

# 21797478:TFM\_FAJARDO\_final.p df

*por* Blanca Fajardo Vilorio

---

**Fecha de entrega:** 28-jul-2023 12:25p.m. (UTC+0200)

**Identificador de la entrega:** 2137997854

**Nombre del archivo:** ments\_1a258251-126d-4915-add3-828fb26a6066\_TFM\_FAJARDO\_final.pdf (1.4M)

**Total de palabras:** 16471

**Total de caracteres:** 93174



UNIVERSITAT  
POLITÈCNICA  
DE VALÈNCIA



Escuela Técnica Superior  
de Ingeniería Agronómica  
y del Medio Natural

3

**UNIVERSITAT POLITÈCNICA DE VALÈNCIA**

**ESCUELA TÉCNICA SUPERIOR DE INGENIERIA  
AGRONÓMICA Y EL MEDIO NATURAL**

**TRABAJO FIN DE MÁSTER EN GANADERÍA DE PRECISIÓN**

**Utilización de acelerómetros para determinar de forma  
automatizada el comportamiento de cabras lecheras**

3

**CURSO ACADÉMICO: 2022/2023**

**Valencia, julio 2023**

**ALUMNA: Fajardo Vilorio, Blanca**

**TUTOR: Calvet Sanz, Salvador**

**COTUTORA: Villagra García, Aranzazu**

**TÍTULO:** Utilización de acelerómetros para determinar de forma automatizada el comportamiento de cabras lecheras.

Valencia, julio 2022

**Resumen:**

La Industria 4.0 ha traído consigo una serie de innovaciones tecnológicas como sensores, computación en la nube, machine learning e inteligencia artificial, que están transformando diferentes sectores. La Ganadería de Precisión (PLF, de sus siglas en inglés “Precision Livestock Farming”) es el resultado de la implementación de estas tecnologías en el sector ganadero. El uso de Big Data juega un papel clave en la aplicación de tecnologías avanzadas a las prácticas de cría de animales, ofreciendo una solución escalable para almacenar grandes cantidades de datos en un servidor remoto.

En particular, los sensores de movimiento, como los acelerómetros, son una herramienta esencial para estudiar la actividad animal, permitiendo monitorear con precisión comportamientos como el pastoreo, la alimentación, la rumia y la cojera. Sin embargo, los sistemas de machine learning desarrollados para el ganado vacuno lechero no pueden aplicarse directamente a las cabras, ya que existe una diferencia en los patrones de señal del acelerómetro entre las especies, lo que significa que se necesitan diferentes algoritmos. Por ese motivo en este trabajo se evalúa la aplicabilidad de acelerómetros en la monitorización de la actividad de cabras lecheras.

Para analizar el comportamiento de las cabras se probaron dos tipos de acelerómetros de las empresas Hobo y Digital. Se incluyeron en el estudio 15 cabras Murciano-Granadinas. En ellas se probaron de forma no invasiva distintas colocaciones de los sensores y se observaron durante 4 horas al día para registrar su actividad. Posteriormente, los datos generados se analizaron utilizando machine learning.

En los resultados obtenidos se muestra que el modelo Hobo Pendant G presentó problemas de memoria limitada para recopilar datos continuos. En cambio, los dispositivos de la empresa Digital ofrecieron una sujeción más segura en el cuello y mayor capacidad de almacenamiento, y por tanto fueron los utilizados en la fase de validación del estudio. De las 140 horas de observación realizada se pudieron aprovechar 76.7 horas de comportamientos etiquetados. Los datos generados se evaluaron con el modelo XGBoost, obteniendo una precisión del 66.22%, siendo efectivo para detectar los comportamientos “Activa” y “Tumbada”, pero mostraron dificultades en los demás comportamientos. Las especificidades fueron altas en general, pero la sensibilidad varió, lo que indica diferentes niveles de éxito en la detección de casos positivos para cada comportamiento. El desequilibrio en el número de etiquetas de cada comportamiento tuvo un efecto clave en la clasificación del modelo, viéndose perjudicados los comportamientos menos habituales. En vista del potencial de los acelerómetros, los consideramos apropiados para monitorizar y comprender el comportamiento de las cabras.

3

ALUMNA: Fajardo Vilorio, Blanca

TUTOR: Calvet Sanz, Salvador

COTUTORA: Villagra García, Aranzazu

**Palabras clave:** comportamiento; acelerómetro; bienestar animal; pequeños rumiantes.

**TÍTOL:** Ús d'acceleròmetres per a determinar de forma automatitzada el comportament de cabres lleteres.

València, juliol 2022

**Resum:**

La Indústria 4.0 ha portat amb si una sèrie d'innovacions tecnològiques com ara sensors, computació en el núvol, *machine learning* i intel·ligència artificial, que estan transformant diferents sectors. La Ramaderia de Precisió (PLF, de les seues sigles en anglés "*Precision Livestock Farming*") és el resultat de la implementació d'aquestes tecnologies en el sector ramader. L'ús de *Big Data* juga un paper clau en l'aplicació de tecnologies avançades a les pràctiques de cria d'animals, oferint una solució escalable per emmagatzemar grans quantitats de dades en un servidor remot.

En particular, els sensors de moviment, com ara els acceleròmetres, són una eina essencial per a estudiar l'activitat animal, permetent monitorar amb precisió comportaments com el pasturatge, l'alimentació, la rumiada i la coïxesa. No obstant això, els sistemes de *machine learning* desenvolupats per al bestiar boví lleter no es poden aplicar directament a les cabres, ja que existeix una diferència en els patrons de senyal de l'acceleròmetre entre les espècies, la qual cosa significa que es necessiten diferents algorismes. Per aquest motiu, en aquest treball s'avalua l'aplicabilitat dels acceleròmetres en la monitorització de l'activitat de cabres lleteres.

Per a analitzar el comportament de les cabres, es van provar dos tipus d'acceleròmetres de les empreses Hobo i Digital. Es van incloure en l'estudi 15 cabres Murciano-Granadines. En elles es van provar de forma no invasiva diferents col·locacions dels sensors i es van observar durant 4 hores al dia per a registrar la seua activitat. Posteriorment, les dades generades es van analitzar utilitzant *machine learning*.

En els resultats obtinguts es mostra com el model Hobo Pendant G va presentar problemes de memòria limitada per a recopilar dades contínues. En canvi, els dispositius de l'empresa Digital van oferir una subjectació més segura al coll i major capacitat d'emmagatzematge, i per tant van ser els utilitzats en la fase de validació de l'estudi. De les 140 hores d'observació es van poder aprofitar 76.7 hores de comportaments etiquetats. Les dades generades es van avaluar amb el model XGBoost, obtenint una precisió del 66,22%, sent efectiu per a detectar els comportaments "Activa" i "Tombada", però van mostrar dificultats en els altres comportaments. Les especificitats van ser altes en general, però la sensibilitat va variar, la qual cosa indica diferents nivells d'èxit en la detecció de casos positius per a cada comportament. El desequilibri en el nombre d'etiquetes de cada comportament va tindre un efecte clau en la classificació del model, veient-se perjudicats els comportaments menys habituals. En vista del potencial dels acceleròmetres, els considerem apropiats per a monitoritzar i comprendre el comportament de les cabres.

3

ALUMNA: Fajardo Vilorio, Blanca

TUTOR: Calvet Sanz, Salvador

COTUTORA: Villagra García, Aranzazu

**Paraules clau:** comportament, acceleròmetre, benestar animal, rumiants menuts.

**TITLE:** Use of accelerometers to automatically determine the behaviour of dairy goats.

Valencia, July 2022

**Abstract:**

Industry 4.0 has brought a series of technological innovations such as sensors, cloud computing, machine learning, and artificial intelligence, which are transforming various sectors. Precision Livestock Farming (PLF) is the result of implementing these technologies in the livestock industry. The use of big data plays a crucial role in applying advanced technologies to animal breeding practices, offering a scalable solution to store enormous amounts of data on a remote server.

Particularly, motion sensors like accelerometers are essential tools for studying animal activity, allowing for precise monitoring of behaviours such as grazing, feeding, rumination, and lameness. However, machine learning systems developed for dairy cattle cannot be applied directly to goats due to differences in accelerometer signal patterns between species, requiring different algorithms. Therefore, this study evaluates the applicability of accelerometers in monitoring dairy goat activity.

To analyse goat behaviour, two types of accelerometers were tested on 15 Murciano-Granadina goats. Different sensor placements were tested non-invasively, and the goats were observed for 4 hours a day to record their activity. Subsequently, the generated data were analysed using machine learning.

The results showed that the Hobo Pendant G model had limited memory issues for continuous data collection. On the contrary, the Digital animal devices offered a more secure neck attachment and higher storage capacity, and therefore they were used in the validation phase. From the 140 hours of monitored behaviour, we produced 76.7 hours of labelled data. The data generated were evaluated with the XGBoost model, achieving an accuracy of 66.22%, effectively detecting behaviours labelled as "Active" and "Resting," but showing difficulties in identifying other behaviours. Specificities were generally high, but sensitivity varied, indicating different levels of success in detecting positive cases for each behaviour. The imbalance in the number of labels for each behaviour had a significant effect on the model's classification, with infrequent behaviours being disadvantaged.

Given the potential of accelerometers, we consider them suitable for monitoring and understanding goat behaviour.

**3**

**STUDENT:** Fajardo Vilorio, Blanca

**TUTOR:** Calvet Sanz, Salvador

**COTUTOR:** Villagra García, Aranzazu

**Keywords:** behaviour, accelerometers, animal welfare, small ruminants

3

### AGRADECIMIENTOS

En primer lugar, me gustaría agradecer, a mis compañeras Carmen Cano y Marica Marchese, su inmensa dedicación y compromiso al invertir numerosas horas en la observación y seguimiento de mi trabajo de investigación. Su apoyo y participación hicieron que todo el proceso fuera muy enriquecedor.

También a Daniel, por llegar en el momento adecuado para darle luz al camino de este trabajo. Su experiencia y conocimientos fueron fundamentales para alcanzar resultados sólidos y precisos en el estudio.

Así mismo, quiero agradecer a todos los profesores y compañeros que me brindaron su apoyo y aliento durante el transcurso de mi TFM.

A todos vosotros, gracias por ser parte de esta etapa de mi formación académica.

## ÍNDICE

AGRADECIMIENTOS.....	5
1 INTRODUCCIÓN.....	9
1.1 GANADERÍA DE PRECISIÓN.....	9
1.1.1 JUSTIFICACIÓN DEL USO DE NUEVAS TECNOLOGÍAS EN GRANJAS.....	9
1.1.2 SENSORES UTILIZADOS EN GANADERÍA DE PRECISIÓN .....	10
1.1.3 LA GESTIÓN DE LA INFORMACIÓN EN GANADERÍA DE PRECISIÓN.....	10
1.1.4 LIMITACIONES DE LA TECNOLOGÍA.....	12
1.2 ACELERÓMETROS COMO SENSORES DE MOVIMIENTO.....	12
1.2.1 DESCRIPCIÓN DE LA TECNOLOGÍA .....	12
1.2.2 TRATAMIENTO DE DATOS DE ACELERÓMETROS .....	14
1.2.3 USO DE ACELERÓMETROS EN GRANJA .....	15
1.3 USO DE GANADERÍA DE PRECISIÓN EN EL SECTOR CAPRINO .....	16
2 OBJETIVOS.....	18
3 MATERIAL Y MÉTODOS .....	19
3.1 INSTALACIONES Y ANIMALES UTILIZADOS EN EL ESTUDIO.....	19
3.2 DISEÑO EXPERIMENTAL .....	19
3.3 INTEGRIDAD Y USABILIDAD.....	19
3.3.1 ACELERÓMETROS UTILIZADOS.....	19
3.3.2 PRUEBAS DE INTEGRIDAD .....	21
3.4 OBSERVACIONES Y RECOGIDA DE DATOS.....	23
3.5 TRATAMIENTO DE LOS DATOS .....	24
4 RESULTADOS Y DISCUSIÓN.....	29
4.1 ENSAYO DE INTEGRIDAD Y USABILIDAD .....	29
4.2 PREDICCIÓN DE COMPORTAMIENTOS CON ACELERÓMETROS.....	30
4.2.1 DATOS DESCRIPTIVOS .....	30
4.2.2 MODELOS DE APRENDIZAJE AUTOMÁTICO .....	34
5 CONCLUSIONES.....	37
6 BIBLIOGRAFÍA.....	38

## ÍNDICE DE TABLAS

<b>Tabla 1: Etograma de comportamientos etiquetados</b> .....	24
<b>Tabla 2: Catálogo conductual y tiempo de etiquetado</b> .....	30
<b>Tabla 3: Resultados estadísticos de la matriz de confusión</b> .....	35

## ÍNDICE DE FIGURAS

<b>Figura 1: Conjunto de tecnologías avanzadas. Fuente: Adaptado de Neethirajan (2020)</b> .....	11
<b>Figura 2: Diferencias entre paradigmas predictivos y reactivos de manejo de enfermedades en animales. Fuente: Adaptado de Neethirajan (2020)</b> .....	11
<b>Figura 3: Fórmula vector suma de la aceleración</b> .....	13
<b>Figura 4: Fases del estudio</b> .....	19
<b>Figura 5: HOB0® Pendant G</b> .....	20
<b>Figura 6: Dispositivo de la empresa Digitalimal (a) y disposición de los ejes (b)</b> .....	20
<b>Figura 7: Ciclo de funcionamiento de equipos Digitalimal. Fuente: García (2022)</b> .....	21
<b>Figura 8: Interior de la carcasa del equipo Digitalimal</b> .....	21
<b>Figura 9: Colocación registrador Hobo Pendant G en la pata</b> .....	22
<b>Figura 10: Colocación registrador Hobo Pendant G en el cuello</b> .....	22
<b>Figura 11: Equipo de Digitalimal instalado en una cabra</b> .....	23
<b>Figura 12: Aplicación "Etiquetado comportamientos"</b> .....	24
<b>Figura 13: Flujo de trabajo general. Fuente: Adaptado de Fehlmann et al. (2017)</b> .....	25
<b>Figura 14: Cálculos de la matriz de confusión</b> .....	28
<b>Figura 15: Representación gráfica del número de muestras por comportamiento</b> .....	31
<b>Figura 16: Visualización de datos ACC mediante gráfico dinámico</b> .....	32
<b>Figura 17: Gráfica de precisión de clasificación</b> .....	33
<b>Figura 18: Boxplot de los distintos estadísticos</b> .....	33
<b>Figura 19: Gráfica de matriz de confusión de resultados de validación cruzada</b> .....	34

## INDICE DE ABREVIATURAS

**ACC:** Acelerómetro

**APP:** Aplicación

**GPS:** Global Positioning System.

**IA:** Inteligencia Artificial

**ICTA:** Instituto de Ciencia y Tecnología Animal

**KNN:** K-Nearest Neighbor

**LDA:** Linear Discriminant Analysis

**ML:** Machine Learning

**NN:** Neural Network

**ODBA:** Aceleración dinámica general del cuerpo

**PLF:** Precision Livestock Farming (o Ganadería de Precisión)

**“rabc”:** r for animal behavior classification

**RF:** Random Forest

**RFID:** Radio Frequency Identification

**SI:** Sistema Internacional

**SVM:** Support Vector Machine

**TIC:** Tecnología de la Información y la Comunicación

# 1 INTRODUCCIÓN

## 1.1 GANADERÍA DE PRECISIÓN

### 1.1.1 JUSTIFICACIÓN DEL USO DE NUEVAS TECNOLOGÍAS EN GRANJAS

Se estima que en 2050 la población humana mundial ascenderá a más de nueve mil millones de habitantes (ONU, 2019). Del mismo modo, la demanda de carne y otros productos alimenticios de origen animal está aumentando progresivamente (Yaseer & Chen, 2021). En consecuencia, se espera un aumento del número de cabezas de ganado, lo cual plantea importantes desafíos para la industria ganadera y la sostenibilidad ambiental (Neethirajan, 2020). Esto significa que necesitamos producir más animales con una cantidad limitada de tierra, agua y otros recursos naturales (Sharma *et al.*, 2020). La producción ganadera es responsable de una cantidad significativa de emisiones de gases de efecto invernadero, así como de la deforestación, la contaminación del agua y la pérdida de biodiversidad. Además, la cría intensiva de animales a menudo se asocia con problemas de bienestar animal.

En este contexto, la implementación de prácticas modernas de gestión del impacto ambiental del ganado y el bienestar animal se ha convertido en una prioridad para la industria ganadera (Benjamin & Yik, 2019). Esto implica la adopción de tecnologías y técnicas más sostenibles, como la gestión eficiente de los residuos animales y la utilización de energías renovables en las explotaciones ganaderas. Además, se están desarrollando normativas y sistemas de certificación que garantizan el bienestar animal y la sostenibilidad ambiental de los productos ganaderos (Buller *et al.*, 2020). La implementación de prácticas más sostenibles puede tener beneficios económicos y sociales para las comunidades rurales. La adopción de prácticas de gestión del impacto ambiental del ganado y el bienestar animal podría mejorar la eficiencia de la producción y reducir los costes a largo plazo. Asimismo, fomentar la creación de empleos en el sector agropecuario y aumentar la calidad de vida de las comunidades rurales.

La Industria 4.0 ha traído consigo una serie de innovaciones tecnológicas como sensores, computación en la nube, machine learning (ML) e inteligencia artificial (IA), que están transformando diferentes sectores, incluyendo la industria ganadera (Neethirajan, 2020). La aplicación de ciencia de datos y tecnologías IoT al sector ganadero ayuda a garantizar la trazabilidad en la producción de alimentos y a reducir posibles pérdidas de productividad en la ganadería. La Ganadería de Precisión (PLF, de sus siglas en inglés "Precision Livestock Farming"), es el resultado de la implementación de estas tecnologías en el sector ganadero. PLF es un enfoque de sistema de producción que puede ser definido como el manejo del ganado a través de la monitorización y el control continuo, automático y en tiempo real tanto del animal como del medio ambiente. La monitorización de la actividad y el descanso en animales es esencial para evaluar su bienestar y rendimiento (McLennan *et al.*, 2015). PLF utiliza las tecnologías de la información y la comunicación (TIC) para reducir los costes y mejorar tanto la eficiencia del proceso de producción como la salud animal (García *et al.*, 2020).

En la ganadería tradicional las decisiones se basan mayoritariamente en la experiencia del productor. La mecanización durante las décadas ha llevado a una gestión más automatizada de grupos, facilitando las tareas del ganadero. Sin embargo, es necesario tener en cuenta que los animales, como todos los organismos vivos, son complejos, individualmente distintos y variantes en el tiempo (Buller *et al.*, 2020). La aplicación de PLF tiene un gran potencial para ayudar a los ganaderos a criar animales en buenas condiciones, así como a producir alimentos de manera

segura y con un impacto ambiental reducido (Lovarelli *et al.*, 2020). Al monitorear y controlar continuamente el ambiente en el que se encuentran los animales, es posible ajustar las condiciones de manera óptima para su salud y bienestar, al mismo tiempo que se minimiza el consumo de recursos naturales y se reduce la emisión de gases de efecto invernadero.

Sin embargo, la implementación de la Ganadería de Precisión también plantea desafíos importantes, como la necesidad de desarrollar sistemas de monitoreo y control eficientes y la necesidad de capacitar al personal encargado de operar estos sistemas. En PLF, las decisiones se basan en datos cuantitativos y su gran potencial se centra en detectar problemas que amenazan el bienestar animal sin manipular a los animales o inducir estrés, ofreciendo al ganadero el poder actuar cuando surjan los primeros signos de deterioro del bienestar o la salud (Morrone *et al.*, 2022).

### 1.1.2 SENSORES UTILIZADOS EN GANADERÍA DE PRECISIÓN

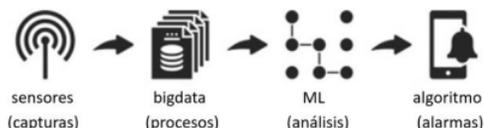
Las tecnologías PLF implican la implementación de sensores, u otras tecnologías de observación o monitoreo, a animales individuales y/o a su entorno. Un sensor es todo aquello que tiene una propiedad sensible a una magnitud del medio, y al variar esta magnitud también varía la intensidad con la que responde el sensor. Entre los sensores utilizados en PLF, se encuentran los sensores de temperatura, humedad, presión, grabaciones de video y/o audio o imágenes satelitales, movimiento como el *Global Positioning System* (GPS) y acelerómetros (Norton *et al.*, 2019). El uso de herramientas PLF en el sector ganadero puede tener distintos objetivos tales como la localización y rastreo de los animales en su entorno, el análisis del comportamiento y detección de patrones de actividad, el estudio del comportamiento social o la estimación del uso del pasto por los animales (Riaboff *et al.*, 2022). Los diferentes tipos de sensores se pueden clasificar en los basados en el control del clima, estimaciones de peso, conducta animal, dosis de alimento, uso de agua, robots de ordeño, temperatura corporal, detectar estrés, analizar el sonido, imágenes térmicas infrarrojas, RFID, podómetros etc. Los sensores utilizados pueden ser portátiles si se instalan sobre el propio animal (muchas veces con conexión inalámbrica de datos), o no portátiles si se fijan en las instalaciones de la granja. Respecto a su relación con el animal, los sensores pueden ser invasivos o no invasivos (Neethirajan, 2017).

Los sensores de movimiento, en particular, son útiles para el monitoreo del comportamiento de los animales, ya que permiten medir la actividad y el movimiento de los animales de forma no invasiva y en tiempo real. Este trabajo se centra en utilizar acelerómetros, que es uno de los tipos de sensor de movimiento.

### 1.1.3 LA GESTIÓN DE LA INFORMACIÓN EN GANADERÍA DE PRECISIÓN

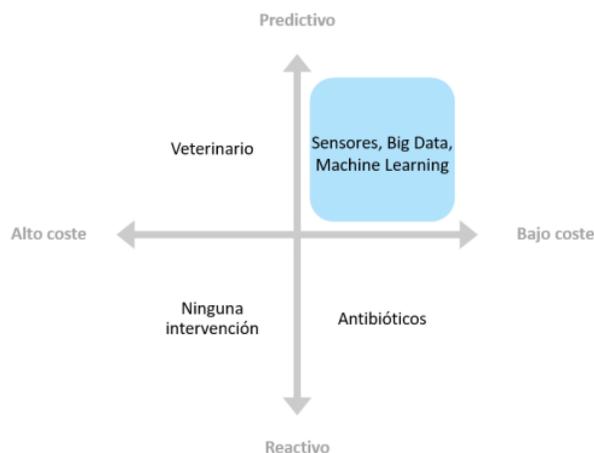
Para aplicar modelos mecanicistas en la cría de animales, necesitamos recopilar un gran volumen de diversos conjuntos de datos. Algunos de ellos pueden incluir datos climáticos, de calidad del aire, señales de voz, datos visuales de movimiento y otros datos de comportamiento animal. Varios sensores pueden ayudarnos a capturar datos en tiempo real de manera efectiva. Pero dicho sistema necesitará almacenar grandes volúmenes de datos de texto, audio y video. Almacenar y procesar cantidades tan grandes de datos, todos los días, durante todo el año no es posible con un ordenador común, pues tendrá limitaciones de almacenamiento y computación. Se hacen por tanto necesarios sistemas de almacenamiento y computación en la nube.

Big data juega un papel clave en la aplicación de tecnologías avanzadas (Figura 1) a las prácticas de cría de animales y ofrece una solución escalable para almacenar grandes cantidades de datos en un servidor remoto. **En todos estos casos, recurrir a técnicas de ciencia de datos** como los algoritmos avanzados de IA y ML pueden hacer uso de esta gran cantidad de datos para analizar, predecir y notificar a los agricultores en caso de que haya algo anormal en el comportamiento, la salud o las condiciones de bienestar de los animales (Neethirajan, 2020). De esta forma, convertir las biorespuestas en información relevante que puede aplicarse fácilmente a diferentes aspectos de gestión centrados en las necesidades de los animales, brindando una atención personalizada y óptima en beneficio de la producción (Tullo *et al.*, 2019).



**Figura 1: Conjunto de tecnologías avanzadas. Fuente: Adaptado de Neethirajan (2020)**

PLF tiene como objetivo mejorar la producción animal en términos de eficiencia, impacto ambiental, bienestar, salud y calidad de vida del ganadero. Para mejorar la eficiencia es fundamental gestionar correctamente los datos que se generan día a día en las explotaciones ganaderas. Una correcta gestión de datos puede resultar en una mejora de la productividad, en términos de gestión de lotes de pastoreo, nutrición del ganado y salud animal (García *et al.*, 2020). Los métodos de detección temprana de enfermedades no son nada nuevo, sin embargo, los sensores, los grandes datos y los algoritmos de ML tienen una ventaja de coste significativa sobre los métodos de detección más antiguos (Figura 2). Por lo tanto, en el contexto de la cría de animales, los sensores, los macrodatos y algoritmos avanzados de IA y ML van de la mano para brindar soluciones completas.



**Figura 2: Diferencias entre paradigmas predictivos y reactivos de manejo de enfermedades en animales. Fuente: Adaptado de Neethirajan (2020).**

Es importante destacar que la implementación de tecnologías PLF no reemplaza la experiencia y el conocimiento del ganadero, sino que los complementa. Los datos recopilados por los sensores pueden ser interpretados y aplicados de manera efectiva solo si se combinan con el

conocimiento y la experiencia del ganadero. Por lo tanto, la implementación de tecnologías PLF en la ganadería debe ser vista como una herramienta adicional para mejorar la producción y el bienestar animal, en lugar de una solución independiente.

#### 1.1.4 LIMITACIONES DE LA TECNOLOGÍA

El creciente uso de tecnología PLF en la industria agropecuaria representa una tendencia al alza en la búsqueda de mejorar la salud y bienestar de los animales de granja. Se trata de herramientas emergentes que sirven para avanzar en áreas donde el conocimiento científico es insuficiente, o donde realizamos suposiciones o simplificaciones que pueden ser incorrectas (Ellis *et al.*, 2020). Sin embargo, este avance también plantea una serie de retos y obstáculos que es necesario abordar para poder maximizar su utilidad.

Uno de los inconvenientes que se presentan es que las tecnologías son diseñadas por seres humanos, lo que limita la capacidad de detectar ciertos problemas específicos que puedan afectar a los animales. A pesar de que PLF ofrece nuevos datos sobre la salud y comportamiento animal, la interpretación de estos datos y su traducción en indicadores pueden ser subjetivas y, por tanto, generar cierta incertidumbre. Por lo tanto, independientemente de su capacidad para proporcionar resultados exitosos o no, la aplicación de tecnologías avanzadas a la cría de animales nos ayudará a obtener más conocimientos y, en última instancia, a mejorar nuestra comprensión de cómo funcionan los sistemas animales (Neethirajan, 2020). Además, los costes asociados al uso de estas tecnologías pueden ser prohibitivos para muchos productores. Los márgenes de beneficio en la agricultura suelen ser muy bajos y la inversión en tecnología PLF puede reducir aún más la rentabilidad de las operaciones agrícolas, si esa inversión no tiene un retorno evidente. En algunos casos, la tecnología no puede utilizarse de manera efectiva debido a la falta de conectividad a Internet en áreas rurales, lo que dificulta el acceso a estos sistemas. Otro obstáculo importante que enfrenta la tecnología PLF es que los sensores utilizan diferentes estándares de comunicación, lo que puede dificultar la interoperabilidad entre ellos. Los sensores utilizan diferentes estándares de comunicación y formatos de datos, lo que dificulta la integración y el análisis de los datos recolectados. Según Morrone *et al.* (2022) este es un desafío importante que debe superarse para lograr una mayor eficiencia en la gestión y el bienestar de los animales. Además de otras complicaciones como la batería sobre todo si se requiere un uso continuo del dispositivo.

Estos inconvenientes seguramente se resolverán en los próximos años, ya que la tecnología avanza exponencialmente cada año, lo que permite adquirir dispositivos cada vez más económicos y efectivos. En todo el mundo, el uso de dispositivos de alta tecnología en nuestra vida cotidiana ha cambiado significativamente la vida de las personas. La adopción de estas tecnologías en las granjas es inevitable y se volverá tan común como lo es el uso de teléfonos inteligentes en la actualidad (Morrone *et al.*, 2022).

## 1.2 ACELERÓMETROS COMO SENSORES DE MOVIMIENTO

### 1.2.1 DESCRIPCIÓN DE LA TECNOLOGÍA

La tecnología ha avanzado enormemente en los últimos años, permitiendo a los investigadores y científicos estudiar el comportamiento animal de una manera más precisa y efectiva. En particular, los sensores de movimiento son una herramienta esencial para estudiar la actividad animal, y los acelerómetros (ACC) son de los más utilizados para este fin (Thompson *et al.*, 2019; Werner *et al.*, 2019). Estos sensores de movimiento, sensores de inercia y podómetros, etc.

pueden monitorear con precisión la actividad del ganado como el pastoreo, la alimentación, la rumia y la cojera (Yaseer & Chen, 2021). Según Barwick (2020), la capacidad de los ACC para medir la postura y los estados de actividad se ha implantado bien en rumiantes de pequeño y gran tamaño.

Un ACC es un dispositivo electromecánico que mide las fuerzas de aceleración. La aceleración es una cantidad vectorial que define el cambio de velocidad en metros por segundo al cuadrado, también expresado como fuerzas  $g$  ( $1g = 9,81 \text{ m/s}^2$ ). En estos sensores portátiles de pequeño tamaño, el movimiento crea un voltaje al estresar pequeños cristales alojados dentro del ACC (Chapa *et al.*, 2020). El sensor interpreta la magnitud del voltaje para determinar la velocidad y la orientación del movimiento. Los ACC miden la atracción gravitacional de la tierra determinando también el ángulo en el que se inclina el dispositivo, las fuerzas de aceleración y la gravedad (vector  $g$ ). La posición del sensor puede detectarse con gran precisión cuando el sensor no se mueve. Si el sensor está en movimiento, la posición se puede calcular solo si se conoce la orientación del dispositivo con respecto a la gravedad. Además, en un ACC triaxial se acumula información tridimensional (ejes  $x$ ,  $y$ ,  $z$ ). Son tres sensores de aceleración que se disponen ortogonalmente, que pueden proporcionar una visión más completa del movimiento del animal (Fogarty *et al.*, 2020).

Hay dos tipos principales de variables que se pueden derivar de los datos de aceleración triaxial que son relevantes para la identificación del comportamiento. Estos son la aceleración estática, que depende de la gravedad y describe la postura del animal, y la aceleración dinámica del cuerpo (ODBA), que refleja el movimiento del cuerpo del animal. La aceleración corporal dinámica vectorial se calculó utilizando los componentes dinámicos de la señal para evaluar el nivel de actividad del individuo, realizando la siguiente operación (Figura 3).

$$\sqrt{X^2 + Y^2 + Z^2}$$

**Figura 3: Fórmula vector suma de la aceleración.**

Además de la información sobre la velocidad, la aceleración y la orientación de un objeto, un ACC también proporciona otros datos relevantes. Por ejemplo, pueden ser configurados para medir diferentes parámetros como la sensibilidad, la resolución, la frecuencia de los movimientos, el rango de medición, el ángulo de inclinación y la duración de la actividad. La frecuencia de la actividad de los animales es un parámetro fundamental que se puede medir mediante estos sensores, lo que permite a los investigadores obtener información valiosa sobre patrones y tendencias de comportamiento (Kleanthous *et al.*, 2022). De esta forma es posible adaptar los dispositivos a las necesidades específicas de cada aplicación y, origina desafíos técnicos como: dónde se colocará el sensor, cuál será la frecuencia de muestreo y cómo se transmitirán los datos, entre otros. Según lo revisado por Chapa *et al.* (2020), los datos medidos pueden guardarse en el almacenamiento de memoria del dispositivo (normalmente con capacidad limitada) y descargarse al final del periodo de observación o pueden enviarse inmediatamente a un dispositivo de almacenamiento externo a través de una conexión WI-FI establecida, lo que permite el monitoreo en tiempo real. Todas estas consideraciones tienen un impacto en la precisión de los algoritmos, así como en la escalabilidad y la practicidad de la solución que, por lo tanto, podría utilizarse en las granjas de animales.

Los ACCs son una alternativa económica, de bajo consumo de batería y, por lo general, brindan lecturas precisas de la actividad humana y animal (Javed *et al.*, 2020). Otras ventajas son la

flexibilidad para medir una amplia gama de parámetros y la capacidad de colocar los sensores en diferentes partes del animal (Riaboff *et al.*, 2022). Pueden ser alimentados por baterías portátiles y fáciles de usar en distintas situaciones, así como conectarse de forma inalámbrica a dispositivos de registro y monitoreo, lo que permite transferir los datos de forma remota y en tiempo real. La evaluación de la posición del sensor, la frecuencia de muestreo, el análisis de los datos del sensor y el tamaño de la ventana para el procesamiento de los datos ayudaría significativamente a mejorar la predicción del comportamiento de los animales (Neethirajan, 2020). Sin embargo, estos dispositivos también presentan algunas limitaciones.

El principal desafío en muchos sistemas de investigación es que se requiere una frecuencia de muestreo bastante alta, el 70% de los estudios muestreó a menos de 20 Hz (típicamente 10 Hz) (Riaboff *et al.*, 2022), lo que limita la vida útil de la batería del sistema. A medida que la tecnología de las baterías evolucione y el consumo de batería de los dispositivos electrónico disminuya, los futuros sensores podrán realizar análisis y mediciones más sofisticados. Con relación a esto, el peso y tamaño de los ACCs puede afectar la actividad del animal debido a su peso adicional. El peso adicional del dispositivo podría alterar las mediciones. Otro de los principales problemas es el ruido y la dificultad para distinguir la aceleración causada por la gravedad de otras fuentes de aceleración. Además, los ACCs también pueden verse afectados por las interferencias electromagnéticas de otros dispositivos, lo que puede afectar la precisión de las mediciones. Además, el mantenimiento regular, que incluye la calibración, el reemplazo de baterías y la limpieza del dispositivo, puede resultar complicado en algunos casos.

En el mercado se encuentran disponibles acelerómetros tridimensionales para cuantificar automáticamente el comportamiento del ganado, especialmente en bovino. Por ejemplo, el sensor CowManager (Agis, Harmelen, Países Bajos), el collar MooMonitor+ (Dairymaster, Tralee, Irlanda), AfiAct Podometer Plus (Afimilk, SAE Afikim, Kibbutz Afikim, Israel) o IceTag (IceRobotics Ltd., Edimburgo, Escocia), pero el tamaño de estos productos los hace inadecuados para su uso en cabras (Zobel *et al.*, 2015). El registrador Hobo Pendant G (Onset Computer Corporation, Bourne, MA) es más pequeño lo que facilitaría su uso en pequeños rumiantes.

### 1.2.2 TRATAMIENTO DE DATOS DE ACELERÓMETROS

Cada vez más, el seguimiento de animales se combina con la recopilación de datos del ACC. Comparando con la observación humana directa, el uso de ACC para estudiar comportamientos animales tiene una ventaja obvia, pues se reduce la influencia por la presencia humana. Sin embargo, este mérito solo se puede lograr cuando se dispone de un modelo de clasificación de comportamiento fiable que pueda convertir los datos del ACC en tipos de comportamientos significativos (Yu & Klaassen, 2021).

Muchos estudios ya han realizado clasificaciones <sup>2</sup> de comportamiento a partir de datos de ACC (Yu & Klaassen, 2021). La información recopilada se trata mediante algoritmos específicos para convertirla en datos interpretables (Tullo *et al.*, 2019). La clasificación del comportamiento animal con datos de movimiento implica sofisticados métodos estadísticos y de ML. La clasificación involucra el entrenamiento, prueba y uso de métricas de evaluación para medir el desempeño de los algoritmos. Los algoritmos de ML se dividen en dos categorías generales de aprendizaje, supervisado y no supervisado (Tran *et al.*, 2022). Cada método tiene diferentes ventajas y desventajas. Los algoritmos de ML no supervisados no utilizan observaciones de comportamiento como entrada de entrenamiento, se basan en datos de reubicación sin las observaciones directas del comportamiento, tiene un costo computacional mucho menor y se puede implementar fácilmente en tiempo real (Wang, 2019). Sin embargo, un algoritmo de

aprendizaje automático supervisado requiere observaciones de comportamiento realizadas en el momento en el que se recopilan los datos de aceleración, para la clasificación los comportamientos predeterminados. Esto tiene un coste computacional alto, lo que dificulta la implementación de dicho algoritmo dentro de un dispositivo remoto. La implementación de esta técnica en la investigación del comportamiento animal se ha visto limitada debido a dificultades técnicas y al análisis complicado, lo que ha disuadido a muchos profesionales de aplicar este enfoque, pero el aprendizaje supervisado a partir de datos de aceleración ha mostrado datos prometedores en muchas especies. Esto destaca la necesidad de desarrollar una herramienta ampliamente aplicable para clasificar el comportamiento a partir de datos de aceleración. La aplicación web de acceso libre basada en Python llamada AcceleRater fue desarrollada como herramienta para entrenar, visualizar y usar modelos para el aprendizaje supervisado del comportamiento a partir de mediciones de ACC (Resheff *et al.*, 2014). Con la finalidad de fomentar el uso de datos de comportamiento de ACC con los conocimientos prometedores que puede proporcionar. El software fue desarrollado con fondos disponibles de la Fundación Minerva y la Universidad Hebrea de Jerusalén para el Minerva Center for Movement Ecology. Dicho software demuestra tener una capacidad limitada para tratar grandes cantidades de datos, lo cual hace necesario el desarrollo de programas más avanzados en Python o R.

Los clasificadores comúnmente utilizados son el Support Vector Machine (SVM) (Mansbridge *et al.*, 2018), K-Nearest Neighbor (KNN) y Random Forest (RF), Decision-tree (Mansbridge *et al.*, 2018), Linear Discriminant Analysis (LDA) (Barwick *et al.*, 2020), Neural Network (NN) (Nweke *et al.*, 2018; Fogarty *et al.*, 2020)), XGBoost (Yu & Klaassen, 2021). En general, estos métodos se pueden aplicar a datos de acelerómetros para producir modelos de actividad individuales al comparar la entrada de datos de las observaciones del sensor con un conjunto de modelos de plantilla en el conjunto de datos de entrenamiento (Sukor *et al.*, 2018).

### 1.2.3 USO DE ACELERÓMETROS EN GRANJA

Se han realizado diversos estudios para investigar una variedad de comportamientos animales, desde actividades rutinarias como correr y jugar en perros (Ladha *et al.*, 2013), hasta comportamientos más específicos destinados a evaluar el bienestar, como la evaluación de cojeras en vacas (O'Leary *et al.*, 2020). Debido a su pequeño tamaño y la versatilidad de los datos producidos (Kleanthous *et al.*, 2022), se ha descubierto que los ACCs son particularmente efectivos para monitorear el comportamiento animal en entornos a gran escala (Jukan *et al.*, 2018; Fogarty *et al.*, 2020).

Algunos estudios informan de que los granjeros prefieren sensores conectados en el animal (Van De Gucht *et al.*, 2017a, b), como los ACCs. Estos ya se han implantado de forma efectiva y a nivel comercial, instalándose en patas, cuello o en las orejas de mascotas, ganado, aves y animales silvestres. Los comportamientos más destacados son la actividad, la rumia, el tiempo de descanso y la alimentación (O'Leary *et al.*, 2020).

Los ACCs montados en las patas fueron las primeras aplicaciones que se usaron con el ganado, bastante precisos, se utilizan comúnmente para medir el tiempo de reposo y activo de las vacas lecheras (Barker *et al.*, 2018). En vacuno lechero, los cambios de locomoción y la inactividad pueden indicar de manera confiable una cojera temprana en etapa preclínica (Taneja *et al.*, 2020). Debido a que la cojera reduce significativamente la producción de leche y aumenta el riesgo de lesiones, es la tercera enfermedad más importante que afecta a la ganadería (Warner *et al.*, 2020). Predecir la cojera por adelantado puede ayudar a los ganaderos a evitar graves pérdidas económicas. Monitorear el comportamiento de acostarse también puede ser útil como

indicador de la comodidad de las vacas, ya que los tiempos de acostarse más prolongados a menudo se asocian con mejores condiciones de descanso y rumia. También, se utilizan relativamente para la detección del celo (Mottram, 2016). En terneros lecheros, los investigadores han utilizado ACCs montados en las piernas para medir el tiempo de reposo y comportamiento de juego locomotor; ACCs montados en el cuello para medir el tiempo total de sueño y acostado, con una precisión de más del 90% (Halachmi *et al.*, 2019); y sensores montados en el cabestro para medir el comportamiento de succión. Se podría decir que esta tecnología se ha adoptado ampliamente y con éxito en la cría de vacas lecheras. En el sector porcino, los ACCs se han utilizado de manera similar, los sensores de etiquetas auriculares pueden clasificar automáticamente el comportamiento de las cerdas (Halachmi *et al.*, 2019), y los sensores adheridos a la pata o la espalda del animal indican la postura (Thompson *et al.*, 2016). Varios proyectos también se han centrado en predecir el parto (Alghamdi *et al.*, 2022; Herlin *et al.*, 2022), debido a los claros aumentos en la actividad de las cerdas relacionadas con el comportamiento de construcción del nido cuando se acerca el parto, lo que permite la intervención y supervisión, o identificar cerdas que representan menos riesgo para sus lechones por su comportamiento de acostarse (Kobek-Kjeldager *et al.*, 2023; Baxter *et al.*, 2023). También, se ha llevado a cabo el uso de múltiples sensores para realizar el reconocimiento de actividad en cerdas (Benjamin & Yik, 2019) en el que se montó un sensor en la parte posterior de la cerda y se fijó otro en la pata trasera del animal. El sensor usado en la pierna estaba destinado a evaluar el comportamiento de los pasos y cambios de comportamiento asociado con cojera en las cerdas (Scheel *et al.*, 2017). La cuantificación automática de la postura y el comportamiento acostado tiene potencial para mejorar el bienestar y la productividad de varias especies domésticas (Thompson *et al.*, 2019). Incluso se han colocado ACCs en las aletas dorsales de peces (Pereñíguez *et al.*, 2022).

### 1.3 USO DE GANADERÍA DE PRECISIÓN EN EL SECTOR CAPRINO

Según los datos del Ministerio de Agricultura, Pesca y Alimentación de España, el sector ovino y caprino representa en España el 11% de la Producción Final Ganadera, si se tiene en cuenta el conjunto del subsector cárnico y el lácteo (MAPA, 2021). Con un censo en caprino de 2,6 millones de animales, ocupando el segundo lugar después de Grecia en la Unión Europea.

A pesar de este alto número de pequeños rumiantes, la investigación sobre enfoques de PLF en pequeños rumiantes es significativamente menor en comparación con el resto del ganado, probablemente por una mezcla de cuestiones económicas y tecnológicas (Mansbridge *et al.*, 2018). La mayoría de los ganaderos ahora se encuentran en una situación en la que, para sustentarse, deben explotar la economía de escala aumentando el tamaño de la granja (Neethirajan, 2020). Como resultado, aquellos que sobreviven tienen el tiempo limitado para interactuar con sus animales. Mientras tanto, ha aumentado la atención que la sociedad presta al bienestar animal y las partes interesadas en el sector ganadero son más conscientes sobre la gestión y el sacrificio de animales de formas más respetuosas con el bienestar (Norton *et al.*, 2019). Una mayor atención a las necesidades individuales de los animales impacta no solo en el bienestar y la salud de los animales, sino también en la capacidad del ganadero para lograr objetivos de sostenibilidad (económicos, ambientales y sociales) (Blokhuys *et al.*, 2019).

Los sistemas de ML desarrollados para el ganado vacuno lechero no se pueden aplicar directamente a las cabras, ya que existe una diferencia en los patrones de señal del acelerómetro entre las especies, lo que significa que se necesitan diferentes algoritmos (Mansbridge *et al.*, 2018). Además, se necesita un hardware diferente, debido a la diferencia en los requisitos de tamaño y peso. En pequeños rumiantes, los acelerómetros se han utilizado

anteriormente para detectar comportamientos básicos (específicamente, estados de comportamiento en lugar de eventos de comportamiento) como actividad general de alto y bajo nivel (McLennan *et al.*, 2015), marcha y postura (Radeski & Ilieski, 2017), o alguna combinación de pastoreo, acostarse, pararse, rumiar, correr y/o caminar (Moreau *et al.*, 2009; Nadimi *et al.*, 2012; Alvarenga *et al.*, 2016; Giovanetti *et al.*, 2017; Barwick *et al.*, 2018b; Decandia *et al.*, 2018; Mansbridge *et al.*, 2018; Walton *et al.*, 2018). Aplicaciones más específicas han incluido la detección de amamantamiento y cojera (Barwick *et al.*, 2018a). Como describe Rabioff *et al.* (2022) algunos estudios se registraron conductas de transición, como levantarse o acostarse e incluso comportamientos sociales y de bienestar, como la interacción entre individuos, el acicalamiento, el lamido social o el rascado. También se han registrado comportamientos, como beber, orinar o defecar. Por ejemplo, se utilizaron sensores para medir el comportamiento de bebida en cabras y detectar posibles problemas de salud relacionados con la ingesta de agua; cámaras para monitorear la actividad de las cabras y detectar cambios en el comportamiento que puedan indicar problemas de salud. Entre otras revisiones científicas que recopilan el potencial de PLF desde la perspectiva de los desarrollos tecnológicos (Tullo *et al.*, 2019). Estos estudios varían en su enfoque, con diferencias en el propósito del estudio, el diseño, la conexión del sensor y la frecuencia de muestreo de datos. Algunas también se han realizado en entornos de corrales controlados, ya sea en su totalidad (Alvarenga *et al.*, 2016; Giovanetti *et al.*, 2017; Barwick *et al.*, 2018a) o en parte (Radeski & Ilieski, 2017). Para ello se observaron sucesivamente a los animales equipados durante un periodo continuo mediante observaciones directas o grabaciones de video. Realizando anotaciones manuales, con aplicaciones diseñadas a medida o software diseñado para la codificación de comportamientos (Rabioff *et al.*, 2022).

La tecnología se está desarrollando a un ritmo acelerado. Esta evolución de las tecnologías TIC ha tenido un impacto significativo en la industria ganadera. Animales como las cabras, activos e inquietos, difíciles de monitorizar con sensores en el propio animal, debido a problemas de integridad, no han sido fáciles de monitorizar en el pasado, pero ahora sí que es posible. Este trabajo pretende a mejorar el conocimiento del uso de acelerómetros en cabras lecheras.

## 2 OBJETIVOS

En este trabajo se evalúa la integridad y usabilidad de sensores de movimiento basados en ACCs para el monitoreo del comportamiento de las cabras. La incorporación de ACCs en cabras supone, una mejora significativa en la capacidad de los investigadores y productores para monitorear el comportamiento de las cabras y evaluar su bienestar en tiempo real y de forma no invasiva. Esta información puede tener implicaciones tanto para detectar cambios de comportamiento que puedan indicar estrés, dolor u otros problemas de salud y, así, mejorar la gestión del ganado y prevenir enfermedades como para la productividad económica.

Por tanto, el objetivo principal de este trabajo es evaluar la aplicabilidad de acelerómetros en la monitorización de la actividad de cabras lecheras. Este objetivo principal se desglosa en dos subobjetivos:

- I. Evaluar la integridad y usabilidad de los sensores de movimiento.
- II. Cuantificar la capacidad predictiva de los acelerómetros para predecir la actividad de cabras lecheras.

### 3 MATERIAL Y MÉTODOS

El presente trabajo se dividió en dos subapartados atendiendo a los dos objetivos principales: la prueba de integridad en primer lugar, y el estudio de los datos generados por los sensores colocados en los animales en segundo lugar. El trabajo se realiza en el marco del proyecto TED-FARM: “Facilitating ecological transition of livestock production through the digitalisation of farming systems” (TED2021-130759B).

#### 3.1 INSTALACIONES Y ANIMALES UTILIZADOS EN EL ESTUDIO

El estudio tuvo lugar en las instalaciones del Instituto Universitario de Investigación de Ciencia y Tecnología Animal (ICTA) de la Universidad Politécnica de Valencia (UPV), situado en Valencia.

Para llevar a cabo el estudio se utilizó un corral de 15 cabras Murciano-Granadinas de la granja experimental de la Universidad Politécnica de Valencia. El grupo de cabras utilizadas de  $50 \pm 3$  kg de peso vivo (p.v.) se encontraban en estado no productivo. La validación se realizó en un corral exterior de la granja experimental de pequeños rumiantes. La dimensión del corral era de  $30 \text{ m}^2$  ( $2 \text{ m}^2/\text{animal}$ ) equipado con un bebedero automático con recuperador de pérdidas (que aportaba agua a voluntad durante todo el ensayo) y dos comederos tipo canal (uno con acceso a paja ad libitum y otro con 500 g de pienso concentrado al día).

#### 3.2 DISEÑO EXPERIMENTAL

El proyecto constó de tres fases realizadas entre febrero y julio de 2023, abarcando un total de 22 semanas. Durante las primeras 18 semanas se trabajó en las granjas experimentales del ICTA observando directamente a las cabras, y las últimas 4 semanas se procedió al análisis los datos. En la Figura 4 se detallan las fases del estudio.



Figura 4: Fases del estudio.

#### 3.3 INTEGRIDAD Y USABILIDAD

##### 3.3.1 ACELERÓMETROS UTILIZADOS

La elección del acelerómetro utilizado en el estudio se realizó después de llevar a cabo unas pruebas previas entre dos modelos. Por un lado, se utilizó el registrador de datos de aceleración triaxial HOBO® Pendant G (Onset Computer Corporation, Pocasset, MA, EE.UU.) (Figura 5). Se valoró el uso de este modelo debido a su pequeño tamaño ( $58 \text{ mm} \times 33 \text{ mm} \times 23 \text{ mm}$ ), su peso ligero (18 g incluida una batería de litio de 3 V de larga duración) y bajo coste. El dispositivo registra simultáneamente la aceleración y la inclinación mediante la medición de una señal analógica de cada uno de sus tres ejes (x, y, z). Estas señales se convierten a unidades de gravedad que cubren un rango desde  $-3$  a  $+3g$  ( $1g = 9,8 \text{ m/s}^2$ ). La gravedad es una unidad de aceleración que se basa en la aceleración debida a la gravedad terrestre. Un  $g$  es aproximadamente igual a  $9.8 \text{ m/s}^2$ , que es la aceleración experimentada por un objeto en caída libre debido a la gravedad de la tierra. En cuanto a la precisión del acelerómetro, ésta es de  $\pm 0.075 g$ ;  $0.735 \text{ m/s}^2$  a  $25^\circ\text{C}$  y  $\pm 0.105 g$ ;  $1.03 \text{ m/s}^2$  de  $-20^\circ\text{C}$  a  $70^\circ\text{C}$ .

La memoria del registrador de 64Kb permite registrar 21.800 lecturas de los ejes x,y,z a intervalos de registro determinados por el usuario. El intervalo de registro puede configurarse como modo Normal que permite variar la frecuencia de muestreo entre 1s y 12h, y el modo Rápido de 2Hz a 100Hz.



Figura 5: HOBO® Pendant G

El segundo modelo es un sensor disponible a nivel comercial a través de la empresa española Digitanimal. Los dispositivos proporcionados por esta empresa están provistos de tres tipos de sensores: un GPS, un acelerómetro de tres ejes y un sensor de temperatura superficial. Para este estudio se utilizaron collares en los que únicamente estaba operativo el acelerómetro.

Este equipo tiene un diseño que se ajusta fácilmente al cuello de los animales sin que afecte a sus movimientos (Figura 6 a). Este dispositivo pesa 265 gramos y tiene las siguientes dimensiones 10,6 x 7,7 x 5,0 cm. Externamente se compone de una carcasa protectora certificada de grado IP67 según la norma UNE-EN 60529:2018, un collar ajustable y un contrapeso, gracias al cual el sensor mantiene una posición fija en el cuello del animal.

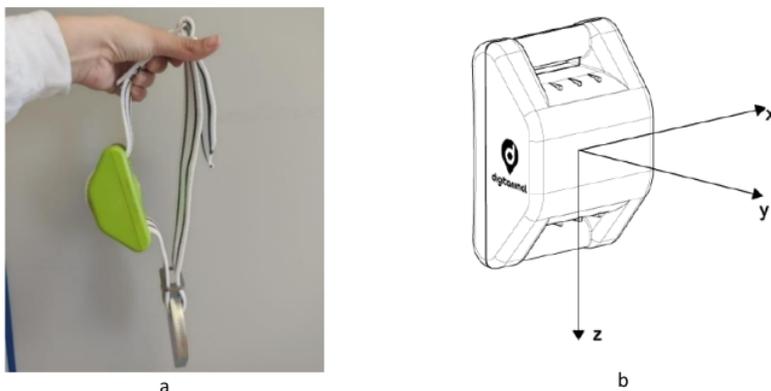


Figura 6: Dispositivo de la empresa Digitanimal (a) y disposición de los ejes (b)

Bajo la carcasa se encuentra protegido un microcontrolador de bajo consumo, una tarjeta microSD y una batería de litio (Figura 8). El microcontrolador es el encargado de repetir de forma cíclica el proceso de captura de datos. Primero realiza las lecturas a intervalos de tiempo regulares. Después son agregados en tres estadísticos por eje: valor medio, desviación típica y máxima excursión dentro de la ventana de muestras. Tras recopilar toda la información, se codifican los datos registrados y, por último, se guardan en una única trama de información en la tarjeta microSD. El ciclo total se completa tras un estado de inactividad, el microcontrolador

se reinicia y durante este periodo <sup>1</sup> no realiza ningún tipo de tarea. Este estado permite reducir el consumo del dispositivo y alargar la vida útil de su batería. Por tanto, el ciclo completo de funcionamiento consiste en 6 pasos, representados en la Figura 7, repetidos cada 30 minutos.



Figura 7: Ciclo de funcionamiento de equipos Digitanimal. Fuente: García (2022).

El sensor empleado es un acelerómetro lineal (LIS3DH) de tres ejes de ultra bajo consumo y alto rendimiento perteneciente a la familia “nano”, con salida estándar de interfaz serial digital I2C/SPI. El dispositivo cuenta con modos operativos de consumo de energía ultra bajo que permiten un ahorro de energía avanzado y funciones integradas inteligentes. El LIS3DH tiene escalas completas dinámicamente seleccionables por el usuario de 2g /±4g /8g /16g, una precisión de 0.008 g y es capaz de medir aceleraciones con velocidades de datos de salida de 1Hz a 5.3kHz. Las lecturas del sensor se ven afectadas por la posición que tenga este respecto a la componente vertical de la gravedad, el cual depende de la posición del animal y también de la posición que tenga la carcasa en el cuello del animal (Figura 6 b).



Figura 8: Interior de la carcasa del equipo Digitanimal

### 3.3.2 PRUEBAS DE INTEGRIDAD

Se realizó una primera prueba de integridad de los sensores para observar cómo reaccionaban las cabras ante un objeto extraño en su cuerpo y se valoró diariamente la presencia o ausencia de comportamientos anómalos. En esta primera fase, que tuvo una duración de dos semanas, se buscaba identificar cualquier tipo de problema y tomar las medidas adecuadas para realizar el registro de actividad de forma óptima. Los 4 primeros días, los animales llevaban instalado el sensor bajo supervisión y, posteriormente, los sensores se dejaron instalados sin supervisión durante 6 días consecutivos. Durante este periodo los equipos no se encontraban en

funcionamiento, pero se realizaban observaciones para analizar las actividades y posturas evaluables de las cabras.

El registrador de datos HOB0 Pendant G se probó en distintas partes del cuerpo de los animales gracias a su pequeño tamaño. Por un lado, se protegió con una funda creada con guantes quirúrgicos y se colocaron en la pata derecha delantera por encima del corvejón con un vendaje cohesivo VetWrap (Figura 9). Antes de instalar el registrador, se vendó la pata con dos capas de VetWrap y, a continuación, el sensor se envolvió con VetWrap hasta que estuvo seguro. Por otro lado, el registrador de datos se sujetó en el collar de identificación del animal. En este caso, algunos sensores se precintaron directamente en el collar por la parte interna, utilizando previamente la funda protectora nombrada anteriormente (Figura 10 a), y otros se precintaron en la cara exterior del collar utilizando una carcasa de plástico como protección. En el interior de la carcasa el sensor se fijó con silicona y relleno para que tuviera una posición totalmente fija (Figura 10 b).



**Figura 9: Colocación registrador Hobo Pendant G en la pata.**



**Figura 10: Colocación registrador Hobo Pendant G en el cuello.**

El equipo de Digitanimal solo tiene una posición de instalación: la carcasa debe ubicarse en el lado izquierdo del animal con la parte plana hacia dentro y el contrapeso en la base del cuello (Figura 11). Para instalarlo correctamente se redactó un protocolo detallado que proporcionaba instrucciones paso a paso acerca de la configuración del sensor, incluyendo desde su montaje hasta la desconexión y descarga de los datos.

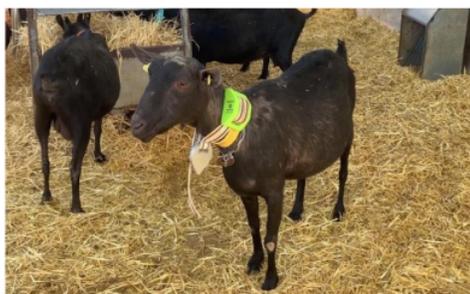


Figura 11: Equipo de Digitanimal instalado en una cabra.

### 3.4 OBSERVACIONES Y RECOGIDA DE DATOS

Como se indica en el apartado 4.1. de resultados, finalmente se optó por el sensor de Digitanimal para realizar la campaña de observaciones y recogida de datos, debido a que es capaz de registrar datos de forma continua durante más tiempo, es más robusto y tiene una colocación definida y lista para su posible comercialización.

Esta fase de observación comenzó la tercera semana del ensayo. Las primeras tres semanas sirvieron de entrenamiento y mejora frente a la toma de datos, ya que era el primer contacto con la observación y etiquetado de comportamientos de las cabras. Durante esta fase se registraron 56 días de medición, que supusieron un total de 225 horas de medida de actividad. Los equipos empleados para el estudio estaban configurados para registrar lecturas continuas a una frecuencia de muestreo de 10 Hz, por lo que tomaron diez lecturas por segundo para cada dimensión espacial (x, y, z).

Los datos registrados por el sensor de Digitanimal se complementaron con el registro de comportamientos mediante observación directa. Estos comportamientos se registraron como etiquetas asociadas a los datos del acelerómetro mediante una aplicación para Android “Etiquetado de Comportamientos” (Figura 12), desarrollada por la propia empresa para fines de I+D.

Inicialmente, la aplicación utilizada para el registro de comportamientos contaba con una lista de comportamientos específicos que se definían en las siguientes etiquetas: Comiendo, Bebiendo, De pie, Tumbada, Rumiano, Lamiendo cría, Interacción cría, Rascándose, Explorando suelo, Chupando elemento, Interacción social, Corriendo, Auto acicalado, Caminando y Otros. Sin embargo, a medida que avanzaba el ensayo, la aplicación se modificó para incluir comportamientos más generales. Esto permitió simplificar la clasificación de comportamientos y facilitar el registro de datos. De modo que se decidió trabajar con 7 etiquetas: activa, desplazándose, tumbada, pelea, rumiando, comiendo y rascándose. En la Tabla 1 se definen brevemente cada una de estas etiquetas.

Posteriormente, los comportamientos registrados en la aplicación (Figura 12) se sincronizaron temporalmente con los datos registrados por el sensor.

**Tabla 1: Etograma de comportamientos etiquetados**

Comportamiento	Descripción
<b>Activa</b>	Cualquier posición o acción no definida. Incluye conductas como beber, interacción social, interacción con elementos del corral, saltar, explorar el suelo, ...
<b>Desplazándose</b>	Desplazarse por el suelo ya sea de forma galopante o andante.
<b>Tumbada</b>	Acostado de cualquier postura para descansar, dormir o masticar.
<b>Rumiando</b>	Movimientos de mandíbula.
<b>Pelea</b>	Golpear a otro animal.
<b>Comiendo</b>	Manipular o consumir alimentos activamente
<b>Rascándose</b>	Rascado con la pata trasera, boca u objetos del corral



**Figura 12: Aplicación "Etiquetado comportamientos"**

Como se ha comentado anteriormente, el periodo de adaptación permitió tanto a los observadores como a las propias cabras habituarse al proceso de observación, identificando posibles mejoras en la forma de registrar la actividad de los animales. Por consiguiente, el objetivo principal fue familiarizarse con la metodología de observación y etiquetado.

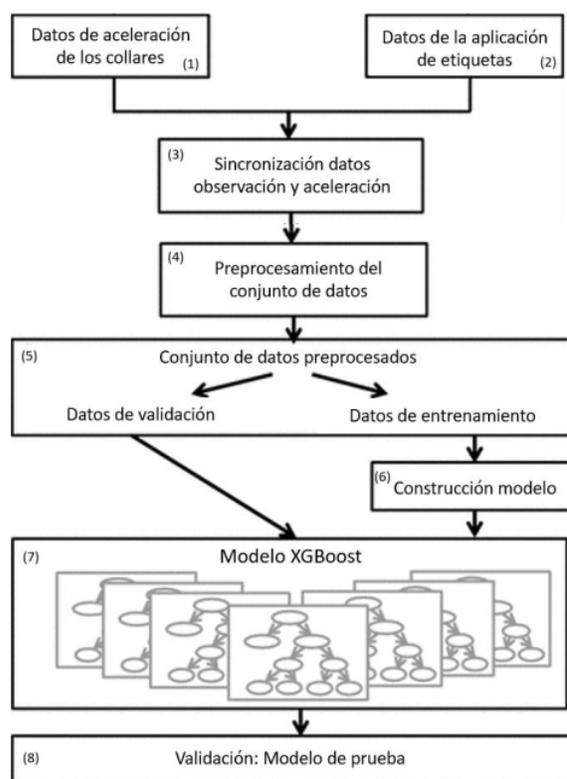
Durante toda esta fase, las observaciones se realizaron de forma individualizada, ya que cada sensor y evento de observación tenían una cabra asociada a la vez. Se debían realizar de forma muy precisa, sin perder la atención en los movimientos de la cabra seleccionada. En cuanto al montaje, a la conexión y desconexión del sensor y descarga de datos se siguió el protocolo antes mencionado.

En el caso de querer pausar la observación, y continuar más tarde, el acelerómetro se debía desinstalar, desconectar y empezar de nuevo. Al acabar cada observación se realizaba la descarga de datos de la tarjeta microSD de cada sensor al ordenador, y el paso de la información a la empresa colaboradora para tener los datos sincronizados lo antes posible y llevar un control sobre las observaciones realizadas.

### 3.5 TRATAMIENTO DE LOS DATOS

En la sexta semana se actualizó la aplicación y se definieron los nuevos comportamientos o etiquetas para la clasificación del algoritmo (Tabla 1). A partir de dicha semana se capturaron

los datos a utilizar en la validación de los comportamientos de las cabras. Los datos fueron recogidos durante períodos continuados de cuatro horas al día, moviendo las horas de observación (mañana y tarde) con el objetivo de poder capturar todos los comportamientos de interés desarrollados a distintas horas del día. Una vez cumplidas las 18 semanas de observación y registro de datos, se procedió a realizar el tratamiento de los mismos. Se indican a continuación los principales pasos seguidos en el flujo de trabajo que se resumen en la Figura 13.



**Figura 13: Flujo de trabajo general. Fuente: Adaptado de Fehlmann et al. (2017).**

Los datos registrados y guardados por el sensor en la tarjeta microSD, se extraían al finalizar cada observación con el fin de identificar y guardar correctamente los datos de cada experimento (Paso 1). Estos son los llamados “datos brutos” del acelerómetro que eran subidos a la nube de la empresa para ponerlos a disposición de Digitalanimal.

Junto con los datos de etiquetas de la aplicación (2), la empresa se encargaba de la decodificación y sincronización de los datos brutos, para proporcionarnos los datos sincronizados siguiendo los datos de registro generados durante cada medición, de modo que se sincronizaban las etiquetas de comportamiento con los datos de acelerómetro (3). Estos datos de registro se recogían en un archivo de Excel en el que se reflejaban los siguientes datos: nombre del animal, código del acelerómetro, código de la tarjeta microSD, fecha y hora de la instalación, conexión, desinstalación y desconexión de cada equipo, nombre del experimento (codificado de esta forma: EQUIPO\_mSD\_DD-MM-YYYY) y comentarios. Los datos brutos, el

registro de observaciones, los datos sincronizados y otros documentos de apoyo se almacenaron en la nube para compartir la información con la empresa Digitanimal.

Una vez recopilados todos los ficheros de acelerómetro sincronizados, se dispuso de 7.5 M de datos, debíamos realizar un preprocesado y así, obtener datos adecuados para el análisis (4). En esta etapa se realizó una limpieza, visualización de los datos, exploración, cálculo, selección, así como visualización de propiedades que luego serán utilizadas en el modelo predictivo.

Para traducir los datos del acelerómetro a comportamiento de animales se utilizó, por un lado, la herramienta web “AcceleRater” (<http://accapp.move-ecol-minerva.huji.ac.il/>). AcceleRater es una aplicación web basada en Python que utiliza la biblioteca de aprendizaje `sci-kit` para ajustar modelos y para la mayoría de las operaciones de preprocesamiento. AcceleRater requiere que el usuario prepare el archivo de datos de entrada por adelantado. Una vez preparados, el usuario indica algunos atributos básicos del conjunto de datos de entrada como el número de ejes y el formato del archivo. Para cualquier selección, la aplicación ofrece diferentes estructuras de archivos de entrada, todas deben formatearse como archivos de valores separados por comas (csv), con medidas del ACC en filas y etiquetas de comportamiento en la última columna. El requisito mínimo es cargar el archivo de datos ACC etiquetado previamente y ejecutar el programa con la selección predeterminada de las propiedades estadísticas de resumen, el método de validación cruzada (5) y los modelos (6, 7, 8). El objetivo de dicha aplicación web es facilitar el uso de la clasificación de comportamientos basada en ACCs al incluir variedad de modelos, opciones de reconstrucción de modelos, pruebas alternativas y resultados informativos. El protocolo de computación y selección de propiedades se encuentra descrito en el artículo publicado por Resheff *et al.*, 2014.

Por otro lado, se ha realizado el preprocesamiento de los datos del ensayo mediante el software R (R versión 4.2.1 R Core Team (2022). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R-project.org/>). Utilizando el paquete “rabc” (r for animal behavior classification) (Yu & Klaassen, 2021). Este paquete utiliza datos de acelerómetro con sus correspondientes comportamientos para el desarrollo de los clasificadores de comportamiento animal mediante ML supervisado.

Primero, se procedió a limpiar y transformar los datos. Para ello, se realizó una revisión de las etiquetas guardadas en cada uno de los archivos. En el caso de encontrar etiquetas no contempladas en el ensayo, se eliminaron los datos de dichas etiquetas y en algunos casos se renombraron. También se encontraron reinicios del acelerómetro que ocasionaban la pérdida de datos en las frecuencias de muestreo los cuales fueron establecidos a 10 Hz. Por ello, las lecturas guardadas en la tarjeta de memoria que fueron inferiores a 10Hz se descartaron. En relación, hubo lecturas con solapamiento de etiquetas, en este caso se decidió dejar la etiqueta predominante en la frecuencia de muestreo. Una vez realizada la limpieza de los datos, se obtuvieron aproximadamente 2.7 M de datos idóneos para la extracción de propiedades. Por otro lado, se convirtieron las unidades de aceleración del SI  $m/s^2$  a gravedad  $g$ , para formatear los datos de acuerdo con el paquete rabc.

A partir de los datos limpios y transformados, primero se seleccionó un tamaño de ventana de 5 segundos (para generar el cálculo de las propiedades) considerado en las predicciones. Según Riaboff *et al.* (2022) casi el 40% de los estudios utilizaron dicho tamaño de ventana. Se estimaron entonces las propiedades de los datos a través de estadísticas descriptivas, como: la media, la desviación estándar, la varianza, el máximo y el mínimo, el rango, la entropía, entre otros, tanto para el conjunto de 10 datos por segundo, así como en términos de frecuencia. Además, se

estimó el ODBA como una característica que indica el movimiento total del animal en el momento. Esta característica ha sido ampliamente estudiada por otros autores (Martín López *et al.*, 2020; Wilson *et al.*, 2020), para indicar la cantidad de energía que puede estar utilizando el animal por el movimiento generado. Estas propiedades se calcularon para cada eje del ACC por separado, excepto para ODBA que se calcula usando todos los ejes disponibles.

Tras el cálculo y visualización de las propiedades, se seleccionaron las más relevantes para la construcción del modelo utilizando la función `select_features` del paquete `rabc`. Para ello se aplica una selección directa secuencial (SFS) utilizando el modelo de refuerzo de XGBoost, que no solo se utiliza en la selección de propiedades, sino también en el modelo de clasificación final. Después de la selección y visualización de propiedades se entrenó el modelo de ML supervisado (5).

Para la generación del algoritmo predictivo de los datos de este estudio, se decidió utilizar el modelo XGBoost (6) con las propiedades más relevantes seleccionadas a través del entrenamiento y validación de los datos. En comparación con otros modelos de ML supervisado, XGBoost clasificó el comportamiento de forma similar a métodos alternativos (SVM, GBM, RPART, CFOREST). Sin embargo, XGBoost generó el algoritmo con un menor tiempo y uso de recursos de hardware.

XGBoost (Extreme Gradient Boosting) es un algoritmo predictivo supervisado que utiliza el principio de *boosting*. Este genera múltiples modelos de predicción “débiles” secuencialmente, y cada uno de estos toma los resultados del modelo anterior para generar un modelo más “fuerte”, con mejor poder predictivo y mayor estabilidad en sus resultados. Para ello utiliza un algoritmo de optimización, en este caso *Gradient Descent*.

La construcción y evaluación de los modelos de aprendizaje automático supervisado incluyen tres pasos: (a) ajuste de hiperparámetros del modelo de aprendizaje automático mediante validación cruzada (5 subconjuntos), (b) entrenamiento del modelo con un conjunto de datos de entrenamiento, así como el ajuste de hiperparámetros óptimos y (c) evaluación del rendimiento del modelo a través de la validación con un conjunto de datos de prueba. La función `train_model` del paquete “`caret`” y “`xgboost`” con el método “`xgbtree`” realiza automáticamente estos tres pasos para la construcción y evaluación del modelo.

El conjunto de datos se dividió en entrenamiento (`train_ratio = 75%`), en el que se consideran las variables predictoras y el comportamiento observado, y el resto de los datos se utilizan para su validación (`test_data = 25%`), donde solo se incluyen las variables predictoras.

La capacidad de predicción del modelo se evaluó mediante la matriz de confusión. La matriz de confusión es un método de evaluación de modelos de clasificación tomando el `test_data` para validar la capacidad de predicción del modelo. Se asemeja a un “entrenamiento y validación” quintuple con un `train_ratio` de 75%. Utilizando la función `confusionMatrix` del paquete “`caret`” se calcularon diferentes estadísticos, expuestos en la Figura 14.

PREDICIÓN	OBSERVACIONES	
	POSITIVO	NEGATIVO
POSITIVO	Verdadero positivo (TP)	Falso positivo (FP)
NEGATIVO	Falso negativo (FN)	Verdadero negativo (TN)

Formulas utilizadas:

$$\text{Sensibilidad} = \frac{TP}{TP+FN} \quad \text{Especificidad} = \frac{TN}{FP+TN}$$

$$PPV = \frac{\text{sensibilidad} + \text{prevalencia}}{((\text{sensibilidad} \times \text{prevalencia}) + ((1 - \text{especificidad}) \times (1 - \text{prevalencia}))}$$

$$PVN = \frac{\text{especificidad} \times (1 - \text{prevalencia})}{((1 - \text{sensibilidad}) \times \text{prevalencia}) + (\text{especificidad} \times (1 - \text{prevalencia}))}$$

$$\text{Prevalencia} = \frac{TP+FN}{TP+FP+FN+TN} \quad \text{Tasa de detección} = \frac{TP}{TP+FP+FN+TN}$$

$$\text{Frecuencia de detección} = \frac{TP+FP}{TP+FP+FN+TN}$$

$$\text{Exactitud equilibrada} = \frac{\text{sensibilidad} + \text{especificidad}}{2}$$

**Figura 14: Cálculos de la matriz de confusión.**

TP - Verdadero Positivo: cantidad de positivos que fueron clasificados correctamente como positivos por el modelo.  
 FP - Falso Positivo: cantidad de negativos que fueron clasificados incorrectamente como positivos.  
 FN - Falso Negativo: cantidad de positivos que fueron clasificados incorrectamente como negativos.  
 TN - Verdadero Negativo: cantidad de negativos que fueron clasificados correctamente como negativos por el modelo.  
 PPV: predicción de valores positivos  
 PVN: predicción de valores negativos

## 4 RESULTADOS Y DISCUSIÓN

### 4.1 ENSAYO DE INTEGRIDAD Y USABILIDAD

En el estudio realizado para evaluar la integridad y usabilidad de los dos modelos de acelerómetros utilizados, se identificaron varias dificultades significativas. El primer modelo evaluado fue el acelerómetro genérico HOBO Pendant G, el cual fue instalado en las patas y el cuello de las cabras durante las primeras dos semanas del estudio. Durante este periodo, se detectaron dos problemas principales que afectaron su desempeño.

En primer lugar, en la instalación del sensor en las patas de las cabras se observaron eventos de pérdida del sensor y de orientación incorrecta de los ejes del acelerómetro. Estas deficiencias comprometieron la precisión de las mediciones de aceleración del movimiento de los animales, lo que a su vez redujo la capacidad de la acelerometría para determinar patrones de comportamiento y orientación corporal. Al contrario que en el cuello, posición más usada (57%) en los estudios según Riaboff *et al.* (2022). Los datos de acelerómetros anclados en el cuello permitían representar comportamientos relacionados con la ingesta por el movimiento de la cabeza y masticación (da Silva Santos *et al.*, 2023). Es importante destacar que, a pesar de estos problemas, el tamaño y peso del sensor resultaron adecuados para su uso en cabras de pequeño tamaño.

En segundo lugar, se encontró que la duración de la memoria del dispositivo HOBO Pendant G era insuficiente para realizar validaciones adecuadas a una frecuencia de muestreo razonable de 10 Hz. Apoyando esta decisión en el estudio de Riaboff *et al.* (2022), donde cita que la frecuencia media utilizada para muestrear este tipo de datos de ACC es de 12Hz. La capacidad de almacenamiento del dispositivo permitía registrar datos únicamente durante un periodo limitado de tiempo (36 min) antes de que la memoria se llenara. Esta limitación en la duración de la memoria dificultó la recopilación de datos continuos y prolongados.

Como alternativa, se evaluaron los dispositivos de la empresa Digitanimal, los cuales mostraron resultados más prometedores en términos de integridad y usabilidad. Además, son equipos ya preparados para su comercialización (García, 2022). Estos dispositivos contaban con una sujeción y protección más segura y estable en el cuello de las cabras, lo que evitó la pérdida del sensor durante el estudio. Sin embargo, se observaron posibles variaciones en la orientación del sensor debido a la curiosidad de las cabras por la novedad del dispositivo, tanto en su propio cuerpo como en el de sus compañeras de corral. Aunque estos eventos ocurrieron muy puntualmente se tomaron medidas para evitar que ocurriera. Fue fundamental proporcionar a las cabras un período de habituación adecuado, además de ajustar correctamente la correa.

El ajuste de la correa debe realizarse bajo el contexto de bienestar animal. No debe causar incomodidad o lesiones y tener en cuenta el crecimiento potencial del animal. Conviene recordar que los collares demasiado flojos podrían ser susceptibles a la variación de su posición y medidas poco precisas. El tamaño de la carcasa sería otro punto para mejorar, pues se detectaron dificultades en la entrada de la cabeza de la cabra en las cornadizas. En consecuencia, el tamaño del contrapeso podría reducirse para disminuir el peso total del collar.

No obstante, los registradores de Digitanimal tenían una mayor capacidad de almacenamiento de datos en comparación con el modelo HOBO Pendant G. Esta mayor capacidad permitió

recopilar datos a 10Hz y de manera continua durante periodos más largos sin interrupciones. La capacidad de almacenamiento adecuada fue un factor crucial para garantizar la recopilación de datos suficientes y la realización de validaciones adecuadas en futuros análisis. Por este motivo, el dispositivo de la empresa Digitanimal fue el elegido para realizar las observaciones y recogida de datos.

## 4.2 PREDICCIÓN DE COMPORTAMIENTOS CON ACELERÓMETROS

La herramienta diseñada para la clasificación del comportamiento animal AcceleRater, se probó reiteradamente utilizando conjuntos de datos de distinto tamaño hasta encontrar el tamaño adecuado para el correcto funcionamiento de la aplicación. Finalmente, el conjunto de datos utilizado constaba de 684 mil muestras y 4 clases de comportamientos: activa, desplazándose, inactiva y tumbada. Lo que resultaba en un total de 19 horas.

Aquí encontramos el primer inconveniente. El motivo de utilizar una cantidad tan pequeña de datos se debió a que la app requería la transferencia de datos a través de internet. Esto limitaba el tamaño de datos etiquetados evaluables. Esta limitación hace que otros autores también consideren su uso y trabajen en el refinamiento de versiones futuras de dicha aplicación (Resheff *et al.*, 2014). Esta muestra no podía reflejar adecuadamente la verdadera distribución de estos comportamientos a lo largo del periodo de investigación. Por este motivo se decidió realizar el análisis utilizando el paquete rabc escrito en el lenguaje R.

Tanto rabc como AcceleRater entrenan modelos de clasificación de comportamiento. Sin embargo, existen tres diferencias principales que hemos podido observar y se encuentran descritas en el estudio (Yu & Klaassen, 2021). En primer lugar, el paquete rabc permite al usuario preprocesar y procesar los datos libremente. En segundo lugar, AcceleRater ofrece un proceso de caja negra, en cambio, las herramientas de visualización dentro de rabc ayudan al usuario a comprender el proceso de clasificación de comportamientos y el por qué algunos comportamientos pueden clasificarse mejor que otros, proporcionando vías para modificar o mejorar el modelo de clasificación de comportamientos. Finalmente, las propiedades calculadas en el paquete rabc pueden ampliarse aún más si se considera necesario e incluirlas en análisis de los datos.

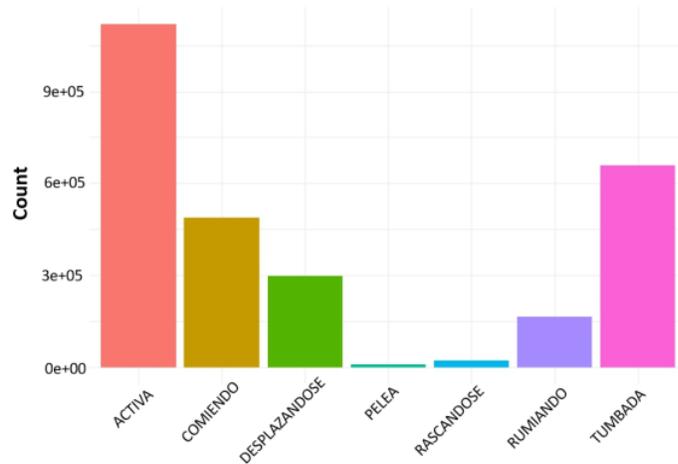
### 4.2.1 DATOS DESCRIPTIVOS

En total se dispuso para el tratamiento de datos, de un total de 140 horas de observación. La Tabla 2 muestra el catálogo conductual utilizado, así como el tiempo etiquetado para cada comportamiento tras la limpieza de datos, que resultó en 76.7 horas útiles.

Tabla 2: Catálogo conductual y tiempo de etiquetado.

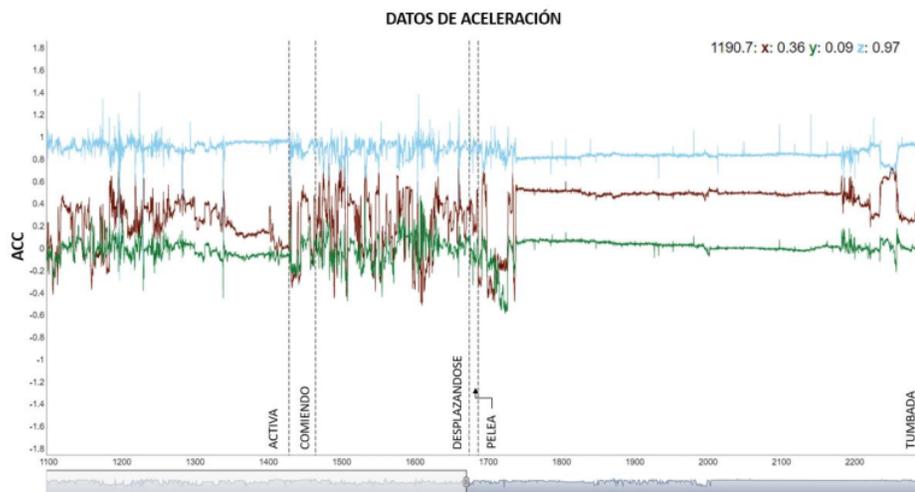
Comportamiento	Etiquetado (h)	Filtrado (h)
Activa	57.02	31.1
Tumbada	30.84	18.3
Comiendo	23.51	13.6
Desplazándose	18.64	8.24
Rumiando	8.16	4.57
Rascándose	1.39	0.625
Pelea	0.83	0.286

Como podemos ver en la Figura 15, encontramos etiquetas con diferentes cantidades de datos. Esto podría afectar al rendimiento y precisión del modelo. Las etiquetas desplazándose, pelea, rascándose y rumiando al tener menos muestras para entrenar al modelo, podría llevar a que el modelo tenga una precisión menor para predecir esos comportamientos. Además, si dichas etiquetas no representan adecuadamente la variabilidad del comportamiento que se está prediciendo, el modelo podría tener dificultades para realizar predicciones precisas.



**Figura 15: Representación gráfica del número de muestras por comportamiento.**

Al trazar el conjunto de datos de ACC utilizando la función `plot_acc`, observamos en la Figura 16 que el comportamiento de los datos del ACC (eje x en marrón, eje y en verde, eje z en azul) pueden ser distintos en segmentos etiquetados con el mismo comportamiento. Esto justifica su reetiquetado en el conjunto de datos o eliminación de conjuntos de datos si no cumple con la toma de 10 datos por segundo (10Hz). Esta acción se realiza con el fin de homogenizar los datos para mejorar la predicción en el posterior desarrollo del modelo. En el estudio (Williams et al., 2019), también detectaron algunos segmentos que durante la compilación de los datos se contaminaron con comportamientos falsos positivos. Esto podría deberse a una debilidad en el método de sincronización de los datos o incluso del propio receptor de datos al recibir una nueva orden de etiquetado.



**Figura 16: Visualización de datos ACC mediante gráfico dinámico.**

El análisis de las propiedades estimadas de los datos de ACC (estadística descriptiva, frecuencia, ODBA, entre otros) han sido ampliamente estudiadas por otros artículos con enfoque de seleccionar las de mayor influencia y que ayuden a mejorar la predicción del modelo (Riaboff *et al.*, 2022; da Silva Santos *et al.*, 2023). Las propiedades que mayor influencia tienen sobre la predicción del modelo se seleccionaron mediante la función `select_features`, el cual consistió en el uso de una selección progresiva profunda (SFS), utilizando el modelo `xgboost` y estableciendo la selección de 10 propiedades principales. Este gráfico permite identificar que combinación de propiedades estadísticas proporcionan mejores resultados en términos de precisión y ayuda a seleccionar el modelo más adecuado (sin *overfitting* o *underfitting*) para la tarea de clasificación en cuestión. En este caso se observa que después de la propiedad seleccionada “y\_min”, casi no hay mejoras en la precisión de la clasificación con la adición de más propiedades.

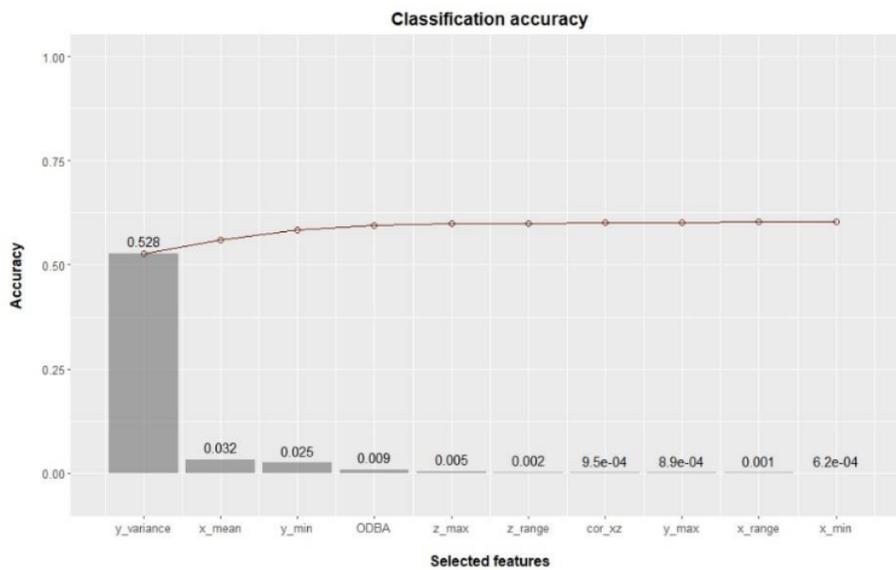


Figura 17: Grafica de precisión de clasificación.

La visualización de propiedades puede ayudar aún más a decidir cuales utilizar en el modelo de clasificación de comportamiento final y reducir los tiempos de procesado, así como el uso de recursos computacionales. De la misma forma, es útil para decidir que propiedades pueden explicar mejor un comportamiento específico y de esta forma mejorar la clasificación en el modelo supervisado. En el estudio de Gertz *et al.* (2020), observaron que la incorporación al modelo de distinto número de propiedades estadísticas resultó en ligeras diferencias en el rendimiento, pero grandes diferencias en los requisitos de tiempo computacional. Paralelamente, mediante la función `plot_grouped_feature`, generamos un boxplot para todos los comportamientos y todas las propiedades. Como observamos en la Figura 18, se representa la diferenciación entre comportamiento de acuerdo con las propiedades extraídas a partir de los datos. Algunas de las propiedades como ODBA y `x_mean` sugieren una clara diferenciación de las etiquetas lo que al final mejorará la clasificación de los diferentes comportamientos para mejorar la predicción del modelo.

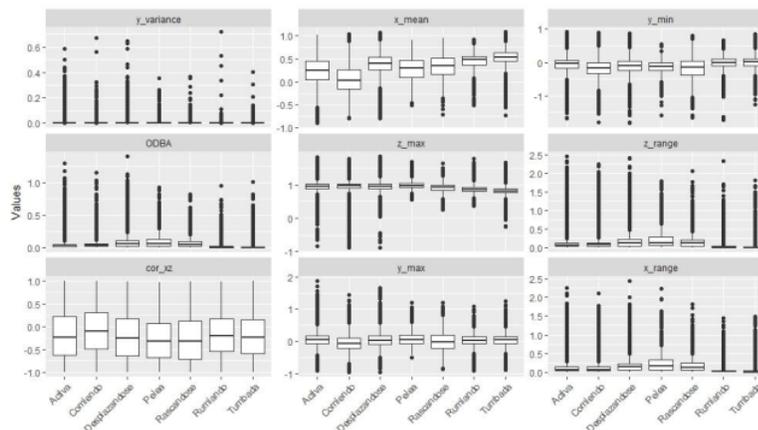


Figura 18: Boxplot de los distintos estadísticos

## 4.2.2 MODELOS DE APRENDIZAJE AUTOMÁTICO

El objetivo de este estudio fue evaluar si los datos del sensor se pueden clasificar de acuerdo con los comportamientos asociados, utilizando el modelo de clasificación supervisado XGBoost. Según Riaboff *et al.* (2022), los modelos de ML supervisado se usan en el 56% de los estudios y, para evaluar su capacidad de predicción se generó una matriz de confusión. En la diagonal de la matriz de confusión (Figura 19), donde el comportamiento observado se organiza en columnas y el comportamiento predicho se organiza en filas, se representan las predicciones correctas (en verde), con todas las predicciones incorrectas fuera de la diagonal (en rojo).

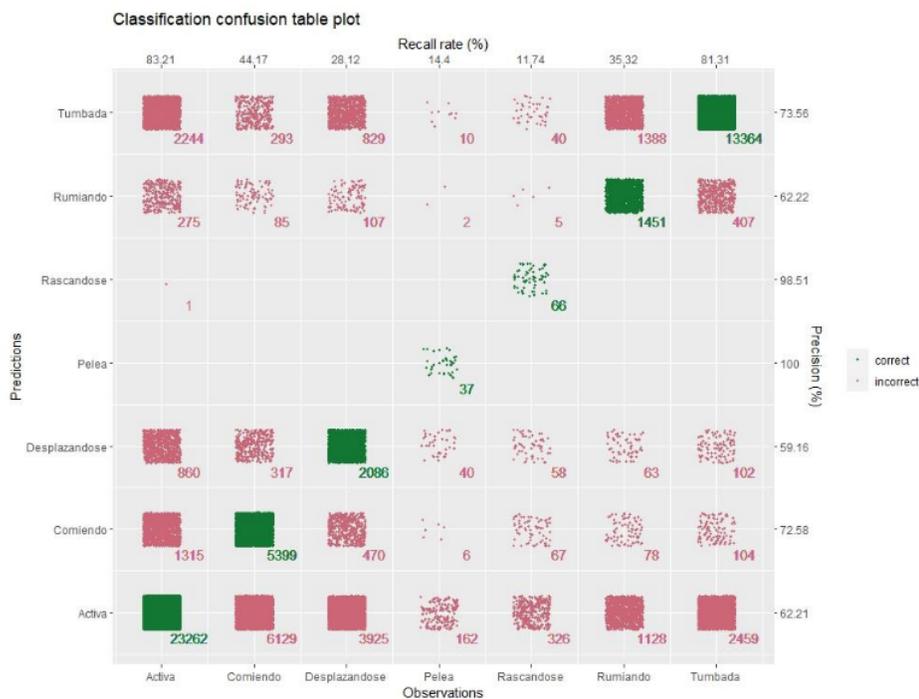


Figura 19: Gráfica de matriz de confusión de resultados de validación cruzada.

En general, el modelo tiene un nivel de precisión del 0.662 con un intervalo de confianza del 95% que va del (0.658, 0.665), lo que indica que clasifica correctamente el 66.22% del conjunto de datos. El rendimiento del modelo se encuentra dentro del rango establecido en otros trabajos con precisiones que van del 48% al 63% (Rodríguez-Baena et al., 2020). El coeficiente Kappa resultó en 0.551, lo que nos dice que la clasificación es significativamente mejor que la clasificación aleatoria. El valor p es una medida estadística que indica la significancia de la diferencia entre la exactitud del modelo y la tasa de información nula (0.405). Un p valor muy bajo, como en este caso ( $< 2.2e-16$ ), sugiere que la exactitud del modelo es significativamente mejor que la tasa de información nula.

**Tabla 3: Resultados estadísticos de la matriz de confusión.**

	ACTIVA	COMIENDO	DESPLAZÁNDOSE	PELEA	RASCÁNDOSE	RUMIANDO	TUMBADA
SENSIBILIDAD	0.832	0.442	0.281	0.144	0.117	0.353	0.813
ESPECIFICIDAD	0.655	0.964	0.977	1.000	1.000	0.986	0.909
PPV	0.622	0.726	0.592	1.000	0.985	0.622	0.736
PVN	0.851	0.889	0.919	0.997	0.993	0.960	0.940
PREVALENCIA	0.405	0.177	0.108	0.004	0.008	0.060	0.238
TASA DE DETECCIÓN	0.337	0.078	0.030	0.001	0.001	0.021	0.194
FRECUENCIA DE DETECCIÓN	0.542	0.108	0.051	0.001	0.001	0.034	0.264
EXACTITUD EQUILIBRADA	0.744	0.703	0.629	0.572	0.559	0.670	0.861

PPV: predicción de valores positivos  
 PVN: predicción de valores negativos

En la Tabla 3 se pueden observar las sensibilidades de cada comportamiento. Para el comportamiento "Activa", el modelo logra una sensibilidad del 0.832, identificando correctamente la actividad en el 83.2% de los casos reales. Similarmente, el comportamiento etiquetado como "Tumbada" tiene una sensibilidad del 81.3%, lo que indica que es acertadamente identificada en el 81.3% de las ocasiones. Por otro lado, hay un grupo de actividades, como "Comiendo", "Desplazándose" y "Rumiando", que muestran sensibilidades más bajas, con valores de 0.442, 0.281 y 0.353, respectivamente. Además, existen dos etiquetas, "Pelea" (0.144) y "Rascándose" (0.117), con sensibilidades aún más bajas, lo que indica que el modelo tiene dificultades para detectar correctamente estos comportamientos.

El modelo ha mostrado altas especificidades para la mayoría de los comportamientos, oscilando entre 90.9% y 100%, lo que indica que es capaz de identificar correctamente los casos negativos de cada uno de los comportamientos. Salvo para el comportamiento "Activa", la especificidad es de 0.655, lo que significa que solo el 65.5% de los casos negativos de "Activa" fueron clasificados correctamente como negativos por el modelo.

El valor predictivo positivo mide la proporción de muestras clasificadas como positivas son realmente positivas. Para "Pelea" el modelo tiene un valor predictivo positivo del 100% lo que significa que todas las muestras clasificadas como "Pelea" son realmente "Pelea". El comportamiento "Rascándose" también obtuvo un buen valor predictivo 98.5% de los casos. En cambio, para los demás comportamientos la proporción de muestras clasificadas como positivas que realmente son positivas fueron inferiores, desde 59.2% del comportamiento "Desplazándose" hasta 73.6% del comportamiento etiquetado como "Tumbada".

El valor predictivo negativo mide la proporción de muestras clasificadas como negativas que son realmente negativas. A nivel general, todos los comportamientos obtuvieron un buen valor predictivo negativo. Para el comportamiento "Pelea" el modelo tiene un valor predictivo negativo del 99.7%, lo que significa que casi todas las muestras clasificadas como negativas son

realmente negativas. En cambio, el comportamiento “Activa” obtuvo el menor PVN con un 85.1%.

La prevalencia representa <sup>1</sup> la proporción de cada etiqueta en el conjunto total de datos. Por ejemplo, “Activa” tiene una prevalencia del 0.405, lo que indica que el 40.5% de los comportamientos en el conjunto de datos son etiquetas de tipo “Activa”. “Comiendo” representa el 17.7% y “Desplazándose” el 10.8%. En el caso de “Pelea”, “Rascándose” “Rumiando” y “Tumbada” la frecuencia relativa con la que ocurre un determinado evento dentro de las actividades de las cabras son de 0.4%, 0.8%, 6% y 23.8%, respectivamente.

La tasa de detección representa la tasa de detección de los comportamientos reales. El modelo ha detectado correctamente el 33.7% de los datos reales de “Activa” y para el comportamiento “Tumbada” ha detectado un 19.4% de los casos reales. A diferencia de los demás comportamientos que tan solo obtuvieron un 7.8% en el mejor caso “Comiendo” y 0.1% en el peor caso para los comportamientos “Pelea” y “Rascándose”.

Frecuencia de detección representa la tasa de clasificación de cada clase por el modelo. El comportamiento “Activa” es clasificado por el modelo en un 54.2% de los casos como “Activa”. Del mismo modo que en la tasa de detección de comportamientos reales, “Tumbada” sí que obtuvo una tasa de clasificación de la etiqueta mayor (26.4%) pero para el resto de los comportamientos la tasa de clasificación no superó el 11%.

Exactitud equilibrada es la media aritmética de la sensibilidad y la especificidad. Para el comportamiento "Tumbada", el modelo muestra una precisión equilibrada de 0.861 (86.1%), que es una medida general del rendimiento del modelo para este comportamiento. Salvo para los comportamientos etiquetados como “Pelea” y “Rascándose” que obtuvieron un 57.2% y un 55.9%, respectivamente. Los demás comportamientos, resultaron en valores similares desde 74.4% para “Activa” hasta 55.95% para “Rascándose”.

Los resultados indican que el modelo tiene un buen rendimiento en la detección de los comportamientos “Activa” y “Tumbada”, pero presenta dificultades en la detección otros comportamientos. Hecho que concuerda con otros estudios donde decidieron excluir comportamientos como caminar, rascarse y otros que tienen poca representación de base (da Silva Santos *et al.*, 2023). La especificidad es alta en general, lo que muestra que el modelo puede clasificar correctamente los casos negativos en la mayoría de los comportamientos. En el caso del comportamiento “Pelea”, aun teniendo pocos datos, el modelo es capaz de no confundirlo, seguramente debido a que este comportamiento tiene unos patrones de aceleración característicos. Sin embargo, la sensibilidad varía, lo que indica que el modelo tiene diferentes niveles de éxito en la detección de los casos positivos para cada etiqueta de comportamientos. Además, el comportamiento “Rumiando” podría estar confundándose con “Tumbada”, probablemente debido a que ambos comportamientos se realizaban simultáneamente en la mayor parte del tiempo. Una posible explicación de estos resultados podría ser la impureza de las etiquetas utilizadas, como cita Gertz et al. (2020), es posible confundir al clasificador en la identificación de los comportamientos según el patrón de aceleración de los datos. Sin embargo, como se muestra en la literatura y los resultados obtenidos, XGBoost es relativamente robusto contra el ruido.

## 5 CONCLUSIONES

Los resultados obtenidos en el estudio de integridad y usabilidad muestran que tanto el tamaño como el peso del collar afectan a la usabilidad del acelerómetro. Se resalta la importancia de una colocación adecuada del collar con una carcasa robusta para el correcto despliegue del dispositivo que registra el movimiento corporal, garantizando tanto el bienestar animal como la precisión. Además, es de gran importancia contar con sensores que tengan suficiente capacidad de almacenamiento y durabilidad de la batería.

En cuanto al estudio de los datos, el modelo XGBoost pudo clasificar de manera aceptable los comportamientos etiquetados como "Activa" y "Tumbada", pero tuvo dificultades para clasificar correctamente los comportamientos "Desplazándose", "Rascándose", "Comiendo", "Rumiando" y "Pelea", confundiéndolos principalmente con "Activa", excepto "Rumiando", que fue confundido con "Tumbada". El desequilibrio en el número de etiquetas de cada comportamiento tuvo un efecto clave en la clasificación del modelo, viéndose perjudicados los comportamientos menos habituales. En este sentido, calificamos a los acelerómetros como apropiados para monitorizar y comprender el comportamiento de las cabras, proporcionando indicadores de salud, bienestar animal y para detectar eventos de interés reproductivo.

## 6 BIBLIOGRAFÍA

- ALGHAMDI, S., ZHAO, Z., HA, D. S., MOROTA, G., & HA, S. S. (2022). Improved pig behavior analysis by optimizing window sizes for individual behaviors on acceleration and angular velocity data. *Journal of Animal Science*, *100*(11). <https://doi.org/10.1093/jas/skac293>
- ALVARENGA, F. A. P., BORGES, I., PALKOVIČ, L., RODINA, J., ODDY, V. H., & DOBOS, R. C. (2016). Using a three-axis accelerometer to identify and classify sheep behaviour at pasture. *Applied animal behaviour science*, *181*, 91–99. <https://doi.org/10.1016/j.applanim.2016.05.026>
- BARKER, Z. E., VÁZQUEZ DIOSDADO, J. A., CODLING, E. A., BELL, N. J., HODGES, H. R., CROFT, D. P., & AMORY, J. R. (2018). Use of novel sensors combining local positioning and acceleration to measure feeding behavior differences associated with lameness in dairy cattle. *Journal of Dairy Science*, *101*(7), 6310–6321. <https://doi.org/10.3168/jds.2016-12172>
- BARWICK, J., LAMB, D., DOBOS, R., SCHNEIDER, D., WELCH, M., & TROTTER, M. (2018). Predicting lameness in sheep activity using Tri-axial acceleration signals. *Animals: an open access journal from MDPI*, *8*(1), 12. <https://doi.org/10.3390/ani8010012>
- BARWICK, J., LAMB, D. W., DOBOS, R., WELCH, M., & TROTTER, M. (2018). Categorising sheep activity using a tri-axial accelerometer. *Computers and Electronics in Agriculture*, *145*, 289–297. <https://doi.org/10.1016/j.compag.2018.01.007>
- BARWICK J., LAMB D.W., DOBOS R., WELCH M., SCHNEIDER D. & TROTTER M. (2020). Identifying Sheep Activity from Tri-Axial Acceleration Signals Using a Moving Window Classification Model. *Remote Sensing 2020*, Vol. 12, Page 646. <https://doi.org/10.3390/rs12040646>
- BAXTER, E. M., HALL, S. A., FARISH, M., DONBAVAND, J., BRIMS, M., JACK, M., LAWRENCE, A. B., & CAMERLINK, I. (2023). Piglets' behaviour and performance in relation to sow characteristics. *Animal: An International Journal of Animal Bioscience*, *17*(2), 100699. <https://doi.org/10.1016/j.animal.2022.100699>
- BENJAMIN, M., & YIK, S. (2019). Precision livestock farming in swine welfare: A review for swine practitioners. *Animals: An Open Access Journal from MDPI*, *9*(4), 133. <https://doi.org/10.3390/ani9040133>
- BLOKHUIS, H., VEISSIER, I., MIELE, M. & JONES, B. (2019). Safeguarding farm animal welfare. *Sustainability Certification Schemes in the Agricultural and Natural Resource Sectors: Outcomes for Society and the Environment*, pp. 137-153. <https://www.taylorfrancis.com/chapters/edit/10.4324/9780203701737-6/safeguarding-farm-animal-welfare-harry-blokhuis-isabelle-veissier-mara-miele-bryan-jones>
- BULLER, H., BLOKHUIS, H., LOKHORST, K., SILBERBERG, M. & VEISSIER, I. (2020). Animal Welfare Management in a Digital World. *Animals*, *10*(10), 1779. <https://doi.org/10.3390/ani10101779>
- 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), 104262.  
<https://doi.org/10.1016/j.beproc.2020.104262>
- DA SILVA SANTOS, A., DE MEDEIROS, V. W. C., & GONÇALVES, G. E. (2023). Monitoring and classification of cattle behavior: a survey. *Smart Agricultural Technology*, 3(100091), 100091. <https://doi.org/10.1016/j.atech.2022.100091>
- DECANDIA, M., GIOVANETTI, V., MOLLE, G., ACCIARO, M., MAMELI, M., CABIDDU, A., COSSU, R., SERRA, M. G., MANCA, C., RASSU, S. P. G., & DIMAURO, C. (2018). The effect of different time epoch settings on the classification of sheep behaviour using tri-axial accelerometry. *Computers and Electronics in Agriculture*, 154, 112–119. <https://doi.org/10.1016/j.compag.2018.09.002>
- DICKINSON, E. R., STEPHENS, P. A., MARKS, N. J., WILSON, R. P., & SCANTLEBURY, D. M. (2020). Best practice for collar deployment of tri-axial accelerometers on a terrestrial quadruped to provide accurate measurement of body acceleration. *Animal Biotelemetry*, 8(1). <https://doi.org/10.1186/s40317-020-00198-9>
- ELLIS, J. L., JACOBS, M., DIJKSTRA, J., VAN LAAR, H., CANT, J. P., TULPAN, D., & FERGUSON, N. (2020). Review: Synergy between mechanistic modelling and data-driven models for modern animal production systems in the era of big data. *Animal: An International Journal of Animal Bioscience*, 14(S2), s223–s237. <https://doi.org/10.1017/S1751731120000312>
- FEHLMANN, G., O'RIAIN, M. J., HOPKINS, P. W., O'SULLIVAN, J., HOLTON, M. D., SHEPARD, E. L. C., & KING, A. J. (2017). Identification of behaviours from accelerometer data in a wild social primate. *Animal Biotelemetry*, 5(1). <https://doi.org/10.1186/s40317-017-0121-3>
- FOGARTY, E. S., SWAIN, D. L., CRONIN, G. M., MORAES, L. E., & TROTTER, M. (2020). Behaviour classification of extensively grazed sheep using machine learning. *Computers and Electronics in Agriculture*, 169(105175), 105175. <https://doi.org/10.1016/j.compag.2019.105175>
- GARCÍA, J. N. (2022). Modelado de la conducta de ganado bovino mediante iot y ciencia de datos. Universidad Rey Juan Carlos. <https://dialnet.unirioja.es/servlet/tesis?codigo=311548>
- GARCÍA, R., AGUILAR, J., TORO, M., PINTO, A. & RODRÍGUEZ, P. (2020). A systematic literature review on the use of machine learning in precision livestock farming. *Computers and Electronics in Agriculture*, 105826, 179. <https://doi.org/10.1016/j.compag.2020.105826>
- GERTZ, M., GROßE-BUTENUTH, K., JUNGE, W., MAASSEN-FRANCKE, B., RENNER, C., SPARENBERG, H., & KRIETER, J. (2020). Using the XGBoost algorithm to classify neck and leg activity sensor data using on-farm health recordings for locomotor-associated diseases. *Computers and Electronics in Agriculture*, 173(105404), 105404. <https://doi.org/10.1016/j.compag.2020.105404>
- GIOVANETTI, V., DECANDIA, M., MOLLE, G., ACCIARO, M., MAMELI, M., CABIDDU, A., COSSU, R., SERRA, M. G., MANCA, C., RASSU, S. P. G., & DIMAURO, C. (2017). Automatic classification system for grazing, ruminating and resting behaviour of dairy sheep using

a tri-axial accelerometer. *Livestock science*, 196, 42–48.  
<https://doi.org/10.1016/j.livsci.2016.12.011>

- HALACHMI, I., GUARINO, M., BEWLEY, J., & PASTELL, M. (2019). Smart animal agriculture: Application of real-time sensors to improve animal well-being and production. *Annual Review of Animal Biosciences*, 7(1), 403–425.  
<https://doi.org/10.1146/annurev-animal-020518-114851>
- HERLIN, A. H., DASEN, S., GOMEZ, I., JARA, A. J., MARTÍNEZ, I. C., PENARANDA, A., BUGUEIRO, A., OLLAGNIER, C., LIECHTI, P., JEANNINGROS, L., EL ACHKAR, C. M., & VERJUS, C. (2022). Chapter 7: Experiences of developing an innovative application of sensors to monitor the health and activity of the peri-partum sow. *En Practical Precision Livestock Farming* (pp. 119–136). Wageningen Academic Publishers.  
<https://doi.org/10.3920/978-90-8686-934-3>
- JAVED, A. R., SARWAR, M. U., KHAN, S., IWENDI, C., MITTAL, M., & KUMAR, N. (2020). Analyzing the effectiveness and contribution of each axis of Triaxial accelerometer sensor for accurate activity recognition. *Sensors (Basel, Switzerland)*, 20(8).  
<https://doi.org/10.3390/s20082216>
- JUKAN, A., MASIP-BRUIJN, X., & AMLA, N. (2018). Smart computing and sensing technologies for animal welfare: A systematic review. *ACM Computing Surveys*, 50(1), 1–27.  
<https://doi.org/10.1145/3041960>
- KLEANTHOS, N., HUSSAIN, A. J., KHAN, W., SNEDDON, J., AL-SHAMMA'A, A., & LIATSI, P. (2022). A survey of machine learning approaches in animal behaviour. *Neurocomputing*, 491, 442–463. <https://doi.org/10.1016/j.neucom.2021.10.126>
- KOBEK-KJELDAGER, C., PEDERSEN, L. J., & LARSEN, M. L. V. (2023). Behavioural characteristics of fatal piglet crushing events under outdoor conditions. *Livestock Science*, 268(105164), 105164. <https://doi.org/10.1016/j.livsci.2023.105164>
- LADHA, C., HAMMERLA, N., HUGHES, E., OLIVIER, P., & PLOETZ, T. (2013). Dog's life: Wearable activity recognition for dogs. *Proceedings of the 2013 ACM international joint conference on Pervasive and ubiquitous computing*. <https://doi.org/10.1145/2493432.2493519>
- LOVARELLI, D., BACENETTI, J. & GUARINO, M. (2020). A review on dairy cattle farming: Is precision livestock farming the compromise for an environmental, economic and social sustainable production? *Journal of Cleaner Production*, 121409, 262.  
<https://doi.org/10.1016/j.jclepro.2020.121409>
- MARTÍN LÓPEZ, L. M., AGUILAR DE SOTO, N., MADSEN, P. T., & JOHNSON, M. (2022). Overall dynamic body acceleration measures activity differently on large versus small aquatic animals. *Methods in Ecology and Evolution*, 13(2), 447–458.  
<https://doi.org/10.1111/2041-210X.13751>
- MAPA (2021). Ovino-caprino. *Sector ovino y caprino es España*. Gob.es.  
<https://www.mapa.gob.es/es/ganaderia/temas/produccion-y-mercados-ganaderos/sectores-ganaderos/ovino-caprino/default.aspx#ancla0>

- MANSBRIDGE, N., MITSCH, J., BOLLARD, N., ELLIS, K., MIGUEL-PACHECO, G. G., DOTTORINI, T., & KALER, J. (2018). Feature selection and comparison of machine learning algorithms in classification of grazing and rumination behaviour in sheep. *Sensors (Basel, Switzerland)*, *18*(10), 3532. <https://doi.org/10.3390/s18103532>
- MCLENNAN, K. M., SKILLINGS, E. A., REBELO, C. J.B., CORKE, M. J., PIRES, M. A., MORTON, A. J., CONSTANTINO-CASAS, F. (2015). Technical note: Validation of an automatic recording system to assess behavioural activity level in sheep (*Ovis aries*). *Small Ruminant Research*, *127*, 92-96. <https://doi.org/10.1016/j.smallrumres.2015.04.002>
- MOREAU, M., SIEBERT, S., BUERKERT, A., & SCHLECHT, E. (2009). Use of a tri-axial accelerometer for automated recording and classification of goats' grazing behaviour. *Applied Animal Behaviour Science*, *119*(3-4), 158-170. <https://doi.org/10.1016/j.applanim.2009.04.008>
- MORRONE, S., DIUMARO, C., GAMBELLA, F., & GRAZIA, M. (2022). Industry 4.0 and Precision Livestock Farming (PLF): An up to Date Overview across Animal Productions. *Sensors*, *22*(12), 4319. <https://doi.org/10.3390/s22124319>
- MOTTRAM, T. (2016). Animal board invited review: precision livestock farming for dairy cows with a focus on oestrus detection. *Animal: An International Journal of Animal Bioscience*, *10*(10), 1575-1584. <https://doi.org/10.1017/S1751731115002517>
- NADIMI, E. S., JØRGENSEN, R. N., BLANES-VIDAL, V., & CHRISTENSEN, S. (2012). Monitoring and classifying animal behavior using ZigBee-based mobile ad hoc wireless sensor networks and artificial neural networks. *Computers and Electronics in Agriculture*, *82*, 44-54. <https://doi.org/10.1016/j.compag.2011.12.008>
- NEETHIRAJAN, SURESH (2017). Recent advances in wearable sensors for animal health management. *Sensing and Bio-Sensing Research*, *12*, 15-29. <https://doi.org/10.1016/j.sbsr.2016.11.004>
- NEETHIRAJAN, S. (2020). The role of sensors, big data and machine learning in modern animal farming. *Sensing and Bio-Sensing Research*, *29*(100367), 100367. <https://doi.org/10.1016/j.sbsr.2020.100367>
- NORTON, T., CHEN, C., LARSEN, M. L. V. & BERCKMANS, D. (2019). Review: Precision livestock farming: building 'digital representations' to bring the animals closer to the Farmer. *Animal*, (2019), 3009-3017, *13*(12). <https://doi.org/10.1017/S175173111900199X>
- NWEKE, H. F., TEH, Y. W., AL-GARADI, M. A., & ALO, U. R. (2018). Deep learning algorithms for human activity recognition using mobile and wearable sensor networks: State of the art and research challenges. *Expert Systems with Applications*, *105*, 233-261. <https://doi.org/10.1016/j.eswa.2018.03.056>
- O'LEARY, N. W., BYRNE, D. T., O'CONNOR, A. H., & SHALLOO, L. (2020). Invited review: Cattle lameness detection with accelerometers. *Journal of Dairy Science*, *103*(5), 3895-3911. <https://doi.org/10.3168/jds.2019-17123>
- ONU (2019). Una población en crecimiento. *Organización Naciones Unidas, Desafíos globales, Población*. <https://www.un.org/es/global-issues/population>

- PEREÑÍGUEZ, J. M., VENERUS, L. A., GUTIÉRREZ-CÁNOVAS, C., ABECASIS, D., CIANCIO, J. E., JIMÉNEZ-MONTALBÁN, P., & GARCÍA-CHARTON, J. A. (2022). Acoustic telemetry and accelerometers: a field comparison of different proxies for activity in the marine environment. *ICES Journal of Marine Science: Journal Du Conseil*, *79*(10), 2600–2613. <https://doi.org/10.1093/icesjms/fsac190>
- RADESKI, M., & ILIESKI, V. (2017). Gait and posture discrimination in sheep using a tri-axial accelerometer. *Animal: An International Journal of Animal Bioscience*, *11*(7), 1249–1257. <https://doi.org/10.1017/S175173111600255X>
- RESHEFF, Y. S., ROTICS, S., HAREL, R., SPIEGEL, O., & NATHAN, R. (2014). AcceleRater: a web application for supervised learning of behavioral modes from acceleration measurements. *Movement Ecology*, *2*(1), 27. <https://doi.org/10.1186/s40462-014-0027-0>
- RODRIGUEZ-BAENA, D. S., GOMEZ-VELA, F. A., GARCÍA-TORRES, M., DIVINA, F., BARRANCO, C. D., DAZ-DIAZ, N., JIMENEZ, M., & MONTALVO, G. (2020). Identifying livestock behavior patterns based on accelerometer dataset. *Journal of Computational Science*, *41*(101076), 101076. <https://doi.org/10.1016/j.jocs.2020.101076>
- RIABOFF, L., SHALLOO, L., SMEATON, A. F., COUVREUR, S., MADOUASSE, A., & KEANE, M. T. (2022). Predicting livestock behaviour using accelerometers: A systematic review of processing techniques for ruminant behaviour prediction from raw accelerometer data. *Computers and Electronics in Agriculture*, *192*(106610), 106610. <https://doi.org/10.1016/j.compag.2021.106610>
- SCHEEL, C., TRAUlsen, I., AUER, W., MÜLLER, K., STAMER, E., & KRIETER, J. (2017). Detecting lameness in sows from ear tag-sampled acceleration data using wavelets. *Animal: An International Journal of Animal Bioscience*, *11*(11), 2076–2083. <https://doi.org/10.1017/s1751731117000726>
- SHARMA, R., KAMBLE, S. S., GUNASEKARAN, A., KUMAR, V., & KUMAR, A. (2020). A systematic literature review on machine learning applications for sustainable agriculture supply chain performance. *Computers & Operations Research*, *119*(104926), 104926. <https://doi.org/10.1016/j.cor.2020.104926>
- SUKOR, A. S. A., ZAKARIA, A., & RAHIM, N. A. (2018). Activity recognition using accelerometer sensor and machine learning classifiers. *2018 IEEE 14th International Colloquium on Signal Processing & Its Applications (CSPA)*, 233–238. <https://ieeexplore.ieee.org/document/8368718>
- TANEJA, M., BYABAZAIRE, J., JALODIA, N., DAVY, A., OLARIU, C., & MALONE, P. (2020). Machine learning based fog computing assisted data-driven approach for early lameness detection in dairy cattle. *Computers and Electronics in Agriculture*, *171*(105286), 105286. <https://doi.org/10.1016/j.compag.2020.105286>
- THOMPSON, R., MATHESON, S. M., PLÖTZ, T., EDWARDS, S. A., & KYRIAZAKIS, I. (2016). Porcine lie detectors: Automatic quantification of posture state and transitions in sows using inertial sensors. *Computers and Electronics in Agriculture*, *127*, 521–530. <https://doi.org/10.1016/j.compag.2016.07.017>

- THOMPSON, R. J., MATTHEWS, S., PLÖTZ, T., & KYRIAZAKIS, I. (2019). Freedom to lie: How farrowing environment affects sow lying behaviour assessment using inertial sensors. *Computers and Electronics in Agriculture*, 157, 549–557. <https://doi.org/10.1016/j.compag.2019.01.035>
- TRAN, D.-N., NGUYEN, T. N., KHANH, P. C. P., & TRAN, D.-T. (2022). An IoT-based design using accelerometers in animal behavior recognition systems. *IEEE sensors journal*, 22(18), 17515–17528. <https://doi.org/10.1109/jsen.2021.3051194>
- TULLO, E., FINZI, A. & GUARINO, M. (2019). Review: Environmental impact of livestock farming and Precision Livestock Farming as a mitigation strategy. *Science of The Total Environment*, (2019), 2751-2760, 650. <https://doi.org/10.1016/j.scitotenv.2018.10.018>
- VAN DE GUCHT, T., SAEYS, W., VAN NUFFEL, A., PLUYM, L., PICCART, K., LAUWERS, L., VANGEYTE, J., & VAN WEYENBERG, S. (2017). Farmers' preferences for automatic lameness-detection systems in dairy cattle. *Journal of Dairy Science*, 100(7), 5746–5757. <https://doi.org/10.3168/jds.2016-12285>
- VAN DE GUCHT, TIM, VAN WEYENBERG, S., VAN NUFFEL, A., LAUWERS, L., VANGEYTE, J., & SAEYS, W. (2017). Supporting the development and adoption of automatic lameness detection systems in dairy cattle: Effect of system cost and performance on potential market shares. *Animals: An Open Access Journal from MDPI*, 7(10), 77. <https://doi.org/10.3390/ani7100077>
- WALTON, E., CASEY, C., MITSCH, J., VÁZQUEZ-DIOSDADO, J. A., YAN, J., DOTTORINI, T., ELLIS, K. A., 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), 171442. <https://doi.org/10.1098/rsos.171442>
- WANG, G. (2019). Machine learning for inferring animal behavior from location and movement data. *Ecological Informatics*, 49, 69–76. <https://doi.org/10.1016/j.ecoinf.2018.12.002>
- WARNER, D., VASSEUR, E., LEFEBVRE, D. M., & LACROIX, R. (2020). A machine learning based decision aid for lameness in dairy herds using farm-based records. *Computers and Electronics in Agriculture*, 169(105193), 105193. <https://doi.org/10.1016/j.compag.2019.105193>
- WERNER, J., UMSTATTER, C., LESO, L., KENNEDY, E., GEOGHEGAN, A., SHALLOO, L., SCHICK, M., & O'BRIEN, B. (2019). Evaluation and application potential of an accelerometer-based collar device for measuring grazing behavior of dairy cows. *Animal: An International Journal of Animal Bioscience*, 13(9), 2070–2079. <https://doi.org/10.1017/S1751731118003658>
- WILSON, R. P., BÖRGER, L., HOLTON, M. D., SCANTLEBURY, D. M., GÓMEZ-LAICH, A., QUINTANA, F., ROSELL, F., GRAF, P. M., WILLIAMS, H., GUNNER, R., HOPKINS, L., MARKS, N., GERALDI, N. R., DUARTE, C. M., SCOTT, R., STRANO, M. S., ROBOTKA, H., EIZAGUIRRE, C., FAHLMAN, A., & SHEPARD, E. L. C. (2020). Estimates for energy expenditure in free-living animals using acceleration proxies: A reappraisal. *The Journal of Animal Ecology*, 89(1), 161–172. <https://doi.org/10.1111/1365-2656.13040>

- WILLIAMS, M. L., JAMES, W. P., & ROSE, M. T. (2019). Variable segmentation and ensemble classifiers for predicting dairy cow behaviour. *Biosystems Engineering*, 178, 156–167. <https://doi.org/10.1016/j.biosystemseng.2018.11.011>
- YASEER, A., & CHEN, H. (2021). A review of sensors and machine learning in animal farming. *2021 IEEE 11th Annual International Conference on CYBER Technology in Automation, Control, and Intelligent Systems (CYBER)*. <https://doi.org/10.1109/CYBER53097.2021.9588295>
- YU, H., & KLAASSEN, M. (2021). R package for animal behavior classification from accelerometer data-rabc. *Ecology and Evolution*, 11(18), 12364–12377. <https://doi.org/10.1002/ece3.7937>
- ZOBEL, G., WEARY, D. M., LESLIE, K., CHAPINAL, N., & VON KEYSERLINGK, M. A. G. (2015). Technical note: validation of data loggers for recording lying behavior in dairy goats. *Journal of Dairy Science*, 98(2), 1082–1089. <https://doi.org/10.3168/jds.2014-8635>

INFORME DE ORIGINALIDAD

5%

INDICE DE SIMILITUD

5%

FUENTES DE INTERNET

0%

PUBLICACIONES

%

TRABAJOS DEL  
ESTUDIANTE

FUENTES PRIMARIAS

1

[burjcdigital.urjc.es](http://burjcdigital.urjc.es)

Fuente de Internet

2%

2

[es.biomedicalhouse.com](http://es.biomedicalhouse.com)

Fuente de Internet

2%

3

[riunet.upv.es](http://riunet.upv.es)

Fuente de Internet

1%

Excluir citas

Activo

Excluir coincidencias < 70 words

Excluir bibliografía

Activo