL MODELO
> #
> qqnorm(MODELO1$residuals)
> qqline(MODELO1$residuals)
> par(mfrow = c(1,2))
> plot(MODELO1, which = 1:4)
<Enter> para ver el próximo gráfico: #
<Enter> para ver el próximo gráfico: #
Warning message:
not plotting observations with leverage one:
  4, 9, 10, 11, 12, 16, 18, 25, 30, 36, 37, 40, 45, 52, 54, 55, 60, 62, 65, 75, 78, 80, 90,
93, 97, 98, 122, 128
> #normalidad de residuos
> shapiro.test(MODELO1$residuals)
      Shapiro-Wilk normality test
data:  MODELO1$residuals
W = 0.97812, p-value = 0.03496

```

SCRIPT (Producción estándar 305d)

```

# Preparación de los datos
# Lectura de datos
library(car)
library(emmeans)
library(psych)
library(nortest)
setwd("E:/INVESTIGACIONES UNSAAC/KORAIMA/DATOS KORAIMA")
datos<-read.csv('DATOS11.csv', header = T, sep = ";")
head(datos)
str(datos)
datos$CODIGO <- as.factor(datos$CODIGO)
datos$RAZA <- as.factor(datos$RAZA)
datos$INT_PART <- as.numeric(datos$INT_PART)
datos$N_LACT <- as.factor(datos$N_LACT)
datos$M_PARTO <- as.factor(datos$M_PARTO)
datos$ESTACION <- as.factor(datos$ESTACION)
datos$D_LACT <- as.numeric(datos$D_LACT)
datos$MES_YEAR <- as.factor(datos$MES_YEAR)
#attach(datos)
is.data.frame(datos)
#
# GENERAR SUB CONJUNTOS
LACT1<-subset(datos, N_LACT == "1")
LACT2<-subset(datos, N_LACT == "2")
LACT3<-subset(datos, N_LACT == "3")
LACT4<-subset(datos, N_LACT == "4")
LACT5<-subset(datos, N_LACT == "5")
#
#PRUEBA DE NORMALIDAD
boxplot(datos$PROD_STAND~datos$N_LACT)
#TEST DE SHAPIRO-WILKS
shapiro.test(LACT1$PROD_STAND)
shapiro.test(LACT2$PROD_STAND)
shapiro.test(LACT3$PROD_STAND)
shapiro.test(LACT4$PROD_STAND)
#shapiro.test(LACT5$PROD_STAND)
#
#PRUEBA DE KOLMOGOROV SMIRNOV

```

```

lillie.test(LACT1$PROD_STAND)
lillie.test(LACT2$PROD_STAND)
lillie.test(LACT3$PROD_STAND)
lillie.test(LACT4$PROD_STAND)
#lillie.test(LACT5$PROD_STAND)
#
#PRUEBA DE HOMOGENEIDAD DE VARIANZA "FLIGNER-KILLEN Y LEVENNE"
fligner.test(datos$PROD_STAND~datos$N_LACT)
leveneTest(datos$PROD_STAND~datos$N_LACT,center = "median")
#
bartlett.test(datos$PROD_STAND~datos$N_LACT)
#
#modelo
MODELO1 <- aov(PROD_STAND ~ RAZA + N_LACT + MES_YEAR, data = datos)
summary.lm(MODELO1)
#
#ANALISIS DE VARIANZA
anova(MODELO1)
#
#PRUEBA DE TUKEY usando libreria agricola
library(agricolae)
outhSD <-HSD.test(MODELO1, "RAZA",console=TRUE)
outhSD <-HSD.test(MODELO1, "N_LACT",console=TRUE)
outhSD <-HSD.test(MODELO1, "MES_YEAR",console=TRUE)
#EVALUACION GRAFICA DE NORMALIDAD DE RESIDUOS DEL MODELO
qqnorm(MODELO1$residuals)
qqline(MODELO1$residuals)
par(mfrow = c(1,2))
plot(MODELO1, which = 1:4)
#
#
#normalidad de residuos
shapiro.test(MODELO1$residuals)

```

RESULTADOS

```

> # Preparación de los datos
> # Lectura de datos
> library(car)
> library(emmeans)
> library(psych)
> library(nortest)
> setwd("E:/INVESTIGACIONES UNSAAC/KORAIMA/DATOS KORAIMA")
> datos<-read.csv('DATOS11.csv', header = T, sep = ";")
> head(datos)
  CODIGO RAZA Fecha_NAC INT_PARTOS N_LACT Fecha_PARTO Fecha_INI_LACT M_PARTO ESTACION YEAR
1  1510  HO 20/07/2012      759      2  3/03/2017    5/04/2017    abril  LLUVIA 2017
2  1510  HO 20/07/2012     1010      3  8/12/2019    15/12/2019  diciembre  LLUVIA 2019
3  1535  HO 14/03/2018       NA      2 15/03/2022    21/03/2022    marzo  LLUVIA 2022
4  1547  HO 12/12/2013      833      2  7/11/2018    9/11/2018  noviembre  LLUVIA 2018
5  1547  HO 12/12/2013      346      3 19/10/2019    25/10/2019    octubre  SEQUIA 2019
6  1547  HO 12/12/2013      546      4 17/04/2021    23/04/2021    abril  LLUVIA 2021
  MES_YEAR PROD_REAL PROD_STAND D_LACT
1  Abr-17    4088.1    4088.1    272
2  Dic-19    4444.6    4079.2    362
3  Mar-22    5089.3    4484.4    386
4  Nov-18    1497.8    1497.8    149
5  Oct-19    5344.9    4939.1    362
6  Abr-21       NA    5055.8    402
> str(datos)
'data.frame': 129 obs. of 14 variables:
 $ CODIGO      : int  1510 1510 1535 1547 1547 1547 1547 1548 1548 1554 ...
 $ RAZA        : chr   "HO" "HO" "HO" "HO" ...
 $ Fecha_NAC   : chr   "20/07/2012" "20/07/2012" "14/03/2018" "12/12/2013" ...
 $ INT_PARTOS  : int   759 1010 NA 833 346 546 551 468 1188 502 ...
 $ N_LACT      : int    2 3 2 2 3 4 5 2 3 2 ...
 $ Fecha_PARTO : chr   "3/03/2017" "8/12/2019" "15/03/2022" "7/11/2018" ...
 $ Fecha_INI_LACT: chr   "5/04/2017" "15/12/2019" "21/03/2022" "9/11/2018" ...
 $ M_PARTO     : chr   "abril" "diciembre" "marzo" "noviembre" ...
 $ ESTACION    : chr   "LLUVIA" "LLUVIA" "LLUVIA" "LLUVIA" ...
 $ YEAR        : int   2017 2019 2022 2018 2019 2021 2022 2017 2020 2017 ...
 $ MES_YEAR    : chr   "Abr-17" "Dic-19" "Mar-22" "Nov-18" ...
 $ PROD_REAL   : num   4088 4445 5089 1498 5345 ...
 $ PROD_STAND  : num   4088 4079 4484 1498 4939 ...
 $ D_LACT      : int   272 362 386 149 362 402 431 372 136 364 ...
> datos$CODIGO <- as.factor(datos$CODIGO)
> datos$RAZA <- as.factor(datos$RAZA)
> datos$INT_PART <- as.numeric(datos$INT_PART)
> datos$N_LACT <- as.factor(datos$N_LACT)
> datos$M_PARTO <- as.factor(datos$M_PARTO)

```

```

> datos$ESTACION <- as.factor(datos$ESTACION)
> datos$D_LACT <- as.numeric(datos$D_LACT)
> datos$MES_YEAR <- as.factor(datos$MES_YEAR)
> #attach(datos)
> is.data.frame(datos)
[1] TRUE
> #
> # GENERAR SUB CONJUNTOS
> LACT1<-subset(datos, N_LACT == "1")
> LACT2<-subset(datos, N_LACT == "2")
> LACT3<-subset(datos, N_LACT == "3")
> LACT4<-subset(datos, N_LACT == "4")
> LACT5<-subset(datos, N_LACT == "5")
> #
> #PRUEBA DE NORMALIDAD
> boxplot(datos$PROD_STAND~datos$N_LACT)
> #TEST DE SHAPIRO-WILKS
> shapiro.test(LACT1$PROD_STAND)
      Shapiro-Wilk normality test
data:  LACT1$PROD_STAND
W = 0.96688, p-value = 0.2338
> shapiro.test(LACT2$PROD_STAND)
      Shapiro-Wilk normality test
data:  LACT2$PROD_STAND
W = 0.98367, p-value = 0.79
> shapiro.test(LACT3$PROD_STAND)
      Shapiro-Wilk normality test
data:  LACT3$PROD_STAND
W = 0.93956, p-value = 0.1311
> shapiro.test(LACT4$PROD_STAND)
      Shapiro-Wilk normality test
data:  LACT4$PROD_STAND
W = 0.94955, p-value = 0.5537
> #shapiro.test(LACT5$PROD_STAND)
> #
> #PRUEBA DE KOLMOGOROV SMIRNOV
> lillie.test(LACT1$PROD_STAND)
      Lilliefors (Kolmogorov-Smirnov) normality test
data:  LACT1$PROD_STAND
D = 0.097667, p-value = 0.3647
> lillie.test(LACT2$PROD_STAND)
      Lilliefors (Kolmogorov-Smirnov) normality test
data:  LACT2$PROD_STAND
D = 0.093927, p-value = 0.4447
> lillie.test(LACT3$PROD_STAND)
      Lilliefors (Kolmogorov-Smirnov) normality test
data:  LACT3$PROD_STAND
D = 0.13939, p-value = 0.2164
> lillie.test(LACT4$PROD_STAND)
      Lilliefors (Kolmogorov-Smirnov) normality test
data:  LACT4$PROD_STAND
D = 0.12542, p-value = 0.7965
> #lillie.test(LACT5$PROD_STAND)
> #
> #PRUEBA DE HOMOGENEIDAD DE VARIANZA "FLIGNER-KIILLEN Y LEVENNE"
> fligner.test(datos$PROD_STAND~datos$N_LACT)
      Fligner-Killeen test of homogeneity of variances
data:  datos$PROD_STAND by datos$N_LACT
Fligner-Killeen:med chi-squared = 3.6595, df = 4, p-value = 0.454
> leveneTest(datos$PROD_STAND~datos$N_LACT,center = "median")
Levene's Test for Homogeneity of Variance (center = "median")
      Df F value Pr(>F)
group  4  1.0718 0.3734
      124
> #
> bartlett.test(datos$PROD_STAND~datos$N_LACT)
      Bartlett test of homogeneity of variances
data:  datos$PROD_STAND by datos$N_LACT
Bartlett's K-squared = 2.9067, df = 4, p-value = 0.5736
> #
> #modelo
> MODELO1 <- aov(PROD_STAND ~ RAZA + N_LACT + MES_YEAR, data = datos)
> summary.lm(MODELO1)
Call:
aov(formula = PROD_STAND ~ RAZA + N_LACT + MES_YEAR, data = datos)
Residuals:
      Min       1Q   Median       3Q      Max

```

```

-1793.2 -421.0      0.0  341.7 1760.5
Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept)  3827.39    702.95   5.445 8.22e-07 ***
RAZAH0       810.40    589.49   1.375 0.173862
RAZAH0 HIBRIDO 860.90    615.97   1.398 0.166900
N_LACT2      182.94    339.63   0.539 0.591933
N_LACT3      767.76    398.89   1.925 0.058575 .
N_LACT4      688.52    452.33   1.522 0.132748
N_LACT5       92.08    855.90   0.108 0.914656
MES_YEARAbr-20 -639.69   1233.10  -0.519 0.605660
MES_YEARAbr-21 -1323.04   905.47  -1.461 0.148715
MES_YEARAbr-23 -1540.26   1235.50  -1.247 0.216925
MES_YEARAg0-19 -1187.09   1173.54  -1.012 0.315450
MES_YEARAg0-20 -1635.24   1144.29  -1.429 0.157708
MES_YEARAg0-21 -1050.20   743.70  -1.412 0.162607
MES_YEARAg0-23 -888.34   1144.29  -0.776 0.440332
MES_YEARDic-19 -777.00    907.10  -0.857 0.394780
MES_YEARDic-20 -2834.75   696.28  -4.071 0.000128 ***
MES_YEARDic-22 -1266.04   932.94  -1.357 0.179391
MES_YEARDic-23 -1344.49   1233.10  -1.090 0.279532
MES_YEAREn0-17 -1020.39   1173.54  -0.869 0.387727
MES_YEAREn0-21 -2788.16   753.77  -3.699 0.000443 ***
MES_YEAREn0-22 -1136.81   972.05  -1.169 0.246409
MES_YEAREn0-23 -2463.62   669.11  -3.682 0.000468 ***
MES_YEARFeb-17 -528.99   1173.54  -0.451 0.653637
MES_YEARFeb-21 -2339.64   932.94  -2.508 0.014615 *
MES_YEARFeb-22 -1091.14   1144.29  -0.954 0.343791
MES_YEARFeb-23 -1753.42   922.60  -1.901 0.061733 .
MES_YEARJul-20 -3403.56   1196.30  -2.845 0.005908 **
MES_YEARJul-21 -2070.12   822.10  -2.518 0.014233 *
MES_YEARJul-22 -1483.46   1196.30  -1.240 0.219352
MES_YEARJul-23 -1730.59   1173.54  -1.475 0.145055
MES_YEARJun-18 -1528.54   1144.29  -1.336 0.186204
MES_YEARJun-20 -1847.19   1173.54  -1.574 0.120263
MES_YEARJun-21 -665.84   1144.29  -0.582 0.562631
MES_YEARJun-22 -1669.03   805.72  -2.071 0.042226 *
MES_YEARJun-23 -3632.49   1173.54  -3.095 0.002884 **
MES_YEARMar-19 -1399.65   703.83  -1.989 0.050893 .
MES_YEARMar-21 -3207.45   838.10  -3.827 0.000291 ***
MES_YEARMar-22 -731.82    905.47  -0.808 0.421864
MES_YEARMar-23 -1593.43   652.84  -2.441 0.017347 *
MES_YEARMay-17 -368.14   1144.29  -0.322 0.748684
MES_YEARMay-18  403.29    778.08   0.518 0.605976
MES_YEARMay-19  527.86   1144.29   0.461 0.646098
MES_YEARMay-20 -2395.89   791.50  -3.027 0.003520 **
MES_YEARMay-21 -1448.45   919.13  -1.576 0.119833
MES_YEARMay-23 -2391.55   715.17  -3.344 0.001364 **
MES_YEARNov-18 -3322.94   1144.29  -2.904 0.005008 **
MES_YEARNov-19 -1677.87   802.93  -2.090 0.040504 *
MES_YEARNov-20 -1128.14   1176.79  -0.959 0.341230
MES_YEARNov-21 -1585.79   929.52  -1.706 0.092704 .
MES_YEARNov-22 -4026.06   1196.30  -3.365 0.001277 **
MES_YEARNov-23 -1656.24   1144.29  -1.447 0.152520
MES_YEAROct-17 -906.81    895.13  -1.013 0.314736
MES_YEAROct-18 -1123.54   892.30  -1.259 0.212411
MES_YEAROct-19 -1325.91   958.09  -1.384 0.171048
MES_YEAROct-21 -2975.31   1200.00  -2.479 0.015721 *
MES_YEAROct-22 -1177.82   713.70  -1.650 0.103631
MES_YEAROct-23 -1561.80   705.90  -2.213 0.030396 *
MES_YEARSet-18 -339.46   1196.30  -0.284 0.777486
MES_YEARSet-19  1.00    1200.00   0.001 0.999338
MES_YEARSet-20 -3054.05   919.13  -3.323 0.001457 **
MES_YEARSet-21 -2319.29   1173.54  -1.976 0.052301 .
MES_YEARSet-22 -2101.66   1235.50  -1.701 0.093639 .
MES_YEARSet-23 -1616.06   1235.50  -1.308 0.195403
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 1013 on 66 degrees of freedom
Multiple R-squared:  0.6155, Adjusted R-squared:  0.2543
F-statistic: 1.704 on 62 and 66 DF, p-value: 0.01706
> #
> #ANALISIS DE VARIANZA
> anova(MODELO1)
Analysis of Variance Table
Response: PROD_STAND

```

```

      Df    Sum Sq Mean Sq F value    Pr(>F)
RAZA      2  1758357  879178   0.8566 0.42928
N_LACT     4  7239171 1809793   1.7632 0.14679
MES_YEAR  56 99436915 1775659   1.7300 0.01641 *
Residuals 66 67742486 1026401
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> #
> #PRUEBA DE TUKEY usando libreria agricola
> library(agricolae)
> outHSD <-HSD.test(MODELO1, "RAZA",console=TRUE)

Study: MODELO1 ~ "RAZA"

HSD Test for PROD_STAND

Mean Square Error: 1026401

RAZA, means
      PROD_STAND      std r      se    Min    Max      Q25      Q50      Q75
BS      2839.700 1525.777  6 413.6023 1566.5 5716.9 1876.300 2428.3 3011.500
HO      3312.090 1194.403 96 103.4006  837.3 5872.9 2540.025 3340.0 4165.925
HO HIBRIDO 3131.541 1023.789 27 194.9740 1021.7 4181.8 2536.450 3382.2 3931.500
Alpha: 0.05 ; DF Error: 66
Critical Value of Studentized Range: 3.390864
Groups according to probability of means differences and alpha level( 0.05 )
Treatments with the same letter are not significantly different.
      PROD_STAND groups
HO      3312.090      a
HO HIBRIDO 3131.541      a
BS      2839.700      a
> outHSD <-HSD.test(MODELO1, "N_LACT",console=TRUE)
Study: MODELO1 ~ "N_LACT"
HSD Test for PROD_STAND
Mean Square Error: 1026401
N_LACT, means
      PROD_STAND      std r      se    Min    Max      Q25      Q50      Q75
1  2938.013 1221.2828 44 152.7328 1005.3 5872.90 1778.775 3042.95 3659.250
2  3372.181 1087.3535 43 154.4985  837.3 5716.90 2729.900 3375.20 4099.750
3  3400.308 1237.9815 26 198.6881 1379.5 5596.40 2147.050 3677.05 4144.325
4  3646.273  931.9129 14 270.7663 2351.0 5327.31 2887.425 3665.55 4113.150
5  2909.150 2199.0314  2 716.3802 1354.2 4464.10 2131.675 2909.15 3686.625

Alpha: 0.05 ; DF Error: 66
Critical Value of Studentized Range: 3.966331
Groups according to probability of means differences and alpha level( 0.05 )
Treatments with the same letter are not significantly different.
      PROD_STAND groups
4  3646.273      a
3  3400.308      a
2  3372.181      a
1  2938.013      a
5  2909.150      a
> outHSD <-HSD.test(MODELO1, "MES_YEAR",console=TRUE)
Study: MODELO1 ~ "MES_YEAR"
HSD Test for PROD_STAND
Mean Square Error: 1026401
> #EVALUACION GRAFICA DE NORMALIDAD DE RESIDUOS DEL MODELO
> #
> qqnorm(MODELO1$residuals)
> qqline(MODELO1$residuals)
> par(mfrow = c(1,2))
> plot(MODELO1, which = 1:4)
<Enter> para ver el próximo gráfico: #
<Enter> para ver el próximo gráfico: #
Aviso:
not plotting observations with leverage one:
  4, 9, 10, 11, 12, 16, 25, 30, 37, 45, 52, 54, 55, 60, 62, 65, 78, 79, 80, 82, 87, 90, 97,
98, 101, 122, 127, 128
> #normalidad de residuos
> shapiro.test(MODELO1$residuals)
      Shapiro-Wilk normality test
data:  MODLO1$residuals
W = 0.96924, p-value = 0.004962

```

SCRIPT (Prom_real)

```

# Preparación de los datos
# Lectura de datos
library(car)
library(emmeans)
library(psych)
library(nortest)
setwd("E:/INVESTIGACIONES UNSAAC/KORAIMA/DATOS KORAIMA")
datos<-read.csv('DATOS11.csv', header = T, sep = ";")
head(datos)
str(datos)
datos$CODIGO <- as.factor(datos$CODIGO)
datos$RAZA <- as.factor(datos$RAZA)
datos$INT_PART <- as.numeric(datos$INT_PART)
datos$N_LACT <- as.factor(datos$N_LACT)
datos$M_PARTO <- as.factor(datos$M_PARTO)
datos$ESTACION <- as.factor(datos$ESTACION)
datos$D_LACT <- as.numeric(datos$D_LACT)
datos$MES_YEAR <- as.factor(datos$MES_YEAR)
#attach(datos)
is.data.frame(datos)
#
# GENERAR SUB CONJUNTOS
LACT1<-subset(datos, N_LACT == "1")
LACT2<-subset(datos, N_LACT == "2")
LACT3<-subset(datos, N_LACT == "3")
LACT4<-subset(datos, N_LACT == "4")
LACT5<-subset(datos, N_LACT == "5")
#
#PRUEBA DE NORMALIDAD
boxplot(datos$PROM_REAL~datos$N_LACT)
#TEST DE SHAPIRO-WILKS
shapiro.test(LACT1$D_LACT)
shapiro.test(LACT2$D_LACT)
shapiro.test(LACT3$D_LACT)
shapiro.test(LACT4$D_LACT)
#shapiro.test(LACT5$PROD_STAND)
#
#PRUEBA DE KOLMOGOROV SMIRNOV
lillie.test(LACT1$PROM_REAL)
lillie.test(LACT2$PROM_REAL)
lillie.test(LACT3$PROM_REAL)
lillie.test(LACT4$PROM_REAL)
#lillie.test(LACT5$PROM_REAL)
#
#PRUEBA DE HOMOGENEIDAD DE VARIANZA "FLIGNER-KIILLEN Y LEVENNE"
fligner.test(datos$PROD_REAL~datos$N_LACT)
leveneTest(datos$PROD_REAL~datos$N_LACT,center = "median")
#
bartlett.test(datos$PROM_REAL~datos$N_LACT)
#
#modelo
MODELO1 <- aov(PROM_REAL ~ RAZA + N_LACT + MES_YEAR, data = datos)
summary.lm(MODELO1)
#
#ANALISIS DE VARIANZA
anova(MODELO1)
#
#PRUEBA DE TUKEY usando libreria agricola
library(agricolae)
outhSD <-HSD.test(MODELO1, "RAZA",console=TRUE)
outhSD <-HSD.test(MODELO1, "N_LACT",console=TRUE)
outhSD <-HSD.test(MODELO1, "MES_YEAR",console=TRUE)
#
#EVALUACION GRAFICA DE NORMALIDAD DE RESIDUOS DEL MODELO
#
qqnorm(MODELO1$residuals)
qqline(MODELO1$residuals)
par(mfrow = c(1,2))
plot(MODELO1, which = 1:4)
#
#
#normalidad de residuos
shapiro.test(MODELO1$residuals)

```

RESULTADOS

```
> # Preparación de los datos
```

```

> # Lectura de datos
> library(car)
> library(emmeans)
> library(psych)
> library(nortest)
> setwd("E:/INVESTIGACIONES UNSAAC/KORAIMA/DATOS KORAIMA")
> datos<-read.csv('DATOS11.csv', header = T, sep = ";")
> head(datos)
  NRO CODIGO RAZA      F_NAC INT_PARTOS N_LACT      F_PARTO F_INI_LACT  M_PARTO ESTACION YEAR
1   1   1510   HO 20/07/2012      759      2 3/03/2017 5/04/2017   abril  LLUVIA 2017
2   2   1510   HO 20/07/2012     1010      3 8/12/2019 15/12/2019 diciembre LLUVIA 2019
3   3   1535   HO 14/03/2018     2217      2 15/03/2022 21/03/2022   marzo  LLUVIA 2022
4   4   1547   HO 12/12/2013      833      2 7/11/2018 9/11/2018 noviembre LLUVIA 2018
5   5   1547   HO 12/12/2013      346      3 19/10/2019 25/10/2019  octubre SEQUIA 2019
6   6   1547   HO 12/12/2013      546      4 17/04/2021 23/04/2021   abril  LLUVIA 2021
  MES_YEAR PROD_REAL PROD_STAND D_LACT PROM_REAL PROM_STAND
1  Abr-17   4088.1    4088.1    272    15.03    15.03
2  Dic-19   4444.6    4079.2    362    12.28    13.37
3  Mar-22   5089.3    4484.4    386    13.18    14.70
4  Nov-18   1497.8    1497.8    149    10.05    10.05
5  Oct-19   5344.9    4939.1    362    14.76    16.19
6  Abr-21   6470.3    5055.8    402    16.10    16.58
> str(datos)
'data.frame': 129 obs. of 17 variables:
 $ NRO      : int  1 2 3 4 5 6 7 8 9 10 ...
 $ CODIGO   : int  1510 1510 1535 1547 1547 1547 1547 1548 1548 1554 ...
 $ RAZA     : chr  "HO" "HO" "HO" "HO" ...
 $ F_NAC    : chr  "20/07/2012" "20/07/2012" "14/03/2018" "12/12/2013" ...
 $ INT_PARTOS: int  759 1010 2217 833 346 546 551 468 1188 502 ...
 $ N_LACT   : int  2 3 2 2 3 4 5 2 3 2 ...
 $ F_PARTO  : chr  "3/03/2017" "8/12/2019" "15/03/2022" "7/11/2018" ...
 $ F_INI_LACT: chr  "5/04/2017" "15/12/2019" "21/03/2022" "9/11/2018" ...
 $ M_PARTO  : chr  "abril" "diciembre" "marzo" "noviembre" ...
 $ ESTACION : chr  "LLUVIA" "LLUVIA" "LLUVIA" "LLUVIA" ...
 $ YEAR     : int  2017 2019 2022 2018 2019 2021 2022 2017 2020 2017 ...
 $ MES_YEAR : chr  "Abr-17" "Dic-19" "Mar-22" "Nov-18" ...
 $ PROD_REAL: num  4088 4445 5089 1498 5345 ...
 $ PROD_STAND: num  4088 4079 4484 1498 4939 ...
 $ D_LACT   : int  272 362 386 149 362 402 431 372 136 364 ...
 $ PROM_REAL : num  15 12.3 13.2 10.1 14.8 ...
 $ PROM_STAND: num  15 13.4 14.7 10.1 16.2 ...
> datos$CODIGO <- as.factor(datos$CODIGO)
> datos$RAZA <- as.factor(datos$RAZA)
> datos$INT_PART <- as.numeric(datos$INT_PART)
> datos$N_LACT <- as.factor(datos$N_LACT)
> datos$M_PARTO <- as.factor(datos$M_PARTO)
> datos$ESTACION <- as.factor(datos$ESTACION)
> datos$D_LACT <- as.numeric(datos$D_LACT)
> datos$MES_YEAR <- as.factor(datos$MES_YEAR)
> #attach(datos)
> is.data.frame(datos)
[1] TRUE
> #
> # GENERAR SUB CONJUNTOS
> LACT1<-subset(datos, N_LACT == "1")
> LACT2<-subset(datos, N_LACT == "2")
> LACT3<-subset(datos, N_LACT == "3")
> LACT4<-subset(datos, N_LACT == "4")
> LACT5<-subset(datos, N_LACT == "5")
> #
> #PRUEBA DE NORMALIDAD
> boxplot(datos$PROM_REAL~datos$N_LACT)
> #TEST DE SHAPIRO-WILKS
> shapiro.test(LACT1$D_LACT)
  Shapiro-Wilk normality test
data:  LACT1$D_LACT
W = 0.934, p-value = 0.01442
> shapiro.test(LACT2$D_LACT)
  Shapiro-Wilk normality test
data:  LACT2$D_LACT
W = 0.92295, p-value = 0.006718
> shapiro.test(LACT3$D_LACT)
  Shapiro-Wilk normality test
data:  LACT3$D_LACT
W = 0.94284, p-value = 0.157
> shapiro.test(LACT4$D_LACT)
  Shapiro-Wilk normality test

```

```

data: LACT4$D_LACT
W = 0.96495, p-value = 0.8029
> #shapiro.test(LACT5$PROD_STAND)
> #
> #PRUEBA DE KOLMOGOROV SMIRNOV
> lillie.test(LACT1$PROM_REAL)
      Lilliefors (Kolmogorov-Smirnov) normality test
data: LACT1$PROM_REAL
D = 0.1259, p-value = 0.07753
> lillie.test(LACT2$PROM_REAL)
      Lilliefors (Kolmogorov-Smirnov) normality test
data: LACT2$PROM_REAL
D = 0.092823, p-value = 0.464
> lillie.test(LACT3$PROM_REAL)
      Lilliefors (Kolmogorov-Smirnov) normality test
data: LACT3$PROM_REAL
D = 0.1819, p-value = 0.02676
> lillie.test(LACT4$PROM_REAL)
      Lilliefors (Kolmogorov-Smirnov) normality test
data: LACT4$PROM_REAL
D = 0.19033, p-value = 0.1837
> #lillie.test(LACT5$PROM_REAL)
> #
> #PRUEBA DE HOMOGENEIDAD DE VARIANZA "FLIGNER-KIILLEN Y LEVENNE"
> fligner.test(datos$PROD_REAL~datos$N_LACT)
      Fligner-Killeen test of homogeneity of variances
data: datos$PROD_REAL by datos$N_LACT
Fligner-Killeen:med chi-squared = 1.1177, df = 4, p-value = 0.8915
> leveneTest(datos$PROD_REAL~datos$N_LACT,center = "median")
Levene's Test for Homogeneity of Variance (center = "median")
      Df F value Pr(>F)
group   4  0.1855 0.9456
124
> #
> bartlett.test(datos$PROM_REAL~datos$N_LACT)
      Bartlett test of homogeneity of variances
data: datos$PROM_REAL by datos$N_LACT
Bartlett's K-squared = 2.207, df = 4, p-value = 0.6977
> #
> #modelo
> MODELO1 <- aov(PROM_REAL ~ RAZA + N_LACT + MES_YEAR, data = datos)
> summary.lm(MODELO1)
Call:
aov(formula = PROM_REAL ~ RAZA + N_LACT + MES_YEAR, data = datos)
Residuals:
      Min       1Q   Median       3Q      Max
-4.3415 -0.6549  0.0000  0.5911  4.4137
Coefficients:
      Estimate Std. Error t value Pr(>|t|)
(Intercept)  13.54535    1.26421  10.714  4.4e-16 ***
RAZAH0       -0.08936    1.06016  -0.084  0.933082
RAZAH0 HIBRIDO -0.40336    1.10777  -0.364  0.716931
N_LACT2       0.66556    0.61080   1.090  0.279826
N_LACT3       1.63303    0.71738   2.276  0.026074 *
N_LACT4       1.17784    0.81349   1.448  0.152382
N_LACT5       0.98130    1.53928   0.638  0.526000
MES_YEARAbr-20 -3.45535    2.21765  -1.558  0.123989
MES_YEARAbr-21 -1.55269    1.62842  -0.953  0.343818
MES_YEARAbr-23 -2.84502    2.22196  -1.280  0.204882
MES_YEARAg0-19 -3.02599    2.11053  -1.434  0.156363
MES_YEARAg0-20 -3.57155    2.05792  -1.736  0.087317 .
MES_YEARAg0-21 -1.60496    1.33749  -1.200  0.234437
MES_YEARAg0-23 -1.57155    2.05792  -0.764  0.447792
MES_YEARDic-19 -1.74529    1.63135  -1.070  0.288587
MES_YEARDic-20 -3.52626    1.25221  -2.816  0.006405 **
MES_YEARDic-22 -2.72399    1.67783  -1.624  0.109246
MES_YEARDic-23 -3.73535    2.21765  -1.684  0.096833 .
MES_YEARENE-17 -2.42599    2.11053  -1.149  0.254512
MES_YEARENE-21 -3.97388    1.35559  -2.931  0.004632 **
MES_YEARENE-22 -1.02202    1.74816  -0.585  0.560791
MES_YEARENE-23 -4.53788    1.20335  -3.771  0.000350 ***
MES_YEARFeb-17 -0.74599    2.11053  -0.353  0.724870
MES_YEARFeb-21 -3.36399    1.67783  -2.005  0.049072 *
MES_YEARFeb-22 -0.56155    2.05792  -0.273  0.785803
MES_YEARFeb-23 -3.35751    1.65923  -2.024  0.047070 *
MES_YEARJul-20 -0.36902    2.15146  -0.172  0.864338
MES_YEARJul-21 -1.78987    1.47849  -1.211  0.230365

```

```

MES_YEARJul-22 -3.21902      2.15146    -1.496  0.139367
MES_YEARJul-23 -4.08599      2.11053    -1.936  0.057153 .
MES_YEARJun-18 -0.57155      2.05792    -0.278  0.782086
MES_YEARJun-20 -2.96599      2.11053    -1.405  0.164614
MES_YEARJun-21 -0.27155      2.05792    -0.132  0.895422
MES_YEARJun-22 -2.78752      1.44902    -1.924  0.058704 .
MES_YEARJun-23 -4.63599      2.11053    -2.197  0.031567 *
MES_YEARMar-19 -1.65725      1.26579    -1.309  0.194986
MES_YEARMar-21 -3.40433      1.50726    -2.259  0.027217 *
MES_YEARMar-22 -1.53269      1.62842    -0.941  0.350028
MES_YEARMar-23 -2.67568      1.17409    -2.279  0.025912 *
MES_YEARMay-17 -0.53155      2.05792    -0.258  0.796983
MES_YEARMay-18  2.33001      1.39933     1.665  0.100635
MES_YEARMay-19  1.35845      2.05792     0.660  0.511482
MES_YEARMay-20 -4.95170      1.42345    -3.479  0.000897 ***
MES_YEARMay-21 -0.75328      1.65299    -0.456  0.650094
MES_YEARMay-23 -3.89908      1.28618    -3.032  0.003474 **
MES_YEARNov-18 -4.07155      2.05792    -1.978  0.052051 .
MES_YEARNov-19 -1.46451      1.44402    -1.014  0.314195
MES_YEARNov-20 -1.45755      2.11638    -0.689  0.493427
MES_YEARNov-21 -2.88099      1.67167    -1.723  0.089495 .
MES_YEARNov-22 -6.92902      2.15146    -3.221  0.001986 **
MES_YEARNov-23 -1.90155      2.05792    -0.924  0.358844
MES_YEAROct-17  0.18623      1.60983     0.116  0.908255
MES_YEAROct-18 -0.94655      1.60473    -0.590  0.557306
MES_YEAROct-19 -2.83902      1.72305    -1.648  0.104172
MES_YEAROct-21 -0.29383      2.15812    -0.136  0.892117
MES_YEAROct-22 -2.48670      1.28354    -1.937  0.056980 .
MES_YEAROct-23 -2.49272      1.26950    -1.964  0.053799 .
MES_YEARSet-18  3.07098      2.15146     1.427  0.158181
MES_YEARSet-19 -0.57383      2.15812    -0.266  0.791151
MES_YEARSet-20 -3.15328      1.65299    -1.908  0.060792 .
MES_YEARSet-21 -3.37599      2.11053    -1.600  0.114466
MES_YEARSet-22 -4.49502      2.22196    -2.023  0.047127 *
MES_YEARSet-23 -3.48502      2.22196    -1.568  0.121559
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
Residual standard error: 1.822 on 66 degrees of freedom
Multiple R-squared:  0.6465, Adjusted R-squared:  0.3144
F-statistic: 1.947 on 62 and 66 DF,  p-value: 0.004133
> #
> #ANALISIS DE VARIANZA
> anova(MODELO1)
Analysis of Variance Table
Response: PROM_REAL
          Df Sum Sq Mean Sq F value    Pr(>F)
RAZA         2   17.08   8.5379   2.5719 0.084030 .
N_LACT        4   36.07   9.0178   2.7164 0.037066 *
MES_YEAR     56 347.57   6.2067   1.8696 0.007476 **
Residuals    66 219.10   3.3197
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> #
> #PRUEBA DE TUKEY usando libreria agricola
> library(agricolae)
> outHSD <-HSD.test(MODELO1, "RAZA",console=TRUE)
Study: MODELO1 ~ "RAZA"
HSD Test for PROM_REAL
Mean Square Error:  3.319734
RAZA, means
      PROM_REAL      std  r      se  Min   Max   Q25   Q50   Q75
BS      11.40167 2.505366  6 0.7438340 9.44 14.84  9.815  9.96 13.3225
HO      11.94521 2.247271 96 0.1859585 7.18 18.16 10.475 11.83 13.4475
HO HIBRIDO 11.06370 1.876900 27 0.3506467 6.96 15.65  9.980 10.81 12.1500

Alpha: 0.05 ; DF Error: 66
Critical Value of Studentized Range: 3.390864
Groups according to probability of means differences and alpha level( 0.05 )
Treatments with the same letter are not significantly different.
      PROM_REAL groups
HO      11.94521      a
BS      11.40167      a
HO HIBRIDO 11.06370      a
> outHSD <-HSD.test(MODELO1, "N_LACT",console=TRUE)
Study: MODELO1 ~ "N_LACT"
HSD Test for PROM_REAL
Mean Square Error:  3.319734

```

```

N_LACT, means
  PROM_REAL      std  r      se  Min  Max    Q25    Q50    Q75
1  11.01659 2.352421 44 0.2746789 6.96 17.34  9.4300 10.495 12.3275
2  12.03023 1.998274 43 0.2778545 7.18 15.65 10.5300 12.350 13.5100
3  12.32885 2.225700 26 0.3573263 8.16 18.16 11.3150 11.950 12.7750
4  12.10286 1.784551 14 0.4869537 9.58 16.10 10.8800 11.685 13.1025
5  10.92500 3.174909  2 1.2883583 8.68 13.17  9.8025 10.925 12.0475
Alpha: 0.05 ; DF Error: 66
Critical Value of Studentized Range: 3.966331
Groups according to probability of means differences and alpha level( 0.05 )
Treatments with the same letter are not significantly different.
  PROM_REAL groups
3  12.32885      a
4  12.10286     ab
2  12.03023     ab
1  11.01659      b
5  10.92500      b
> outHSD <-HSD.test(MODELO1, "MES_YEAR",console=TRUE)
Study: MODELO1 ~ "MES_YEAR"
HSD Test for PROM_REAL
Mean Square Error:  3.319734
> #
> #EVALUACION GRAFICA DE NORMALIDAD DE RESIDUOS DEL MODELO
> #
> qqnorm(MODELO1$residuals)
> qqline(MODELO1$residuals)
> par(mfrow = c(1,2))
> plot(MODELO1, which = 1:4)
<Enter> para ver el próximo gráfico: #
<Enter> para ver el próximo gráfico: #
Aviso:
not plotting observations with leverage one:
  4, 9, 10, 11, 12, 16, 25, 30, 37, 45, 52, 54, 55, 60, 62, 65, 78, 79, 80, 82, 87, 90, 97,
98, 101, 122, 127, 128
> #normalidad de residuos
> shapiro.test(MODELO1$residuals)
      Shapiro-Wilk normality test
data:  MODELO1$residuals
W = 0.95164, p-value = 0.0001616

```

SCRIPT (Prom_stand)

```

# Preparación de los datos
# Lectura de datos
library(car)
library(emmeans)
library(psych)
library(nortest)
setwd("E:/INVESTIGACIONES UNSAAC/KORAIMA/DATOS KORAIMA")
datos<-read.csv('DATOS11.csv', header = T, sep = ";")
head(datos)
str(datos)
datos$CODIGO <- as.factor(datos$CODIGO)
datos$RAZA <- as.factor(datos$RAZA)
datos$INT_PART <- as.numeric(datos$INT_PART)
datos$N_LACT <- as.factor(datos$N_LACT)
datos$M_PARTO <- as.factor(datos$M_PARTO)
datos$ESTACION <- as.factor(datos$ESTACION)
datos$D_LACT <- as.numeric(datos$D_LACT)
datos$MES_YEAR <- as.factor(datos$MES_YEAR)
#attach(datos)
is.data.frame(datos)
#
# GENERAR SUB CONJUNTOS
LACT1<-subset(datos, N_LACT == "1")
LACT2<-subset(datos, N_LACT == "2")
LACT3<-subset(datos, N_LACT == "3")
LACT4<-subset(datos, N_LACT == "4")
LACT5<-subset(datos, N_LACT == "5")
#
#PRUEBA DE NORMALIDAD
boxplot(datos$PROM_STAND~datos$N_LACT)
#TEST DE SHAPIRO-WILKS
shapiro.test(LACT1$PROM_STAND)
shapiro.test(LACT2$PROM_STAND)
shapiro.test(LACT3$PROM_STAND)
shapiro.test(LACT4$PROM_STAND)

```

```

#shapiro.test(LACT5$PROD_STAND)
#
#PRUEBA DE KOLMOGOROV SMIRNOV
lillie.test(LACT1$PROM_STAND)
lillie.test(LACT2$PROM_STAND)
lillie.test(LACT3$PROM_STAND)
lillie.test(LACT4$PROM_STAND)
#lillie.test(LACT5$PROM_STAND)
#
#PRUEBA DE HOMOGENEIDAD DE VARIANZA "FLIGNER-KIILLEN Y LEVENNE"
fligner.test(datos$PROD_STAND~datos$N_LACT)
leveneTest(datos$PROD_STAND~datos$N_LACT,center = "median")
#
bartlett.test(datos$PROM_STAND~datos$N_LACT)
#
#modelo
MODELO1 <- aov(PROM_STAND ~ RAZA + N_LACT + MES_YEAR, data = datos)
summary.lm(MODELO1)
#
#ANALISIS DE VARIANZA
anova(MODELO1)
#
#PRUEBA DE TUKEY usando libreria agricola
library(agricolae)
outhSD <-HSD.test(MODELO1, "RAZA",console=TRUE)
outhSD <-HSD.test(MODELO1, "N_LACT",console=TRUE)
outhSD <-HSD.test(MODELO1, "MES_YEAR",console=TRUE)
#
#EVALUACION GRAFICA DE NORMALIDAD DE RESIDUOS DEL MODELO
#
qqnorm(MODELO1$residuals)
qqline(MODELO1$residuals)
par(mfrow = c(1,2))
plot(MODELO1, which = 1:4)
#
#
#normalidad de residuos
shapiro.test(MODELO1$residuals)

```

RESULTADOS

```

> # Preparación de los datos
> # Lectura de datos
> library(car)
> library(emmeans)
> library(psych)
> library(nortest)
> setwd("E:/INVESTIGACIONES UNSAAC/KORAIMA/DATOS KORAIMA")
> datos<-read.csv('DATOS11.csv', header = T, sep = ";")
> head(datos)
  NRO CODIGO RAZA      F_NAC INT_PARTOS N_LACT      F_PARTO F_INI_LACT  M_PARTO ESTACION YEAR
1   1   1510   HO 20/07/2012      759      2 3/03/2017 5/04/2017   abril  LLUVIA 2017
2   2   1510   HO 20/07/2012     1010      3 8/12/2019 15/12/2019 diciembre LLUVIA 2019
3   3   1535   HO 14/03/2018     2217      2 15/03/2022 21/03/2022   marzo  LLUVIA 2022
4   4   1547   HO 12/12/2013      833      2 7/11/2018 9/11/2018 noviembre LLUVIA 2018
5   5   1547   HO 12/12/2013      346      3 19/10/2019 25/10/2019  octubre SEQUIA 2019
6   6   1547   HO 12/12/2013      546      4 17/04/2021 23/04/2021   abril  LLUVIA 2021

  MES_YEAR PROD_REAL PROD_STAND D_LACT PROM_REAL PROM_STAND
1  Abr-17      4088.1      4088.1    272      15.03      15.03
2  Dic-19     4444.6     4079.2    362      12.28      13.37
3  Mar-22     5089.3     4484.4    386      13.18      14.70
4  Nov-18     1497.8     1497.8    149      10.05      10.05
5  Oct-19     5344.9     4939.1    362      14.76      16.19
6  Abr-21     6470.3     5055.8    402      16.10      16.58
> str(datos)
'data.frame':   129 obs. of  17 variables:
 $ NRO      : int   1 2 3 4 5 6 7 8 9 10 ...
 $ CODIGO   : int  1510 1510 1535 1547 1547 1547 1547 1548 1548 1554 ...
 $ RAZA     : chr   "HO" "HO" "HO" "HO" ...
 $ F_NAC    : chr   "20/07/2012" "20/07/2012" "14/03/2018" "12/12/2013" ...
 $ INT_PARTOS: int   759 1010 2217 833 346 546 551 468 1188 502 ...
 $ N_LACT   : int    2 3 2 2 3 4 5 2 3 2 ...
 $ F_PARTO  : chr   "3/03/2017" "8/12/2019" "15/03/2022" "7/11/2018" ...
 $ F_INI_LACT: chr   "5/04/2017" "15/12/2019" "21/03/2022" "9/11/2018" ...
 $ M_PARTO  : chr   "abril" "diciembre" "marzo" "noviembre" ...
 $ ESTACION : chr   "LLUVIA" "LLUVIA" "LLUVIA" "LLUVIA" ...
 $ YEAR     : int   2017 2019 2022 2018 2019 2021 2022 2017 2020 2017 ...
 $ MES_YEAR : chr   "Abr-17" "Dic-19" "Mar-22" "Nov-18" ...
 $ PROD_REAL: num   4088 4445 5089 1498 5345 ...

```

```

$ PROD_STAND: num 4088 4079 4484 1498 4939 ...
$ D_LACT : int 272 362 386 149 362 402 431 372 136 364 ...
$ PROM_REAL : num 15 12.3 13.2 10.1 14.8 ...
$ PROM_STAND: num 15 13.4 14.7 10.1 16.2 ...
> datos$CODIGO <- as.factor(datos$CODIGO)
> datos$RAZA <- as.factor(datos$RAZA)
> datos$INT_PART <- as.numeric(datos$INT_PART)
> datos$N_LACT <- as.factor(datos$N_LACT)
> datos$M_PARTO <- as.factor(datos$M_PARTO)
> datos$ESTACION <- as.factor(datos$ESTACION)
> datos$D_LACT <- as.numeric(datos$D_LACT)
> datos$MES_YEAR <- as.factor(datos$MES_YEAR)
> #attach(datos)
> is.data.frame(datos)
[1] TRUE
> #
> # GENERAR SUB CONJUNTOS
> LACT1<-subset(datos, N_LACT == "1")
> LACT2<-subset(datos, N_LACT == "2")
> LACT3<-subset(datos, N_LACT == "3")
> LACT4<-subset(datos, N_LACT == "4")
> LACT5<-subset(datos, N_LACT == "5")
> #
> #PRUEBA DE NORMALIDAD
> boxplot(datos$PROM_STAND~datos$N_LACT)
> #TEST DE SHAPIRO-WILKS
> shapiro.test(LACT1$PROM_STAND)
Shapiro-Wilk normality test
data: LACT1$PROM_STAND
W = 0.93694, p-value = 0.01834
> shapiro.test(LACT2$PROM_STAND)
Shapiro-Wilk normality test
data: LACT2$PROM_STAND
W = 0.9865, p-value = 0.8868
> shapiro.test(LACT3$PROM_STAND)
Shapiro-Wilk normality test
data: LACT3$PROM_STAND
W = 0.96783, p-value = 0.5679
> shapiro.test(LACT4$PROM_STAND)
Shapiro-Wilk normality test
data: LACT4$PROM_STAND
W = 0.95859, p-value = 0.6999
> #shapiro.test(LACT5$PROD_STAND)
> #
> #PRUEBA DE KOLMOGOROV SMIRNOV
> lillie.test(LACT1$PROM_STAND)
Lilliefors (Kolmogorov-Smirnov) normality test
data: LACT1$PROM_STAND
D = 0.12812, p-value = 0.06744
> lillie.test(LACT2$PROM_STAND)
Lilliefors (Kolmogorov-Smirnov) normality test
data: LACT2$PROM_STAND
D = 0.071894, p-value = 0.8343
> lillie.test(LACT3$PROM_STAND)
Lilliefors (Kolmogorov-Smirnov) normality test
data: LACT3$PROM_STAND
D = 0.13659, p-value = 0.2421
> lillie.test(LACT4$PROM_STAND)
Lilliefors (Kolmogorov-Smirnov) normality test
data: LACT4$PROM_STAND
D = 0.11944, p-value = 0.8497
> #lillie.test(LACT5$PROD_STAND)
> #
> #PRUEBA DE HOMOGENEIDAD DE VARIANZA "FLIGNER-KIILLEN Y LEVENNE"
> fligner.test(datos$PROD_STAND~datos$N_LACT)
Fligner-Killeen test of homogeneity of variances
data: datos$PROD_STAND by datos$N_LACT
Fligner-Killeen:med chi-squared = 3.6595, df = 4, p-value = 0.454
> leveneTest(datos$PROD_STAND~datos$N_LACT,center = "median")
Levene's Test for Homogeneity of Variance (center = "median")
Df F value Pr(>F)
group 4 1.0718 0.3734
124
> #
> bartlett.test(datos$PROM_STAND~datos$N_LACT)
Bartlett test of homogeneity of variances
data: datos$PROM_STAND by datos$N_LACT

```

Bartlett's K-squared = 1.381, df = 4, p-value = 0.8475

```
> #
> #modelo
> MODELO1 <- aov(PROM_STAND ~ RAZA + N_LACT + MES_YEAR, data = datos)
> summary.lm(MODELO1)
Call:
aov(formula = PROM_STAND ~ RAZA + N_LACT + MES_YEAR, data = datos)
Residuals:
    Min       1Q   Median       3Q      Max
-4.8432 -0.7247  0.0000  0.6525  5.1324
Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)    15.0092     1.4166  10.595 7.03e-16 ***
RAZAH0         -0.3426     1.1879   -0.288 0.773942
RAZAH0 HIBRIDO -0.6167     1.2413   -0.497 0.620979
N_LACT2         0.9004     0.6844    1.316 0.192878
N_LACT3         2.2440     0.8038    2.792 0.006853 **
N_LACT4         1.6775     0.9115    1.840 0.070210 .
N_LACT5         1.4754     1.7248    0.855 0.395404
MES_YEARAbr-20  -4.5592     2.4849   -1.835 0.071050 .
MES_YEARAbr-21  -2.8905     1.8247   -1.584 0.117941
MES_YEARAbr-23  -3.7965     2.4897   -1.525 0.132073
MES_YEARAgO-19  -3.3566     2.3649   -1.419 0.160504
MES_YEARAgO-20  -5.0169     2.3059   -2.176 0.033165 *
MES_YEARAgO-21  -1.7524     1.4987   -1.169 0.246500
MES_YEARAgO-23  -2.6769     2.3059   -1.161 0.249865
MES_YEARDic-19  -2.0237     1.8279   -1.107 0.272264
MES_YEARDic-20  -5.0580     1.4031   -3.605 0.000601 ***
MES_YEARDic-22  -3.3945     1.8800   -1.806 0.075545 .
MES_YEARDic-23  -5.1992     2.4849   -2.092 0.040261 *
MES_YEAREnE-17  -2.8066     2.3649   -1.187 0.239571
MES_YEAREnE-21  -5.2182     1.5190   -3.435 0.001028 **
MES_YEAREnE-22  -2.3735     1.9588   -1.212 0.229949
MES_YEAREnE-23  -5.7861     1.3484   -4.291 5.94e-05 ***
MES_YEARFeb-17  -1.1966     2.3649   -0.506 0.614558
MES_YEARFeb-21  -4.5945     1.8800   -2.444 0.017211 *
MES_YEARFeb-22  -2.0069     2.3059   -0.870 0.387268
MES_YEARFeb-23  -4.3136     1.8592   -2.320 0.023435 *
MES_YEARJul-20  -2.1905     2.4107   -0.909 0.366835
MES_YEARJul-21  -2.6593     1.6567   -1.605 0.113216
MES_YEARJul-22  -4.0505     2.4107   -1.680 0.097644 .
MES_YEARJul-23  -5.1366     2.3649   -2.172 0.033451 *
MES_YEARJun-18  -2.0169     2.3059   -0.875 0.384920
MES_YEARJun-20  -4.1766     2.3649   -1.766 0.082006 .
MES_YEARJun-21  -1.7169     2.3059   -0.745 0.459169
MES_YEARJun-22  -3.8100     1.6236   -2.347 0.021958 *
MES_YEARJun-23  -5.8466     2.3649   -2.472 0.016012 *
MES_YEARMar-19  -2.4219     1.4183   -1.708 0.092410 .
MES_YEARMar-21  -4.8452     1.6889   -2.869 0.005528 **
MES_YEARMar-22  -1.7205     1.8247   -0.943 0.349155
MES_YEARMar-23  -3.7990     1.3156   -2.888 0.005243 **
MES_YEARMay-17  -0.9669     2.3059   -0.419 0.676337
MES_YEARMay-18   2.3569     1.5680    1.503 0.137561
MES_YEARMay-19   1.9731     2.3059    0.856 0.395288
MES_YEARMay-20  -6.3321     1.5950   -3.970 0.000180 ***
MES_YEARMay-21  -0.8467     1.8522   -0.457 0.649074
MES_YEARMay-23  -5.1930     1.4412   -3.603 0.000604 ***
MES_YEARNov-18  -5.5169     2.3059   -2.393 0.019588 *
MES_YEARNov-19  -2.1734     1.6180   -1.343 0.183805
MES_YEARNov-20  -3.0229     2.3714   -1.275 0.206881
MES_YEARNov-21  -3.9016     1.8731   -2.083 0.041137 *
MES_YEARNov-22  -8.7505     2.4107   -3.630 0.000554 ***
MES_YEARNov-23  -3.3469     2.3059   -1.451 0.151390
MES_YEAROct-17  -0.7468     1.8038   -0.414 0.680228
MES_YEAROct-18  -1.6169     1.7981   -0.899 0.371794
MES_YEAROct-19  -3.5355     1.9307   -1.831 0.071581 .
MES_YEAROct-21  -2.0041     2.4182   -0.829 0.410225
MES_YEAROct-22  -3.1780     1.4382   -2.210 0.030603 *
MES_YEAROct-23  -3.6930     1.4225   -2.596 0.011610 *
MES_YEARSet-18   1.2495     2.4107    0.518 0.605988
MES_YEARSet-19   1.1259     2.4182    0.466 0.643043
MES_YEARSet-20  -4.8017     1.8522   -2.592 0.011723 *
MES_YEARSet-21  -4.5866     2.3649   -1.939 0.056722 .
MES_YEARSet-22  -5.6365     2.4897   -2.264 0.026873 *
MES_YEARSet-23  -4.0465     2.4897   -1.625 0.108872
---
```

```

Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 2.042 on 66 degrees of freedom
Multiple R-squared:  0.6807, Adjusted R-squared:  0.3808
F-statistic: 2.269 on 62 and 66 DF, p-value: 0.0006065
> #
> #ANALISIS DE VARIANZA
> anova(MODELO1)
Analysis of Variance Table
Response: PROM_STAND
      Df Sum Sq Mean Sq F value    Pr(>F)
RAZA    2  18.71   9.3533   2.2440 0.114060
N_LACT   4  62.97  15.7422   3.7769 0.007944 **
MES_YEAR 56 504.79   9.0141   2.1627 0.001387 **
Residuals 66 275.09   4.1681
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> #
> #PRUEBA DE TUKEY usando libreria agricola
> library(agricolae)
> outHSD <-HSD.test(MODELO1, "RAZA",console=TRUE)
Study: MODELO1 ~ "RAZA"
HSD Test for PROM_STAND
Mean Square Error:  4.168073
RAZA, means
      PROM_STAND      std  r      se Min  Max    Q25    Q50    Q75
BS      12.18500  3.788112  6 0.8334739 9.44 18.74  9.8150 10.140 13.7425
HO      12.49292  2.636831 96 0.2083685 7.18 19.26 10.5575 12.315 14.5550
HO HIBRIDO 11.55222  2.062314 27 0.3929034 6.96 15.65 10.1550 11.340 13.1050

Alpha: 0.05 ; DF Error: 66
Critical Value of Studentized Range: 3.390864
Groups according to probability of means differences and alpha level( 0.05 )
Treatments with the same letter are not significantly different.
      PROM_STAND groups
HO      12.49292      a
BS      12.18500      a
HO HIBRIDO 11.55222      a
> outHSD <-HSD.test(MODELO1, "N_LACT",console=TRUE)
Study: MODELO1 ~ "N_LACT"
HSD Test for PROM_STAND
Mean Square Error:  4.168073
N_LACT, means
      PROM_STAND      std  r      se Min  Max    Q25    Q50    Q75
1      11.32432  2.693986 44 0.3077806 6.96 19.26  9.5150 10.765 12.9500
2      12.62488  2.420421 43 0.3113389 7.18 18.74 10.6350 12.830 14.4000
3      13.03846  2.440281 26 0.4003879 8.16 18.35 11.4225 12.830 14.4450
4      12.92000  2.321057 14 0.5456368 9.58 17.47 11.2575 12.435 14.1975
5      11.66000  4.214356  2 1.4436192 8.68 14.64 10.1700 11.660 13.1500
Alpha: 0.05 ; DF Error: 66
Critical Value of Studentized Range: 3.966331
Groups according to probability of means differences and alpha level( 0.05 )
Treatments with the same letter are not significantly different.
      PROM_STAND groups
3      13.03846      a
4      12.92000     ab
2      12.62488     ab
5      11.66000     ab
1      11.32432      b
> outHSD <-HSD.test(MODELO1, "MES_YEAR",console=TRUE)
Study: MODELO1 ~ "MES_YEAR"
HSD Test for PROM_STAND
Mean Square Error:  4.168073
> #
> #EVALUACION GRAFICA DE NORMALIDAD DE RESIDUOS DEL MODELO
> #
> qqnorm(MODELO1$residuals)
> qqline(MODELO1$residuals)
> par(mfrow = c(1,2))
> plot(MODELO1, which = 1:4)
<Enter> para ver el próximo gráfico: #
<Enter> para ver el próximo gráfico: #
Aviso:
not plotting observations with leverage one:
  4, 9, 10, 11, 12, 16, 25, 30, 37, 45, 52, 54, 55, 60, 62, 65, 78, 79, 80, 82, 87, 90, 97,
98, 101, 122, 127, 128
> #normalidad de residuos

```

```
> shapiro.test(MODELO1$residuals)
      Shapiro-Wilk normality test
data:  MODELO1$residuals
W = 0.96063, p-value = 0.0008643
```

SCRIPT (Días en lactación)

```
# Preparación de los datos
# Lectura de datos
library(car)
library(emmeans)
library(psych)
library(nortest)
setwd("E:/INVESTIGACIONES UNSAAC/KORAIMA/DATOS KORAIMA")
datos<-read.csv('DATOS11.csv', header = T, sep = ";")
head(datos)
str(datos)
datos$CODIGO <- as.factor(datos$CODIGO)
datos$RAZA <- as.factor(datos$RAZA)
datos$INT_PART <- as.numeric(datos$INT_PART)
datos$N_LACT <- as.factor(datos$N_LACT)
datos$M_PARTO <- as.factor(datos$M_PARTO)
datos$ESTACION <- as.factor(datos$ESTACION)
datos$D_LACT <- as.numeric(datos$D_LACT)
datos$MES_YEAR <- as.factor(datos$MES_YEAR)
#attach(datos)
is.data.frame(datos)
#
# GENERAR SUB CONJUNTOS
LACT1<-subset(datos, N_LACT == "1")
LACT2<-subset(datos, N_LACT == "2")
LACT3<-subset(datos, N_LACT == "3")
LACT4<-subset(datos, N_LACT == "4")
LACT5<-subset(datos, N_LACT == "5")
#
#PRUEBA DE NORMALIDAD
boxplot(datos$D_LACT~datos$N_LACT)
#TEST DE SHAPIRO-WILKS
shapiro.test(LACT1$D_LACT)
shapiro.test(LACT2$D_LACT)
shapiro.test(LACT3$D_LACT)
shapiro.test(LACT4$D_LACT)
#shapiro.test(LACT5$PROD_STAND)
#
#PRUEBA DE KOLMOGOROV SMIRNOV
lillie.test(LACT1$D_LACT)
lillie.test(LACT2$D_LACT)
lillie.test(LACT3$D_LACT)
lillie.test(LACT4$D_LACT)
#lillie.test(LACT5$D_LACT)
#
#PRUEBA DE HOMOGENEIDAD DE VARIANZA "FLIGNER-KIILLEN Y LEVENNE"
fligner.test(datos$D_LACT~datos$N_LACT)
leveneTest(datos$D_LACT~datos$N_LACT,center = "median")
#
bartlett.test(datos$D_LACT~datos$N_LACT)
#
#modelo
MODELO1 <- aov(D_LACT ~ RAZA + N_LACT + MES_YEAR, data = datos)
summary.lm(MODELO1)
#
#ANALISIS DE VARIANZA
anova(MODELO1)
#
#PRUEBA DE TUKEY usando libreria agricola
library(agricolae)
outhSD <-HSD.test(MODELO1, "RAZA",console=TRUE)
outhSD <-HSD.test(MODELO1, "N_LACT",console=TRUE)
outhSD <-HSD.test(MODELO1, "MES_YEAR",console=TRUE)
#
#EVALUACION GRAFICA DE NORMALIDAD DE RESIDUOS DEL MODELO
#
qqnorm(MODELO1$residuals)
qqline(MODELO1$residuals)
par(mfrow = c(1,2))
plot(MODELO1, which = 1:4)
#
```

```
#
#normalidad de residuos
shapiro.test(MODELO1$residuals)
```

RESULTADOS

```
> # Preparación de los datos
> # Lectura de datos
> library(car)
> library(emmeans)
> library(psych)
> library(nortest)
> setwd("E:/INVESTIGACIONES UNSAAC/KORAIMA/DATOS KORAIMA")
> datos<-read.csv('DATOS11.csv', header = T, sep = ";")
> head(datos)
  CODIGO RAZA Fecha_NAC INT_PARTOS N_LACT Fecha_PARTO Fecha_INI_LACT M_PARTO ESTACION YEAR
1 1510 HO 20/07/2012 759 2 3/03/2017 5/04/2017 abril LLUVIA 2017
2 1510 HO 20/07/2012 1010 3 8/12/2019 15/12/2019 diciembre LLUVIA 2019
3 1535 HO 14/03/2018 NA 2 15/03/2022 21/03/2022 marzo LLUVIA 2022
4 1547 HO 12/12/2013 833 2 7/11/2018 9/11/2018 noviembre LLUVIA 2018
5 1547 HO 12/12/2013 346 3 19/10/2019 25/10/2019 octubre SEQUIA 2019
6 1547 HO 12/12/2013 546 4 17/04/2021 23/04/2021 abril LLUVIA 2021
  MES_YEAR PROD_REAL PROD_STAND D_LACT
1 Abr-17 4088.1 4088.1 272
2 Dic-19 4444.6 4079.2 362
3 Mar-22 5089.3 4484.4 386
4 Nov-18 1497.8 1497.8 149
5 Oct-19 5344.9 4939.1 362
6 Abr-21 NA 5055.8 402
> str(datos)
'data.frame': 129 obs. of 14 variables:
 $ CODIGO : int 1510 1510 1535 1547 1547 1547 1547 1548 1548 1554 ...
 $ RAZA : chr "HO" "HO" "HO" "HO" ...
 $ Fecha_NAC : chr "20/07/2012" "20/07/2012" "14/03/2018" "12/12/2013" ...
 $ INT_PARTOS : int 759 1010 NA 833 346 546 551 468 1188 502 ...
 $ N_LACT : int 2 3 2 2 3 4 5 2 3 2 ...
 $ Fecha_PARTO : chr "3/03/2017" "8/12/2019" "15/03/2022" "7/11/2018" ...
 $ Fecha_INI_LACT : chr "5/04/2017" "15/12/2019" "21/03/2022" "9/11/2018" ...
 $ M_PARTO : chr "abril" "diciembre" "marzo" "noviembre" ...
 $ ESTACION : chr "LLUVIA" "LLUVIA" "LLUVIA" "LLUVIA" ...
 $ YEAR : int 2017 2019 2022 2018 2019 2021 2022 2017 2020 2017 ...
 $ MES_YEAR : chr "Abr-17" "Dic-19" "Mar-22" "Nov-18" ...
 $ PROD_REAL : num 4088 4445 5089 1498 5345 ...
 $ PROD_STAND : num 4088 4079 4484 1498 4939 ...
 $ D_LACT : int 272 362 386 149 362 402 431 372 136 364 ...
> datos$CODIGO <- as.factor(datos$CODIGO)
> datos$RAZA <- as.factor(datos$RAZA)
> datos$INT_PART <- as.numeric(datos$INT_PART)
> datos$N_LACT <- as.factor(datos$N_LACT)
> datos$M_PARTO <- as.factor(datos$M_PARTO)
> datos$ESTACION <- as.factor(datos$ESTACION)
> datos$D_LACT <- as.numeric(datos$D_LACT)
> datos$MES_YEAR <- as.factor(datos$MES_YEAR)
> #attach(datos)
> is.data.frame(datos)
[1] TRUE
> #
> # GENERAR SUB CONJUNTOS
> LACT1<-subset(datos, N_LACT == "1")
> LACT2<-subset(datos, N_LACT == "2")
> LACT3<-subset(datos, N_LACT == "3")
> LACT4<-subset(datos, N_LACT == "4")
> LACT5<-subset(datos, N_LACT == "5")
> #
> #PRUEBA DE NORMALIDAD
> boxplot(datos$D_LACT~datos$N_LACT)
> #TEST DE SHAPIRO-WILKS
> shapiro.test(LACT1$D_LACT)
Shapiro-Wilk normality test
data: LACT1$D_LACT
W = 0.934, p-value = 0.01442
> shapiro.test(LACT2$D_LACT)
Shapiro-Wilk normality test
data: LACT2$D_LACT
W = 0.92295, p-value = 0.006718
> shapiro.test(LACT3$D_LACT)
Shapiro-Wilk normality test
data: LACT3$D_LACT
```

```

W = 0.94284, p-value = 0.157
> shapiro.test(LACT4$D_LACT)
      Shapiro-Wilk normality test
data:  LACT4$D_LACT
W = 0.96495, p-value = 0.8029
> #shapiro.test(LACT5$PROD_STAND)
> #
> #PRUEBA DE KOLMOGOROV SMIRNOV
> lillie.test(LACT1$D_LACT)
      Lilliefors (Kolmogorov-Smirnov) normality test
data:  LACT1$D_LACT
D = 0.091833, p-value = 0.4634
> lillie.test(LACT2$D_LACT)
      Lilliefors (Kolmogorov-Smirnov) normality test
data:  LACT2$D_LACT
D = 0.1355, p-value = 0.04588
> lillie.test(LACT3$D_LACT)
      Lilliefors (Kolmogorov-Smirnov) normality test
data:  LACT3$D_LACT
D = 0.12325, p-value = 0.3926
> lillie.test(LACT4$D_LACT)
      Lilliefors (Kolmogorov-Smirnov) normality test
data:  LACT4$D_LACT
D = 0.13894, p-value = 0.6558
> #lillie.test(LACT5$D_LACT)
> #
> #PRUEBA DE HOMOGENEIDAD DE VARIANZA "FLIGNER-KIILLEN Y LEVENNE"
> fligner.test(datos$D_LACT~datos$N_LACT)
      Fligner-Killeen test of homogeneity of variances
data:  datos$D_LACT by datos$N_LACT
Fligner-Killeen:med chi-squared = 1.1042, df = 4, p-value = 0.8936
> leveneTest(datos$D_LACT~datos$N_LACT,center = "median")
Levene's Test for Homogeneity of Variance (center = "median")
      Df F value Pr(>F)
group  4  0.1084 0.9794
124
> #
> bartlett.test(datos$D_LACT~datos$N_LACT)
      Bartlett test of homogeneity of variances
data:  datos$D_LACT by datos$N_LACT
Bartlett's K-squared = 0.60755, df = 4, p-value = 0.9622
> #
> #modelo
> MODELO1 <- aov(D_LACT ~ RAZA + N_LACT + M_PARTO + YEAR, data = datos)
> summary.lm(MODELO1)
Call:
aov(formula = D_LACT ~ RAZA + N_LACT + M_PARTO + YEAR, data = datos)
Residuals:
      Min       1Q   Median       3Q      Max
-268.82 -109.94  -20.56   78.02  503.88
Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)  -3253.542   17608.211  -0.185   0.854
RAZAH0         71.072     73.203    0.971   0.334
RAZAH0 HIBRIDO  126.174     77.907    1.620   0.108
N_LACT2        28.981     36.753    0.789   0.432
N_LACT3        49.561     45.431    1.091   0.278
N_LACT4        66.092     56.075    1.179   0.241
N_LACT5       18.454    122.979    0.150   0.881
M_PARTOagosto  12.293     86.887    0.141   0.888
M_PARTOdiciembre -28.848     79.266  -0.364   0.717
M_PARTOenero  -114.047     77.212  -1.477   0.143
M_PARTOfebrero  -27.869     93.553  -0.298   0.766
M_PARTOjulio  -121.316     99.881  -1.215   0.227
M_PARTOjunio   -72.960     86.120  -0.847   0.399
M_PARTOmarzo   -29.257     73.920  -0.396   0.693
M_PARTOmayero  -69.937     73.883  -0.947   0.346
M_PARTOnoviembre -57.587     79.313  -0.726   0.469
M_PARTOoctubre -61.059     73.570  -0.830   0.408
M_PARTOsetiembre -99.092     88.008  -1.126   0.263
YEAR           1.753       8.720   0.201   0.841
Residual standard error: 161.3 on 110 degrees of freedom
Multiple R-squared:  0.09424, Adjusted R-squared:  -0.05398
F-statistic: 0.6358 on 18 and 110 DF, p-value: 0.8642
> #
> #modelo
> MODELO1 <- aov(D_LACT ~ RAZA + N_LACT + MES_YEAR, data = datos)

```

```

> summary.lm(MODELO1)
Call:
aov(formula = D_LACT ~ RAZA + N_LACT + MES_YEAR, data = datos)
Residuals:
    Min       1Q   Median       3Q      Max
-303.05  -52.84    0.00   48.78  305.95
Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)    283.653    106.696   2.659  0.00984 **
RAZAH0         93.555     89.475   1.046  0.29956
RAZAH0 HIBRIDO  140.610     93.493   1.504  0.13736
N_LACT2         30.574     51.550   0.593  0.55515
N_LACT3         95.535     60.545   1.578  0.11937
N_LACT4         80.369     68.656   1.171  0.24597
N_LACT5        -90.661    129.911  -0.698  0.48771
MES_YEARAbr-20   53.347     187.164   0.285  0.77652
MES_YEARAbr-21 -103.680     137.434  -0.754  0.45329
MES_YEARAbr-23  -23.798     187.527  -0.127  0.89940
MES_YEARAgO-19   -7.209     178.124  -0.040  0.96784
MES_YEARAgO-20 -105.782     173.683  -0.609  0.54458
MES_YEARAgO-21  -16.870     112.881  -0.149  0.88166
MES_YEARAgO-23  -75.782     173.683  -0.436  0.66403
MES_YEARDic-19  -36.763     137.682  -0.267  0.79029
MES_YEARDic-20 -200.149     105.683  -1.894  0.06263 .
MES_YEARDic-22  340.264     141.605   2.403  0.01908 *
MES_YEARDic-23  -30.653     187.164  -0.164  0.87041
MES_YEARENE-17   44.791     178.124   0.251  0.80224
MES_YEARENE-21 -195.366     114.409  -1.708  0.09241 .
MES_YEARENE-22 -177.771     147.540  -1.205  0.23254
MES_YEARENE-23 -109.359     101.560  -1.077  0.28549
MES_YEARFeb-17   86.791     178.124   0.487  0.62769
MES_YEARFeb-21 -144.236     141.605  -1.019  0.31212
MES_YEARFeb-22 -132.782     173.683  -0.765  0.44729
MES_YEARFeb-23   13.024     140.034   0.093  0.92618
MES_YEARJul-20 -336.744     181.577  -1.855  0.06813 .
MES_YEARJul-21 -154.090     124.781  -1.235  0.22125
MES_YEARJul-22  -75.744     181.577  -0.417  0.67793
MES_YEARJul-23  140.791     178.124   0.790  0.43212
MES_YEARJun-18 -164.782     173.683  -0.949  0.34621
MES_YEARJun-20 -111.209     178.124  -0.624  0.53456
MES_YEARJun-21 -107.782     173.683  -0.621  0.53702
MES_YEARJun-22 -105.596     122.294  -0.863  0.39101
MES_YEARJun-23 -263.209     178.124  -1.478  0.14425
MES_YEARMar-19  -20.989     106.829  -0.196  0.84484
MES_YEARMar-21 -277.423     127.209  -2.181  0.03276 *
MES_YEARMar-22  -50.680     137.434  -0.369  0.71349
MES_YEARMar-23   6.060      99.090   0.061  0.95142
MES_YEARMay-17  -43.782     173.683  -0.252  0.80176
MES_YEARMay-18  -1.472     118.100  -0.012  0.99009
MES_YEARMay-19   36.218     173.683   0.209  0.83546
MES_YEARMay-20 -141.276     120.136  -1.176  0.24383
MES_YEARMay-21  -58.790     139.508  -0.421  0.67482
MES_YEARMay-23 -126.167     108.550  -1.162  0.24930
MES_YEARNov-18 -258.782     173.683  -1.490  0.14100
MES_YEARNov-19 -133.066     121.871  -1.092  0.27886
MES_YEARNov-20  -30.837     178.617  -0.173  0.86346
MES_YEARNov-21  -68.709     141.085  -0.487  0.62787
MES_YEARNov-22 -303.744     181.577  -1.673  0.09910 .
MES_YEARNov-23 -148.782     173.683  -0.857  0.39475
MES_YEAROct-17 -108.495     135.866  -0.799  0.42742
MES_YEAROct-18 -103.282     135.435  -0.763  0.44842
MES_YEAROct-19  -97.744     145.421  -0.672  0.50384
MES_YEAROct-21 -293.578     182.140  -1.612  0.11177
MES_YEAROct-22  123.265     108.327   1.138  0.25928
MES_YEAROct-23 -104.067     107.143  -0.971  0.33495
MES_YEARSet-18 -193.744     181.577  -1.067  0.28986
MES_YEARSet-19   36.422     182.140   0.200  0.84212
MES_YEARSet-20 -276.790     139.508  -1.984  0.05141 .
MES_YEARSet-21 -147.209     178.124  -0.826  0.41153
MES_YEARSet-22 -107.798     187.527  -0.575  0.56735
MES_YEARSet-23  -32.798     187.527  -0.175  0.86170
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
Residual standard error: 153.8 on 66 degrees of freedom
Multiple R-squared:  0.5058, Adjusted R-squared:  0.04155
F-statistic: 1.09 on 62 and 66 DF, p-value: 0.3654
> #

```

```

> #ANALISIS DE VARIANZA
> anova(MODELO1)
Analysis of Variance Table
Response: D_LACT
      Df Sum Sq Mean Sq F value Pr(>F)
RAZA    2   88977   44488   1.8814 0.1605
N_LACT   4   55684   13921   0.5887 0.6719
MES_YEAR 56 1452626   25940   1.0970 0.3571
Residuals 66 1560651   23646
> #
> #PRUEBA DE TUKEY usando libreria agricola
> library(agricolae)
> outHSD <-HSD.test(MODELO1, "RAZA",console=TRUE)
Study: MODELO1 ~ "RAZA"
HSD Test for D_LACT
Mean Square Error: 23646.22
RAZA, means
      D_LACT      std      r      se Min Max      Q25      Q50      Q75
BS      275.1667 155.8402  6 62.77768 160 561 168.00 213.5 316.00
HO      330.4896 151.1046 96 15.69442 106 837 227.75 302.0 398.25
HO HIBRIDO 385.1852 173.0311 27 29.59368 117 725 220.50 413.0 502.00
Alpha: 0.05 ; DF Error: 66
Critical Value of Studentized Range: 3.390864
Groups according to probability of means differences and alpha level( 0.05 )
Treatments with the same letter are not significantly different.
      D_LACT groups
HO HIBRIDO 385.1852      a
HO      330.4896      a
BS      275.1667      a
> outHSD <-HSD.test(MODELO1, "N_LACT",console=TRUE)
Study: MODELO1 ~ "N_LACT"
HSD Test for D_LACT
Mean Square Error: 23646.22

N_LACT, means
      D_LACT      std      r      se Min Max      Q25      Q50      Q75
1 319.3182 154.4269 44 23.18219 114 757 203.00 298.5 407.00
2 343.8605 164.2038 43 23.45020 106 837 234.50 302.0 421.00
3 344.6538 161.9355 26 30.15742 124 667 187.00 353.5 426.75
4 385.2857 139.6834 14 41.09764 164 638 272.50 377.5 494.75
5 293.5000 194.4544 2 108.73413 156 431 224.75 293.5 362.25
Alpha: 0.05 ; DF Error: 66
Critical Value of Studentized Range: 3.966331
Groups according to probability of means differences and alpha level( 0.05 )
Treatments with the same letter are not significantly different.
      D_LACT groups
4 385.2857      a
3 344.6538      a
2 343.8605      a
1 319.3182      a
5 293.5000      a
> outHSD <-HSD.test(MODELO1, "MES_YEAR",console=TRUE)
Study: MODELO1 ~ "MES_YEAR"
HSD Test for D_LACT
Mean Square Error: 23646.22
> #EVALUACION GRAFICA DE NORMALIDAD DE RESIDUOS DEL MODELO
> #
> qqnorm(MODELO1$residuals)
> qqline(MODELO1$residuals)
> par(mfrow = c(1,2))
> plot(MODELO1, which = 1:4)
<Enter> para ver el próximo gráfico: #
<Enter> para ver el próximo gráfico: #
Aviso:
not plotting observations with leverage one:
  4, 9, 10, 11, 12, 16, 25, 30, 37, 45, 52, 54, 55, 60, 62, 65, 78, 79, 80, 82, 87, 90, 97,
98, 101, 122, 127, 128
> #normalidad de residuos
> shapiro.test(MODELO1$residuals)
      Shapiro-Wilk normality test
data:  MODELO1$residuals
W = 0.97309, p-value = 0.01137

```

Anexo 2. Modelo de comandos empleados en el procesamiento de datos en el Rstudio para el “segundo objetivo”

SCRIPT (Intervalo entre partos)

```
> # Preparación de los datos
> # Lectura de datos
> library(car)
> library(emmeans)
> library(psych)
> library(nortest)
> setwd("E:/INVESTIGACIONES UNSAAC/KORAIMA/DATOS KORAIMA")
> datos<-read.csv('DATOS11.csv', header = T, sep = ";")
> head(datos)
  NRO CODIGO RAZA      F_NAC INT_PARTOS N_LACT      F_PARTO F_INI_LACT  M_PARTO ESTACION YEAR MES_YEAR
1   1   1510   HO 20/07/2012        759      2 3/03/2017 5/04/2017    abril  LLUVIA 2017  Abr-17
2   2   1510   HO 20/07/2012       1010      3 8/12/2019 15/12/2019 diciembre LLUVIA 2019  Dic-19
3   3   1535   HO 14/03/2018         NA      2 15/03/2022 21/03/2022    marzo  LLUVIA 2022  Mar-22
4   4   1547   HO 12/12/2013        833      2 7/11/2018 9/11/2018 noviembre LLUVIA 2018  Nov-18
5   5   1547   HO 12/12/2013        346      3 19/10/2019 25/10/2019    octubre  SEQUIA 2019  Oct-19
6   6   1547   HO 12/12/2013        546      4 17/04/2021 23/04/2021    abril  LLUVIA 2021  Abr-21
  PROD_REAL PROD_STAND D_LACT PROM_REAL PROM_STAND
1    4088.1    4088.1    272    15.03    15.03
2    4444.6    4079.2    362    12.28    13.37
3    5089.3    4484.4    386    13.18    14.70
4    1497.8    1497.8    149    10.05    10.05
5    5344.9    4939.1    362    14.76    16.19
6    6470.3    5055.8    402    16.10    16.58
> str(datos)
'data.frame': 129 obs. of 17 variables:
 $ NRO      : int  1 2 3 4 5 6 7 8 9 10 ...
 $ CODIGO   : int  1510 1510 1535 1547 1547 1547 1547 1548 1548 1554 ...
 $ RAZA     : chr  "HO" "HO" "HO" "HO" ...
 $ F_NAC    : chr  "20/07/2012" "20/07/2012" "14/03/2018" "12/12/2013" ...
 $ INT_PARTOS: int  759 1010 NA 833 346 546 551 468 1188 502 ...
 $ N_LACT   : int  2 3 2 2 3 4 5 2 3 2 ...
 $ F_PARTO  : chr  "3/03/2017" "8/12/2019" "15/03/2022" "7/11/2018" ...
 $ F_INI_LACT: chr  "5/04/2017" "15/12/2019" "21/03/2022" "9/11/2018" ...
 $ M_PARTO  : chr  "abril" "diciembre" "marzo" "noviembre" ...
 $ ESTACION : chr  "LLUVIA" "LLUVIA" "LLUVIA" "LLUVIA" ...
 $ YEAR     : int  2017 2019 2022 2018 2019 2021 2022 2017 2020 2017 ...
 $ MES_YEAR : chr  "Abr-17" "Dic-19" "Mar-22" "Nov-18" ...
 $ PROD_REAL: num  4088 4445 5089 1498 5345 ...
 $ PROD_STAND: num  4088 4079 4484 1498 4939 ...
 $ D_LACT   : int  272 362 386 149 362 402 431 372 136 364 ...
 $ PROM_REAL: num  15 12.3 13.2 10.1 14.8 ...
 $ PROM_STAND: num  15 13.4 14.7 10.1 16.2 ...
> datos$CODIGO <- as.factor(datos$CODIGO)
> datos$RAZA <- as.factor(datos$RAZA)
> datos$INT_PART <- as.numeric(datos$INT_PART)
> datos$N_LACT <- as.factor(datos$N_LACT)
> datos$M_PARTO <- as.factor(datos$M_PARTO)
> datos$ESTACION <- as.factor(datos$ESTACION)
> datos$D_LACT <- as.numeric(datos$D_LACT)
> datos$MES_YEAR <- as.factor(datos$MES_YEAR)
> #attach(datos)
> is.data.frame(datos)
[1] TRUE
> #
> # GENERAR SUB CONJUNTOS
> LACT1<-subset(datos, N_LACT == "1")
> LACT2<-subset(datos, N_LACT == "2")
> LACT3<-subset(datos, N_LACT == "3")
> LACT4<-subset(datos, N_LACT == "4")
> LACT5<-subset(datos, N_LACT == "5")
> #
> #PRUEBA DE NORMALIDAD
> boxplot(datos$INT_PART~datos$N_LACT)
> #TEST DE SHAPIRO-WILKS
> shapiro.test(LACT1$INT_PART)
      Shapiro-Wilk normality test
data:  LACT1$INT_PART
W = 0.97312, p-value = 0.3882
> shapiro.test(LACT2$INT_PART)
      Shapiro-Wilk normality test
data:  LACT2$INT_PART
```

```

W = 0.90823, p-value = 0.002563
> shapiro.test(LACT3$INT_PART)
      Shapiro-Wilk normality test
data:  LACT3$INT_PART
W = 0.86801, p-value = 0.003246
> shapiro.test(LACT4$INT_PART)
      Shapiro-Wilk normality test
data:  LACT4$INT_PART
W = 0.86841, p-value = 0.03986
> #shapiro.test(LACT5$INT_PART)
> #
> #PRUEBA DE KOLMOGOROV SMIRNOV
> lillie.test(LACT1$INT_PART)
      Lilliefors (Kolmogorov-Smirnov) normality test
data:  LACT1$INT_PART
D = 0.10399, p-value = 0.272
> lillie.test(LACT2$INT_PART)
      Lilliefors (Kolmogorov-Smirnov) normality test
data:  LACT2$INT_PART
D = 0.18213, p-value = 0.001234
> lillie.test(LACT3$INT_PART)
      Lilliefors (Kolmogorov-Smirnov) normality test
data:  LACT3$INT_PART
D = 0.22145, p-value = 0.00202
> lillie.test(LACT4$INT_PART)
      Lilliefors (Kolmogorov-Smirnov) normality test
data:  LACT4$INT_PART
D = 0.18598, p-value = 0.2104
> #lillie.test(LACT5$INT_PART)
> #
> #PRUEBA DE HOMOGENEIDAD DE VARIANZA "FLIGNER-KIILLEN Y LEVENNE"
> fligner.test(datos$INT_PART~datos$N_LACT)
      Fligner-Killeen test of homogeneity of variances
data:  datos$INT_PART by datos$N_LACT
Fligner-Killeen:med chi-squared = 8.002, df = 4, p-value = 0.0915
> leveneTest(datos$INT_PART~datos$N_LACT,center = "median")
Levene's Test for Homogeneity of Variance (center = "median")
      Df F value Pr(>F)
group  4  1.9517 0.1061
123
> #
> bartlett.test(datos$INT_PART~datos$N_LACT)
      Bartlett test of homogeneity of variances
data:  datos$INT_PART by datos$N_LACT
Bartlett's K-squared = 10.509, df = 4, p-value = 0.03267
> #
> #modelo
> MODELO1 <- aov(INT_PART ~ RAZA + N_LACT + M_PARTO, data = datos)
> summary.lm(MODELO1)
Call:
aov(formula = INT_PART ~ RAZA + N_LACT + M_PARTO, data = datos)
Residuals:
      Min       1Q   Median       3Q      Max
-633.80 -155.85  -14.83  147.73  674.74
Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)    1297.26    126.84  10.228 < 2e-16 ***
RAZAH0         -114.57    114.11  -1.004  0.31756
RAZAH0 HIBRIDO  -155.72    123.06  -1.265  0.20843
N_LACT2        -559.52     58.29  -9.599 3.25e-16 ***
N_LACT3        -582.97     69.79  -8.353 2.22e-13 ***
N_LACT4        -618.42     83.02  -7.449 2.26e-11 ***
N_LACT5        -610.93    191.67  -3.187  0.00187 **
M_PARTOagosto   -13.37    132.80  -0.101  0.92001
M_PARTOdiciembre 189.36    122.10   1.551  0.12380
M_PARTOenero    -124.38    116.36  -1.069  0.28748
M_PARTOfebrero  149.59    142.99   1.046  0.29779
M_PARTOjulio     86.39    154.35   0.560  0.57680
M_PARTOjunio    -116.48    131.47  -0.886  0.37758
M_PARTOmarzo     15.26    113.37   0.135  0.89321
M_PARTOmayero     6.85    114.95   0.060  0.95259
M_PARTOnoviembre  45.11    122.81   0.367  0.71410
M_PARTOoctubre  -22.14    113.30  -0.195  0.84542
M_PARTOsetiembre  41.21    138.61   0.297  0.76680
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
Residual standard error: 254.5 on 110 degrees of freedom

```

(1 observation deleted due to missingness)
Multiple R-squared: 0.6215, Adjusted R-squared: 0.563
F-statistic: 10.63 on 17 and 110 DF, p-value: 2.663e-16

```
> #
> #ANALISIS DE VARIANZA
> anova(MODELO1)
Analysis of Variance Table
```

Response: INT_PART

	Df	Sum Sq	Mean Sq	F value	Pr(>F)
RAZA	2	269191	134596	2.0780	0.1301
N_LACT	4	10560013	2640003	40.7577	<2e-16 ***
M_PARTO	11	871346	79213	1.2229	0.2804
Residuals	110	7125049	64773		

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

```
> #
> #PRUEBA DE TUKEY usando libreria agricola
> library(agricolae)
> outHSD <-HSD.test(MODELO1, "RAZA",console=TRUE)
```

Study: MODELO1 ~ "RAZA"

HSD Test for INT_PART

Mean Square Error: 64773.17

RAZA, means

	INT_PART	std	r	se	Min	Max	Q25	Q50	Q75
BS	1018.5000	664.0999	6	103.90153	457	1972	477.5	775	1509.0
HO	801.6211	377.8396	95	26.11174	318	1767	500.5	695	1080.5
HO HIBRIDO	801.2593	335.7863	27	48.97965	356	1731	509.0	757	1038.5

Alpha: 0.05 ; DF Error: 110

Critical Value of Studentized Range: 3.359968

Groups according to probability of means differences and alpha level(0.05)

Treatments with the same letter are not significantly different.

INT_PART groups

BS	1018.5000	a
HO	801.6211	a
HO HIBRIDO	801.2593	a

```
> outHSD <-HSD.test(MODELO1, "N_LACT",console=TRUE)
```

Study: MODELO1 ~ "N_LACT"

HSD Test for INT_PART

Mean Square Error: 64773.17

N_LACT, means

	INT_PART	std	r	se	Min	Max	Q25	Q50	Q75
1	1209.5455	319.83393	44	38.36818	523	1972	1033.75	1148.0	1377.50
2	618.3810	198.27745	42	39.27109	318	1150	495.50	554.5	764.25
3	614.3846	237.16342	26	49.91268	346	1188	455.75	552.5	725.75
4	552.5714	235.48631	14	68.01952	329	1083	354.50	466.0	719.00
5	498.5000	74.24621	2	179.96273	446	551	472.25	498.5	524.75

Alpha: 0.05 ; DF Error: 110

Critical Value of Studentized Range: 3.922386

Groups according to probability of means differences and alpha level(0.05)

Treatments with the same letter are not significantly different.

INT_PART groups

1	1209.5455	a
2	618.3810	b
3	614.3846	b
4	552.5714	b
5	498.5000	b

```
> outHSD <-HSD.test(MODELO1, "M_PARTO",console=TRUE)
```

Study: MODELO1 ~ "M_PARTO"

HSD Test for INT_PART

Mean Square Error: 64773.17

M_PARTO, means

	INT_PART	std	r	se	Min	Max	Q25	Q50	Q75
abril	776.2500	530.5560	8	89.98137	418	1972	465.25	528.5	839.00
agosto	765.8571	367.3488	7	96.19413	329	1354	453.50	892.0	939.50
diciembre	1118.0000	372.4401	11	76.73637	492	1651	974.50	1099.0	1428.00
enero	640.5000	242.4217	14	68.01952	421	1203	499.75	512.5	731.25
febrero	1135.0000	507.5139	6	103.90153	571	1767	838.50	944.0	1571.50
julio	690.8000	335.6325	5	113.81843	374	1188	450.00	574.0	868.00
junio	705.5000	346.9874	8	89.98137	380	1329	500.25	552.5	790.75
marzo	871.2632	396.7277	19	58.38762	356	1731	512.50	807.0	1068.50
mayo	849.4375	382.7035	16	63.62643	337	1377	474.50	911.5	1150.75
noviembre	916.7273	245.6942	11	76.73637	551	1246	719.50	1004.0	1080.50
octubre	624.5000	344.7285	16	63.62643	318	1667	365.25	557.0	650.50
setiembre	704.8571	362.2197	7	96.19413	354	1468	525.00	601.0	730.50

```

Alpha: 0.05 ; DF Error: 110
Critical Value of Studentized Range: 4.722893
Groups according to probability of means differences and alpha level( 0.05 )
Treatments with the same letter are not significantly different.
      INT PART groups
febrero  1135.0000    a
diciembre 1118.0000    a
noviembre  916.7273   ab
marzo     871.2632   ab
mayo      849.4375   ab
abril     776.2500   ab
agosto    765.8571   ab
junio     705.5000   ab
setiembre 704.8571   ab
julio     690.8000   ab
enero     640.5000    b
octubre   624.5000    b
>
> #
> #EVALUACION GRAFICA DE NORMALIDAD DE RESIDUOS DEL MODELO
> #
> qqnorm(MODELO1$residuals)
> qqline(MODELO1$residuals)
> par(mfrow = c(1,2))
> plot(MODELO1, which = 1:4)
<Enter> para ver el próximo gráfico: #
<Enter> para ver el próximo gráfico: #
> #normalidad de residuos
> shapiro.test(MODELO1$residuals)
      Shapiro-Wilk normality test
data:  MODELO1$residuals
W = 0.98672, p-value = 0.2499
Hibrido
> #por razas
> #modelo
> MODELO2 <- aov(INT_PART ~ N_LACT + M_PARTO, data = Hibrido)
> summary.lm(MODELO2)
Call:
aov(formula = INT_PART ~ N_LACT + M_PARTO, data = Hibrido)
Residuals:
      Min       1Q   Median       3Q      Max
-544.22  -52.83   -9.50   40.50  663.78
Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)      716.9      360.4   1.989  0.06659 .
N_LACT2          -327.9      238.1  -1.377  0.19014
N_LACT3          -298.9      233.9  -1.278  0.22203
N_LACT4          -690.9      216.0  -3.198  0.00645 **
M_PARTOagosto     278.0      385.9   0.720  0.48309
M_PARTOdiciembre   382.1      452.9   0.844  0.41298
M_PARTOenero       130.5      321.0   0.407  0.69046
M_PARTOfebrero     283.1      452.9   0.625  0.54192
M_PARTOjunio       106.0      431.8   0.245  0.80966
M_PARTOmarzo       350.3      354.0   0.990  0.33916
M_PARTOmayo        437.7      362.4   1.208  0.24718
M_PARTOnoviembre   536.0      431.8   1.241  0.23492
M_PARTOsetiembre   233.3      322.9   0.723  0.48182
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
Residual standard error: 274.2 on 14 degrees of freedom
Multiple R-squared:  0.6409, Adjusted R-squared:  0.3331
F-statistic: 2.082 on 12 and 14 DF, p-value: 0.09586
> #
> #anova
> anova(MODELO2)
Analysis of Variance Table
Response: INT_PART
      Df Sum Sq Mean Sq F value    Pr(>F)
N_LACT   3 1613243   537748   7.1515 0.003803 **
M_PARTO   9  265604    29512   0.3925 0.919087
Residuals 14 1052716    75194
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> #
> #PRUEBA DE TUKEY usando libreria agricola
> library(agricolae)
> outHSD <-HSD.test(MODELO2, "N_LACT",console=TRUE)

```

```

Study: MODELO2 ~ "N_LACT"
HSD Test for INT_PART
Mean Square Error: 75194.02
N_LACT, means
  INT_PART      std r      se Min  Max    Q25    Q50    Q75
1 1087.8182 305.63469 11 82.67902 523 1731 1015.00 1094.0 1205.0
2 655.2500 185.63693 8 96.94974 442 925 506.25 606.0 797.5
3 597.6667 164.17998 6 111.94792 418 829 481.75 554.5 718.0
4 420.0000 90.50967 2 193.89949 356 484 388.00 420.0 452.0

Alpha: 0.05 ; DF Error: 14
Critical Value of Studentized Range: 4.110506
Groups according to probability of means differences and alpha level( 0.05 )
Treatments with the same letter are not significantly different.
  INT_PART groups
1 1087.8182 a
2 655.2500 b
3 597.6667 b
4 420.0000 b
> outHSD <-HSD.test(MODELO2, "M_PARTO",console=TRUE)
Study: MODELO2 ~ "M_PARTO"
HSD Test for INT_PART
Mean Square Error: 75194.02
M_PARTO, means
  INT_PART      std r      se Min  Max    Q25    Q50    Q75
abril 418.0000 NA 1 274.21529 418 418 418.00 418.0 418.00
agosto 667.0000 318.1981 2 193.89949 442 892 554.50 667.0 779.50
diciembre 1099.0000 NA 1 274.21529 1099 1099 1099.00 1099.0 1099.00
enero 534.0000 75.9254 4 137.10764 473 645 499.25 509.0 543.75
febrero 1000.0000 NA 1 274.21529 1000 1000 1000.00 1000.0 1000.00
junio 495.0000 NA 1 274.21529 495 495 495.00 495.0 495.00
marzo 943.5000 435.1456 8 96.94974 356 1731 693.25 929.5 1105.75
mayo 950.8000 320.5631 5 122.63280 484 1273 766.00 1094.0 1137.00
noviembre 925.0000 NA 1 274.21529 925 925 925.00 925.0 925.00
setiembre 641.6667 101.3180 3 158.31827 567 757 584.00 601.0 679.00
Alpha: 0.05 ; DF Error: 14
Critical Value of Studentized Range: 5.253408
Groups according to probability of means differences and alpha level( 0.05 )
Treatments with the same letter are not significantly different.
  INT_PART groups
diciembre 1099.0000 a
febrero 1000.0000 a
mayo 950.8000 a
marzo 943.5000 a
noviembre 925.0000 a
agosto 667.0000 a
setiembre 641.6667 a
enero 534.0000 a
junio 495.0000 a
abril 418.0000 a
> #
> #EVALUACION GRAFICA DE NORMALIDAD DE RESIDUOS DEL MODELO
> #
> qqnorm(MODELO2$residuals)
> qqline(MODELO2$residuals)
> par(mfrow = c(1,2))
> plot(MODELO2, which = 1:4)
<Enter> para ver el próximo gráfico: #
<Enter> para ver el próximo gráfico: #
Aviso:
not plotting observations with leverage one:
4, 21, 22, 24, 25
> #normalidad de residuos
> shapiro.test(MODELO2$residuals)
Shapiro-Wilk normality test
data: MODELO2$residuals
W = 0.82823, p-value = 0.0004399
Holstein
> #por razas
> #modelo
> MODELO2 <- aov(INT_PART ~ N_LACT + M_PARTO, data = holstein)
> summary.lm(MODELO2)
Call:
aov(formula = INT_PART ~ N_LACT + M_PARTO, data = holstein)

Residuals:
  Min      1Q  Median      3Q     Max

```

```

-512.1 -155.0   -8.4  124.6  544.7
Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)   1134.701    117.110   9.689 4.42e-15 ***
N_LACT2       -570.772     64.790  -8.810 2.29e-13 ***
N_LACT3       -619.876     77.561  -7.992 9.03e-12 ***
N_LACT4       -598.190     87.581  -6.830 1.58e-09 ***
N_LACT5       -587.185    181.450  -3.236 0.00177 **
M_PARTOagosto    48.039    160.856   0.299 0.76599
M_PARTOdiciembre 328.095    136.664   2.401 0.01871 *
M_PARTOenero   -105.502    135.822  -0.777 0.43962
M_PARTOfebrero  265.428    153.908   1.725 0.08851 .
M_PARTOjulio    166.154    160.325   1.036 0.30320
M_PARTOjunio   -58.945    142.297  -0.414 0.67982
M_PARTOmarzo    111.074    128.886   0.862 0.39141
M_PARTOmayero    41.330    129.011   0.320 0.74954
M_PARTOnoviembre 71.495    132.320   0.540 0.59050
M_PARTOoctubre   7.469    124.316   0.060 0.95224
M_PARTOsetiembre 77.034    164.599   0.468 0.64107
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
Residual standard error: 237.7 on 79 degrees of freedom
(1 observation deleted due to missingness)
Multiple R-squared:  0.6674, Adjusted R-squared:  0.6042
F-statistic: 10.57 on 15 and 79 DF, p-value: 2.353e-13
> #
> #anova
> anova(MODELO2)
Analysis of Variance Table

Response: INT_PART
              Df Sum Sq Mean Sq F value    Pr(>F)
N_LACT         4 7696997 1924249  34.0532 < 2e-16 ***
M_PARTO        11 1258645  114422   2.0249 0.03659 *
Residuals      79 4464058   56507
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> #
> #PRUEBA DE TUKEY usando libreria agricola
> library(agricolae)
> outHSD <-HSD.test(MODELO2, "N_LACT",console=TRUE)
Study: MODELO2 ~ "N_LACT"
HSD Test for INT_PART
Mean Square Error: 56507.07
N_LACT, means
      INT_PART      std  r      se Min  Max    Q25    Q50    Q75
1 1219.3333 292.29005 30  43.40010 536 1767 1054.75 1185.5 1378.50
2  619.0000 205.58241 32  42.02197 318 1150  497.75  554.5  771.00
3  624.8947 264.33709 19  54.53491 346 1188  448.00  555.0  718.50
4  574.6667 247.11033 12  68.62159 329 1083  350.25  497.0  735.25
5  498.5000  74.24621  2 168.08787 446  551  472.25  498.5  524.75
Alpha: 0.05 ; DF Error: 79
Critical Value of Studentized Range: 3.948175
Groups according to probability of means differences and alpha level( 0.05 )
Treatments with the same letter are not significantly different.
      INT_PART groups
1 1219.3333      a
3  624.8947      b
2  619.0000      b
4  574.6667      b
5  498.5000      b
> outHSD <-HSD.test(MODELO2, "M_PARTO",console=TRUE)
Study: MODELO2 ~ "M_PARTO"
HSD Test for INT_PART
Mean Square Error: 56507.07
M_PARTO, means
      INT_PART      std  r      se Min  Max    Q25    Q50    Q75
abril      672.6000 253.2929  5 106.30810 468 1079 511.00 546.0  759.00
agosto     890.5000 422.7754  4 118.85607 329 1354 767.75 939.5 1062.25
diciembre 1129.3333 415.1370  9  79.23738 492 1651 939.00 1155.0 1477.00
enero      701.7778 285.4338  9  79.23738 421 1203 497.00  536.0  960.00
febrero    1162.0000 562.5793  5 106.30810 571 1767 822.00  888.0 1762.00
julio      690.8000 335.6325  5 106.30810 374 1188 450.00  574.0  868.00
junio      735.5714 363.3551  7  89.84675 380 1329 526.00  555.0  916.50
marzo      818.7273 378.8805 11  71.67291 421 1601 500.00  733.0  984.50
mayo       803.3636 413.6622 11  71.67291 337 1377 433.00  695.0 1151.50
noviembre  915.9000 258.9682 10  75.17118 551 1246 662.75 1029.0 1081.25
octubre    555.0000 211.0020 15  61.37701 318 1083 362.50  551.0  633.50

```

```

setiembre 752.2500 498.5729 4 118.85607 354 1468 450.75 593.5 895.00
Alpha: 0.05 ; DF Error: 79
Critical Value of Studentized Range: 4.763054
Groups according to probability of means differences and alpha level( 0.05 )
Treatments with the same letter are not significantly different.
      INT_PART groups
febrero 1162.0000      a
diciembre 1129.3333      a
noviembre 915.9000     ab
agosto 890.5000      abc
marzo 818.7273      abc
mayo 803.3636      abc
setiembre 752.2500     abc
junio 735.5714      abc
enero 701.7778       bc
julio 690.8000       bc
abril 672.6000       bc
octubre 555.0000       c
> #
> #EVALUACION GRAFICA DE NORMALIDAD DE RESIDUOS DEL MODELO
> #
> qqnorm(MODELO2$residuals)
> qqline(MODELO2$residuals)
> par(mfrow = c(1,2))
> plot(MODELO2, which = 1:4)
<Enter> para ver el próximo gráfico: #
<Enter> para ver el próximo gráfico: #
> #normalidad de residuos
> shapiro.test(MODELO2$residuals)
      Shapiro-Wilk normality test
data:  MODELO2$residuals
W = 0.98769, p-value = 0.5234

```

Anexo 3. Modelo de comandos empleados en el procesamiento de datos en el Rstudio para el “Tercer objetivo”

Se usaron 4 modelos:

1 modelo de Woods: $Y = ax^b e^{-cx}$

2. Modelo de Wilmink: $Y = a + bx + ce^{-kx}$

3. Modelo de crecimiento desacelerado con declive lineal: $Y = a + (b - a) * (1 - e^{(-k*x)} - c * x)$

3. Modelo cuadrático polinomial o de Dave: $Y = a + b\sqrt{x} + c * \log(x)$

Script (1ra lactancia)

```
# Cargar los datos desde el archivo Excel
setwd("C:/Users/User/Downloads")
#produccion1 <- read.csv('datoskr.csv', header = T, sep = ";")
# Cargar los datos desde el archivo Excel
library(readxl)
produccion <- read_excel("BDKORAIMA.xlsx")
# Cargar librerías necesarias
library(dplyr)
library(tidyr)
library(ggplot2)
# Seleccionar las columnas correspondientes a los días de recolección
data_days <- produccion %>% select(`1`:`840`) # Seleccionar columnas numeradas del 1 al 840
data_days305 <- produccion %>% select(`1`:`305`) # seleccionar columnas numeradas de 1 a 305 días
# Asegurarse de que todas las columnas sean numéricas
data_days <- data_days %>% mutate(across(everything(), as.numeric))
data_days305 <- data_days305 %>% mutate(across(everything(), as.numeric))
#
# Objetivo 3
# Modelar el comportamiento de la curva de lactación mediante modelos matemáticos
# Paso 1: Asegurar que las columnas de días sean numéricas
produccion_clean305 <- produccion %>%
  mutate(across(`1`:`305`, as.numeric)) # Convertir las columnas de producción diaria a
numérico
#
# Paso 2b: Transformar los datos a formato largo
library(tidyr)
prod_long305 <- produccion_clean305 %>%
  select(CODIGO, RAZA, Nro_LACT, `1`:`305`) %>%
  pivot_longer(
    cols = `1`:`305`,
    names_to = "Dia",
    values_to = "Produccion"
  ) %>%
  mutate(
    Dia = as.numeric(Dia), # Convertir los días a numéricos
    Produccion = as.numeric(Produccion) # Asegurar que Producción también es numérica
  ) %>%
  filter(!is.na(Produccion) & Produccion > 0) # Filtrar valores no válidos o NA
#
# Verificar los primeros datos
print(head(prod_long305))
# subconjuntos por raza
lact1 <- subset (prod_long305, Nro_LACT == "1")
lact2 <- subset (prod_long305, Nro_LACT == "2")
lact3aM <- subset(prod_long305, Nro_LACT == "3":"5")
#
str(lact1)
#EVALUACION DE MODELOS
library(lme4)
library(nlme)
#
#plot all cows
p <- ggplot(data = prod_long305, aes(x = Dia, y = Produccion, colour = Nro_LACT)) +
  geom_point() +
  theme_bw() +
  ylab("Milk yield (L for week)") +
  xlab("Date") +
  theme(legend.position = "none")
p
#unique(data$CowId)
CODIGO <- as.vector(unique(prod_long305$CODIGO))
#
# CowIds.list <- split(CowIds, seq(length(CowIds)))
#COD.BUSCADO <- c(1,2,3)
```

```

p <- ggplot(data = prod_long305, #>% filter(COD.BUSCADO %in% prod_long305$Nro_LACT),
  aes(x = Dia, y = Produccion, colour = Nro_LACT)) +
  geom_point() +
  geom_smooth()+
  ylab("prod leche (Kg por día)")+
  xlab("Date")+
  theme_bw()+
  theme(legend.position = "día")
#p
s <- p + facet_wrap( ~ Nro_LACT)
s

# 1. Ajuste de los 4 modelos de tercera a más lactancia
# otra forma
datos<-lact1
summary(datos$Dia) # Verifica valores mínimos
summary(datos$Produccion)
# Cargar paquetes
library(ggplot2)
library(dplyr)
library(tidyr)
library(purrr)
library(boot)
# Modelo 1: Wood -> Y = a * x^b * exp(-c * x)
modelo_wood <- nls(Produccion ~ a * Dia^b * exp(-c * Dia),
  data = datos,
  start = list(a = 25, b = 0.1, c = 0.01),
  control = nls.control(maxiter = 100))
summary(modelo_wood)
# Modelo 2. Wilmlink --> Y ~ a + b*exp(d*x) + c*x
modelo_wilmlink <- nls(Produccion ~ a + b*exp(d*Dia) + c*Dia,
  data = datos,
  start = c(a= max(datos$Produccion, na.rm = TRUE),
    b=-11,
    c=-.07,
    d=-.05),
  control = nls.control(maxiter = 200, warnOnly = TRUE))
summary(modelo_wilmlink)
# Modelo 3: crecimiento desacelerado con declive lineal --> Y ~ a + (b - a) * (1 - e^(-k *
x)) - c * x
modelo_transform <- nls(Produccion ~ a + (b - a) * (1 - e^(-k * Dia)) - c * Dia,
  data = datos,
  start = list(a = max(datos$Produccion, na.rm = TRUE),
    b = 30,
    c = 0.005,
    e = 2.7182818284,
    k = 0.08),
  control = list(maxiter = 100, tol = 1e-05, minFactor = 0.0009765625,
    printEval = FALSE, warnOnly = TRUE, scaleOffset = 0,
    nDcentral = FALSE), na.action = na.exclude, algorithm = "default",
  trace = FALSE)
summary(modelo_transform)
#
# Modelo 4: Quadratic Polynomial (Dave)
modelo_dave <- nls(Produccion ~ a + b * Dia^0.5 + c * log(Dia),
  data = datos,
  start = c(a = max(datos$Produccion, na.rm = TRUE),
    b = 30, c = 0.05),
  control = nls.control(maxiter = 100))
summary(modelo_dave)
# 2. Crear predicciones para graficar las curvas
# Crear secuencia de días para predicción
nuevo_dia <- data.frame(Dia = seq(min(datos$Dia), max(datos$Dia), length.out = 200))
# Generar predicciones
nuevo_dia$wood <- predict(modelo_wood, newdata = nuevo_dia)
nuevo_dia$wilmlink <- predict(modelo_wilmlink, newdata = nuevo_dia)
nuevo_dia$transf <- predict(modelo_transform, newdata = nuevo_dia)
nuevo_dia$dave <- predict(modelo_dave, newdata = nuevo_dia)
# Convertir a formato largo para graficar fácilmente
curvas_predichas <- pivot_longer(nuevo_dia, cols = -Dia,
  names_to = "Modelo",
  values_to = "Prediccion")
# 3. Graficar curvas de predicción vs. datos reales
ggplot() +
  geom_point(data = datos, aes(x = Dia, y = Produccion), alpha = 0.4) +
  geom_line(data = curvas_predichas, aes(x = Dia, y = Prediccion, color = Modelo), size = 1)
+

```

```

labs(title = "Curvas de lactancia predichas por modelo",
      x = "Día de lactación",
      y = "Producción de leche") +
theme_minimal() +
scale_color_brewer(palette = "Set1")

# 4 Calcular estadísticos comparativos
# R² manual para modelos nls
r2_nls <- function(model, obs) {
  rss <- sum(residuals(model)^2)
  tss <- sum((obs - mean(obs))^2)
  1 - rss/tss

# RMSE genérico
rmse <- function(model, obs) {
  sqrt(mean(residuals(model)^2))
# Validación cruzada manual para nls (modelo combinado y modelo wilmlink)
cv_nls_rmse <- function(model_formula, start_list, data, K = 10) {
  folds <- sample(rep(1:K, length.out = nrow(data)))
  errors <- map_dbl(1:K, function(k) {
    train <- data[folds != k, ]
    test <- data[folds == k, ]
    fit <- tryCatch(nls(model_formula, data = train, start = start_list,
                        control = nls.control(maxiter = 100)), error = function(e)
return(NA))
    if (is.na(fit)) return(NA)
    pred <- predict(fit, newdata = test)
    sqrt(mean((test$Produccion - pred)^2))
  })
  mean(errors, na.rm = TRUE)
# Validación cruzada para modelos lineales
cv1 <- cv.glm(datos, modelo_transform, K = 10)
cv_rmse_transform <- sqrt(cv1$delta[1])
# Para modelo wood
cv_rmse_wood <- cv_nls_rmse(Produccion ~ a * Dia^b * exp(-c * Dia),
                           list(a = 0.1, b = 0.1, c = 0.01), datos)
# Para modelo wilmlink
cv_rmse_wilmlink <- cv_nls_rmse(Produccion ~ a + b * Dia + c * exp(-k * Dia),
                               list(a = 0.1, b = 0.05, c = 10, k = 0.05), datos)
# Para modelo de Dave
cv_rmse_dave <- cv_nls_rmse(Produccion ~ a + b * Dia^0.5 + c * log(Dia),
                           list(a = 0.1, b = 30, k = 0.01, c = 0.05), datos)
# Crear resumen de resultados
resultados <- data.frame(
  Modelo = c("Wood", "Wilmlink", "Transformado", "Dave"),
  AIC = c(AIC(modelo_wood), AIC(modelo_wilmlink), AIC(modelo_transform), AIC(modelo_dave)),
  BIC = c(BIC(modelo_wood), BIC(modelo_wilmlink), BIC(modelo_transform), BIC(modelo_dave)),
  R2 = c(r2_nls(modelo_wood, datos$Produccion),
        r2_nls(modelo_wilmlink, datos$Produccion),
        summary(modelo_transform)$r.squared,
        r2_nls(modelo_dave, datos$Produccion)),
  RMSE = c(rmse(modelo_wood, datos$Produccion),
           rmse(modelo_wilmlink, datos$Produccion),
           rmse(modelo_transform, datos$Produccion),
           rmse(modelo_dave, datos$Produccion)),
  CV_RMSE = c(cv_rmse_wood, cv_rmse_wilmlink, cv_rmse_transform, cv_rmse_dave)
print(resultados)
# Graficar comparación de modelos por criterios
# Convertir a formato largo para graficar
resultados_largos <- resultados %>%
  pivot_longer(cols = -Modelo, names_to = "Criterio", values_to = "Valor")
# Gráfico de comparación
ggplot(resultados_largos, aes(x = Modelo, y = Valor, fill = Modelo)) +
  geom_bar(stat = "identity", position = "dodge") +
  facet_wrap(~ Criterio, scales = "free_y") +
  labs(title = "Comparación de modelos de curva de lactancia",
       y = "Valor del criterio", x = "Modelo") +
  theme_minimal() +
  theme(axis.text.x = element_text(angle = 45, hjust = 1)) +
  scale_fill_brewer(palette = "Set2")
# 6 obtener estos componentes por modelo
# Crear secuencia de 1 a 305 días
dias_305 <- data.frame(Dia = 1:305)

# Predicciones para cada modelo
dias_305$wood <- predict(modelo_wood, newdata = dias_305)
dias_305$wilmlink <- predict(modelo_wilmlink, newdata = dias_305)

```

```

dias_305$transf <- predict(modelo_transform, newdata = dias_305)
dias_305$dave <- predict(modelo_dave, newdata = dias_305)
# Función para obtener componentes
obtener_componentes <- function(dias, produccion) {
  dia_pico <- dias[which.max(produccion)]
  pico <- max(produccion)
  total305 <- sum(produccion) # Aproximación por suma (integración discreta)
  return(c(Dia_Pico = dia_pico, Pico = pico, Total_305 = total305))
# Aplicar a cada modelo
comp_wood <- obtener_componentes(dias_305$Dia, dias_305$wood)
comp_wilmink <- obtener_componentes(dias_305$Dia, dias_305$wilmink)
comp_transf <- obtener_componentes(dias_305$Dia, dias_305$transf)
comp_dave <- obtener_componentes(dias_305$Dia, dias_305$dave)
# Combinar en un data frame
componentes_lactancia <- rbind(
  Wood = comp_wood,
  Wilmink = comp_wilmink,
  Transformado = comp_transf,
  Combinado = comp_dave
) %>% as.data.frame()
componentes_lactancia

```

RESULTADOS

```


> # Cargar los datos desde el archivo Excel
> setwd("C:/Users/User/Downloads")
> #produccion1 <- read.csv('datoskr.csv', header = T, sep = ";")
> # Cargar los datos desde el archivo Excel
> library(readxl)
> produccion <- read_excel("BDKORAIMA.xlsx")
> # Cargar librerías necesarias
> library(dplyr)
> library(tidyr)
> library(ggplot2)
> # Seleccionar las columnas correspondientes a los días de recolección
> data_days <- produccion %>% select(`1`:`840`) # Seleccionar columnas numeradas del 1 al
840
> data_days305 <- produccion %>% select(`1`:`305`) # seleccionar columnas numeradas de 1 a
305 días
> # Asegurarse de que todas las columnas sean numéricas
> data_days <- data_days %>% mutate(across(everything(), as.numeric))
> data_days305 <- data_days305 %>% mutate(across(everything(), as.numeric))
> #
> # Objetivo e Hipotesis especifica 3
> # Modelar el comportamiento de la curva de lactación mediante modelos matemáticos
>
> # Paso 1: Asegurar que las columnas de días sean numéricas
> produccion_clean305 <- produccion %>%
+   mutate(across(`1`:`305`, as.numeric)) # Convertir las columnas de producción diaria a
numérico
> #
> # Paso 2b: Transformar los datos a formato largo
> library(tidyr)
> prod_long305 <- produccion_clean305 %>%
+   select(CODIGO, RAZA, Nro_LACT, `1`:`305`) %>%
+   pivot_longer(
+     cols = `1`:`305`,
+     names_to = "Dia",
+     values_to = "Produccion"
+   ) %>%
+   mutate(
+     Dia = as.numeric(Dia), # Convertir los días a numéricos
+     Produccion = as.numeric(Produccion) # Asegurar que Producción también es numérica
+   ) %>%
+   filter(!is.na(Produccion) & Produccion > 0) # Filtrar valores no válidos o NA
> #
> # Verificar los primeros datos
> print(head(prod_long305))
# A tibble: 6 × 5
  CODIGO RAZA Nro_LACT Dia Produccion
  <dbl> <chr>   <dbl> <dbl>   <dbl>
1  1510 HO      2      1    14.3
2  1510 HO      2      2    15.2
3  1510 HO      2      3    17.2
4  1510 HO      2      4     18
5  1510 HO      2      5    18.4
6  1510 HO      2      6    19.5
> # subconjuntos por raza

```

```

> lact1 <- subset (prod_long305, Nro_LACT == "1")
> lact2 <- subset (prod_long305, Nro_LACT == "2")
> lact3aM <- subset(prod_long305, Nro_LACT == "3":"5")
> #
> str(lact1)
tibble [11,076 × 5] (S3: tbl_df/tbl/data.frame)
 $ CODIGO      : num [1:11076] 1561 1561 1561 1561 1561 ...
 $ RAZA        : chr [1:11076] "HO" "HO" "HO" "HO" ...
 $ Nro_LACT    : num [1:11076] 1 1 1 1 1 1 1 1 1 ...
 $ Dia         : num [1:11076] 1 2 3 4 5 6 7 8 9 10 ...
 $ Produccion: num [1:11076] 6.5 6.5 8.8 9.6 8.6 9.7 9.4 9.2 10.3 9.8 ...
> #EVALUACION DE MODELOS
> library(lme4)
> library(nlme)
> #plot all cows
> p <- ggplot(data = prod_long305, aes(x = Dia, y = Produccion, colour = Nro_LACT)) +
  geom_point()+
  + theme_bw()+
  + ylab("Milk yield (L for week)")+
  + xlab("Date")+
  + theme(legend.position = "none")
> p


```



```

> #unique(data$CowId)
> CODIGO <- as.vector(unique(prod_long305$CODIGO))
> #
> # CowIds.list <- split(CowIds, seq(length(CowIds)))
>
> #COD.BUSCADO <- c(1,2,3)
>
> p <- ggplot(data = prod_long305, ##>% filter(COD.BUSCADO %in% prod_long305$Nro_LACT),
+ aes(x = Dia, y = Produccion, colour = Nro_LACT)) +
+ geom_point() +
+ geom_smooth()+
+ ylab("prod leche (Kg por dia)")+
+ xlab("Date")+
+ theme_bw()+
+ theme(legend.position = "dia")
> #p
> s <- p + facet_wrap( ~ Nro_LACT)
> s
`geom_smooth()` using method = 'gam' and formula = 'y ~ s(x, bs = "cs")'

```



```

> # 1. Ajuste de los 4 modelos de primera lactancia
> # 1. Ajuste de los 4 modelos de tercera a más lactancia

```

```

> # otra forma
> datos<-lact1
> summary(datos$Dia) # Verifica valores mínimos
  Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
   1.0   63.0   127.0   135.1   202.0   305.0
> summary(datos$Produccion)
  Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
   1.70   9.10   11.20   11.66   13.70   26.20
> # Cargar paquetes
> library(ggplot2)
> library(dplyr)
> library(tidyr)
> library(purrr)
> library(boot)
> # Modelo 1: Wood -> Y = a * x^b * exp(-c * x)
> modelo_wood <- nls(Produccion ~ a * Dia^b * exp(-c * Dia),
+                   data = datos,
+                   start = list(a = 25, b = 0.1, c = 0.01),
+                   control = nls.control(maxiter = 100))
> summary(modelo_wood)
Formula: Produccion ~ a * Dia^b * exp(-c * Dia)
Parameters:
      Estimate Std. Error t value Pr(>|t|)
a 1.232e+01  2.250e-01  54.756 < 2e-16 ***
b 4.210e-03  5.577e-03   0.755   0.45
c 5.601e-04  6.830e-05   8.201 2.65e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
Residual standard error: 3.414 on 11073 degrees of freedom
Number of iterations to convergence: 6
Achieved convergence tolerance: 1.634e-06
> # Modelo 2. Wilink --> Y ~ a + b*exp(d*x) + c*x
> modelo_wilink <- nls(Produccion ~ a + b*exp(d*Dia) + c*Dia,
+                   data = datos,
+                   start = c(a= max(datos$Produccion, na.rm = TRUE),
+                             b=-11,
+                             c=-.07,
+                             d=-.05),
+                   control = nls.control(maxiter = 200, warnOnly = TRUE))
> summary(modelo_wilink)
Formula: Produccion ~ a + b * exp(d * Dia) + c * Dia
Parameters:
      Estimate Std. Error t value Pr(>|t|)
a 1.260e+01  6.376e-02 197.614 < 2e-16 ***
b -1.061e+01  1.898e+00 -5.589 2.34e-08 ***
c -6.658e-03  3.957e-04 -16.825 < 2e-16 ***
d -6.712e-01  1.198e-01 -5.600 2.19e-08 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
Residual standard error: 3.393 on 11072 degrees of freedom
Number of iterations to convergence: 10
Achieved convergence tolerance: 5.161e-06
> # Modelo 3: crecimiento desacelerado con declive lineal --> Y ~ a + (b - a) * (1 - e^(-k
* x)) - c * x
> modelo_transform <- nls(Produccion ~ a + (b - a) * (1 - e^(-k * Dia)) - c * Dia,
+ data = datos,
+ start = list(a = max(datos$Produccion, na.rm = TRUE),
+             b = 30,
+             c = 0.005,
+             e = 2.7182818284,
+             k = 0.08),
+ control = list(maxiter = 100, tol = 1e-05, minFactor = 0.0009765625,
+               printEval = FALSE, warnOnly = TRUE, scaleOffset = 0,
+               nDcentral = FALSE), na.action = na.exclude, algorithm = "default",
+ trace = FALSE)
Error en nlsModel(formula, mf, start, wts, scaleOffset = scOff, nDcentral = nDcntr):
singular gradient matrix at initial parameter estimates
> summary(modelo_transform)
Call:
lm(formula = Produccion ~ sqrt(Dia) + log(Dia), data = datos)
Residuals:
    Min       1Q   Median       3Q      Max
-12.6235  -2.3796  -0.3539   1.9230  12.2429
Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)  15.7698      0.4336  36.366 < 2e-16 ***
sqrt(Dia)    -0.6463      0.0468 -13.810 < 2e-16 ***

```

```

log(Dia)      0.9818      0.1936      5.073 4.12e-07 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
Residual standard error: 3.503 on 3684 degrees of freedom
Multiple R-squared:  0.1964, Adjusted R-squared:  0.196
F-statistic: 450.2 on 2 and 3684 DF, p-value: < 2.2e-16
> #
> # Modelo 4: Quadratic Polynomial (Dave)
> modelo_dave <- nls(Produccion ~ a + b * Dia^0.5 + c * log(Dia),
+                   data = datos,
+                   start = c(a = max(datos$Produccion, na.rm = TRUE),
+                             b = 30, c = 0.05),
+                   control = nls.control(maxiter = 100))
> summary(modelo_dave)
Formula: Produccion ~ a + b * Dia^0.5 + c * log(Dia)
Parameters:
      Estimate Std. Error t value Pr(>|t|)
a 11.75661     0.23532    49.96 < 2e-16 ***
b -0.27158     0.02604   -10.43 < 2e-16 ***
c  0.62396     0.10612     5.88 4.23e-09 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
Residual standard error: 3.407 on 11073 degrees of freedom
Number of iterations to convergence: 1
Achieved convergence tolerance: 5.718e-07
> # 2. Crear predicciones para graficar las curvas
> # Crear secuencia de días para predicción
> nuevo_dia <- data.frame(Dia = seq(min(datos$Dia), max(datos$Dia), length.out = 200))
>
> # Generar predicciones
> nuevo_dia$wood <- predict(modelo_wood, newdata = nuevo_dia)
> nuevo_dia$wilink <- predict(modelo_wilink, newdata = nuevo_dia)
> nuevo_dia$transf <- predict(modelo_transform, newdata = nuevo_dia)
> nuevo_dia$dave <- predict(modelo_dave, newdata = nuevo_dia)
>
> # Convertir a formato largo para graficar fácilmente
> curvas_predichas <- pivot_longer(nuevo_dia, cols = -Dia,
+                                names_to = "Modelo",
+                                values_to = "Prediccion")
> #
> # 3. Graficar curvas de predicción vs. datos reales
> ggplot() +
+   geom_point(data = datos, aes(x = Dia, y = Produccion), alpha = 0.4) +
+   geom_line(data = curvas_predichas, aes(x = Dia, y = Prediccion, color = Modelo), size =
1) +
+   labs(title = "Curvas de lactancia predichas por modelo",
+        x = "Día de lactación",
+        y = "Producción de leche") +
+   theme_minimal() +
+   scale_color_brewer(palette = "Set1")
> # 4 Calcular estadísticos comparativos
> # R² manual para modelos nls
> r2_nls <- function(model, obs) {
+   rss <- sum(residuals(model)^2)
+   tss <- sum((obs - mean(obs))^2)
+   1 - rss/tss
+ }
>
> # RMSE genérico
> rmse <- function(model, obs) {
+   sqrt(mean(residuals(model)^2))
+ }
>
> # Validación cruzada manual para nls (modelo combinado y modelo wilink)
> cv_nls_rmse <- function(model_formula, start_list, data, K = 10) {
+   folds <- sample(rep(1:K, length.out = nrow(data)))
+   errors <- map_dbl(1:K, function(k) {
+     train <- data[folds != k, ]
+     test <- data[folds == k, ]
+     fit <- tryCatch(nls(model_formula, data = train, start = start_list,
+                           control = nls.control(maxiter = 100)), error = function(e)
return(NA))
+     if (is.na(fit)) return(NA)
+     pred <- predict(fit, newdata = test)
+     sqrt(mean((test$Produccion - pred)^2))
+   })
+   mean(errors, na.rm = TRUE)

```

```

+ }
>
> # Validación cruzada para modelos lineales
> cv1 <- cv.glm(datos, modelo_transform, K = 10)
> cv_rmse_transform <- sqrt(cv1$delta[1])
>
> # Para modelo wood
> cv_rmse_wood <- cv_nls_rmse(Produccion ~ a * Dia^b * exp(-c * Dia),
+                             list(a = 0.1, b = 0.1, c = 0.01), datos)
> #Para modelo wilmlink
> cv_rmse_wilmlink <- cv_nls_rmse(Produccion ~ a + b * Dia + c * exp(-k * Dia),
+                                 list(a = 0.1, b = 0.05, c = 10, k = 0.05), datos)
> # Para modelo de Dave
> cv_rmse_dave <- cv_nls_rmse(Produccion ~ a + b * Dia^0.5 + c * log(Dia),
+                             list(a = 0.1, b = 30, k = 0.01, c = 0.05), datos)
> # Crear resumen de resultados
> resultados <- data.frame(
+   Modelo = c("Wood", "Wilmlink", "Transformado", "Dave"),
+   AIC = c(AIC(modelo_wood), AIC(modelo_wilmlink), AIC(modelo_transform), AIC(modelo_dave)),
+   BIC = c(BIC(modelo_wood), BIC(modelo_wilmlink), BIC(modelo_transform), BIC(modelo_dave)),
+   R2 = c(r2_nls(modelo_wood, datos$Produccion),
+          r2_nls(modelo_wilmlink, datos$Produccion),
+          summary(modelo_transform)$r.squared,
+          r2_nls(modelo_dave, datos$Produccion)),
+   RMSE = c(rmse(modelo_wood, datos$Produccion),
+            rmse(modelo_wilmlink, datos$Produccion),
+            rmse(modelo_transform, datos$Produccion),
+            rmse(modelo_dave, datos$Produccion)),
+   CV_RMSE = c(cv_rmse_wood, cv_rmse_wilmlink, cv_rmse_transform, cv_rmse_dave)
+ )
>
> print(resultados)
      Modelo      AIC      BIC      R2      RMSE CV_RMSE
1      Wood 58639.19 58668.44 0.02071960 3.413810      NaN
2    Wilmlink 58502.44 58539.01 0.03291049 3.392494      NaN
3 Transformado 19712.17 19737.02 0.19641953 3.501443      NaN
4      Dave 58592.68 58621.93 0.02482346 3.406649      NaN

> # Graficar comparación de modelos por criterios
> # Convertir a formato largo para graficar
> resultados_largos <- resultados %>%
+   pivot_longer(cols = -Modelo, names_to = "Criterio", values_to = "Valor")
>
> # Gráfico de comparación
> ggplot(resultados_largos, aes(x = Modelo, y = Valor, fill = Modelo)) +
+   geom_bar(stat = "identity", position = "dodge") +
+   facet_wrap(~ Criterio, scales = "free_y") +
+   labs(title = "Comparación de modelos de curva de lactancia",
+        y = "Valor del criterio", x = "Modelo") +
+   theme_minimal() +
+   theme(axis.text.x = element_text(angle = 45, hjust = 1)) +
+   scale_fill_brewer(palette = "Set2")
Aviso:
Removed 4 rows containing missing values or values outside the scale range (`geom_bar()`).
> # 6 obtener estos componentes por modelo
> # Crear secuencia de 1 a 305 días
> dias_305 <- data.frame(Dia = 1:305)
>
> # Predicciones para cada modelo
> dias_305$wood <- predict(modelo_wood, newdata = dias_305)
> dias_305$wilmlink <- predict(modelo_wilmlink, newdata = dias_305)
> dias_305$transf <- predict(modelo_transform, newdata = dias_305)
> dias_305$dave <- predict(modelo_dave, newdata = dias_305)
> # Función para obtener componentes
> obtener_componentes <- function(dias, produccion) {
+   dia_pico <- dias[which.max(produccion)]
+   pico <- max(produccion)
+   total305 <- sum(produccion) # Aproximación por suma (integración discreta)
+   return(c(Dia_Pico = dia_pico, Pico = pico, Total_305 = total305))
+ }
> # Aplicar a cada modelo
> comp_wood <- obtener_componentes(dias_305$Dia, dias_305$wood)
> comp_wilmlink <- obtener_componentes(dias_305$Dia, dias_305$wilmlink)
> comp_transf <- obtener_componentes(dias_305$Dia, dias_305$transf)
> comp_dave <- obtener_componentes(dias_305$Dia, dias_305$dave)
>
> # Combinar en un data frame
> componentes_lactancia <- rbind(

```

```

+ Wood = comp_wood,
+ Wilmink = comp_wilmink,
+ Transformado = comp_transf,
+ Combinado = comp_dave
+ ) %>% as.data.frame()
>
> componentes_lactancia
      Dia_Pico      Pico Total_305
Wood          8 12.37287  3522.127
Wilmink        10 12.52002  3521.062
Transformado    9 15.98812  3926.364
Combinado      21 12.41176  3519.736

```

SCRIPT (2da lactancia)

```


> # Cargar los datos desde el archivo Excel
> setwd("C:/Users/User/Downloads")
> #produccion1 <- read.csv('datoskr.csv', header = T, sep =";")
> # Cargar los datos desde el archivo Excel
> library(readxl)
> produccion <- read_excel("BDKORAIMA.xlsx")
> # Cargar librerías necesarias
> library(dplyr)
> library(tidyr)
> library(ggplot2)
> # Seleccionar las columnas correspondientes a los días de recolección
> data_days <- produccion %>% select(`1`:`840`) # Seleccionar columnas numeradas del 1 al 840
> data_days305 <- produccion %>% select(`1`:`305`) # seleccionar columnas numeradas de 1 a 305 días
> # Asegurarse de que todas las columnas sean numéricas
> data_days <- data_days %>% mutate(across(everything(), as.numeric))
> data_days305 <- data_days305 %>% mutate(across(everything(), as.numeric))
> #
> # Objetivo e Hipotesis especifica 3
> # Modelar el comportamiento de la curva de lactación mediante modelos matemáticos
>
> # Paso 1: Asegurar que las columnas de días sean numéricas
> produccion_clean305 <- produccion %>%
+   mutate(across(`1`:`305`, as.numeric)) # Convertir las columnas de producción diaria a numérico
> #
> # Paso 2b: Transformar los datos a formato largo
> library(tidyr)
> prod_long305 <- produccion_clean305 %>%
+   select(CODIGO, RAZA, Nro_LACT, `1`:`305`) %>%
+   pivot_longer(
+     cols = `1`:`305`,
+     names_to = "Dia",
+     values_to = "Produccion"
+   ) %>%
+   mutate(
+     Dia = as.numeric(Dia), # Convertir los días a numéricos
+     Produccion = as.numeric(Produccion) # Asegurar que Producción también es numérica
+   ) %>%
+   filter(!is.na(Produccion) & Produccion > 0) # Filtrar valores no válidos o NA
> #
> # Verificar los primeros datos
> print(head(prod_long305))
# A tibble: 6 × 5
  CODIGO RAZA   Nro_LACT   Dia Produccion
  <dbl> <chr>   <dbl> <dbl>   <dbl>
1  1510 HO         2     1    14.3
2  1510 HO         2     2    15.2
3  1510 HO         2     3    17.2
4  1510 HO         2     4     18
5  1510 HO         2     5    18.4
6  1510 HO         2     6    19.5
> # subconjuntos por raza
> lact1 <- subset (prod_long305, Nro_LACT == "1")
> lact2 <- subset (prod_long305, Nro_LACT == "2")
> lact3aM <- subset(prod_long305, Nro_LACT == "3":"5")
> #
> str(lact1)
tibble [11,076 × 5] (S3: tbl_df/tbl/data.frame)
 $ CODIGO      : num [1:11076] 1561 1561 1561 1561 1561 ...
 $ RAZA        : chr [1:11076] "HO" "HO" "HO" "HO" ...
 $ Nro_LACT    : num [1:11076] 1 1 1 1 1 1 1 1 1 1 ...
 $ Dia        : num [1:11076] 1 2 3 4 5 6 7 8 9 10 ...
 $ Produccion: num [1:11076] 6.5 6.5 8.8 9.6 8.6 9.7 9.4 9.2 10.3 9.8 ...
> #EVALUACION DE MODELOS
> library(lme4)

```

```

> library(nlme)
> #plot all cows
> p <- ggplot(data = prod_long305, aes(x = Dia, y = Produccion, colour = Nro_LACT)) +
  geom_point()+
  + theme_bw()+
  + ylab("Milk yield (L for week)")+
  + xlab("Date")+
  + theme(legend.position = "none")
> p

```



```

> #unique(data$CowId)
> CODIGO <- as.vector(unique(prod_long305$CODIGO))
> #
> # CowIds.list <- split(CowIds, seq(length(CowIds)))
>
> #COD.BUSCADO <- c(1,2,3)
>
> p <- ggplot(data = prod_long305, ##>% filter(COD.BUSCADO %in% prod_long305$Nro_LACT),
+ aes(x = Dia, y = Produccion, colour = Nro_LACT)) +
+ geom_point() +
+ geom_smooth()+
+ ylab("prod leche (Kg por dia)")+
+ xlab("Date")+
+ theme_bw()+
+ theme(legend.position = "dia")
> #p
> s <- p + facet_wrap( ~ Nro_LACT)
> s
`geom_smooth()` using method = 'gam' and formula = 'y ~ s(x, bs = "cs")'

```



```

> # 1. Ajuste de los 4 modelos de segunda lactancia
> # otra forma
> datos<-lact2
> summary(datos$Dia) # Verifica valores mínimos
  Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
   1.0   66.0   133.0  138.2  207.0   305.0
> summary(datos$Produccion)
  Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
   1.40   10.00   12.50   12.79   15.00   28.60
> # Cargar paquetes
> library(ggplot2)
> library(dplyr)
> library(tidyr)
> library(purrr)
> library(boot)
> # Modelo 1: Wood -> Y = a * x^b * exp(-c * x)

```

```

> modelo_wood <- nls(Produccion ~ a * Dia^b * exp(-c * Dia),
+                   data = datos,
+                   start = list(a = 25, b = 0.1, c = 0.01),
+                   control = nls.control(maxiter = 100))
> summary(modelo_wood)
Formula: Produccion ~ a * Dia^b * exp(-c * Dia)
Parameters:
      Estimate Std. Error t value Pr(>|t|)
a 1.364e+01  2.229e-01  61.195  <2e-16 ***
b 4.238e-02  5.061e-03   8.374  <2e-16 ***
c 1.940e-03  6.467e-05  30.001  <2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
Residual standard error: 3.452 on 11301 degrees of freedom
Number of iterations to convergence: 5
Achieved convergence tolerance: 3.973e-06
> # Modelo 2. Wilink --> Y ~ a + b*exp(d*x) + c*x
> modelo_wilink <- nls(Produccion ~ a + b*exp(d*Dia) + c*Dia,
+                   data = datos,
+                   start = c(a= max(datos$Produccion, na.rm = TRUE),
+                             b=-11,
+                             c=-.07,
+                             d=-.05),
+                   control = nls.control(maxiter = 200, warnOnly = TRUE))
> summary(modelo_wilink)
Formula: Produccion ~ a + b * exp(d * Dia) + c * Dia
Parameters:
      Estimate Std. Error t value Pr(>|t|)
a 1.550e+01  6.476e-02 239.311 < 2e-16 ***
b -1.412e+01  2.285e+00  -6.180 6.65e-10 ***
c -1.927e-02  3.962e-04 -48.641 < 2e-16 ***
d -7.471e-01  1.152e-01  -6.486 9.21e-11 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
Residual standard error: 3.436 on 11300 degrees of freedom
Number of iterations to convergence: 9
Achieved convergence tolerance: 5.729e-06
> # Modelo 3: crecimiento desacelerado con declive lineal --> Y ~ a + (b - a) * (1 - e^(-k
* x)) - c * x
> modelo_transform <- nls(Produccion ~ a + (b - a) * (1 - e^(-k * Dia)) - c * Dia,
+                   data = datos,
+                   start = list(a = max(datos$Produccion, na.rm = TRUE),
+                             b = 30,
+                             c = 0.005,
+                             e = 2.7182818284,
+                             k = 0.08),
+                   control = list(maxiter = 100, tol = 1e-05, minFactor = 0.0009765625,
+                             printEval = FALSE, warnOnly = TRUE, scaleOffset = 0,
+                             nDcentral = FALSE), na.action = na.exclude, algorithm = "default",
+                   trace = FALSE)
Error en nlsModel(formula, mf, start, wts, scaleOffset = scOff, nDcentral = nDcntr):
singular gradient matrix at initial parameter estimates
> summary(modelo_transform)
Call:
lm(formula = Produccion ~ sqrt(Dia) + log(Dia), data = datos)
Residuals:
      Min       1Q   Median       3Q      Max
-12.6235  -2.3796  -0.3539   1.9230  12.2429
Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)  15.7698      0.4336  36.366 < 2e-16 ***
sqrt(Dia)    -0.6463      0.0468 -13.810 < 2e-16 ***
log(Dia)     0.9818      0.1936   5.073 4.12e-07 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
Residual standard error: 3.503 on 3684 degrees of freedom
Multiple R-squared:  0.1964, Adjusted R-squared:  0.196
F-statistic: 450.2 on 2 and 3684 DF, p-value: < 2.2e-16
> #
> # Modelo 4: Quadratic Polynomial (Dave)
> modelo_dave <- nls(Produccion ~ a + b * Dia^0.5 + c * log(Dia),
+                   data = datos,
+                   start = c(a = max(datos$Produccion, na.rm = TRUE),
+                             b = 30, c = 0.05),
+                   control = nls.control(maxiter = 100))
> summary(modelo_dave)
Formula: Produccion ~ a + b * Dia^0.5 + c * log(Dia)

```

```

Parameters:
  Estimate Std. Error t value Pr(>|t|)
a 13.11492    0.24009    54.62 <2e-16 ***
b -0.80018    0.02635   -30.36 <2e-16 ***
c  1.84460    0.10794    17.09 <2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
Residual standard error: 3.441 on 11301 degrees of freedom
Number of iterations to convergence: 1
Achieved convergence tolerance: 8.957e-07
> #
> # 2. Crear predicciones para graficar las curvas
> # Crear secuencia de dias para prediccion
> nuevo_dia <- data.frame(Dia = seq(min(datos$Dia), max(datos$Dia), length.out = 200))
>
> # Generar predicciones
> nuevo_dia$wood <- predict(modelo_wood, newdata = nuevo_dia)
> nuevo_dia$wilmink <- predict(modelo_wilmink, newdata = nuevo_dia)
> nuevo_dia$transf <- predict(modelo_transform, newdata = nuevo_dia)
> nuevo_dia$dave <- predict(modelo_dave, newdata = nuevo_dia)
>
> # Convertir a formato largo para graficar fácilmente
> curvas_predichas <- pivot_longer(nuevo_dia, cols = -Dia,
+                                 names_to = "Modelo",
+                                 values_to = "Prediccion")
> #
> # 3. Graficar curvas de prediccion vs. datos reales
> ggplot() +
+   geom_point(data = datos, aes(x = Dia, y = Produccion), alpha = 0.4) +
+   geom_line(data = curvas_predichas, aes(x = Dia, y = Prediccion, color = Modelo), size =
1) +
+   labs(title = "Curvas de lactancia predichas por modelo",
+        x = "Día de lactación",
+        y = "Producción de leche") +
+   theme_minimal() +
+   scale_color_brewer(palette = "Set1")
> # 4 Calcular estadísticos comparativos
> # R² manual para modelos nls
> r2_nls <- function(model, obs) {
+   rss <- sum(residuals(model)^2)
+   tss <- sum((obs - mean(obs))^2)
+   1 - rss/tss
+ }
> # RMSE genérico
> rmse <- function(model, obs) {
+   sqrt(mean(residuals(model)^2))
+ }
> # Validación cruzada manual para nls (modelo combinado y modelo wilmink)
> cv_nls_rmse <- function(model_formula, start_list, data, K = 10) {
+   folds <- sample(rep(1:K, length.out = nrow(data)))
+   errors <- map_dbl(1:K, function(k) {
+     train <- data[folds != k, ]
+     test <- data[folds == k, ]
+     fit <- tryCatch(nls(model_formula, data = train, start = start_list,
+                           control = nls.control(maxiter = 100)), error = function(e)
return(NA))
+     if (is.na(fit)) return(NA)
+     pred <- predict(fit, newdata = test)
+     sqrt(mean((test$Produccion - pred)^2))
+   })
+   mean(errors, na.rm = TRUE)
+ }
> # Validación cruzada para modelos lineales
> cv1 <- cv.glm(datos, modelo_transform, K = 10)
> cv_rmse_transform <- sqrt(cv1$delta[1])
>
> # Para modelo wood
> cv_rmse_wood <- cv_nls_rmse(Produccion ~ a * Dia^b * exp(-c * Dia),
+                             list(a = 0.1, b = 0.1, c = 0.01), datos)
> #Para modelo wilmink
> cv_rmse_wilmink <- cv_nls_rmse(Produccion ~ a + b * Dia + c * exp(-k * Dia),
+                               list(a = 0.1, b = 0.05, c = 10, k = 0.05), datos)
Error in `map_dbl()` :
[i] In index: 1.
Caused by error in `if (is.na(fit)) ...`:
! the condition has length > 1
Run `rlang::last_trace()` to see where the error occurred.
> # Para modelo de Dave

```

```

> cv_rmse_dave <- cv_nls_rmse(Produccion ~ a + b * Dia^0.5 + c * log(Dia),
+                             list(a = 0.1, b = 30, k = 0.01, c = 0.05), datos)
> # Crear resumen de resultados
> resultados <- data.frame(
+   Modelo = c("Wood", "Wilmlink", "Transformado", "Dave"),
+   AIC = c(AIC(modelo_wood), AIC(modelo_wilmlink), AIC(modelo_transform), AIC(modelo_dave)),
+   BIC = c(BIC(modelo_wood), BIC(modelo_wilmlink), BIC(modelo_transform), BIC(modelo_dave)),
+   R2 = c(r2_nls(modelo_wood, datos$Produccion),
+           r2_nls(modelo_wilmlink, datos$Produccion),
+           summary(modelo_transform)$r.squared,
+           r2_nls(modelo_dave, datos$Produccion)),
+   RMSE = c(rmse(modelo_wood, datos$Produccion),
+             rmse(modelo_wilmlink, datos$Produccion),
+             rmse(modelo_transform, datos$Produccion),
+             rmse(modelo_dave, datos$Produccion)),
+   CV_RMSE = c(cv_rmse_wood, cv_rmse_wilmlink, cv_rmse_transform, cv_rmse_dave)
+ )
>
> print(resultados)
      Modelo      AIC      BIC      R2      RMSE CV_RMSE
1      Wood 60097.18 60126.52 0.1713709 3.451932    NaN
2    Wilmlink 59988.21 60024.87 0.1794660 3.435029    NaN
3 Transformado 19712.17 19737.02 0.1964195 3.501443    NaN
4      Dave 60022.90 60052.23 0.1767987 3.440608    NaN

> # Graficar comparación de modelos por criterios
> # Convertir a formato largo para graficar
> resultados_largos <- resultados %>%
+   pivot_longer(cols = -Modelo, names_to = "Criterio", values_to = "Valor")
>
> # Gráfico de comparación
> ggplot(resultados_largos, aes(x = Modelo, y = Valor, fill = Modelo)) +
+   geom_bar(stat = "identity", position = "dodge") +
+   facet_wrap(~ Criterio, scales = "free_y") +
+   labs(title = "Comparación de modelos de curva de lactancia",
+        y = "Valor del criterio", x = "Modelo") +
+   theme_minimal() +
+   theme(axis.text.x = element_text(angle = 45, hjust = 1)) +
+   scale_fill_brewer(palette = "Set2")
Aviso:
Removed 4 rows containing missing values or values outside the scale range (`geom_bar()`).
> # 6 obtener estos componentes por modelo
> # Crear secuencia de 1 a 305 días
> dias_305 <- data.frame(Dia = 1:305)
>
> # Predicciones para cada modelo
> dias_305$wood <- predict(modelo_wood, newdata = dias_305)
> dias_305$wilmlink <- predict(modelo_wilmlink, newdata = dias_305)
> dias_305$transf <- predict(modelo_transform, newdata = dias_305)
> dias_305$dave <- predict(modelo_dave, newdata = dias_305)
>
> # Función para obtener componentes
> obtener_componentes <- function(dias, produccion) {
+   dia_pico <- dias[which.max(produccion)]
+   pico <- max(produccion)
+   total305 <- sum(produccion) # Aproximación por suma (integración discreta)
+   return(c(Dia_Pico = dia_pico, Pico = pico, Total_305 = total305))
+ }
>
> # Aplicar a cada modelo
> comp_wood <- obtener_componentes(dias_305$Dia, dias_305$wood)
> comp_wilmlink <- obtener_componentes(dias_305$Dia, dias_305$wilmlink)
> comp_transf <- obtener_componentes(dias_305$Dia, dias_305$transf)
> comp_dave <- obtener_componentes(dias_305$Dia, dias_305$dave)
>
> # Combinar en un data frame
> componentes_lactancia <- rbind(
+   Wood = comp_wood,
+   Wilmlink = comp_wilmlink,
+   Transformado = comp_transf,
+   Combinado = comp_dave
+ ) %>% as.data.frame()
>
> componentes_lactancia
      Dia_Pico      Pico Total_305
Wood          22 14.89693  3812.471
Wilmlink         8 15.30843  3814.914


```

```
Transformado      9 15.98812 3926.364
Combinado        21 15.06395 3814.362
```


SCRIPT (3ra lactancia a mas)

```
> # Cargar los datos desde el archivo Excel
> setwd("C:/Users/User/Downloads")
> #produccion1 <- read.csv('datoskr.csv', header = T, sep = ";")
> # Cargar los datos desde el archivo Excel
> library(readxl)
> produccion <- read_excel("BDKORAIMA.xlsx")
> # Cargar librerías necesarias
> library(dplyr)
> library(tidyr)
> library(ggplot2)
> # Seleccionar las columnas correspondientes a los días de recolección
> data_days <- produccion %>% select(`1`:`840`) # Seleccionar columnas numeradas del 1 al
840
> data_days305 <- produccion %>% select(`1`:`305`) # seleccionar columnas numeradas de 1 a
305 días
> # Asegurarse de que todas las columnas sean numéricas
> data_days <- data_days %>% mutate(across(everything(), as.numeric))
> data_days305 <- data_days305 %>% mutate(across(everything(), as.numeric))
> #
> # Objetivo e Hipotesis especifica 3
> # Modelar el comportamiento de la curva de lactación mediante modelos matemáticos
>
> # Paso 1: Asegurar que las columnas de días sean numéricas
> produccion_clean305 <- produccion %>%
+   mutate(across(`1`:`305`, as.numeric)) # Convertir las columnas de producción diaria a
numérico
> #
> # Paso 2b: Transformar los datos a formato largo
> library(tidyr)
> prod_long305 <- produccion_clean305 %>%
+   select(CODIGO, RAZA, Nro_LACT, `1`:`305`) %>%
+   pivot_longer(
+     cols = `1`:`305`,
+     names_to = "Dia",
+     values_to = "Produccion"
+   ) %>%
+   mutate(
+     Dia = as.numeric(Dia), # Convertir los días a numéricos
+     Produccion = as.numeric(Produccion) # Asegurar que Producción también es numérica
+   ) %>%
+   filter(!is.na(Produccion) & Produccion > 0) # Filtrar valores no válidos o NA
> #
> # Verificar los primeros datos
> print(head(prod_long305))
# A tibble: 6 × 5
  CODIGO RAZA   Nro_LACT   Dia Produccion
  <dbl> <chr>   <dbl> <dbl>   <dbl>
1  1510 HO         2     1    14.3
2  1510 HO         2     2    15.2
3  1510 HO         2     3    17.2
4  1510 HO         2     4     18
5  1510 HO         2     5    18.4
6  1510 HO         2     6    19.5
> # subconjuntos por raza
> lact1 <- subset (prod_long305, Nro_LACT == "1")
> lact2 <- subset (prod_long305, Nro_LACT == "2")
> lact3aM <- subset(prod_long305, Nro_LACT == "3":"5")
> #
> str(lact1)
tibble [11,076 × 5] (S3: tbl_df/tbl/data.frame)
 $ CODIGO      : num [1:11076] 1561 1561 1561 1561 1561 ...
 $ RAZA        : chr [1:11076] "HO" "HO" "HO" "HO" ...
 $ Nro_LACT    : num [1:11076] 1 1 1 1 1 1 1 1 1 1 ...
 $ Dia        : num [1:11076] 1 2 3 4 5 6 7 8 9 10 ...
 $ Produccion: num [1:11076] 6.5 6.5 8.8 9.6 8.6 9.7 9.4 9.2 10.3 9.8 ...
> #EVALUACION DE MODELOS
> library(lme4)
> library(nlme)
> #plot all cows
> p <- ggplot(data = prod_long305, aes(x = Dia, y = Produccion, colour = Nro_LACT)) +
  geom_point()+
+   theme_bw()+
```

```
+ ylab("Milk yield (L for week)")+
+ xlab("Date")+
+ theme(legend.position = "none")
> p
```



```
> #unique(data$CowId)
> CODIGO <- as.vector(unique(prod_long305$CODIGO))
> # CowIds.list <- split(CowIds, seq(length(CowIds)))
> #COD.BUSCADO <- c(1,2,3)
>
> p <- ggplot(data = prod_long305, ##)%> filter(COD.BUSCADO %in% prod_long305$Nro_LACT),
+ aes(x = Dia, y = Produccion, colour = Nro_LACT)) +
+ geom_point() +
+ geom_smooth()+
+ ylab("prod leche (Kg por dia)")+
+ xlab("Date")+
+ theme_bw()+
+ theme(legend.position = "dia")
> #p
> s <- p + facet_wrap( ~ Nro_LACT)
> s
`geom_smooth()` using method = 'gam' and formula = 'y ~ s(x, bs = "cs")'
```



```
> # 1. Ajuste de los 4 modelos de tercera a más lactancia
> # 1. Ajuste de los 4 modelos de tercera a más lactancia
> # otra forma
> datos<-lact3aM
> summary(datos$Dia) # Verifica valores mínimos
  Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
    1.0   66.0   132.0   139.4   210.0   305.0
> summary(datos$Produccion)
  Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
   1.50   10.30   12.60   13.14   15.50   27.60
> # Cargar paquetes
> library(ggplot2)
> library(dplyr)
> library(tidyr)
> library(purrr)
> library(boot)
>
> # Modelo 1: Wood -> Y = a * x^b * exp(-c * x)
```

```

> modelo_wood <- nls(Produccion ~ a * Dia^b * exp(-c * Dia),
+                   data = datos,
+                   start = list(a = 25, b = 0.1, c = 0.01),
+                   control = nls.control(maxiter = 100))
> summary(modelo_wood)
Formula: Produccion ~ a * Dia^b * exp(-c * Dia)
Parameters:
      Estimate Std. Error t value Pr(>|t|)
a 1.617e+01  4.289e-01  37.689  <2e-16 ***
b 5.346e-04  8.288e-03   0.064   0.949
c 1.568e-03  1.076e-04  14.580  <2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
Residual standard error: 3.514 on 3684 degrees of freedom
Number of iterations to convergence: 5
Achieved convergence tolerance: 6.506e-06
> # Modelo 2. Wilink --> Y ~ a + b*exp(d*x) + c*x
> modelo_wilink <- nls(Produccion ~ a + b*exp(d*Dia) + c*Dia,
+                   data = datos,
+                   start = c(a= max(datos$Produccion, na.rm = TRUE),
+                             b=-11,
+                             c=-.07,
+                             d=-.05),
+                   control = nls.control(maxiter = 200, warnOnly = TRUE))
> summary(modelo_wilink)
Formula: Produccion ~ a + b * exp(d * Dia) + c * Dia
Parameters:
      Estimate Std. Error t value Pr(>|t|)
a 16.013370    0.114012 140.453  < 2e-16 ***
b -15.633114    7.012317  -2.229  0.02585 *
c  -0.020378    0.000692 -29.450  < 2e-16 ***
d -0.999704     0.367624  -2.719  0.00657 **
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
Residual standard error: 3.507 on 3683 degrees of freedom
Number of iterations to convergence: 14
Achieved convergence tolerance: 5.337e-06

> # Modelo 3: crecimiento desacelerado con declive lineal --> Y ~ a + (b - a) * (1 - e^(-k
* x)) - c * x
> modelo_transform <- nls(Produccion ~ a + (b - a) * (1 - e^(-k * Dia)) - c * Dia,
+                   data = datos,
+                   start = list(a = max(datos$Produccion, na.rm = TRUE),
+                             b = 30,
+                             c = 0.005,
+                             e = 2.7182818284,
+                             k = 0.08),
+                   control = list(maxiter = 100, tol = 1e-05, minFactor = 0.0009765625,
+                             printEval = FALSE, warnOnly = TRUE, scaleOffset = 0,
+                             nDcentral = FALSE), na.action = na.exclude, algorithm = "default",
+                   trace = FALSE)
Error en nlsModel(formula, mf, start, wts, scaleOffset = scOff, nDcentral = nDcntr):
singular gradient matrix at initial parameter estimates
> summary(modelo_transform)
Call:
lm(formula = Produccion ~ sqrt(Dia) + log(Dia), data = datos)
Residuals:
      Min       1Q   Median       3Q      Max
-12.6235  -2.3796  -0.3539   1.9230  12.2429
Coefficients:
      Estimate Std. Error t value Pr(>|t|)
(Intercept)  15.7698      0.4336  36.366  < 2e-16 ***
sqrt(Dia)    -0.6463      0.0468 -13.810  < 2e-16 ***
log(Dia)      0.9818      0.1936   5.073 4.12e-07 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
Residual standard error: 3.503 on 3684 degrees of freedom
Multiple R-squared:  0.1964, Adjusted R-squared:  0.196
F-statistic: 450.2 on 2 and 3684 DF, p-value: < 2.2e-16
> #
> # Modelo 4: Quadratic Polynomial (Dave)
> modelo_dave <- nls(Produccion ~ a + b * Dia^0.5 + c * log(Dia),
+                   data = datos,
+                   start = c(a = max(datos$Produccion, na.rm = TRUE),
+                             b = 30, c = 0.05),
+                   control = nls.control(maxiter = 100))
> summary(modelo_dave)

```

```

Formula: Produccion ~ a + b * Dia^0.5 + c * log(Dia)
Parameters:
  Estimate Std. Error t value Pr(>|t|)
a  15.7698      0.4336  36.366 < 2e-16 ***
b  -0.6463      0.0468 -13.810 < 2e-16 ***
c   0.9818      0.1936   5.073 4.12e-07 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
Residual standard error: 3.503 on 3684 degrees of freedom
Number of iterations to convergence: 1
Achieved convergence tolerance: 7.781e-07
> #
> # 2. Crear predicciones para graficar las curvas
> # Crear secuencia de días para predicción
> nuevo_dia <- data.frame(Dia = seq(min(datos$Dia), max(datos$Dia), length.out = 200))
>
> # Generar predicciones
> nuevo_dia$wood <- predict(modelo_wood, newdata = nuevo_dia)
> nuevo_dia$wilink <- predict(modelo_wilink, newdata = nuevo_dia)
> nuevo_dia$transf <- predict(modelo_transform, newdata = nuevo_dia)
> nuevo_dia$dave <- predict(modelo_dave, newdata = nuevo_dia)
>
> # Convertir a formato largo para graficar fácilmente
> curvas_predichas <- pivot_longer(nuevo_dia, cols = -Dia,
+                                 names_to = "Modelo",
+                                 values_to = "Prediccion")
> #
> # 3. Graficar curvas de predicción vs. datos reales
> ggplot() +
+   geom_point(data = datos, aes(x = Dia, y = Produccion), alpha = 0.4) +
+   geom_line(data = curvas_predichas, aes(x = Dia, y = Prediccion, color = Modelo), size =
1) +
+   labs(title = "Curvas de lactancia predichas por modelo",
+        x = "Día de lactación",
+        y = "Producción de leche") +
+   theme_minimal() +
+   scale_color_brewer(palette = "Set1")
>
> # 4 Calcular estadísticos comparativos
> # R² manual para modelos nls
> r2_nls <- function(model, obs) {
+   rss <- sum(residuals(model)^2)
+   tss <- sum((obs - mean(obs))^2)
+   1 - rss/tss
+ }
> # RMSE genérico
> rmse <- function(model, obs) {
+   sqrt(mean(residuals(model)^2))
+ }
>
> # Validación cruzada manual para nls (modelo combinado y modelo wilink)
> cv_nls_rmse <- function(model_formula, start_list, data, K = 10) {
+   folds <- sample(rep(1:K, length.out = nrow(data)))
+   errors <- map_dbl(1:K, function(k) {
+     train <- data[folds != k, ]
+     test <- data[folds == k, ]
+     fit <- tryCatch(nls(model_formula, data = train, start = start_list,
+                           control = nls.control(maxiter = 100)), error = function(e)
return(NA))
+     if (is.na(fit)) return(NA)
+     pred <- predict(fit, newdata = test)
+     sqrt(mean((test$Produccion - pred)^2))
+   })
+   mean(errors, na.rm = TRUE)
+ }
> # Validación cruzada para modelos lineales
> cv1 <- cv.glm(datos, modelo_transform, K = 10)
> cv_rmse_transform <- sqrt(cv1$delta[1])
>
> # Para modelo wood
> cv_rmse_wood <- cv_nls_rmse(Produccion ~ a * Dia^b * exp(-c * Dia),
+                             list(a = 0.1, b = 0.1, c = 0.01), datos)
> #Para modelo wilink
> cv_rmse_wilink <- cv_nls_rmse(Produccion ~ a + b * Dia + c * exp(-k * Dia),
+                               list(a = 0.1, b = 0.05, c = 10, k = 0.05), datos)
>
> # Para modelo de Dave
> cv_rmse_dave <- cv_nls_rmse(Produccion ~ a + b * Dia^0.5 + c * log(Dia),

```

```

+               list(a = 0.1, b = 30, k = 0.01, c = 0.05), datos)
> # Crear resumen de resultados
> resultados <- data.frame(
+   Modelo = c("Wood", "Wilmlink", "Transformado", "Dave"),
+   AIC = c(AIC(modelo_wood), AIC(modelo_wilmlink), AIC(modelo_transform), AIC(modelo_dave)),
+   BIC = c(BIC(modelo_wood), BIC(modelo_wilmlink), BIC(modelo_transform), BIC(modelo_dave)),
+   R2 = c(r2_nls(modelo_wood, datos$Produccion),
+         r2_nls(modelo_wilmlink, datos$Produccion),
+         summary(modelo_transform)$r.squared,
+         r2_nls(modelo_dave, datos$Produccion)),
+   RMSE = c(rmse(modelo_wood, datos$Produccion),
+         rmse(modelo_wilmlink, datos$Produccion),
+         rmse(modelo_transform, datos$Produccion),
+         rmse(modelo_dave, datos$Produccion)),
+   CV_RMSE = c(cv_rmse_wood, cv_rmse_wilmlink, cv_rmse_transform, cv_rmse_dave)
+ )
> print(resultados)
      Modelo      AIC      BIC      R2      RMSE CV_RMSE
1      Wood 19736.45 19761.30 0.1911090 3.512993    NaN
2    Wilmlink 19721.13 19752.20 0.1948994 3.504753    NaN
3 Transformado 19712.17 19737.02 0.1964195 3.501443    NaN
4        Dave 19712.17 19737.02 0.1964195 3.501443    NaN

> # Graficar comparación de modelos por criterios
> # Convertir a formato largo para graficar
> resultados_largos <- resultados %>%
+   pivot_longer(cols = -Modelo, names_to = "Criterio", values_to = "Valor")
> # Gráfico de comparación
> ggplot(resultados_largos, aes(x = Modelo, y = Valor, fill = Modelo)) +
+   geom_bar(stat = "identity", position = "dodge") +
+   facet_wrap(~ Criterio, scales = "free_y") +
+   labs(title = "Comparación de modelos de curva de lactancia",
+        y = "Valor del criterio", x = "Modelo") +
+   theme_minimal() +
+   theme(axis.text.x = element_text(angle = 45, hjust = 1)) +
+   scale_fill_brewer(palette = "Set2")
Aviso:
Removed 4 rows containing missing values or values outside the scale range (`geom_bar()`).
> # 6 obtener estos componentes por modelo
> # Crear secuencia de 1 a 305 días
> dias_305 <- data.frame(Dia = 1:305)
>
> # Predicciones para cada modelo
> dias_305$wood <- predict(modelo_wood, newdata = dias_305)
> dias_305$wilmlink <- predict(modelo_wilmlink, newdata = dias_305)
> dias_305$transf <- predict(modelo_transform, newdata = dias_305)
> dias_305$dave <- predict(modelo_dave, newdata = dias_305)
>
> # Función para obtener componentes
> obtener_componentes <- function(dias, produccion) {
+   dia_pico <- dias[which.max(produccion)]
+   pico <- max(produccion)
+   total305 <- sum(produccion) # Aproximación por suma (integración discreta)
+   return(c(Dia_Pico = dia_pico, Pico = pico, Total_305 = total305))
+ }
>
> # Aplicar a cada modelo
> comp_wood <- obtener_componentes(dias_305$Dia, dias_305$wood)
> comp_wilmlink <- obtener_componentes(dias_305$Dia, dias_305$wilmlink)
> comp_transf <- obtener_componentes(dias_305$Dia, dias_305$transf)
> comp_dave <- obtener_componentes(dias_305$Dia, dias_305$dave)
>
> # Combinar en un data frame
> componentes_lactancia <- rbind(
+   Wood = comp_wood,
+   Wilmlink = comp_wilmlink,
+   Transformado = comp_transf,
+   Combinado = comp_dave
+ ) %>% as.data.frame()
>
> componentes_lactancia
      Dia_Pico      Pico Total_305
Wood          1 16.14022   3925.418
Wilmlink       7 15.85644   3924.023
Transformado   9 15.98812   3926.364
Combinado      9 15.98812   3926.364

```

Y	M	D	Time	Loc	Sex	Age	Notes
1	01	20	11:00	100	M	1	100
2	01	20	11:00	100	M	1	100
3	01	20	11:00	100	M	1	100
4	01	20	11:00	100	M	1	100
5	01	20	11:00	100	M	1	100
6	01	20	11:00	100	M	1	100
7	01	20	11:00	100	M	1	100
8	01	20	11:00	100	M	1	100
9	01	20	11:00	100	M	1	100
10	01	20	11:00	100	M	1	100
11	01	20	11:00	100	M	1	100
12	01	20	11:00	100	M	1	100
13	01	20	11:00	100	M	1	100
14	01	20	11:00	100	M	1	100
15	01	20	11:00	100	M	1	100
16	01	20	11:00	100	M	1	100
17	01	20	11:00	100	M	1	100
18	01	20	11:00	100	M	1	100
19	01	20	11:00	100	M	1	100
20	01	20	11:00	100	M	1	100

116

Anexo 5. Formato de colección de datos de producción diaria para su incorporación al programa de Rstudio

[illegible]

Anexo 6. panel fotográfico de las unidades evaluadas y la colección de leche

