

UNIVERSIDAD DE LA REPÚBLICA

FACULTAD DE VETERINARIA

**VALIDACIÓN DEL USO DE ACELERÓMETROS PARA EL REGISTRO DEL
COMPORTAMIENTO POSTURAL EN VACAS LECHERAS EN UN SISTEMA
PASTORIL**

Por

**ESPÍNOLA DÍAZ Lucía
ODRIOZOLA CAPRIOLI Gonzalo**

TESIS DE GRADO presentada como uno de
los requisitos para obtener el título de
Doctor en Ciencias Veterinarias
Orientación: Producción Animal e Higiene,
Inspección-Control y Tecnología de los Alimentos

MODALIDAD: Ensayo Experimental

**MONTEVIDEO
URUGUAY
2024**

PÁGINA DE APROBACIÓN

TESIS DE GRADO aprobado por:

Presidente de mesa:



Matías Villagrán

Segundo miembro (Tutor):



Carolina Fiol

Tercer miembro:



Libertad Tansini

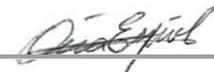
Cuarto miembro (Co-Tutor):



Pablo Rodríguez-Bocca

Fecha: 26/12/2024

Autores:



Lucía Espínola



Gonzalo Odriozola

AGRADECIMIENTOS

A nuestros familiares, por el gran apoyo brindado durante los años de formación como profesionales.

A las amistades que nos acompañaron y brindaron soporte en esta etapa.

A Valentina Sellusti por compartir el trabajo de campo y por toda la ayuda brindada

A Lucia Alvez, Eloísa Bentancur y Victoria Dujó por compartir y elaborar el trabajo de campo.

A Vanessa Lujambio por el acompañamiento brindado durante la carrera.

A Carolina Fiol y Pablo Rodríguez-Bocca nuestra tutora y co-tutor por su gran disposición.

Al IPAV y sus funcionarios por su colaboración durante el proceso del ensayo experimental y el posterior procesamiento de datos.

Finalmente, a nuestra casa de estudio por permitirnos desarrollarnos y formarnos como Veterinaria/o.

TABLA DE CONTENIDO

Páginas

PÁGINA DE APROBACIÓN	2
AGRADECIMIENTOS	3
TABLA DE CONTENIDO	4
LISTADE TABLAS Y FIGURAS	5
1. RESUMEN	6
2. SUMMARY	7
3. INTRODUCCIÓN	8
4. REVISIÓN BIBLIOGRÁFICA	10
4.1. Producción lechera en Uruguay.....	10
4.2. Sistemas de producción de leche y comportamiento en bovinos	11
4.3. Comportamiento postural en bovinos	14
4.4. Métodos de registro de comportamiento	16
4.5. Acelerómetros HOBO y desarrollo de algoritmos	17
5. HIPÓTESIS	20
6. OBJETIVOS	21
7. MATERIALES Y MÉTODOS	22
7.1. Animales y manejo.....	22
7.2. Dispositivos HOBO	23
7.3. Análisis químicos de las pasturas.....	23
7.4. Procesamiento y análisis de datos.....	24
8. RESULTADOS	28
9. DISCUSIÓN	33
10. CONCLUSIONES	39
11. REFERENCIAS BIBLIOGRÁFICAS	40

LISTA DE TABLAS Y FIGURAS

Páginas

Tabla 1. Informe de clasificación (Precisión, Recall, F1 Score y Support)	28
Tabla 2. Error por método. Modelos entrenados con sus respectivos valores de Accuracy expresada en porcentaje (proporción de predicciones correctas realizadas por un modelo de inteligencia artificial con respecto al número total de predicciones).....	32
Figura 1. Ilustración de la posición del acelerómetro triaxial y los ejes X, Y, Z en la cara lateral del miembro trasero en posiciones de pie (a) y echado (b)” (Hendriks et al, 2020, p. 12144)	23
Figura 2. Matriz confusión de los comportamientos. Matriz que exhibe el desempeño del algoritmo mostrando la distribución de los valores de las observaciones visuales con respecto a los comportamientos predichos.....	29
Figuras 3. Densidad en función de Feature XApm+10 (A) y Feature Xlpm+10 (B) Se describen 2 de los Features que lograron clasificar mejor a cada postura. La figura 2A muestra que la categoría Parada (P) tiene alta probabilidad de estar.....	30
Figura 4. Importancia de los features utilizando la disminución media de la impureza. Permite determinar qué tan informativa es una característica (feature) para dividir los datos en clases más homogéneas.....	31

1. RESUMEN

El presente trabajo tuvo como objetivo validar la utilización de acelerómetros triaxiales para el registro de comportamiento postural, en comparación con los registros obtenidos mediante observación visual directa, en vacas lecheras a pastoreo. Se utilizaron 11 vacas Holando y cruce Holando-Jersey que fueron seleccionadas del rodeo general del tambo y manejadas en un sistema de pastoreo en franjas diarias. A partir del día 0 (luego de 7 días de adaptación), al momento del ordeño, se colocaron acelerómetros triaxiales (Hobo Pendant G Acceleration Data Logger, Onset Computer Corporation, Pocasset, MA) en el miembro posterior derecho de todos los animales. Los acelerómetros fueron programados para registrar las actividades cada 30 segundos, realizando el intercambio de los dispositivos cada siete días, y manteniéndolos durante 20 días consecutivos. A su vez, a lo largo de los 20 días, se realizó un muestreo visual directo tipo Scan sampling, a intervalos de 5 minutos, registrando el comportamiento postural (parada, echada, caminando y otros) de cada una de las vacas en estudio. El registro se realizó con 2 observadores por turno en las franjas de pastoreo asignadas. Una vez finalizado el trabajo de campo, se unificaron los datos de las observaciones visuales en una planilla de cálculo (variables de salida), realizando el mismo procedimiento con los datos obtenidos por el HOBO (datos de entrada o features). Este conjunto de datos se utilizó para desarrollar las técnicas de aprendizaje automático y así entrenar los algoritmos, para intentar predecir automáticamente el comportamiento registrado visualmente. Se eligió un modelo de aprendizaje supervisado capaz de procesar problemas de clasificación multiclase y desbalanceado. Utilizando la herramienta Google Colab se cargaron paquetes para ejecutar, y se subieron los datos de entrada (Dataset). El siguiente paso fue definir un conjunto de features relevantes al problema de la clasificación de postura, donde se filtraron por carencia de datos e importancia para la predicción. Estos datos se partieron en un grupo de entrenamiento y otro de evaluación, los de entrenamiento se utilizaron para comparar distintos modelos de aprendizaje automático supervisado (sin ajustar hiper-parámetros), obteniendo diferentes resultados de exactitud para el conjunto de evaluación; siendo Random Forest el más performante (mayor exactitud), se realizó el ajuste de hiper-parámetros obteniendo los siguientes valores: Caminando (Precisión 0,90/Recall 0,32/f1-score 0,47/Support 234); Echada (Precisión 0,94/Recall 0,95/f1-score 0,94/Support 1185); Otros (Precisión 0,00/Recall 0,00/f1-score 0,00/Support 40); Parada (Precisión 0,91/Recall 0,97/f1-score 0,94/Support 2505). En conclusión, el algoritmo desarrollado fue capaz de predecir con alta fiabilidad el comportamiento postural en vacas a pastoreo.

2. SUMMARY

The objective of this study was to validate the use of tri-axial accelerometers for the recording of postural behavior, in comparison with the records obtained by direct visual observation, in grazing dairy cows. Eleven Holando and Holando-Jersey crossbred cows selected from the general dairy herd and managed in a daily strip grazing system were used. Beginning on day 0 (after 7 days of adaptation), at milking, triaxial accelerometers (Hobo Pendant G Acceleration Data Logger, Onset Computer Corporation, Pocasset, MA) were placed on the right hind limb of all animals. The accelerometers were programmed to record activities every 30 seconds, performing device exchange every seven days, and maintaining them for 20 consecutive days. At the same time, throughout the 20 days, a direct visual sampling type Scan sampling was performed at 5-minute intervals, recording the postural behavior (standing, lying down, walking and others) of each of the cows under study. The recording was carried out with 2 observers per shift in the assigned grazing strips. Once the field work was completed, the data from the visual observations were unified in a spreadsheet (output variables), performing the same procedure with the data obtained by the HOBO (input data or features). This data set was used to develop the machine learning techniques to train the algorithms to try to automatically predict the visually recorded behavior. A supervised learning algorithm model capable of processing multi-class and unbalanced classification problems was chosen. Using the Google Colab tool, packages were loaded to run, and the input data (Dataset) was uploaded. The next step was to define a set of features relevant to the posture classification problem, where they were filtered by lack of data and importance for prediction. These data were divided into a training group and an evaluation group, the training data were used to compare different supervised machine learning models (without adjusting hyper-parameters), obtaining different accuracy results for the evaluation set; Random Forest being the most performing (higher accuracy), the hyper-parameters adjustment was performed obtaining the following values: Walking (Accuracy 0.90/Recall 0.32/f1-score 0.47/Support 234); Lying down (Accuracy 0.94/Recall 0.95/f1-score 0.94/Support 1185); Others (Accuracy 0.00/Recall 0.00/f1-score 0.00/Support 40); Standing (Accuracy 0.91/Recall 0.97/f1-score 0.94/Support 2505). In conclusion, the developed algorithm was able to predict with high reliability the postural behavior in grazing cows.

3. INTRODUCCIÓN

La producción láctea es fundamental para la economía uruguaya, representando uno de los principales commodities del país (Consolandich et al., 2011). A lo largo de los años, el sector aumentó el volumen de leche remitida a la industria a pesar de la disminución en el número de productores. Esto se debe a la implementación de nuevas tecnologías y un mejor manejo del rodeo, lo que ha permitido incrementar la producción de leche por animal (Ministerio de Ganadería, Agricultura y Pesca, 2022).

El monitoreo del comportamiento animal ha demostrado ser un elemento crucial para garantizar la salud y productividad del ganado (Cook et al., 2005). Según Fetter et al. (2014), los sistemas de producción lechera se clasifican por variables como alimentación y manejo, donde los sistemas pastoriles destacan por permitirle a los animales expresar el comportamiento natural de la especie. Estos sistemas, que se basan en el uso de pasturas, favorecen el bienestar animal al proporcionar libertad para desarrollar el comportamiento de pastoreo, social y de descanso (Arnott et al., 2016; Charlton & Rutter, 2017; Haley et al., 2000) Además de que, el aumento de pasto en la dieta reduce los costos de producción (Hanrahan et al., 2018). También se ha reportado que cambios en el comportamiento "normal" de las vacas son indicadores de pérdida de bienestar y salud de los animales (Cook et al., 2005), Por tanto, el monitoreo del comportamiento de las vacas en dichos sistemas permite diseñar estrategias de manejo que prioricen el consumo de pastura. Asimismo, estas tecnologías son herramientas muy útiles para el monitoreo de salud, alimentación, manejo y bienestar del rodeo.

La observación visual es el método de referencia para el registro del comportamiento, sin embargo, insume mucho tiempo de observación, además de requerir de recursos humanos con capacitación y experiencia (Mattachini et al., 2013). En este sentido, cobran protagonismo las tecnologías de precisión livestock farming (PLF), siendo útiles para mejorar el registro del comportamiento en sistemas pastoriles. Estas tecnologías, que incluyen dispositivos de audio y video, alimentadores automáticos, detección de flujo de agua, tecnología de identificación por radiofrecuencia (RFID) y acelerómetros, ofrecen alternativas complementarias o sustitutivas a la observación directa (Chapa et al., 2020). Su uso permite reducir el error humano y proporciona datos más precisos sobre el comportamiento animal. Estudios han mostrado una alta correlación entre estas tecnologías y métodos tradicionales de observación (Mattachini et al., 2013), lo que destaca su eficacia para monitorear el bienestar animal y optimizar la gestión de sistemas productivos.

En este sentido, los acelerómetros son una de las herramientas valiosas para registrar el comportamiento postural a pastoreo. Dichos acelerómetros son dispositivos electromecánicos que registran fuerzas de aceleración, y de este modo detectan cambios de velocidad y de dirección del movimiento, determinando así la aceleración de los ejes. Un acelerómetro triaxial presenta tres sensores de aceleración dispuestos

ortogonalmente, lo que permite acumular información tridimensional (ejes X, Y, Z) (Benjamin & Yik, 2019). Asimismo, los acelerómetros proporcionan un método objetivo y no invasivo para medir comportamiento en condiciones extensivas (Rayas-Amor et al., 2017).

La validación de estos dispositivos implica contrastar los registros de los acelerómetros con el método de referencia (observación visual). En los trabajos existentes, el registro del comportamiento postural utilizando los acelerómetros HOBO ha demostrado que los mismos arrojan datos muy análogos a los obtenidos mediante la observación visual, ya sea en sistemas estabulados (Borchers et al., 2016; De Passille et al., 2010; DuBois et al., 2014; Ledgerwood et al., 2010; Zambelis et al., 2019) o pastoriles (Rayas-Amor et al., 2017). Antes de la implementación de tales dispositivos para detectar cambios en el comportamiento, la salud y el estado de bienestar, se debe realizar un trabajo inicial para validar la capacidad de los dispositivos en detectar los patrones de comportamiento con precisión (Rayas-Amor et al., 2017). De Passille, et al. (2010) aseguran que si bien los acelerómetros son eficaces para detectar patrones de marcha es necesario una validación más completa para detectar eventos compuestos. Para lograr un mejor desempeño en la validación en este ensayo se utilizarán distintos algoritmos; los cuales puede definirse como “una secuencia finita de instrucciones, cada una de las cuales tiene un significado preciso y puede ejecutarse con una cantidad finita de esfuerzo en un tiempo finito.” (Aho, Hopcroft, & Ullman, 1988, p.2). El proceso de desarrollo de algoritmos involucra diferentes tipos de variables que deben ser definidas previamente, estas son: variable objetivo, patrón oro, variable característica, y etiquetado (Berckmans & Vandermeulen, 2013). Benaissa et al. (2019) confirmaron que un algoritmo de árbol de decisión (Decision Tree) simple aplicado a los datos de un acelerómetro montado en el cuello fue eficaz para clasificar los comportamientos de alimentación y rumia de las vacas lecheras. Partiendo de estos antecedentes, en este ensayo nos planteamos como objetivo validar la utilización de los acelerómetros HOBO para el registro de comportamiento postural, en comparación con los registros obtenidos mediante observación visual directa, en vacas lecheras a pastoreo. Además, entender y evaluar un modelo de aprendizaje automático que sea capaz de predecir el comportamiento postural (parada, echada, caminando, otros) a través de los acelerómetros HOBO Data Logger y determinar la exactitud y precisión de los acelerómetros HOBO para registrar las diferentes conductas asociadas al comportamiento postural en vacas lecheras a pastoreo. Los objetivos mencionados anteriormente buscan generar conocimiento preciso para los actuales y futuros usuarios de acelerómetros HOBO y de algoritmos aplicados a la producción ya que la tecnología avanza cada vez más en este campo y tener información de alto valor es indispensable para su entendimiento y ejecución.

4. REVISIÓN BIBLIOGRÁFICA

4.1. Producción lechera en Uruguay

La leche bovina es una de las fuentes de nutrientes más consumidas a nivel mundial en virtud de su alto poder nutritivo. La población uruguaya se destaca por su consumo per cápita de 230 litros de leche, más del doble del consumo mundial promedio (Instituto Nacional de la Leche [INALE], s.f.). La producción lechera en Uruguay representa una parte importante de la economía ya que es uno de los principales commodities del país (Consolandich et al., 2011). A lo largo de los años se observa que la evolución en el número de remitentes a planta ha ido en detrimento, en contraposición con el volumen de leche remitido diariamente durante el periodo 1992 al 2021 (Ministerio de Ganadería, Agricultura y Pesca, 2022). Esto se puede explicar por la evolución del contexto de la producción, donde los productores fueron capaces de aumentar la carga animal, mejorar el manejo del rodeo haciendo hincapié en la correcta alimentación y la incorporación de nuevas tecnologías de producción, lo que llevó a un aumento en la producción de leche por animal por día (Ministerio de Ganadería, Agricultura y Pesca, 2022). En contraposición, aquellos productores pequeños que no pudieron afrontar estos cambios, fueron los más afectados teniendo que cerrar y vender sus rodeos al mercado. De esta manera es que se explica la disminución de productores remitentes debido a que anteriormente predominaban los pequeños productores y en la actualidad los medianos y grandes productores son los que persisten, generando una concentración de la producción en un menor número de remitentes, pero aumentando así la producción diaria y el incremento del volumen de leche promedio remitido diariamente a la industria (Ministerio de Ganadería, Agricultura y Pesca, 2022).

La cadena agroalimentaria de producción de leche tiene varios subsectores, el primer lugar lo ocupa la preproducción de leche, en la que se brinda la oferta de insumos y servicios que posteriormente serán utilizados para la producción. En segundo lugar, se encuentra el sector primario, el cual cuenta con tambos de 150 vacas y una superficie de 250 hectáreas en promedio, cuya producción de leche promedio es de 18 litros por vaca al día (Instituto Nacional de la Leche, 2019). Este sector cuenta con 3.300 productores lecheros, de los cuales el 27% se dedica a la producción de queso artesanal utilizando exclusivamente la leche obtenida en el mismo establecimiento, los cuales son de tipo familiar. El 73% restante envían la leche a la industria, actor considerable en la cadena ya que, de los 2200 millones de litros producidos anualmente, recibe el 90% (Instituto Nacional de la Leche, 2021). La industria cuenta con 45 empresas productoras de lácteos, la cual emplea aproximadamente unos 3279 trabajadores anualmente con un 89% de permanencia, siendo Conaprole la que abarca la mayor parte del mercado. En dicha industria se manufacturan la mayoría de los productos lácteos, los cuales son reconocidos por elaborarse con leche libre de

hormonas, libre de antibióticos, libre de metales pesados y libre de contaminación radiactiva. Estos son destinados al consumo interno y en su mayoría al consumo externo. Uruguay es el séptimo exportador de leche a nivel mundial, exportando a más de 60 mercados. Los principales productos son: leche en polvo, alrededor de 141 mil toneladas (ton.) teniendo como los 2 principales mercados Argelia y China; queso, 26 mil ton. a Brasil y Rusia; leche en polvo descremada 20 mil ton. a Brasil y Argelia; y manteca, 12 mil toneladas. a Rusia y Brasil. Este sistema productivo se basa principalmente a cielo abierto con un predominio pastoril y una genética reconocida mundialmente, y trazabilidad completa, lo que demuestra su calidad desde la materia prima hasta su producto final (INALE, 2022; Uruguay XXI, 2021).

Como fuera mencionado, si bien en los tambos de Uruguay existe un predominio de sistemas de producción de base pastoril, en los últimos años se ha incrementado la proporción de tambos con sistemas confinados o sistemas mixtos. A continuación, se presentarán las principales características de los diferentes sistemas de producción, haciendo énfasis en los sistemas pastoriles y su impacto en el comportamiento y bienestar animal.

4.2. Sistemas de producción de leche y comportamiento bovino

Para categorizar los sistemas de producción lechera se toman en cuenta distintas variables, siendo las principales: alimentación, alojamiento, sistemas de ordeño, manejo de la reproducción y tecnología aplicada a cada una de las variables anteriores (Fetter et al., 2014). De acuerdo con lo anterior, un sistema confinado es aquel que se caracteriza por el manejo de los animales en alojamientos bajo techo durante todo el año, con una alimentación en base a ración totalmente mezclada (RTM), lo cual genera gran dependencia del precio de las raciones y concentrados. En general, dichos sistemas poseen un manejo del ordeño de última generación (por ejemplo, sistemas robotizados) y también tecnología de punta aplicada a la reproducción para obtener partos no estacionales y así tener reposición continua de vacas productoras. Esto se aplica en conjunto con una serie de registros y controles muy rigurosos para poder lograr una alta producción por vaca sostenida en el tiempo (Arnott et al., 2016). En contrapartida un sistema pastoril utiliza como base alimenticia principal las pasturas, lo que le confiere cierta ventaja con respecto al mercado de precios de los concentrados y raciones, debido a que solo los usan como complementos. En este sistema, los animales están a cielo abierto todo el tiempo. La tecnología aplicada puede variar muchísimo; existiendo países que emplean altos niveles tecnológicos y otros donde ésta es escasa, lo que se refleja especialmente en la reproducción. Donde los partos son estacionales y en algunos predios aún se utilizan toros, en general son sistemas con producción variable debido a la fluctuación de la disponibilidad de forraje y el cambio del clima (Arnott et al., 2016).

Como alternativa intermedia a los anteriores, surgen los sistemas semi-pastoriles, los cuales se caracterizan por el libre acceso a pasturas, las que son complementadas con RTM o suplementación. Además, se aplican prácticas de semiconfinamiento por periodos de tiempo variables. Teniendo en cuenta que dentro de esta categoría es

relevante la maximización del consumo y aprovechamiento de pasturas, existen diferentes enfoques, como el pastoreo intensivo que puede ser en potreros rotativos o en franjas. Estos últimos son los sistemas predominantes en Uruguay debido a que está inserto en una región templada donde las pasturas son de buena calidad y abundantes, lo que permite tener buenos rendimientos en forraje y su posterior conversión en leche, reduciendo en gran medida los costos de producción (García, 2002).

Como se ha descrito anteriormente, Uruguay es conocido en el mercado lácteo mundial por ser un país productor de base alimentaria pastoril desde sus comienzos en la industria láctea, el cual le asignó un rótulo de poseer sistemas extensivos por muchos años (Fetter et al., 2014). La evolución de la industria internacional en lo que refiere a niveles de calidad y cantidad de producto generado determinó que muchos productores uruguayos comenzaran a incorporar tecnología en todas las áreas de la cadena. Esto incitó a algunos grandes productores a convertirse a un sistema semi intensivo o intensivo, pero aun así existe predominio del sistema semi intensivo en un 50% (Fetter et al., 2014).

Las diferencias relacionadas al manejo diario de las vacas entre los diferentes sistemas traen consigo variabilidad en el patrón de comportamiento y también impactan en la salud y el bienestar del animal (Charlton & Rutter, 2017). El bienestar animal puede definirse de la siguiente manera:

“Un animal experimenta un buen bienestar si está sano, cómodo, bien alimentado, en seguridad, y si no padece sensaciones desagradables como dolor, miedo o desasosiego y es capaz de expresar comportamientos importantes para su estado de bienestar físico y mental (Organización Mundial de Sanidad Animal, 2022, Capítulo 7.1.)”.

La definición anterior se basa en las cinco libertades del animal las cuales son: libres de hambre y sed, libres de malestar físico y térmico, libres de enfermedad y lesiones, libres de poder expresar su comportamiento normal y libres de miedos o angustias (Organización Mundial de Sanidad Animal, 2022).

En ese sentido, generalmente se asume que los sistemas con base pastoril ofrecen una mayor libertad para que las vacas expresen su comportamiento natural, el patrón de pastoreo y las interacciones entre el rodeo son mejores en estas circunstancias (Arnott et al., 2016). A su vez, en los sistemas pastoriles los animales tienen periodos de descanso mayores y de mejor calidad, con niveles más bajos de agresión, esto debido a que pueden elegir mejor sus espacios de acuerdo a jerarquías y confort (Arnott et al., 2016). En contrapartida, los factores perjudiciales a tener en cuenta en dichos sistemas serían las posibles inclemencias climáticas y la posibilidad de no cubrir los requerimientos nutricionales solo con pasturas (Arnott et al., 2016). Por su parte, en los sistemas intensivos en confinamiento los animales reducen los comportamientos naturales y aumenta la incidencia de cojeras y mastitis (Charlton & Rutter, 2017), lo que afecta directamente la postura ya que una vaca con cojera altera la relación parada/echada además cambia patrones de locomoción.

Los sistemas semi pastoriles con confinamiento parcial parecen una buena alternativa entre los dos extremos ya que se comprobó que si se le ofrece la opción al animal de

elegir entre el alojamiento y la pastura estos eligen lo segundo, fundamentalmente al momento de descansar (Arnott et al., 2016). Sin embargo, dichas elecciones pueden variar: animales con buenas experiencias previas en confinamiento lo prefieren sobre el pastoreo (Charlton & Rutter, 2017). Por tanto, si se logra una conjunción entre los dos sistemas confinamiento y pastoril se puede lograr un muy buen resultado, que se verá reflejado en que las vacas producen más leche y expresan un mejor patrón comportamental si tienen acceso a los dos tipos de sistemas (Charlton & Rutter, 2017). A su vez, la posibilidad de que los animales accedan a pasturas presenta ventajas desde el punto de vista del consumidor final. Por una parte, el acceso a pastura se relaciona con una mayor proporción de componentes nutraceuticos para el ser humano, como ser los el ácido linoleico conjugado (CLA) y una menor relación omega 6/omega 3. A su vez, existe una tendencia creciente de los consumidores para que los productos que llegan al mercado sean obtenidos de manera éticas, fundamentalmente en relación a las condiciones de bienestar animal, por eso es de vital importancia al momento de evaluar los sistemas que estos cumplan con el bienestar animal.

La imposibilidad de un animal de expresar su comportamiento normal se puede relacionar con la productividad del sistema. En este sentido, existe amplia información que reporta que las desviaciones del comportamiento esperado en vacas lecheras se asocian con la incidencia de ciertas patologías, así como con alteraciones en el consumo de alimento y en la producción de leche (Charlton & Rutter, 2017). Por tanto, la posibilidad de registrar el comportamiento animal y realizar una detección temprana de cambios en el mismo puede llevar a tomar mejores decisiones, y aquí es donde toma relevancia la ganadería de precisión o precisión livestock farming (PLF) (Charlton & Rutter, 2017). El término PLF se utiliza para denominar a todas aquellas tecnologías que aplican la ingeniería de procesos a la ganadería y lechería (Chapa et al., 2020). Los sistemas PLF, entre otras muchas prestaciones, ofrecen el potencial de monitorear animales de forma permanente y automática a nivel grupal o individual en tiempo real (Chapa et al., 2020). Existe una amplia gama de sensores y monitores de comportamiento comerciales, muchos de los cuales utilizan como base del sistema a los acelerómetros. Para un adecuado uso de los acelerómetros, es necesario realizar la validación de sus registros en relación al método de referencia, que generalmente se encuentra representado por la observación visual. Muchos de los dispositivos comerciales que utilizan acelerómetros ya han sido validados en diferentes países utilizándolos principalmente para el registro del comportamiento postural echada/parada (Borchers et al., 2016; Ledgerwood et al., 2010; Pouloupoulou et al., 2019) y otros para obtener valores de comportamiento en pastoreo y rumia en condiciones de semi confinamiento, obteniéndose una alta correlación con las observaciones visuales (Benaissa et al., 2019; Rayas-Amor et al., 2017; Zambelis et al., 2019). Sin embargo, la mayor parte de los estudios mencionados han sido realizados en sistemas confinados y aún no existen trabajos que validen el uso de acelerómetros HOB0 para el registro de una mayor gama de posturas (echada, parada, caminando y otros) en sistemas semi-pastoriles, como los evaluados en la presente tesis. De esta forma, estudiar el comportamiento animal en pastoreo y con tecnologías PLF tiene un gran potencial como herramienta de análisis y rediseño de los sistemas productivos. Por tanto, la evaluación del comportamiento de las vacas en dichos sistemas permite diseñar estrategias de manejo que maximicen el consumo de pastura por parte de las vacas.

4.3. Comportamiento postural en bovinos

Los bovinos son animales gregarios con alta tendencia al alelo mimetismo, herbívoros generalistas, jerárquicos (dominantes-líderes-subordinados) dependiendo de la capacidad de cada individuo para luchar por los recursos, con elevado cuidado paternal. Además, presentan un tipo de aprendizaje por imitación y, en condiciones de vida salvaje, pueden llegar a vivir de 22 a 25 años. Ungulados de gran peso, que caminan lento, posando siempre su miembro posterior en el mismo lugar en el que posó el anterior (Del Campo et al., 2017; Phillips & Rind, 2002). El comportamiento de estos rumiantes se puede clasificar en tres tipos: comportamiento ingestivo, comportamiento postural y comportamiento filial o social. El comportamiento ingestivo está relacionado con la ingesta de alimento y agua. Incluye actividades como buscar, seleccionar, masticar y tragar el alimento. Los bovinos presentan un patrón de pastoreo crepuscular, es decir que la ingesta es más activa al amanecer y al atardecer (Phillips, 1993). En los sistemas comerciales, este patrón de comportamiento varía y puede estar influenciado por múltiples factores como ser el horario del ordeño, la disponibilidad y calidad del alimento, el acceso al agua, la estructura de la dieta y las condiciones ambientales (Grant & Albright, 2001). Por otro lado, el comportamiento filial o social refiere a las interacciones sociales de las vacas lecheras entre ellas y con otros individuos del grupo. Esto incluye comportamientos como el maternal, el sexual, el lamido mutuo, la vocalización, el acicalamiento, el juego, la formación de la jerarquía social y las interacciones de dominancia y sumisión (Foris et al., 2019; Sato et al., 1993). Por último, el comportamiento postural hace referencia a las diferentes posiciones y movimientos corporales que las vacas adoptan durante diversos eventos y estados.

Para el registro del comportamiento es necesario definir ciertas variables: un evento es un proceso que cursa en el tiempo con fases sucesivas que se siguen una a la otra siendo así un proceso dinámico que genera cambios en el input de energía (Vendler, 1957). En contrapartida, un estado es estático; es decir que continúa mientras no sufra cambios (Vendler, 1957). A modo de ejemplo, el comportamiento de caminata es un evento y estar de pie o echarse representan estados. Ya que el comportamiento postural puede proporcionar información valiosa sobre el grado de comodidad, salud y bienestar de las vacas, a continuación, nos centraremos en este y haremos hincapié en las siguientes posturas: parada, echada, caminando y otros.

El comportamiento postural está compuesto por los siguientes componentes:

- **Comportamiento de parado:** son períodos durante los cuales la vaca está en posición vertical, con los 4 miembros apoyados en el piso, sin estar caminando ni realizando ninguna otra actividad (descansando, rumiando, pastoreando o bebiendo., Alsaad et al., 2015).
- **Comportamiento de echado:** se pueden distinguir cuatro posturas echadas. En la primera postura, la vaca se acuesta sobre el esternón y la cara ventral del abdomen con el cuello estirado. En la segunda postura, la vaca se acuesta sobre el esternón y la cara ventral del abdomen, acurrucada con la cabeza vuelta hacia atrás. En la tercera postura, la vaca se acuesta de lado, con las patas traseras estiradas. Las patas delanteras pueden estar estiradas o no estiradas. En la

cuarta postura, la vaca se acuesta sobre su esternón y sobre su costado lateral, con las patas traseras no estiradas (Van Erp-van der Kooij et al., 2019).

- **Comportamiento de caminar:** periodo caracterizado por al menos 3 zancadas consecutivas en la misma dirección (hacia adelante o hacia atrás). El periodo entre 2 zancadas no debe superar los 4 segundos (Alsaad et al., 2015)
- **Otros:** eventos que realizan los animales que engloban el acto realizado conjuntamente con una postura como puede ser beber, jugar, montar otro animal, acicalarse, rumiar, orinar, defecar o dormir.

Varios estudios han demostrado que las vacas lecheras están altamente motivadas a echarse, reportándose tiempos diarios promedio de 12 horas (Jensen et al., 2005), pudiendo ser una actividad prioritaria frente al comportamiento ingestivo y social. (Munksgaard et al., 2005). Es importante tener en cuenta que el comportamiento postural en las vacas puede verse influenciado por diversos factores, incluidas las condiciones ambientales (por ejemplo, temperatura, disponibilidad de espacio), interacciones sociales, estado de salud y prácticas de manejo (Linnane 2001). Los movimientos naturales para pararse y echarse siguen un patrón de movimiento innato específico de la especie. Estos movimientos están determinados por la estructura esquelética y muscular limitando de esta forma a las vacas a adaptarse a su entorno (Brouwers et al., 2023). De tal forma, el tiempo durante el cual el animal pasa echado puede estar indicando cambios en el confort, bienestar y la salud (Haley et al., 2000). Por ejemplo, vacas con mastitis presentan una motivación reducida para acostarse, debido al dolor experimentado en la ubre (Medrano-Galarza et al., 2012), mientras que vacas con laminitis permanecen echadas por periodos prolongados para aliviar el dolor de sus miembros (Ito et al., 2010). Por otra parte, se ha demostrado que los animales prefieren mantenerse en estación (parados) cuando están sobre pisos incómodos (fríos, húmedos y mojados) (Fast, 2016). En relación a la caminata, debemos considerar dos situaciones diferentes, una de ellas es la caminata que realizan para desplazarse desde y hacia la sala de ordeño, la pastura y/o playa de alimentación, y la otra es la caminata para la búsqueda de parches nuevos y desplazamientos que se dan entre parches en el pastoreo (Delagarde & Lamberton, 2015; Grant & Albright, 2001). En ese sentido, la búsqueda y cosecha del pasto serían componentes que explicarían el mayor costo energético de mantenimiento en vacas a pastoreo en comparación a aquellas en estabulación (Aello & Di Marco, 2003).

Varios autores plantean que el cambio en el patrón de comportamiento diario en las vacas es uno de los criterios más importantes para evaluar el bienestar y la salud de los animales (Cook, et al., 2005). Por lo tanto, registrar de forma sistemática el comportamiento diario y sus modificaciones es útil como una herramienta para detectar cambios ya sean positivos o negativos, en la salud, manejo, alimentación y bienestar de las vacas.

4.4. Métodos de registro de comportamiento

El comportamiento animal en pastoreo puede monitorearse utilizando distintos métodos. Si bien el comportamiento animal en pastoreo puede monitorearse de forma visual, es un proceso que consume mucho tiempo y costo de mano de obra. La

observación visual es considerada el método de referencia (*gold standard*), pero está supeditado al entrenamiento y experiencia de cada observador, lo que puede llevar a variaciones en los resultados, además es limitado el número de animales que se pueden observar a la vez. Por tanto, requiere un alto grado de mano de obra capacitada. Aunque el registro visual aún se mantiene en algunas situaciones experimentales, considerando dichas limitaciones, en los últimos años se han desarrollado diferentes alternativas para el registro del comportamiento mediante tecnologías de monitoreo de precisión (Mattachini et al., 2013). En ese sentido, varias tecnologías relacionadas a la PLF, incluida la de audio y video, alimentadores automáticos, detección de flujo de agua, tecnología RFID (identificación por radiofrecuencia) y acelerómetros son utilizadas como alternativas complementarias o sustitutivas a la observación directa para registrar comportamiento; estas mismas se han puesto a disposición del mercado y han logrado una gran aceptación por parte de los productores (Chapa et al., 2020).

A lo largo del tiempo se han incorporado estas tecnologías como alternativas para eliminar el posible error humano. Un claro ejemplo de esto son los dispositivos para detección de celos o rumia, los cuales utilizan acelerómetros, y que surgen como una alternativa muy prometedora y de muy alto valor para evaluar el comportamiento de los bovinos y por ende traer beneficios a los sistemas productivos. Para el uso adecuado de dichos dispositivos, es necesario realizar la validación del registro obtenido por los acelerómetros en relación al método de referencia, que es representado por la observación visual. Si bien los estudios previos de evaluación del comportamiento postural han reportado una alta correlación entre muchas de dichas tecnologías de precisión, la observación visual y/o la videograbación (Mattachini et al., 2013), según lo encontrado en nuestra búsqueda bibliográfica son escasos los experimentos que validan acelerómetros por medio de técnica de aprendizaje automático.

Acelerómetros

Dentro de las tecnologías existentes para monitorear el comportamiento de los bovinos, aquellos sensores portátiles que contienen acelerómetros son unas de las alternativas más utilizadas. Los acelerómetros son dispositivos electromecánicos que miden las fuerzas de aceleración. Dichas fuerzas pueden ser estáticas (por ejemplo, cuando el animal está acostado), como representada por la fuerza de gravedad, o la de aceleración que genera el movimiento (por ejemplo, cuando el animal está caminando). El voltaje se genera a partir del movimiento ya que este produce una tensión entre los cristales microscópicos que están dentro del acelerómetro; el cual posee sensores que interpretan la cantidad de voltaje, y determina velocidad y orientación del movimiento. En un acelerómetro triaxial, tres sensores de aceleración están dispuestos ortogonalmente y se acumula información tridimensional (ejes X, Y, Z) (Benjamin & Yik, 2019). Una de las grandes ventajas del uso de acelerómetros es su pequeño tamaño, lo que permite acoplar el dispositivo al animal sin alterar su comportamiento.

Los acelerómetros son una herramienta que puede sustituir a la observación visual directa para registrar el comportamiento postural, ya sea para investigaciones o para su posible uso en establecimientos comerciales donde puede brindar información

acerca del estado y bienestar del rodeo. Existen diversos acelerómetros comerciales, tales como AfiAct Pedometer Plus, HOBO Data Logger, CowAlert IceQube, CowManager SensOor, Smartbow, Track A Cow, IceTag y Onset Pendant G data loggers (Borchers et al., 2016; DuBois et al., 2014; Mattachini et al., 2013). Sin embargo, como fuera mencionado, para un adecuado uso de los mismos es necesario su validación en relación al método de referencia.

4.5. Acelerómetros HOBO y desarrollo de algoritmos

Específicamente, en la presente tesis el acelerómetro evaluado fue el HOBO data Logger (HOBO Pendant G Acceleration Data Logger, Onset Computer Corporation, Pocasset, MA), que es un dispositivo de 3 canales con resolución de 8 bits, que puede grabar hasta aproximadamente 21,800 lecturas de aceleración combinadas o eventos de registrador interno. Para su validación, los datos generados por los acelerómetros pueden ser procesados a través de algoritmos, desarrollados previamente para la interpretación de un movimiento como un patrón de comportamiento específico (Chapa et al., 2020). Un algoritmo puede definirse como *“una secuencia finita de instrucciones, cada una de las cuales tiene un significado preciso y puede ejecutarse con una cantidad finita de esfuerzo en un tiempo finito.”* (Aho et al., 1988, p.2). El proceso de desarrollo del algoritmo requiere ciertas variables que se definen previamente: 1) el método de referencia (Gold standard), que para evaluar el comportamiento se toman los registros de las observaciones visuales; 2) los parámetros, que representan las mediciones de los dispositivos HOBO obtenidas para cada horario de toma de muestra (el acelerómetro puede registrar a diferentes intervalos, ej. cada 30 s), que registran las coordenadas X, Y, Z y el eje de inclinación para cada una (en total serían 6 resultados para cada scan sampling). A partir de estas últimas, se calcula la variable característica o de entrada (features), las cuales son utilizadas para predecir la salida del algoritmo o variable objetivo (target variable) que en nuestra tesis representan las diferentes conductas relacionadas al comportamiento posturas, ej.: Echada si/no, parada si/no, caminando si/no, otros si/no (Berckmans, 2013). Luego de obtener dichas variables, el primer paso para desarrollar el algoritmo es el Etiquetado (Labelling), donde se calculan los valores para cada uno de los features y se asocian con la salida, target, esperada. El siguiente paso es entrenar un modelo que aproxime el target a partir de los features. Este proceso se puede acelerar y mejorar ampliamente a partir del uso de inteligencia artificial, lo que se conoce como aprendizaje automático (machine learning) en el que la computadora observa datos y construye automáticamente un modelo basado en estos. El uso de las técnicas de aprendizaje automático facilita ampliamente el manejo de una gran cantidad de datos. Existen distintos tipos de aprendizaje automático, entre ellos se distinguen el aprendizaje supervisado, semisupervisado y no supervisado. El aprendizaje supervisado requiere de etiquetar previamente los datos y un conjunto de datos de entrenamiento, por otra parte, el aprendizaje no supervisado evalúa los datos de forma independiente sin etiquetar y sin necesidad de una variable objetivo clara, y por último el aprendizaje semisupervisado utiliza conjuntos de datos con solo una pequeña fracción de etiquetas (Cockburn, 2020). El aprendizaje supervisado, en donde el modelo es una función paramétrica de la entrada, que son los datos del acelerómetro, y la salida, que en este caso es la clasificación del comportamiento (Cockburn, 2020). Como siguiente paso en el desarrollo del algoritmo, se comparan las salidas del algoritmo con la realidad

comportamiento obtenido en base a trabajo de campo mediante observación visual (Berckmans, (2013). Utilizando el aprendizaje automático supervisado se pueden resolver problemas, los dos más relevantes son: problemas de regresión o problemas de clasificación. La validación del registro de los acelerómetros en relación a la observación visual se trata de un problema de clasificación multiclase no balanceado, donde la salida de la función modelo solo puede tomar un conjunto de valores discretos (multiclase), los cuales son los posibles comportamientos del animal, y además estos comportamientos no se encuentran equidistribuidos en la realidad (desbalanceado). Existen muchos modelos de algoritmos de aprendizaje automático supervisado utilizables para los problemas de clasificación, entre ellos son los Árboles de decisión, Random Forest (RF) y Gradient Boosting Machines (GBM) (Russell & Norvig, 2021).

Posteriormente se debe validar el algoritmo para poder evaluar su rendimiento. Para esto se realiza una prueba (testing) en donde se cargan datos de entrada nuevos, es decir que no hayan sido utilizados para su desarrollo, y se comparan con los que emite automáticamente dicho algoritmo. Como resultado del entrenamiento se obtienen métricas de clasificación como son la precisión, el recall, el f1-score y Support (Berckmans, 2013). Estas ayudan a evaluar el desempeño de los modelos de clasificación. La precisión, mide la proporción de clases categorizadas correctamente de todo el conjunto de datos, y brinda una evaluación fundamental del rendimiento general de un modelo para identificar correctamente los puntos de datos. Una puntuación de precisión más alta indica un modelo de clasificación más confiable (El Moutaouakil & Falih, 2024). El recall indica qué proporciones de positivos reales se identificaron correctamente (verdaderos positivos) en relación con el número total de casos positivos reales. Es una medida de evaluación crucial para valorar la efectividad de un modelo predictivo (El Moutaouakil & Falih, 2024). La f1-score, también conocida como medida f1 o estadística f1, juega un papel importante en la evaluación del rendimiento de los modelos de clasificación. Es una métrica compuesta que combina dos métricas de clasificación esenciales, la precisión y el recall, proporcionando una medida equilibrada entre ambas métricas. Esto hace que la f1-score sea particularmente valiosa cuando se trata de conjuntos de datos desequilibrados o situaciones en las que es importante una alta precisión como un alto recall (El Moutaouakil & Falih, 2024). Finalmente, el Support es el número de apariciones de la clase dada en nuestros datos (El Moutaouakil & Falih, 2024).

En su mayoría, los trabajos existentes que evalúan el comportamiento postural con acelerómetros HOBO han demostrado una alta correlación con los datos obtenidos mediante la observación visual. Diferentes estudios validaron los acelerómetros HOBO en sistemas estabulados, utilizando vacas/terneras lecheras (Benaissa et al., 2019; Borchers et al., 2016; De Passille, et al., 2010; Ledgerwood et al., 2010; Swartz, et al., 2016), o equinos (DuBois et al., 2014), reportando que los dispositivos efectivamente pueden ser utilizados para medir el comportamiento postural, contar el número de pasos y clasificar los diferentes tipos de marcha. Sin embargo, hubo cierta confusión entre caminar y trotar, mientras que el galope fue fácilmente distinguible. Esta discrepancia podría atribuirse a la cantidad de observaciones relativamente baja utilizada en el estudio (De Passille, et al., 2010). Además, los acelerómetros HOBO pudieron medir con alta precisión los comportamientos de echado, parado (DuBois et

al., 2014; Ledgerwood et al., 2010; Swartz et al., 2016), echado hacia la izquierda o hacia la derecha (Ledgerwood et al., 2010). Sin embargo, en un estudio realizado por Borchers et al. (2016) en el que se evaluó el tiempo de descanso con varias tecnologías PLF, el comportamiento de echado tuvo una correlación moderada con las observaciones visuales y las registradas mediante acelerómetros HOBO. Dichos autores plantean la necesidad de ajustar el método con el fin de evitar que los datos sin procesar se conviertan en datos falsos, obteniendo así una mayor correlación entre los registradores y las observaciones visuales, y aumentar la frecuencia de muestreos para mejorar el rendimiento de la tecnología. En otro estudio, se validaron los registradores HOBO en vacas lecheras a pastoreo, evaluando el tiempo de pastoreo y de rumia (Rayas-Amor, et al., 2017). Este estudio se asemeja a la presente tesis por las condiciones en que se realizó, aunque dista fundamentalmente en los comportamientos evaluados. A su vez, en ninguno de los estudios mencionados, se realizó el entrenamiento de un modelo de aprendizaje automático para la validación de los acelerómetros en relación a la observación visual. Esto sí lo hicieron Benaissa et al., (2019), clasificando automáticamente el comportamiento postural e ingestivo en vacas lecheras estabuladas, implementando y comparando 3 tipos de algoritmos k-nearest Neighbours (L-NN), Naive Bayes y Support Vector Machine (SVM), obteniendo muy buenos resultados de precisión (80%-99%) y sensibilidad (87%-99%), con mejor desempeño para la precisión general con SVM seguido de K-NN y Naive Bayes. Este es el estudio que tiene mayor similitud con el nuestro ya que ejecutan algoritmos para validar los dispositivos HOBO, sin embargo, su experimento no fue realizado en sistema pastoril y no utilizaron como modelo de aprendizaje automático a Random Forest.

En resumen, la utilización de los acelerómetros puede brindar información precisa acerca de las diferentes conductas del animal, siendo una herramienta útil en el manejo del rodeo (Borchers et al., 2016). Por otra parte, es escasa la información que existe de su uso en sistemas semi-pastoriles. A su vez, a pesar de los diferentes estudios publicados, la utilización de estos dispositivos aún presenta dificultades tanto para el manejo de éstos como para el manejo de los datos que nos brindan (Hendriks et al., 2020). En suma, los acelerómetros HOBO son una herramienta potencial para el registro del comportamiento postural en pastoreo, sin embargo, es necesario la validación de los mismos para ajustar su utilización en nuestras condiciones.

5. HIPÓTESIS

Es posible entrenar modelos de aprendizaje automático para el registro del comportamiento postural a partir de los acelerómetros triaxiales HOBO Data Logger, que proporcionen una alta precisión y exactitud entre los parámetros registrados por los acelerómetros y los datos obtenidos mediante la observación visual directa en vacas lecheras a pastoreo.

6. OBJETIVOS

6.1. Objetivo general

Validar la utilización de los acelerómetros HOBO para el registro de comportamiento postural, en comparación con los registros obtenidos mediante observación visual directa, en vacas lecheras a pastoreo.

6.2. Objetivos específicos

- Comparar la utilización de acelerómetros HOBO Data Logger triaxiales en vacas lecheras manejadas en un sistema pastoril, a partir de los registros visuales de los parámetros evaluados (parada, echada, caminando y otros) con los datos obtenidos por los acelerómetros HOBO Data Logger.
- Entender y evaluar un modelo de aprendizaje automático que sea capaz de registrar el comportamiento visual postural (parada, echada, caminando y otros) a través de los acelerómetros HOBO Data Logger.
- Determinar la exactitud y precisión de los acelerómetros HOBO para registrar las diferentes conductas asociadas al comportamiento postural (parada, echada, caminando y otros) en vacas lecheras a pastoreo.

7. MATERIALES Y MÉTODOS

7.1. Animales y manejo

El estudio se realizó durante la primavera (septiembre y octubre) en el Campo Experimental n° 2 de la Facultad de Veterinaria, UdelaR, en acuerdo a las normas de la Comisión Honoraria de Experimentación Animal (Protocolo CHEA 1260/21). Se utilizaron 11 vacas Holando y cruza Holando-Jersey multíparas, en lactancia media, seleccionadas de forma que cumplían ciertos criterios de condiciones fisiológicas y productivas: rango de lactancias 2 a 4, rango de edad 3 a 6 años, producción promedio de leche 27 litros/día, y pertenecientes al rodeo general del tambo (120 vacas). Las vacas eran ordeñadas en dos turnos al día, uno matutino (4 a 6 h) y otro vespertino (15 a 17 h), y fueron manejadas en un sistema de pastoreo en franjas diarias, con doble turno de pastoreo luego de cada ordeño, en forma conjunta con el resto de las vacas del tambo. Cada parcela contaba con bebederos y praderas compuestas por una mezcla de *Raigrás spp*, *Trifolium repens*, *Trifolium pratense*, *Lotus spp*, *Alfalfa spp*. El tamaño de la franja diaria se determinaba de acuerdo a la disponibilidad de pastura, con una asignación del 8% de pastura. A su vez, las vacas se suplementaban con concentrado en el ordeño y silo de maíz en comederos colectivos en forma posterior al ordeño.

Previo al comienzo del experimento las vacas se sometieron a un período de adaptación de 3-5 días, durante los cuales se colocaron los dispositivos HOB0 en las vacas para su habituación y se evaluó si los mismos registraban de forma correcta los datos. Por otra parte, se utilizó este tiempo para el entrenamiento de los observadores en el registro de cada comportamiento mediante observación visual adoptando así un criterio uniforme en el registro y manejo de las planillas. Para ello, se establecieron los siguientes criterios: una vaca se encontraba parada cuando estaba en estación con los cuatro miembros apoyados en forma perpendicular con respecto al plano horizontal del piso; echada cuando estaba en decúbito esternal, dorsal o lateral; caminando cuando estaba en avance y progresión, con dos miembros apoyados y dos en vuelo. Y en la categoría de “otras” cuando el animal no se encontraba realizando ninguna de las conductas previamente descritas.

Luego de transcurrido el periodo de adaptación y durante 20 días consecutivos (Día 0 a Día 20) se realizó un muestreo tipo scan sampling (Lehner, 1992), a intervalos de 5 minutos, registrando el comportamiento postural (parada, echada, caminando y otros) para cada una de las vacas en estudio. La observación visual directa se realizó en forma simultánea por 2 de los observadores (cada observador observaba la mitad de los animales) previamente entrenados por turno en las franjas de pastoreo asignadas, durante la mañana (de 07:30 a 14:00 horas) y la tarde (de 17:00 a 19:00-20:00 horas) luego de cada ordeño. Para el registro de comportamiento mediante la observación visual se utilizaron planillas preestablecidas, las cuales contaban con un diseño de celdas para cada comportamiento donde se señalaba lo observado cada 5 minutos. Para facilitar la visualización de los animales a distancia y así no interferir en su comportamiento normal, los individuos se identificaron por medio de bozales y pintura de diferentes colores en el anca.

7.2. Dispositivos HOBO.

Los acelerómetros fueron colocados en el miembro posterior derecho, sujetado mediante vendaje cohesivo VetWrap y cinta pato adhesiva de tal forma que los ejes X, Y, Z quedaron posicionados de la siguiente manera: el eje X perpendicular al suelo cuando la vaca se encontraba parada, el eje Y perpendicular al suelo cuando se encontraba echada y el eje Z tangencial al suelo, apuntando lejos del plano sagital (Figura 1) (Darr y Epperson, 2009).

La colocación de los dispositivos en cada vaca se realizó durante el ordeño vespertino en la sala de ordeño. Dichos acelerómetros fueron programados para registrar las actividades cada 30 segundos, mientras que el retiro y descarga de la información recabada se realizó cada siete días para así tener un margen de seguridad con respecto al uso de la memoria. La extracción de los dispositivos se realizó en el ordeño matutino, e inmediatamente se procedió a la descarga de los datos mediante la aplicación HOBOWare y liberación de memoria con chequeo de la batería para volver a colocar el dispositivo en el mismo animal durante el ordeño de la tarde.

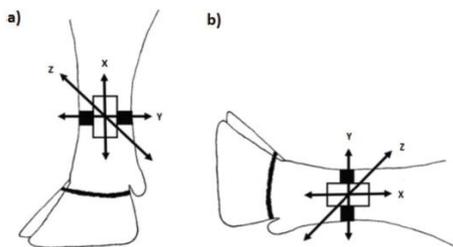


Figura 1: “Ilustración de la posición del acelerómetro triaxial y los ejes X, Y, Z en la cara lateral del miembro trasero en posiciones de pie (a) y echado (b)” (Tomado de Hendriks et al, 2020, p. 12144).

7.3. Análisis químico de las pasturas

Se realizó seguimiento de la disponibilidad de pastura a partir de la técnica del doble muestreo (Haydock & Shaw, 1975), en los Días 0, 5, 15, y 20 del experimento. A su vez, se tomaron muestras de forraje para la descripción de composición química, realizándose los siguientes análisis en el Laboratorio de análisis químicos de alimentos del IPAV: Materia seca (AOAC, 1990), Cenizas (AOAC, 1990), Proteína bruta con el método de Kjeldahl, (AOAC, 1990), Fibra neutro detergente (Licitra et al., 1996), Fibra ácido detergente (Licitra et al., 1996), y Extracto etéreo (Nielsen, 2003), para el que se usó un extractor de grasa Goldfish (Goldfish, Labconco 35001, Texas city, TX, USA). La composición química se presenta en la Tabla 1.

Tabla 1. Composición química de la pastura utilizada (expresada en % base seca).

	DIA 0	DIA 5	DIA 10	DIA 15	DIA 20
MS	24,3	26,4	22,9	21,0	21,3
CE	9,8	11,5	11,1	7,7	9,9
PB	7,9	14,2	9,4	8,0	7,6
FND	67,2	50,3	49,8	53,2	52,6
FAD	39,8	29,8	29,7	30,2	31,8
EE	1,3	2,2	1,3	1,5	2,0
DISP	4777,5	4926,7	4502,7	6655,8	4566,6

MS: Materia Seca; CE: Cenizas; PB: Proteína Bruta; FND: Fibra Neutro Detergente; FAD: Fibra Ácido Detergente; EE: Extracto Etéreo; DISP: Disponibilidad (kilogramos de materia seca por hectárea).

7.4. Procesamiento y análisis de datos.

Una vez finalizado el trabajo de campo, se unificaron los datos de las observaciones visuales en una planilla de cálculo, realizando el mismo procedimiento con los datos obtenidos por el HOBO. Por tanto, estos archivos contaban con un conjunto de datos de X registros, donde para cada uno contaba con los datos recabados por los acelerómetros (que serán utilizados como indicadores, también llamados predictores, *features*, o datos de entrada) y con datos de las observaciones visuales (que serán las variables a predecir, también llamadas variable de salida).

Este conjunto de datos se utilizó para desarrollar las técnicas de aprendizaje automático y así entrenar los algoritmos, para intentar predecir automáticamente el comportamiento registrado visualmente. Para elegir el modelo del algoritmo de aprendizaje supervisado, como fuera mencionado anteriormente, hay que saber frente a qué tipo de problema estamos, y en este caso se trató de un problema de clasificación multiclase ya que cuenta con categorías y la salida pertenece a solo una de esas categorías (parada, echada, caminando y otros) y desbalanceado ya que cada una de ellas no tiene la misma probabilidad de ocurrir (Ahmad, 2024)

Utilizando la herramienta Google Colab¹ se cargaron los paquetes a ejecutar, se convirtieron las planillas de Excel al formato Comma Separated Values, los que posteriormente se adjuntaron al programa como datos de entrada (Dataset). El paso

¹ Google Colaboratory: <https://colab.google/>. Accedido el 30 de abril de 2024.

siguiente fue preprocesar los datos, donde se definieron las variables de entrada o *features* iniciales. Para ello utilizamos la siguiente nomenclatura:

- las coordenadas X|Y|Z,
- su inclinación (posición respecto a la vertical de la gravedad, vector: I), o su aceleración (vector: A), y
- su ubicación con la letra P (pata).
- se incluyeron n (número de observaciones), medidas antes y después de la observación. Si no decía nada era el momento actual, si decía +1 era la siguiente medida en el tiempo; y -1 si era la medida anterior. Si además tenía una 'm' significaba que era la media de los valores. Por ejemplo, +5 (media de las siguientes 5 medidas), -5 (media de las anteriores 5 medidas), m+10 (media de las siguientes 10 medidas), y m-10 (medida de las anteriores 10 medidas).

Por ejemplo, YAp+3 quiere decir que tiene la coordenada Y para aceleración con el acelerómetro ubicado en la pata y 3 medidas en el tiempo hacia adelante.

El siguiente paso fue definir un conjunto de *features* relevantes al problema de la clasificación de postura, donde se filtraron por carencia de datos e importancia para la predicción, quedando los siguientes: 'XAp', 'YAp', 'ZAp', 'Xlp', 'Ylp', 'Zlp', 'XAp-1', 'YAp-1', 'ZAp-1', 'Xlp-1', 'Ylp-1', 'Zlp-1', 'XAp+1', 'YAp+1', 'ZAp+1', 'Xlp+1', 'Ylp+1', 'Zlp+1', 'XApm-5+5', 'YApm-5+5', 'ZApm-5+5', 'Xlpm-5+5', 'Ylpm-5+5', 'Zlpm-5+5', 'XApm-10', 'YApm-10', 'ZApm-10', 'Xlpm-10', 'Ylpm-10', 'Zlpm-10', 'XApm+10', 'YApm+10', 'ZApm+10', 'Xlpm+10', 'Ylpm+10', 'Zlpm+10'. Siendo estos los únicos datos de entrada que utiliza algoritmos de aprendizaje automático.

Sobre estos datos (features anteriores como entrada y la categoría de postura como salida) se evaluaron un conjunto de técnicas de aprendizaje automático supervisado, donde el entrenamiento de cada modelo se realizó con un subconjunto aleatorio del conjunto de datos, llamado conjunto de entrenamiento para lo cual se utilizaron el 75% de los mismos, dejando el 25% restante (llamado conjunto de *testing*) para posteriormente evaluar el entrenamiento, esto tuvo el fin de evitar el sobreentrenamiento (*overfitting*). Un modelo sobreentrenado alcanza alto rendimiento en el conjunto de entrenamiento, pero presenta deficiencias en el grupo de prueba, esto hace que el modelo reconozca y valide muy bien los datos que se usaron para entrenarlo, pero presenta dificultades al momento de reconocer datos que disten de los que se utilizaron para entrenarlo, lo que dificulta su aplicación en nuevos problemas.

Luego se compararon (sin ajustar hiper-parámetros) los siguientes métodos:

- Dummy Classifier
(<https://scikit-learn.org/stable/modules/generated/sklearn.dummy.DummyClassifier.html>)
- Logistic Regression
(https://scikit-learn.org/stable/modules/generated/sklearn.linear_model.LogisticRegression.html).
- Linear Logistic Regression model One Versus Rest

- (https://scikit-learn.org/stable/modules/generated/sklearn.linear_model.LogisticRegression.html).
- Scaled Linear Logistic Regression model One versus Rest
(https://scikit-learn.org/stable/modules/generated/sklearn.pipeline.make_pipeline.html).
 - Scaled Principal Components Logistic Regression model
(https://scikit-learn.org/stable/modules/generated/sklearn.pipeline.make_pipeline.html).
 - Linear Discriminant Analysis
(https://scikit-learn.org/stable/modules/generated/sklearn.discriminant_analysis.LinearDiscriminantAnalysis.html).
 - Linear SVC
(<https://scikit-learn.org/stable/modules/generated/sklearn.svm.LinearSVC.html>)
 - KNeighbors Classifier
(<https://scikit-learn.org/stable/modules/generated/sklearn.neighbors.KNeighborsClassifier.html>).
 - Gaussian Process Classifier
(https://scikit-learn.org/stable/modules/generated/sklearn.gaussian_process.GaussianProcessClassifier.html).
 - Random Forest Classifier
(<https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.RandomForestClassifier.html>).
 - Random Forest with Cost-Sensitive Learning
(<https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.RandomForestClassifier.html>).

Los resultados mostraron que RF fue el más performante (Ver sección Resultados; Tabla 2.). Random Forest (RF) es un algoritmo de aprendizaje automático (machine learning) que combina la salida de múltiples árboles de decisión para alcanzar un solo resultado, este resultado lo podemos mejorar ajustando sus hiper-parámetros, los que configuran al algoritmo para optimizar su rendimiento. Dicha optimización nos puede llevar a un sobreajuste del modelo y este perdería utilidad en la aplicación real siendo

efectivo solamente en el conjunto de entrenamiento, para evitar esta situación se realizó la optimización de hiper-parámetros mediante la validación cruzada de búsqueda aleatoria, utilizando el paquete Scikit-Learn². El ajuste de hiper-parámetros es un proceso costoso computacionalmente, por lo que solo se ajustaron los siguientes hiper-parámetros:

- `n_estimators` (número de árboles en el bosque),
- `max_features` (número máximo de características consideradas para dividir un nodo),
- `max_profundidad` (número máximo de niveles en cada árbol de decisión),
- `min_samples_split` (número mínimo de puntos de datos colocados en un nodo antes de dividir el nodo),
- `min_samples_leaf` (número mínimo de puntos de datos permitidos en un nodo hoja),
- `bootstrap` (método para muestrear puntos de datos con o sin reemplazo).

El procedimiento de ajuste se basó en una búsqueda aleatoria, obteniendo los mejores valores para dichos hiper-parámetros.

Finalmente, estrenamos un nuevo modelo de RF con los hiper-parámetros ajustados, comprobando que tenía una mejor performance en el conjunto de datos de testing. Siendo este nuestro algoritmo de aprendizaje automático final para este problema.

² scikit-learn: machine learning in Python. <https://scikit-learn.org/>. Accedido el 30 de abril de 2024.

8. RESULTADOS

Se registraron un total de 16740 observaciones visuales a lo largo de todo el período de medición; en relación a los comportamientos de parada se registraron 10108, echada 4815, caminando 875 y otros 160. Con dichas observaciones la calidad de predicción de Random Forest se muestra en la Tabla 1. Donde se puede evidenciar que la precisión fue ≥ 0.90 en todos los comportamientos exceptuando la postura otros. Por otra parte, recall y f1-score fueron dispares, ya que echada/parada obtuvieron valores $\geq 0,94$ y caminando/otros fueron $\leq 0,32$.

Tabla 1. Informe de clasificación.

	Precisión	Recall	f1-score	Support
C	0.90	0.32	0.47	234
E	0.94	0.95	0.94	1185
O	0.00	0.00	0.00	40
P	0.91	0.97	0.94	2505

C: Caminando; E: Echada; P: Parada; O: Otros. Precisión: cantidad de clases catalogadas correctamente dentro del total de datos; Recall: proporción de positivos reales que se clasificaron correctamente en relación con el número total de casos positivos reales (verdaderos positivos); F1-score: esta medida también evalúa el rendimiento del modelo proporcionando una medida más equilibrada ya que combina Precisión y Recall ($\text{Precisión} \times \text{Recall}$) / ($\text{Precisión} + \text{Recall}$); Support: número de apariciones de la clase dada en el total de datos.

En la Figura 2 se presenta la matriz de confusión que exhibe el desempeño del algoritmo mostrando la distribución de los valores de las observaciones visuales con respecto a los predichos permitiendo así evaluar la capacidad de predicción del modelo. Se presentan los comportamientos observados (True label) en filas y los comportamientos predichos (Predicted label) en columnas. Se obtuvo así una diagonal de izquierda a derecha, de arriba hacia abajo y en los colores violeta claro, celeste y amarillo donde se presentan las predicciones correctas en base al mejor desempeño en la relación valor real/valor predicho, quedando fuera de esta diagonal todas aquellas predicciones que tienen un valor bajo de esta relación considerándose así predicciones incorrectas.

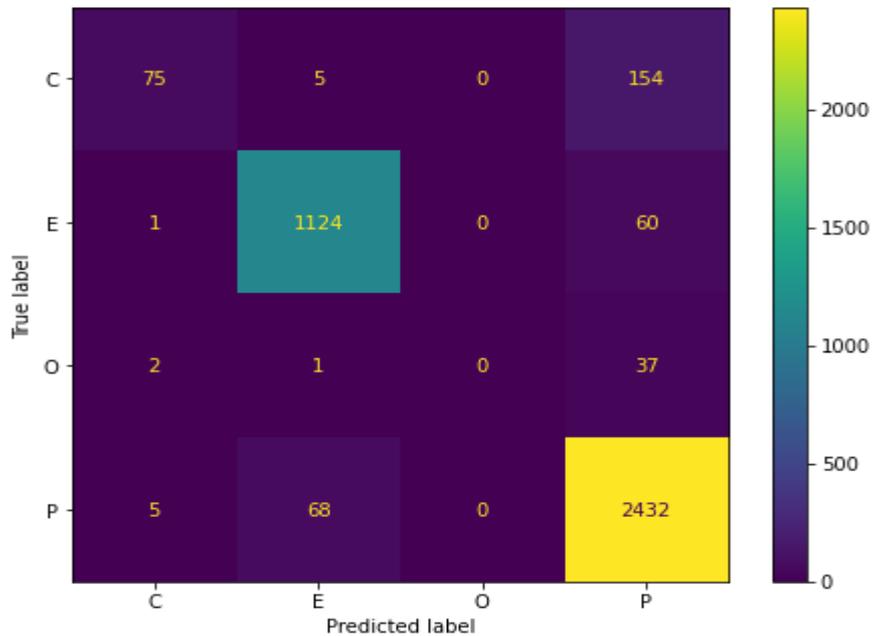


Figura 2. Matriz de confusión de los comportamientos. C: Caminando, E: Echada; P: Parada; O: Otros. Se puede contemplar que el modelo tiene un aumento de precisión a medida que es mayor la cantidad de observaciones reales, llevando la colorimetría de la tabla hacia el color amarillo cuando más preciso es. Además, dicha precisión aumenta a medida que las posturas tienen una mayor cantidad de datos cargados o sea un mejor Support.

En las Figuras 3 A/B se describen 2 de los Features que lograron clasificar mejor a cada postura. La figura 2A muestra que la categoría Parada (P) tiene alta probabilidad de estar asociada con valores de X_{Apm+10} cercanos a 1. Por otra parte, Echada (E) tiene relación con valores alrededor de 0. Sin embargo, Caminando (C) y Otros (O) son más dispersas y menos densas. En la Figura 3B el comportamiento P se observa en valores cercanos a 160 de X_{lpm+10} , E se concentra más en cifras alrededor de 80 y C/O nuevamente tienen una distribución dispersa y de baja densidad. El patrón descrito también se aplica a los demás features utilizados por el modelo; es decir que las figuras presentan una distribución similar, pero en rangos diferentes para valores del eje X.

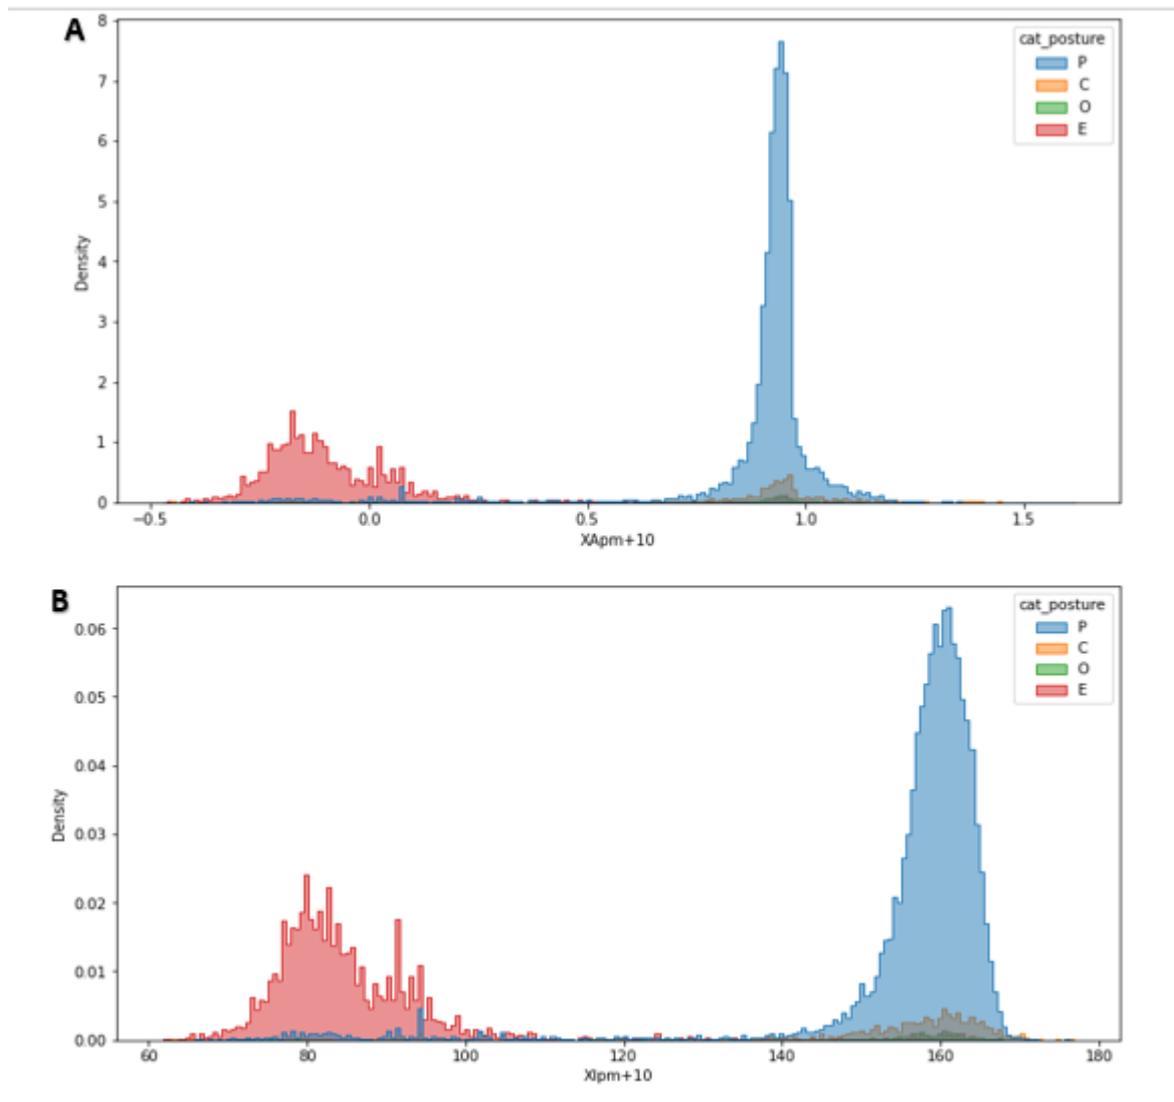


Figura 3. Densidad en función de Feature XApm+10 (A) y Feature XIpm+10 (B)

Eje X: Representa el Feature XApm+10 (A) valores de la coordenada X con el vector de aceleración A, en la media de las siguientes 10 medidas; Feature XApm+10 (B) siendo los valores de la coordenada X, en aceleración A, con la media de las siguientes 10 medidas. Eje Y: (Density): Densidad o frecuencia relativa de ocurrencia de la variable X para cada categoría. Categorías posturales: (Cat_posture): Azul/P (Parada); Naranja/C (Caminando); Verde/O (Otros); Rojo/E (Echada).

La Figura 4 muestra la importancia de los features utilizando la disminución media de la impureza. Esto permite determinar qué tan informativa es una característica (feature) para dividir los datos en clases más homogéneas.

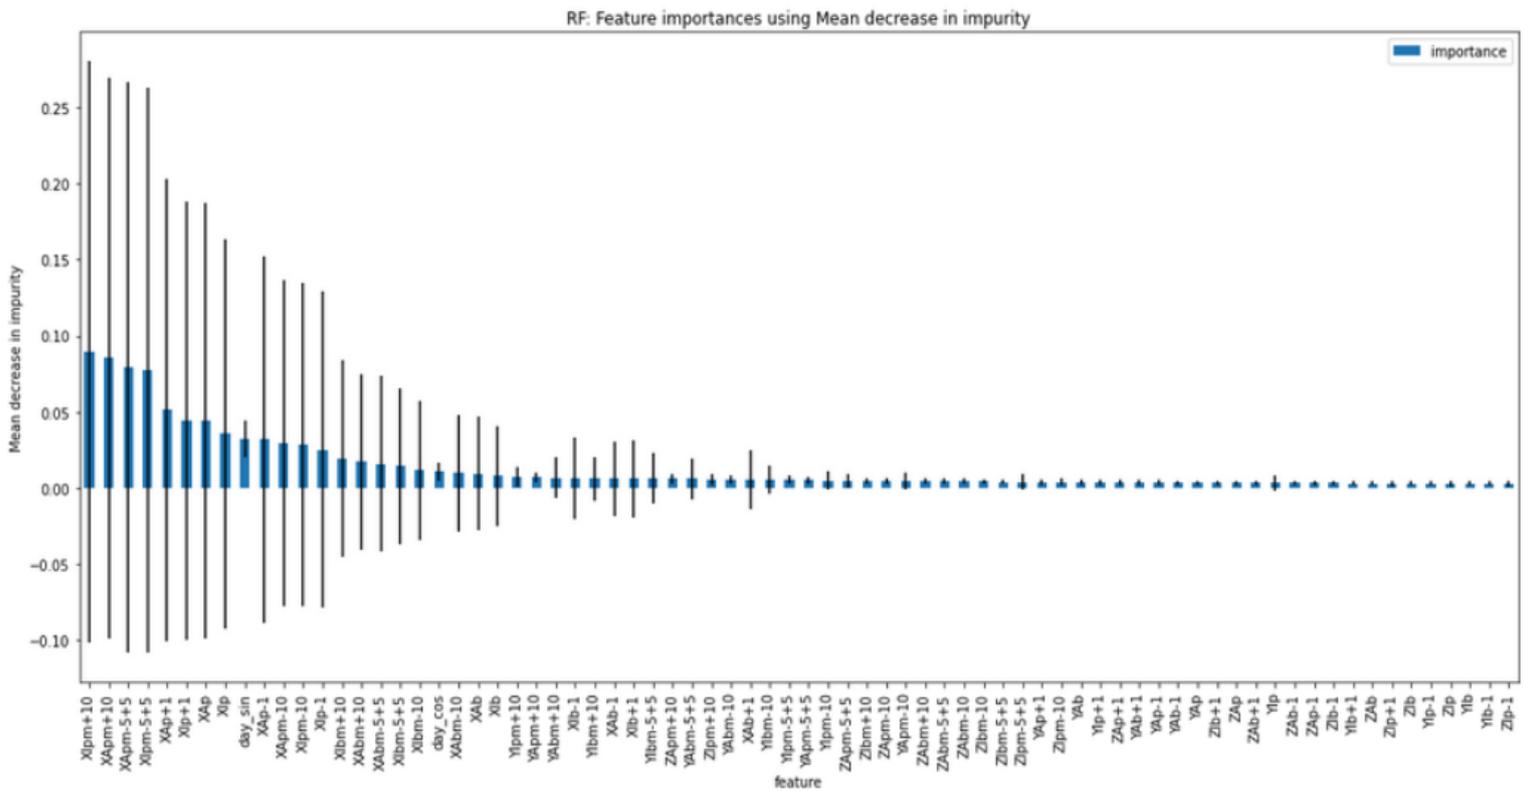


Figura 4. Importancia de los features utilizando la disminución media de la impureza. En el eje vertical se presenta la disminución media de la impureza y en el horizontal los 74 features utilizados, se puede observar una disminución en la importancia de los features (barras azules) a medida que la disminución media de la impureza se acerca a 0, por lo tanto, el feature va perdiendo valor informativo.

Finalmente, en la Tabla 2 se presentan los distintos modelos entrenados con sus respectivos valores de Accuracy expresada en valores de porcentaje (proporción de predicciones correctas realizadas por un modelo de inteligencia artificial con respecto al número total de predicciones).

Tabla 2. Error por método.

Modelo	Accuracy (%)
dummy	0.632
LR	0,888
LR_OVR	0,897
SLR_OVR	0,898
SPCALR_OVR	0,889
LDA	0,892
SVM	0,893
KNN	0,886
RF	0,917
RF_w	0,911

9. DISCUSIÓN

Los resultados obtenidos en este estudio respaldan la hipótesis planteada ya que, fue posible aplicar modelos de aprendizaje automático (Random Forest) para el registro del comportamiento postural utilizando acelerómetros HOBO y comparándolos con datos recabados de la observación visual directa en vacas lecheras a pastoreo. La precisión de los HOBO para cada postura, parada, echada, caminando y otros fue de 0,91, 0,94, 0,90, 0,00 respectivamente. Estos resultados coinciden en gran medida con los obtenidos por Benaissa et al., (2019) en vacas lecheras en sistemas estabulados, utilizando acelerómetros HOBO y distintos algoritmos (K-nearest neighbours, naïve Bayes, y support vector machine). Estos autores tuvieron valores de precisión iguales o superiores a 0,80 para la postura parada, 0,97 para echada y 0,90 en posturas mixtas. Wang et al., (2018) utilizando acelerómetros ADXL345 con el algoritmo Multi-BP-AdaBoost en vacas lecheras confinadas también alcanzaron valores similares: los valores de precisión de parada, echada y caminando fueron 0,80, 0,99 y 0,99, respectivamente. Con este mismo acelerómetro y el algoritmo Gradient Boosted Decision Tree (GBDT) en vacas lecheras estabuladas, Cong Phi Khanh et al., (2020) llegaron a valores similares al ensayo anterior. Los estudios citados anteriormente tienen como denominador común el tipo de sistema donde se desarrollaron ya que, se llevaron a cabo en sistemas estabulados, a diferencia de la presente tesis que se realizó en un sistema pastoril; aportando así hallazgos novedosos en relación al potencial uso de estos dispositivos en animales manejados en sistemas pastoriles. Por tanto, en base a los antecedentes y a los datos de la presente tesis es posible afirmar que los acelerómetros permiten registrar automáticamente el comportamiento postural en vacas lecheras a pastoreo en forma precisa, y específicamente las posturas de echada y parada; tanto en sistemas pastoriles como estabulado. La posibilidad de utilizar los acelerómetros a nivel de campo representa una ventaja porque evita la necesidad de tener que observar de forma directa a los animales o utilizar cámaras de video e iluminación, permitiendo la detección de posturas independientemente del sistema de producción y horario del día (Ringgenberg et al., 2010).

El análisis de los datos reportó una posibilidad de ocurrencia del 63% para la conducta de parada, 30% para echada, 6% para caminando y 1% para otras conductas. La postura parada fue la que obtuvo más del doble de las observaciones visuales, y la clase con mayor número de apariciones (Support); a diferencia de lo reportado por otros estudios, en los que utilizando vacas lecheras estabuladas encontraron que echada fue el comportamiento postural más frecuentemente registrado (Balasso et al., 2023; Benaissa et al., 2019; Cong Phi Khanh et al., 2020; Vázquez-Diosdado et al., (2015); Wang et al., 2018). Considerando que los bovinos tienden a priorizar el descanso frente a otras actividades (Jensen et. al., 2005; Munksgaard et al., 2005), lo esperable es que permanezcan más tiempo echados que parados. No obstante,

durante el muestreo las vacas del presente estudio permanecieron mayormente en la parcela, horario que coincide con el patrón de pastoreo que presenta la especie (Phillips, 1993), lo que podría explicar que estar de pie haya sido la postura más observada, a diferencia de los estudios mencionados que fueron realizados con vacas lecheras en sistemas confinados. Sumado a esto, dicha postura fue la que presentó performance en el algoritmo, con una precisión de 0,91, recall de 0,97, y un f1-score de 0,94. En forma similar, utilizando acelerómetros HOBO y utilizando Random Forest pero con cerdos estabulados, Ringgenberg et al., (2010) obtuvieron una precisión y recall de 0,99. En dicho estudio, los autores, argumentan que la efectividad para detectar dicha postura se debe a la diferencia en los valores de las coordenadas del acelerómetro entre estar de pie y las otras posturas: el valor de las coordenadas del acelerómetro al ángulo que toma el eje x que va perpendicular al suelo, si este está por encima de los 50° la aceleración que toma el dispositivo es de una postura de pie ya por debajo de esto los ángulos varían en cada postura y se pueden confundir generando aceleraciones confusas para que el algoritmo tome un punto de corte para cada postura (Ringgenberg et al., 2010). En una coyuntura distinta y trabajando para determinar la marcha en terneros utilizando acelerómetros HOBO, De Passille, et al., (2010) afirmaron que el balanceo del dispositivo en la pata altera las aceleraciones positivas y negativas convirtiéndolas en difusas, siendo los mejores valores los de la marcha al paso o cuando el animal no balancea el acelerómetro. Benaissa et al., (2019) utilizando HOBO en vacas lecheras ejecutaron varios algoritmos, encontrando que Support Vector Machine (SVM) alcanzó una precisión, recall de 0,76 y 0,68 respectivamente para la postura parada. Por otra parte, Vázquez-Diosdado et al., (2015) trabajando con vacas lecheras estabuladas y utilizando otros acelerómetros triaxiales, pero aplicando también como algoritmo a Random Forest, obtuvieron un recall de 0,88, una precisión de 0,55; y aunque el valor de recall es bueno, a diferencia de nuestro estudio, la precisión mostró que había margen para mejorar la clasificación general. Las diferencias con el presente trabajo podrían estar dadas en el valor del Support; en este sentido, Vázquez-Diosdado et al., (2015) utilizaron un número inferior de datos, 356 observaciones vs 2505 de observaciones de la presente tesis, esto se ve respaldado por el argumento utilizado en el ensayo ya mencionado, donde afirman que la métrica del algoritmo es mejor si se aumenta el número de observaciones y el tiempo de observación de cada conducta. En forma similar, Cong Phi Khanh et al., (2020) reportaron una precisión de 0,82 y recall de 0,76; en contraste con la presente tesis, nuestros resultados no solo reflejan un rendimiento superior en precisión y recall, si no también mejor f1 score. Finalmente, la matriz de confusión demuestra que estar de pie fue la postura que mejor predijo el algoritmo ya que, fue correcta en 97,1% de los casos (concordando el comportamiento observado con el predicho). Por tanto, solo se confundió en 2,9% de los casos, de los cuales las posturas observadas fueron echada y caminando 2,7%, 0,2% respectivamente. En contraste, otros estudios encontraron que sus modelos solo lograron predecir la postura de pie en un rango de 67,7% al 88,8% de los casos (Cong Phi Khanh et al.,

2020; Martiskainen et al., 2009; Vázquez-Diosdado et al., 2015) y en concordancia con nuestros hallazgos, en aquellos casos en que los modelos erraron al predecir la postura parada los animales se encontraban echados. Por tanto, de acuerdo a la bibliografía consultada el presente trabajo fue el que obtuvo la mayor precisión y recall para el registro del comportamiento de parada, mayor a otros estudios en vacas lecheras en sistemas confinados.

El comportamiento de echada obtuvo una precisión de 0,94, lo que concuerda con los trabajos de Vázquez-Diosdado et al., (2015) el que obtuvo una precisión de 0,96 para RF, pero validando otro tipo de dispositivo. Asimismo, Mattachini et al., (2013) con vacas lecheras en confinamiento obtuvieron una precisión por encima del 0,80 utilizando regresión lineal con datos de acelerómetros HOBOT. Con respecto al valor de recall, en el presente estudio fue de 0,95, asemejándose mucho a los trabajos anteriormente citados, confirmando lo que expresa Mattachini et al., (2013) que echada es una de las posturas más fáciles de clasificar. En contraposición, Cong Phi Khanh et al., (2020) obtuvieron un recall de 0,55 utilizando el algoritmo GBDT. Por tanto, en base a estos hallazgos podríamos concluir que RF ha demostrado ser altamente performante para esta postura. Vázquez-Diosdado et al., (2015) aseguran que las observaciones visuales para este comportamiento se pueden realizar cada 10 minutos ya que, al ser un comportamiento estático (i.e. un estado; a diferencia de un evento) el algoritmo no sufre modificaciones en su métrica, por lo que se podría aumentar la ventana de observación. El estudio de Ledgerwood et al. (2010), en vacas lecheras en confinamiento, evaluando los intervalos de duración de los comportamientos echado y parado, obtuvo resultados similares utilizando acelerómetros HOBOT y Regresión Lineal. Esto refuerza la idea de que estos dispositivos presentan alta predictibilidad, sensibilidad y especificidad para determinar si el animal está echado. A su vez en el estudio de Robert et al., (2009), realizado en terneros de razas de carne estabulados, los acelerómetros demostraron una alta precisión para aquellos comportamientos estáticos como echada. Con relación a los resultados de la postura echada obtenidos en la matriz de confusión, se observa que el algoritmo predice de forma correcta la postura echada en el 95% de los casos, sin embargo, existe un 5% de error, en este caso el comportamiento predicho es parado cuando en realidad el comportamiento observado fue echado. Con respecto a los antecedentes, ninguno de los autores que utiliza HOBOT presenta matriz de confusión, es por este motivo que compararemos con otros acelerómetros triaxiales. Vázquez-Diosdado et al., (2015) aplicando RF reportaron que la postura de parada fue con la que más se confundió el algoritmo, sin embargo, sólo alcanzó a predecir de forma correcta el 77,42% de los casos. En forma similar, Cong Phi Khanh et al., (2020) encontraron un desempeño y patrón de error similar para la conducta de parada, pero en ese caso utilizando GBDT. Por otra parte, otros estudios utilizando vacas lecheras estabuladas (Balasso et al., 2023; Moutaouakil & Falih, 2024) obtuvieron resultados excelentes para detectar la postura de echada con CNN. No obstante, los modelos se

equivocaron alrededor del 0,3% identificando a la postura como rumiando, y en ese caso los algoritmos no se confundieron con la conducta de parada porque no estaba dentro de las clases evaluadas. En ese sentido, cabe aclarar que CNN es un algoritmo de aprendizaje supervisado profundo, los que pueden aprender automáticamente a partir de datos sin procesar, permitiendo que el modelo capture patrones complejos a partir de datos de acelerómetros. Es así que, en comparación con los modelos de aprendizaje automático tradicionales como RF los modelos de aprendizaje profundo a menudo logran una mayor precisión al aprender automáticamente patrones complejos a partir de grandes volúmenes de datos sin procesar (Russel & Selvaraj, 2024).

Con respecto a los bajos resultados obtenidos de precisión para caminando y la métrica irrelevante de la postura de "otros", coincide con los antecedentes encontrados: por ejemplo, De Passille, et al., (2010) sostiene que la capacidad de los acelerómetros para identificar patrones de comportamiento aumenta con el incremento de la frecuencia de muestreo de los acelerómetros, y en ese sentido, caminando fue una de las categorías con menores registros. Según Russel & Selvaraj, (2024) los datos insuficientes o "ruidosos" pueden disminuir el rendimiento del modelo y reducir su capacidad de generalización, esta afirmación se sostiene en el bajo rendimiento que obtuvieron en sus modelos al estudiar patrones de comportamiento en vacas estabuladas cuando los datos fueron ineficaces. Por otra parte, en la matriz de confusión se observa que en algunos casos el algoritmo predice que las vacas estaban paradas cuando en realidad estaban caminando, esto podría relacionarse con lo que plantean Price et al., (2022) en su ensayo de clasificación de postura en ovejas en pastoreo ya que el comportamiento parado se puede dar en simultáneo con distintos eventos desarrollados por los rumiantes en pastoreo, debido a que los animales pueden permanecer de pie y pastar o permanecer de pie y también caminar en busca de nuevos parches. Walton et al., (2018) en su estudio sobre la evaluación de la frecuencia de muestreo, el tamaño de la ventana y la posición del sensor para la clasificación del comportamiento de las ovejas en pastoreo concluyeron que los comportamientos mixtos o en fases provocan aceleraciones similares a las de caminar exclusivamente, lo que lleva a clasificaciones erróneas y una disminución en el valor del Recall y la F1. Dicha confusión en la detección de una postura clara puede deberse también a la tasa de muestreo que en este caso fue de 30 segundos, ya que en el estudio realizado por De Passille et al., (2010) se asegura que un muestreo cada 33 segundos está muy cerca de una tasa mínima y de ser posible esta tendría que ser mayor. Sin embargo, en el presente estudios se pudo clasificar con éxito 75 casos, a los que le atribuimos las salidas de los ordeños donde las vacas caminaban durante 15 minutos de corrido, y por ende en ese periodo de tiempo realmente estaban caminando y no así pastando, permitiendo así que el acelerómetro detecte fiablemente el comportamiento. Los acelerómetros parecen presentar poca eficacia en diferenciar comportamientos cuando estos se dan en forma

combinada (De Passille, et al., 2010), lo que posteriormente afecta la performance del algoritmo ya que se generan features con poca relevancia y mucha carencia de datos, lo mismo sucede con el comportamiento “otros” debido a que en esta categoría la mayoría de las posturas son combinadas. A futuro estos inconvenientes se podrían subsanar aumentando el Support de estas posturas o también empleando acelerómetros que generen datos que diferencien posturas combinadas generando así features de más valor para la predicción.

De lo discutido anteriormente se desprende la importancia de la elección de los features (Tabla 3) para el buen rendimiento de la precisión del modelo y la detección oportuna de la postura. En este estudio, los features dependen de las coordenadas de los ejes de los acelerómetros, de sus valores de aceleración y sus respectivas etiquetas, por ejemplo, parada y echada dependen mayormente de los ejes X, Y respectivamente. Los datos recabados de estas coordenadas se consideran más contundentes, siendo las que dependen de los ejes X y Z mucho más confusas (Caminando y otros). Este mismo resultado se obtuvo en el ensayo de Vázquez-Diosdado et al., (2015), donde los ejes que se encontraban paralelos y transversales al suelo presentaban aceleraciones difusas al caminar o realizar actividades compuestas. Sin embargo, cuando el animal se encontraba echado o parado las aceleraciones de los ejes paralelo y perpendicular al suelo eran mucho más claras y sostenidas en cada tasa de muestreo. Esto se repite en nuestra tesis donde los ejes X e Y aportan features más relevantes sobre todo los datos que provienen del dispositivo de la pata, esto se debe a que tienen más libertad de movimiento (Walton et al., 2018). Dichos autores también afirman que datos más confusos generan etiquetas igual de confusas y por ende el feature es deficiente, y al igual que Price et al., (2022) propone la variación de la colocación de dispositivos para así diferenciar comportamientos que se dan en simultáneo, además de aumentar el Support de la muestra para mejorar la capacidad de generalización del algoritmo.

Al evaluar distintos modelos de aprendizaje automático, Random Forest fue el que logró una mejor performance, alcanzando un accuracy de 0,917% seguido por RF_w que obtuvo valores similares. Por otra parte, LR, LR_OVR, SLR_OVR, SPCALR_OVR, LDA, SVM, KNN, generaron resultados análogos de exactitud, valores que van del 0,886% al 0,897%; siendo Dummy el modelo menos performante (0,632%). Según Menze et al., (2009) esto se debe a que RF proporciona medios superiores para medir la relevancia de las características en los datos espectrales, pero en un subconjunto óptimo de características, los clasificadores regularizados podrían ser preferibles. El desempeño obtenido por RF en la presente tesis destaca con respecto a la bibliografía encontrada ya que, existen artículos que utilizaron distintos tipos de algoritmos obteniendo resultados de exactitud para RF más bajos, ya sea en contraposición con nuestro trabajo como con los otros algoritmos (Cong Phi Khanh et al., 2020; El Moutaouakil & Falih, 2024; Vázquez-Diosdado et al., 2015). Con

respecto a LR nuestros resultados también coinciden con los siguientes trabajos, los cuales usaron acelerómetros HOBO: Borchers et al., (2016) en vacas lecheras estabuladas y DuBois et al., (2014) en caballos estabulados, y si bien LR no es de los modelos más complejos, logró acompañarse con la mayoría de los algoritmos evaluados. Cong Phi Khanh et al., (2020), evaluaron algoritmos, entre ellos RF, SVM, KNN, encontrando resultados similares que, en nuestra tesis, aunque plantean que su trabajo tiene la limitante ya que en general los algoritmos SVM y KNN obtuvieron buenos resultados generales, pero al evaluar el rendimiento de clasificación para estar de pie y acostada el desempeño fue más bajo que RF. En el estudio de Benaissa et al., (2019) no utilizaron RF, sin embargo, los resultados para SVM y KNN concuerdan con los reportados por los autores antes mencionados.

En resumen, en nuestro estudio RF obtuvo un buen desempeño por ser altamente performante para predecir las posturas parada y echada, y si bien su expertiz depende mucho de los datos de entrada, en la presente tesis contamos con un elevado Support para dichas posturas, a diferencia de muchos de los estudios reportados en la bibliografía consultada anteriormente. Sin embargo, existen otros algoritmos como CNN que puede desempeñarse mejor con menos datos, o datos más impuros, pero requieren de gran gasto computacional.

10. CONCLUSIONES

Los resultados obtenidos en este estudio mostraron que la validación de los dispositivos HOBO con respecto a las observaciones visuales de las posturas propuestas en vacas lecheras manejadas en un sistema pastoril fue exitosa. La exactitud de los acelerómetros fue superior en posturas estáticas, simples y más frecuentes, perdiendo notablemente el rendimiento en las posturas compuestas que además implican movimiento. Utilizando los datos proporcionados por los HOBO se pueden entrenar modelos de aprendizaje automático que sean capaces de predecir comportamientos, siendo los de bajo costo computacional como RF muy eficaces. Sin embargo, la capacidad de predicción de RF se vio alterada por la relevancia de los features y por el tamaño del Support, por lo que en futuros trabajos se debería mejorar la calidad de los features sobre todo los que dependen de comportamientos compuestos.

11. REFERENCIAS BIBLIOGRÁFICAS

- Ahmad, I. (2024). *50 Algoritmos que todo programador debe conocer* (2ª ed.). Packt Publishing Ltd.
- Aho, A. V., Hopcroft, J. E., & Ullman, J. D. (1988). *Estructura de datos y algoritmos*. México.
- Alelo, S., & Di Marco, O. (2003). *Costo energético de la actividad de vacunos en pastoreo y su efecto en la producción*. https://www.produccion-animal.com.ar/informacion_tecnica/manejo_del_alimento/01-costo_energetico_de_actividad_en_pastoreo_efecto.pdf
- Alsaad, M., Niederhauser, J. J., Beer, G., Zehner, N., Schuepbach-Regula, G., & Steiner, A. (2015). Development and validation of a novel pedometer algorithm to quantify extended characteristics of the locomotor behavior of dairy cows. *Journal Dairy Science*, 98(9), 6236-6242. <https://doi.org/10.3168/jds.2015-9657>
- Arnott, G., Ferris, C. P., & O'Connell, N. E. (2016). Review: Welfare of dairy cows in continuously housed and pasture-based production systems. *Animal*, 11(2), 261-273. <https://doi.org/10.1017/S1751731116001336>
- Asociación de Químicos Analíticos Oficiales. (1990). *Métodos oficiales de análisis* (15ª ed.). AOAC.
- Balasso, P., Taccioli, C., Serva, L., Magrin, L., Andrighetto, I., & Marchesini, G. (2023). Uncovering patterns in dairy cow behaviour: A deep learning approach with tri-axial accelerometer data. *Animals*, 13, 1886. <https://doi.org/10.3390/ani13111886>
- Benaissa, S., Tuytens, F., Plets, D., Pessemier, T., Trogh, J., Tanghe, E., Martens, L., Vandaele, L., Nuffel, A. V., Joseph, W., & Sonck, B. (2019). On the use of on-cow accelerometers for the classification of behaviours in dairy barns. *Veterinary Science*, 125, 425-433. <https://doi.org/10.1016/j.rvsc.2017.10.005>
- Benjamin, M., & Yik, S. (2019). Precision Livestock farming in swine welfare: A review for swine practitioners. *Animals*, 9(4), 1-21. <https://doi.org/10.3390/ani9040133>
- Berckmans, D. (2013). Basic principles of PLF: gold standard, labelling and field data. *Precision Livestock Farming*, 6, 21-29.
- Borchers, M. R., Chang, Y. M., Tsai, I. C., Wadsworth, B. A., & Bewley, J. M. (2016). A validation of technologies monitoring dairy cow feeding, ruminating, and lying behaviors. *Journal of Dairy Science*, 99(9), 7458-7466. <https://doi.org/10.3168/jds.2015-10843>
- Brouwers, S.P., Simmler, M., Savary, P., & Scriba, M.F. (2023). Towards a novel method for detecting atypical lying down and standing up behaviors in dairy cows using accelerometers and machine learning. *Smart Agricultural Technology*, 4, 100199. <https://doi.org/10.1016/j.atech.2023.100199>
- Chapa, J. M., Maschat, K., Iwersen, M., Baumgartner, J., & Drillich, M. (2020). Accelerometer systems as tools for health and welfare assessment in cattle and pigs: A review. *Behavioural Processes*, 181, 104262. <https://doi.org/10.1016/j.beproc.2020.104262>
- Charlton, G. L., & Rutter, S. M. (2017). The behaviour of housed dairy cattle with and without

- pasture access: A review. *Applied Animal Behaviour Science*, 192, 2-9.
<https://doi.org/10.1016/j.applanim.2017.05.015>
- Cockburn, M. (2020). Review: Application and prospective discussion of machine learning for the management of dairy farms. *Animals*, 10(9), 1690.
<https://doi.org/10.3390/ani10091690>
- Cong Phi khanh, P., Tran, D., Duong, V., Hong Thinh, N., & Tran, D. (2020). The new design of cows' behavior classifier based on acceleration data and proposed feature set. *Mathematical Biosciences and Engineering*, 17(4), 2760-2780.
<https://doi.org/10.3934/mbe.2020151>
- Consolandich, G., Ferreira, P., & Fierro, L. (2011). Índice de precios de exportaciones agropecuarias (1999-2009) Construcción de un índice con precios de referencia internacional para las principales exportaciones agropecuarias de Uruguay [Tesis de grado, Facultad de Ciencias Económicas y Administración, UDELAR]. Colibrí.
<https://www.colibri.udelar.edu.uy/jspui/bitstream/20.500.12008/430/1/M-CD4355.pdf>
- Cook, N. B., Bennett, T. B., & Nordlund, K. V. (2005). Monitoring Indices of Cow Comfort in Free-Stall-Housed Dairy Herds. *Journal of Dairy Science*, 88(11), 3876-3885.
[https://doi.org/10.3168/jds.S0022-0302\(05\)73073-3](https://doi.org/10.3168/jds.S0022-0302(05)73073-3)
- Darr, M., & Epperson, W. (2009). Embedded sensor technology for real time determination of animal lying time. *Computers and Electronics in Agriculture*, 66(1), 106-111.
<https://doi.org/10.1016/j.compag.2009.01.004>
- De Passille, A., Jensen, M., Chapinal, N., & Rushen, J. (2010). Technical: use of accelerometers to describe gait patterns in dairy calves. *Journal of Dairy Science*, 93(7), 3287-3293.
<https://doi.org/10.3168/jds.2009-2758>
- Del Campo, M., Estrada, G., González, M., & Herrera, J. P. (2017). Behavioral biomarker of bovines of the dual purpose system. *Revista MVZ Córdoba*, 22(1), 5761-5776.
<https://doi.org/10.21897/rmvz.936>
- Delagarde, R., & Lamberton, P. (2015). Daily grazing time of dairy cows is recorded accurately using the Lifecorder Plus device. *Applied Animal Behaviour Science*, 165(1), 25-32.
<https://doi.org/10.1016/j.applanim.2015.01.014>
- DuBois, C., Zakrajsek, E., Haley, D. B., & Merckies, K. (2014). Validation of triaxial accelerometers to measure the lying behavior of adult domestic horses. *The Animal Consortium*, 9(1), 110-114. <https://doi.org/10.1017/S175173111400247X>
- El Moutaouakil, K., & Falih, N. (2024). A comparative study on time series data-based artificial intelligence approaches for classifying cattle feeding behavior. *Indonesian Journal of Electrical Engineering and Computer Science*, 33(1), 324-332.
<https://doi.org/10.11591/ijai.v13.i1.pp524-532>
- Fast, O. (2016). *Estudio de dos métodos de evaluación de comportamiento de vacas lecheras* [Tesis de grado, Facultad de Agronomía, UDELAR]. Colibrí.
<https://hdl.handle.net/20.500.12008/20651>
- Fetter, M., Filippini, D., Secco, J., Queirolo, I., & Vera, S. (2014). *Intensificación en la lechería uruguaya: análisis físico, económico y ambiental de diferentes sistemas productivos* [Tesis de grado, Facultad de Agronomía, UDELAR]. Colibrí.
<https://hdl.handle.net/20.500.12008/8805>

- Foris, B., Zebunke, M., Langbein, J., & Melzer, N. (2019). Comprehensive analysis of affiliative and agonistic social networks in lactating dairy cattle groups. *Applied Animal Behaviour Science*, 210, 60-67. <https://doi.org/10.1016/j.applanim.2018.10.016>
- García, C. S. (2002). Desafíos y oportunidades para el establecimiento de sistemas estacionales de producción de leche en Argentina y Uruguay. En Centro Médico Veterinario de Paysandú (Ed.), *Jornadas Uruguayas de Buiatría* (Vol. 30, pp.97-106). CMVP. <http://dspace.fvet.edu.uy:8080/xmlui/handle/123456789/466>
- Grant, R., & Albright, J. (2001). Effect of animal grouping on feeding behavior and intake of dairy cattle. *Journal of Dairy Science*, 84(Suppl.), 156-163. [https://www.journalofdairyscience.org/article/S0022-0302\(01\)70210-X/fulltext](https://www.journalofdairyscience.org/article/S0022-0302(01)70210-X/fulltext).
- Haley, D.B., Rushen, J., & de Passillé, A.M. (2000). Behavioural indicators of cow comfort: activity and resting behaviour of dairy cows in two types of housing. *Canadian Journal of Animal Science*, 80(2), 257-263. <https://doi.org/10.4141/A99-084>
- Hanrahan, L., McHugh, N., Hennessy, T., Moran, B., Kearney, R., Wallace, M., & Shalloo, L., (2018). Factors associated with profitability in pasture-based systems of milk production. *Journal of Dairy Science*, 101(6), 5474-5485. <https://doi.org/10.3168/jds.2017-13223>
- Haydock, K., & Shaw, N. (1975). The comparative yield method for estimating dry matter yield of pasture. *Australian Journal of Experimental Agriculture*, 15(76), 663-670. <https://doi.org/10.1071/EA9750663>
- Hendriks, S.J., Phyen, C.V.C., Huzzey, J.M., Mueller, K.R., Turner, S.A., Donaghy, D.J., & Roche, J.R. (2020). Evaluating the appropriate use of wearable accelerometers in research to monitor lying behaviors of dairy cows. *Journal of Dairy Science*, 103(12), 12140-12157. <https://doi.org/10.3168/jds.2019-17887>
- Instituto Nacional de la Leche. (2019). *Encuesta Lechera: Resultados preliminares*. <https://www.inale.org/estadisticas/encuesta-lechera-2019-resultados-preliminares/>
- Instituto Nacional de la Leche. (2021). Situación y perspectivas de la lechería uruguaya. *informes INALE* 20, 7-46. <https://www.inale.org/wp-content/uploads/2022/05/Situaciony perspectivasversionfinal-1.pdf>
- Instituto Nacional de la Leche. (s.f.). *Uruguay lechero*. www.inale.org/uruguay-lechero/
- Ito, K., von Keyserlingk, M. A. G., LeBlanc, S. J., & Weary, D. M. (2010). Lying behavior as an indicator of lameness in dairy cows. *Journal of Dairy Science*, 93(8), 3553-3560. <https://doi.org/10.3168/jds.2009-2951>
- Jensen, M. B., Pedersen, L. J., & Munksgaard, L. (2005). The effect of reward duration on demand functions for rest in dairy heifers and lying requirements as measured by demand functions. *Applied Animal Behaviour Science*, 90(3-4), 207-217. <https://doi.org/10.1016/j.applanim.2004.08.006>
- Ledgerwood, D.N., Winckler, C., & Tucker, C. B. (2010). Evaluation of data loggers, sampling intervals, and editing techniques for measuring the lying behavior of dairy cattle. *American Dairy Science Association*, 93, 5129-5139. <https://doi.org/doi:10.3168/jds.2009-2945>
- Lehner, P. N. (1992). Sampling methods in behavior research. *Poultry Science*, 71(4), 643-649. <https://doi.org/10.3382/ps.0710643>

- Licitra, G., Hernández, T. M., & Van Soest, P. J. (1996). Estandarización de procedimientos para el fraccionamiento de nitrógeno de alimentos para rumiantes. *Ciencia y Tecnología de Alimentación Animal*, 57, 347-358.
- Linnane, M., Brereton, A., & Giller, P. S. (2001). Seasonal changes in circadian grazing patterns of Kerry cows (*Bos Taurus*) in semi-feral conditions in Killarney National Park, Co. Kerry, Ireland. *Applied Animal Behaviour Science*, 71(4), 277-292. [https://doi.org/10.1016/S0168-1591\(00\)00188-X](https://doi.org/10.1016/S0168-1591(00)00188-X)
- Mattachini, G., Antler, A., Riva, E., Arbel, A., & Provolo, G. (2013). Automated measurement of lying behavior for monitoring the comfort and welfare of lactating dairy cows. *Livestock Science*, 158(1-3), 145-150. <https://doi.org/10.1016/j.livsci.2013.10.014>
- Medrano-Galarza, C., Gibbons, J., Wagner, S., de Passillé, A. M., & Rushen, J. (2012). Behavioral changes in dairy cows with mastitis. *Journal of Dairy Science*, 95(12), 6994-7002. <https://doi.org/10.3168/jds.2011-5247>
- Menze, B., Kelm, B., Masuch, R., Himmelreich, U., Bachert, P., Petrich, W., & Hamprecht, F. (2009). A comparison of random forest and its Gini importance with standard chemometric methods for the feature selection and classification of spectral data. *BMC Bioinformatics*, 10(213), 1471-2105. <https://doi.org/10.1186/1471-2105-10-2>
- Ministerio de Ganadería, Agricultura y Pesca. (2022). *Anuario Estadístico Agropecuario 2022* https://descargas.mgap.gub.uy/DIEA/Anuarios/Anuario2022/O_MGAP_Anuario_estad%C3%ADstico_%202022-DIGITAL.pdf
- Munksgaar, L., Jensen, M. B., Pederson, L. J., Hansen, S. W., & Matthews, L. (2005). Quantifying behavioral priorities - effects of time constraints on behavior of dairy cows, *Bos taurus*. *Applied Animal Behaviour Science*, 92(1-2), 3-14. <https://doi.org/10.1016/j.applanim.2004.11.005>
- Nielsen, S.S. (2003). *Manual de laboratorio de análisis de alimentos* (3.^a ed.). Kluwer Academic/Plenum Publishers.
- Organización Mundial de Sanidad Animal. (2022). *Código Terrestre*. https://www.woah.org/es/que-hacemos/normas/codigos-y-manuales/acceso-en-linea-al-codigo-terrestre/index.php?id=169&L=1&htmlfile=glossaire.htm#terme_bien_etre_animal
- Phillips, C. J. C. (1993). Nutritional Behavior. En *Cattle Behavior*. Farming Press.
- Phillips, C. J. C., & Rind, A. I. (2002). The effects of social dominance on the production and behavior of grazing dairy cows offered forage supplements. *Journal of Dairy Science*, 85(1), 51-59. [https://doi.org/10.3168/jds.S0022-0302\(02\)74052-6](https://doi.org/10.3168/jds.S0022-0302(02)74052-6)
- Poulopoulou, I., Lambertz, C., & Gauly, M. (2019). Are automated sensors a reliable tool to estimate behavioural activities in grazing beef cattle?. *Applied Animal Behaviour Science*, 216, 1-5. <https://doi.org/10.1016/j.applanim.2019.04.009>
- Price, E., Langford, J., Fawcett, T., Wilson, A., & Croft, D. (2022). Classifying the posture and activity of ewes and lambs using accelerometers and machine learning on a commercial flock. *Applied Animal Behaviour Science*, 251, 105630. <https://doi.org/10.1016/j.applanim.2022.105630>
- Rayas-Amor, A.A., Morales-Almaráz, E., Licona-Velázquez, G., Vieyra-Alberto, R., García-

- Martínez, A., Martínez-García, C.G., Cruz-Monterrosa, R.G., & Miranda- de la lama, G.C. (2017). Triaxial accelerometers for recording grazing and ruminating time in dairy cows: An alternative to visual observations. *Journal of Veterinary Behavior*, 20, 102-108. <https://doi.org/10.1016/j.jveb.2017.04.003>
- Ringgenberg, N., Bergeron, R., & Devillers N. (2010). Validation of accelerometers to automatically record sow postures and stepping behaviour. *Applied Animal Behaviour Science*, 128, 37-44. <https://doi.org/10.1016/j.applanim.2010.09.018>
- Robert, B., White, B., Renter, D., & Larson, R. (2009). Evaluation of three-dimensional accelerometers to monitor and classify behavior patterns in cattle. *Computers and Electronics in Agriculture*, 67(1-2), 80-84. <https://doi.org/10.1016/j.compag.2009.03.002>
- Russel, N.S., & Selvaraj, A. (2024). Decoding cow behavior patterns from accelerometer data using deep learning. *Journal of Veterinary Behavior*, 74, 68-78. <https://doi.org/10.1016/j.jveb.2024.06.005>
- Russell, S., & Norvig, P. (2021). *Artificial Intelligence: A Modern Approach* (4a ed.). Pearson
- Sato, S., Tarumizu, K., & Hatae, K. (1993). The influence of social factors on allogrooming in cows. *Applied Animal Behaviour Science*, 38(3-4), 235-244. [https://doi.org/10.1016/0168-1591\(93\)90022-H](https://doi.org/10.1016/0168-1591(93)90022-H)
- Swartz, T. H., McGilliard M. L., & Petersson-Wolfe C. S. (2016). Technical note: The use of an accelerometer for measuring step activity and lying behaviors in dairy calves. *Journal Dairy Science*, 99(11), 9109-9113. <https://doi.org/10.3168/jds.2016-11297>
- Uruguay XXI. (2021). *Informe Anual Comercio Exterior 2021*. <https://www.uruguayxxi.gub.uy/uploads/informacion/b3d5451b3ea37c8fe71eae875ebc3d18d0f10f2b.pdf>
- Van Erp-van der Kooij, E., Almalik, O., Cavestany, D., Roelofs, J., & Van Eerdenburg, F. (2019). Lying Postures of Dairy Cows in Cubicles and on Pasture. *Animals*, 9(4), 183. <https://doi.org/10.3390/ani9040183>
- Vázquez Diosdado, J.A., Barker, Z.E., Hodges, H.R., Amory J.R., Croft, D.P., Bell, N.J., & Codling, E.A. (2015). Classification of behaviour in housed dairy cows using an accelerometer-based activity monitoring system. *Animal Biotelemetry*, 3(15), 1-14. <https://doi.org/10.1186/s40317-015-0045-8>
- Vendler, Z. (1957). Verbs and Times. *The Philosophical Review*, 66(2), 143-160. <https://doi.org/10.2307/2182371>
- Walton, E., Casey, C., Mitsch, J., Vázquez-Diosdado, J., Yan, J., Dottorini, T., Ellis, K., Winterlich, A., & Kaler, J. (2018). Evaluation of sampling frequency, window size and sensor position for classification of sheep behaviour. *Royal Society Open Science*, 5(2). <https://doi.org/10.1098/rsos.171442>
- Wang, J., He, Z., Zheng, G., Gao, S., & Zhao, K. (2018). Development and validation of an ensemble classifier for real-time recognition of cow behavior patterns from accelerometer data and location data. *PLoS ONE*, 13(9), e0203546. <https://doi.org/10.1371/journal.pone.0203546>

Zambelis, A., Wolfe, T., & Vasseur, E. (2019). Technical note: Validation of an ear tag accelerometer to identify feeding and activity behaviors of tiestall-housed dairy cattle. *Journal of Dairy Science*, 102(5), 4536-4540. <https://doi.org/10.3168/jds.2018-15766>