

Enrique Samperio Fernández

Aplicaciones de la visión por
computación en el diseño y
desarrollo de productos orientados
a la mejora y sostenibilidad de la
cadena de valor de productos
ganaderos

Director/es

Rebollar Rubio, Rubén
Lidón López, Iván

<http://zaguan.unizar.es/collection/Tesis>



Universidad de Zaragoza
Servicio de Publicaciones

ISSN 2254-7606



Tesis Doctoral

APLICACIONES DE LA VISIÓN POR
COMPUTACIÓN EN EL DISEÑO Y DESARROLLO
DE PRODUCTOS ORIENTADOS A LA MEJORA Y
SOSTENIBILIDAD DE LA CADENA DE VALOR DE
PRODUCTOS GANADEROS

Autor

Enrique Samperio Fernández

Director/es

Rebollar Rubio, Rubén
Lidón López, Iván

UNIVERSIDAD DE ZARAGOZA
Escuela de Doctorado

Programa de Doctorado en Ingeniería de Diseño y Fabricación

2024



Universidad
Zaragoza

Tesis Doctoral

Aplicaciones de la visión por computación en el
diseño y desarrollo de productos orientados a la
mejora y sostenibilidad de la cadena de valor
de productos ganaderos

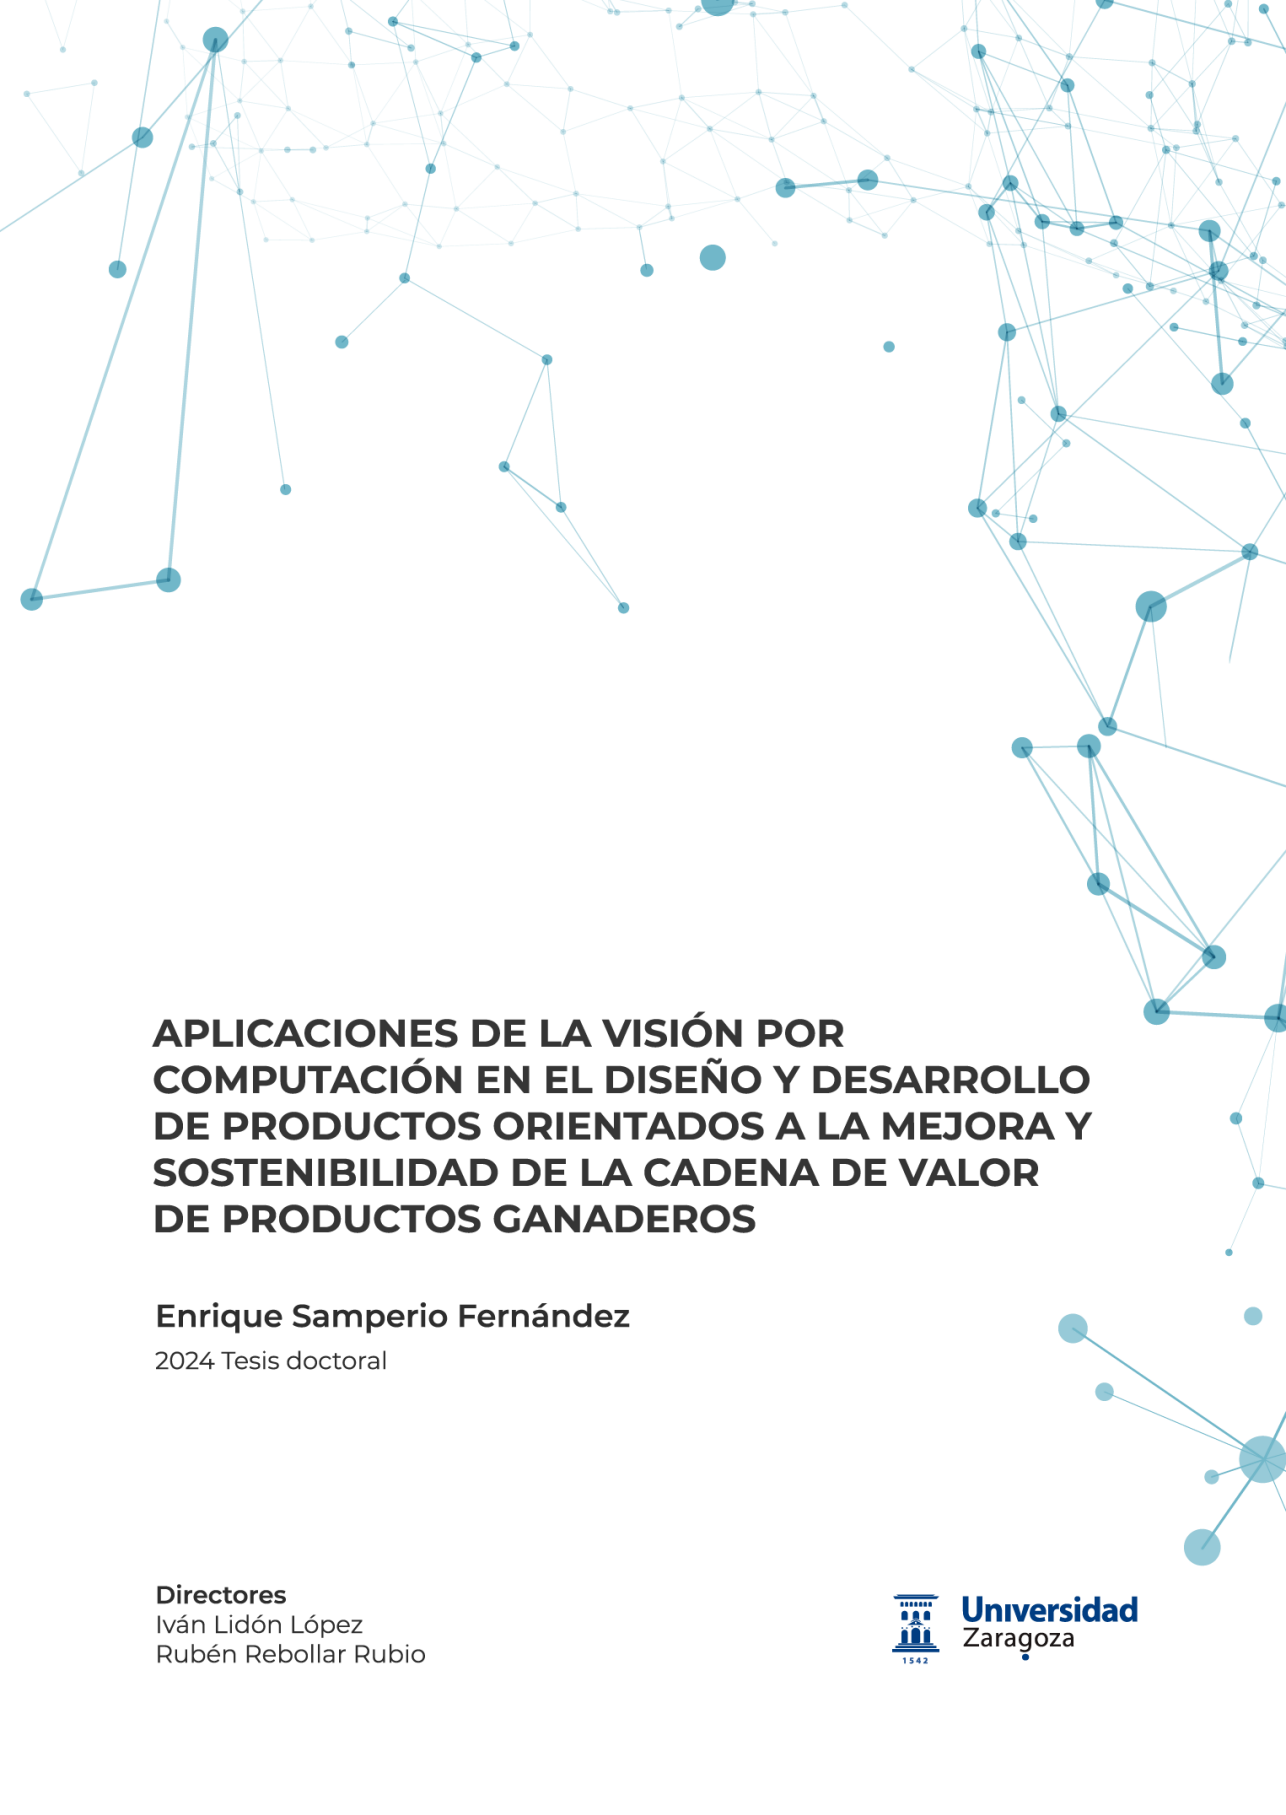
Autor

Enrique Samperio Fernández

Director/es

Iván Lidón López
Rubén Rebollar Rubio

Escuela de Ingeniería y Arquitectura
Ingeniería de Diseño y Fabricación
2024



APLICACIONES DE LA VISIÓN POR COMPUTACIÓN EN EL DISEÑO Y DESARROLLO DE PRODUCTOS ORIENTADOS A LA MEJORA Y SOSTENIBILIDAD DE LA CADENA DE VALOR DE PRODUCTOS GANADEROS

Enrique Samperio Fernández

2024 Tesis doctoral

Directores

Iván Lidón López

Rubén Rebollar Rubio



Universidad
Zaragoza

Agradecimientos

Gracias a mis directores de tesis **Rubén Rebollar** e **Iván Lidón** por su ayuda y consejos; sin ellos no podría haberlo conseguido. Gracias también a las charlas durante los viajes y a las reuniones en torno a buena comida y bebida. A mis compañeros del Área de Proyectos, **Iñaki Gil**, **Susana Díez** y **Jesús Paz**, gracias por aguantarme y soportar mis chistes malos.

Esta tesis no la podría haber llevado a cabo sin la ayuda de los compañeros de la Universidad de León: **Lidia Sánchez**, **Laura Fernández**, **Alexis Gutiérrez** y, en especial, a **Virginia Riego**, con quien más horas he compartido. Gracias a **Manuel Castejón**, quien, además de acompañarme durante todo el proceso, me ha enseñado todo lo que sé sobre visión por computación y aprendizaje automático, y que la mejor forma de trabajar es en pijama desde el sofá.

A **mis amigos**, gracias por su paciencia y por seguir a mi lado a pesar de no haber compartido casi tiempo con ellos estos últimos años. A pesar de la falta de dedicación, siguen estando a mi lado como el primer día.

Gracias a **mis padres** y **hermana** por estar ahí siempre, en las buenas y en las malas, y por enseñarme los valores que me han hecho ser como soy. Sin ellos y sus consejos no habría llegado hasta aquí. Especial agradecimiento a **mi abuelo**, quien habría estado muy orgulloso de verme llegar hasta aquí.

Por último, **Elena**, gracias. Gracias por todo, por ser como eres y por haberme ayudado tanto durante este proceso. Esto es en parte tuyo.

Resumen

El sector ovino en España, particularmente la raza Rasa Aragonesa en Aragón, enfrenta desafíos críticos debido al decreciente consumo de carne de cordero. Esta situación ha impulsado la búsqueda de innovaciones tecnológicas para mejorar la eficiencia y la sostenibilidad del sector. Dentro de la literatura, la inteligencia artificial (IA) se destaca como uno de los métodos más prometedores para abordar estos desafíos. Muchos investigadores han experimentado con técnicas de IA, demostrando su gran potencial, especialmente en lo que respecta a la visión por computación. Sin embargo, la mayoría de los estudios se concentran en los sectores porcino y vacuno, dejando al sector ovino con una atención significativamente menor y con escasos estudios en la literatura.

Este déficit en la investigación ovina constituye la base de la presente tesis, cuyo objetivo general es desarrollar y aplicar herramientas de visión por computación adaptadas a las necesidades específicas del sector ovino. A lo largo de cinco estudios detallados, esta investigación abarca desde la estimación precisa del peso de los corderos y la clasificación del nivel de grasa en vivo hasta la identificación de trayectorias de corte en costillares, utilizando tecnologías avanzadas para optimizar las operaciones y mejorar el bienestar animal.

Los resultados de estos estudios han demostrado la eficacia de las herramientas desarrolladas para mejorar la eficiencia y sostenibilidad en el sector ovino. LambScan y LambTrack, sistemas diseñados para la estimación no invasiva del peso de los corderos, han demostrado su capacidad para maximizar la rentabilidad sin causar estrés a los animales. LAUS, una herramienta para la clasificación del nivel de grasa

en corderos en vivo asegura la calidad de la carne conforme a los estándares del mercado, mejorando tanto la precisión como la sostenibilidad de las prácticas de manejo. Otro avance significativo ha sido la identificación automática de trayectorias de corte en costillares de cordero mediante visión por computación. Esta tecnología permitirá en un futuro mejorar un proceso que actualmente se realiza de forma manual, mejorando la precisión de los cortes y garantizando la alta calidad del producto final. Estos desarrollos integran prácticas más sostenibles en el manejo cotidiano, demostrando que es posible optimizar operaciones y mejorar el bienestar animal simultáneamente.

La contribución de esta tesis al sector agroalimentario es significativa, generando soluciones específicas y viables que facilitan una mayor adopción tecnológica en la ganadería ovina. Las herramientas diseñadas, con un enfoque centrado en el usuario, se adaptan no solo a las necesidades económicas, sino también a las características operativas y ambientales del sector. Estas soluciones establecen un nuevo estándar en la tecnificación de la ganadería ovina, destacando la importancia de soluciones personalizadas para una adopción efectiva y sostenible.

Además, estas soluciones no solo abordan los problemas actuales de eficiencia y sostenibilidad del sector, sino que también potencian la capacidad de adaptarse a las exigencias del mercado y mejorar el bienestar animal, lo cual es cada vez más valorado por los consumidores. La implementación de técnicas de IA y visión por computación se ha vuelto crucial para la supervivencia del sector, ofreciendo una oportunidad única para modernizar los procesos y hacerlos más rentables.

Abstract

The ovine sector in Spain, particularly the Rasa Aragonesa breed in Aragon, faces critical challenges due to the declining consumption of lamb meat. This situation has spurred the search for technological innovations to enhance the efficiency and sustainability of the sector. Within the literature, artificial intelligence (AI) emerges as one of the most promising methods to tackle these challenges. Many researchers have experimented with AI techniques, demonstrating their considerable potential, especially in terms of computer vision. However, the majority of studies focus on the pork and cattle sectors, leaving the ovine sector with significantly less attention and few studies in the literature.

This gap in ovine research forms the basis of this thesis, whose general objective is to develop and apply computer vision tools tailored to the specific needs of the ovine sector. Across five detailed studies, this research spans from the accurate estimation of lambs' weight and the classification of fat levels in live animals to the identification of cutting trajectories in lamb carcasses, utilising advanced technologies to optimise operations and improve animal welfare.

The outcomes of these studies have proven the effectiveness of the developed tools in enhancing efficiency and sustainability in the ovine sector. LambScan and LambTrack, systems designed for the non-invasive weight estimation of lambs, have shown their capacity to maximise profitability without causing stress to the animals. LAUS, a tool for classifying the fat level in live lambs ensures meat quality according to market standards, improving both the precision and sustainability of management practices. Another significant advancement

has been the automatic identification of cutting trajectories in lamb carcasses using computer vision. This technology will allow the improvement of a process that is currently carried out manually, enhancing the precision of cuts and ensuring the high quality of the final product. These developments integrate more sustainable practices into daily management, demonstrating that it is possible to optimise operations and improve animal welfare simultaneously.

The contribution of this thesis to the agri-food sector is significant, generating specific and viable solutions that facilitate greater technological adoption in ovine farming. The designed tools, with a user-centric approach, adapt not only to the economic needs but also to the operational and environmental characteristics of the sector. These solutions establish a new standard in the technification of sheep farming, underscoring the importance of customised solutions for effective and sustainable adoption.

Furthermore, these solutions not only address the current problems of efficiency and sustainability of the sector but also enhance the capacity to adapt to market demands and improve animal welfare, which is increasingly valued by consumers. The implementation of AI and computer vision techniques has become crucial for the survival of the sector, offering a unique opportunity to modernise processes and make them more profitable.

Índice

Agradecimientos	III
Resumen	V
Abstract	VII
1. Introducción	1
2. Objetivos y estructura	11
2.1. Objetivos	13
2.2. Estructura de tesis	14
3. Estado del arte	17
3.1. Inteligencia artificial	19
3.1.1. Campos de la inteligencia artificial	22
3.1.2. Herramientas e impulsores	28
3.2. Aplicaciones de la inteligencia artificial en el sector agroalimen- mentario	29
3.2.1. Desafíos de la IA en el sector agroalimentario	32
3.2.2. Estrategias para el manejo y mejora del sector ovino	34
3.3. Desarrollo del proceso de visión por computación	39
3.3.1. Adquisición de imágenes	39
3.3.2. Preprocesado	42
3.3.3. Segmentación	43
3.3.4. Machine Learning y Deep Learning	44

4. Estimación y control del peso mediante técnicas de visión por computación	47
4.1. Morfometría de la raza de cordero Rasa Aragonesa	51
4.1.1. Adquisición de datos	52
4.1.2. Algoritmo de estimación de peso	54
4.1.3. Conclusiones	56
4.2. LambScan: dispositivo de estimación del peso en vivo del cordero mediante imágenes 3D	57
4.2.1. Adquisición de imágenes	58
4.2.2. Procesamiento de la imagen	59
4.2.3. Algoritmo de aprendizaje automático	61
4.2.4. Desarrollo del dispositivo	65
4.2.5. Conclusiones	67
4.3. LambTrack: Aplicación de monitorización del peso y seguimiento del crecimiento del cordero mediante imágenes	68
4.3.1. Adquisición de imágenes	69
4.3.2. Procesamiento de la imagen	72
4.3.3. Algoritmo de aprendizaje automático	73
4.3.4. Software y funcionalidades de LambTrack	76
4.3.5. Conclusiones	81
5. Clasificación de corderos según su nivel de engrasamiento mediante imágenes de ultrasonidos	83
5.1. LAUS: Dispositivo para la clasificación de corderos según su nivel de grasa mediante imágenes de ultrasonidos	87
5.1.1. Adquisición de imágenes	88
5.1.2. Procesamiento de la imagen	90
5.1.3. Algoritmo de aprendizaje automático	93
5.1.4. Desarrollo del dispositivo	96
5.1.5. Conclusiones	102

6. Detección de trayectorias de corte en costillares de corderos mediante procesamiento de imágenes	103
6.1. Detección de trayectorias de corte en costillares de corderos	107
6.1.1. Adquisición de imágenes	108
6.1.2. Procesamiento de la imagen	111
6.1.3. Algoritmo de detección de trayectorias	116
6.1.4. Resultados	117
6.1.5. Conclusiones	119
7. Discusión y líneas futuras de trabajo	121
7.1. Discusión	123
7.2. Líneas futuras de trabajo	135
8. Conclusiones	139
9. Resultados de la tesis	145
10. Referencias	151

Índice de figuras

Fig. 1. Evolución del censo ovino en España.	4
Fig. 2. Evolución del consumo “aparente” de carne ovina per cápita en España.	4
Fig. 3. Principales campos de la IA.	22
Fig. 4. Tipo de imagen. A. Imagen 2D. B. Imagen 3D (color). C. Imagen 3D (profundidad). D. Imagen térmica. E. Imagen de rayos. F. Imagen de ultrasonidos.	41
Fig. 5. Esquema de las medidas tomadas.	52
Fig. 6. Posición y herramientas de la toma de medidas en el cebadero.	53
Fig. 7. Distribución de las frecuencias de los corderos utilizados para la realización del modelo.	55
Fig. 8. Elementos del dispositivo, colocación en relación con el cordero y el dispositivo propiamente dicho.	59
Fig. 9. Operaciones morfológicas realizadas en las imágenes de vista superior de los corderos.	60
Fig. 10. El sistema de la figura detalla el flujo de los datos a través de los distintos procesos que construyen el modelo predictivo.	62
Fig. 11. RGB (modelo aditivo de color), profundidad, máscara e imágenes segmentadas de dos corderos diferentes).	63
Fig. 12. Conjunto de datos de entrenamiento que compara el área cenital con el peso del cordero.	64
Fig. 13. Vista superior de un cordero en la interfaz final del software desarrollado.	65

Fig. 14. Gráficas de crecimiento de peso durante 70 días desde el nacimiento. Parto múltiple de hembras (Arriba), parto múltiple de machos (Abajo). Percentil 99 (rojo), percentil 50 (verde), percentil 1 (azul).	70
Fig. 15. Set de toma de fotografías.	71
Fig. 16. Operaciones morfológicas. (Izquierda). Máscara. (Derecha). Imagen original.	73
Fig. 17. Módulo Inception V1.	75
Fig. 18. Interfaz de LambTrack.	76
Fig. 19. Creación de perfil.	77
Fig. 20. Identificación mediante NFC.	78
Fig. 21. Calibración y estimación de pesada.	78
Fig. 22. Visualización del crecimiento y exportación de datos.	79
Fig. 23. Comparación de la imagen por ultrasonidos frente al corte de la canal de cordero. (Izquierda) Área de grasa subcutánea captada con el ecógrafo. (Derecha) Capa de grasa observada en la canal del mismo animal post mortem.	89
Fig. 24. Imagen de entrada del ecógrafo. 1. Área de grasa 2-Tejido muscular 3 - Ápofisis transversa	90
Fig. 25. Procesamiento de la imagen.	91
Fig. 26. Ejemplo de la pendiente del % de píxeles blancos de una imagen.	92
Fig. 27. Comparación de mm de grasa y peso por sexo.	94
Fig. 28. Partes y funcionamiento del dispositivo de bloqueo del cordero.	97
Fig. 29. Bloqueador ovino.	99
Fig. 30. Interfaz de la aplicación.	100
Fig. 31. Cordero bloqueado.	101
Fig. 32. Ejemplos de costillares de diferentes especies. De izquierda a derecha. Costillar de Ternera, costillar de cerdo y costillar de cordero.	105
Fig. 33. Set de adquisición de imágenes.	109
Fig. 34. Imágenes capturadas con y sin difusor.	110

Fig. 35. Procesamiento inicial de la imagen mediante la imagen de profundidad.	111
Fig. 36. Recorte de la imagen de rayos X.	112
Fig. 37. Corrección de color.	112
Fig. 38. Proceso de detección de costillas mediante iluminación led y luz negra.	113
Fig. 39. Detección de la columna en el costillar.	114
Fig. 40. Detección de costillas.	115
Fig. 41. Comparación de las costillas detectadas entre los diferentes supuestos.	115
Fig. 42. Curva intermedia entre los laterales de las costillas.	116
Fig. 43. Trayectorias de corte del costillar completo.	117

Índice de tablas

Tabla 1. Coeficientes del modelo.	69
Tabla 2. Comparación del rendimiento del aprendizaje para predecir el peso del cordero basado en el error cuadrático medio negativo obtenido de la validación cruzada de 10 veces.	78
Tabla 3. Comparación de la precisión de los métodos de clasificación de validación cruzada.	110
Tabla 4. Matriz de confusión de la clasificación en el conjunto de validación.	110

1. Introducción

La agricultura y la ganadería han sido esenciales en la evolución de las sociedades humanas desde el surgimiento de la Revolución Neolítica, aproximadamente en el 10,000 a.C., cuando las sociedades cazadoras-recolectoras comenzaron a domesticar plantas y animales. La Revolución Industrial trajo consigo una nueva era para la ganadería, con la mecanización de la producción y el transporte. El uso de herramientas mecánicas y el avance en la medicina veterinaria mejoraron la salud y el rendimiento de los animales. La mejora genética también permitió crear razas especializadas para carne, leche o trabajo, aumentando la productividad. La cría intensiva se consolidó en granjas especializadas. En la actualidad, la ganadería enfrenta el desafío de encontrar prácticas más sostenibles. Las mejoras tecnológicas en el sector ganadero y la mejora en la eficiencia de la alimentación también ofrecen oportunidades para que la producción animal sea más sostenible y adaptada a los desafíos contemporáneos.

En este aspecto, en los últimos años, el sector ganadero con mayor desarrollo dentro de España es el porcino ([SG de Producciones Ganaderas y Cinegéticas, 2020](#)). Como extensión de este proceso nacional, Aragón ha prosperado en esa misma línea aumentando el censo de cerdos en la región y convirtiendo al porcino en el primer sector ganadero y a Aragón en la comunidad autónoma que más cerdo produce en España ([SG de Producciones Ganaderas y Cinegéticas, 2020](#)). Este auge ha hecho que el ganadero aragonés quiera apostar por un producto económicamente más rentable en comparación al producto históricamente más consumido de la comunidad, el cordero ([SG de Producciones Ganaderas y Cinegéticas, 2023](#)).




Fig. 1. Evolución del censo ovino en España.

Fuente: SG de Producciones Ganaderas y Cinegéticas (2023)




Fig. 2. Evolución del consumo “aparente” de carne ovina per cápita en España.

Fuente: SG de Producciones Ganaderas y Cinegéticas (2023)

En la actualidad, el sector ovino en España está atravesando un periodo de incertidumbre y declive, reflejado en una reducción palpable de su producción. Este fenómeno se corrobora mediante las tendencias mostradas en las Fig. 1 y Fig. 2, que ilustran una caída en el consumo de carne ovina por parte de los consumidores españoles (SG de Producciones Ganaderas y Cinegéticas, 2023).

El aumento de la producción y venta del producto porcino, y en menor medida del vacuno, ha obligado al ganadero a mejorar la eficiencia y

sostenibilidad de sus instalaciones, del mismo modo que han hecho otras partes de la cadena de valor. Tecnologías que eran dominio de sectores como el automovilístico, con procesos de producción en serie y elementos de inteligencia artificial, han encontrado su lugar en la modernización de las granjas porcinas (Cang et al., 2019; Matthews et al., 2017; H. Wang et al., 2022). La implementación de inteligencia artificial en el sector ganadero se ha adoptado bajo el concepto de ganadería de precisión (PLF, por sus siglas en inglés). Estas inversiones, aunque significativas, se justifican por los retornos que ofrecen en eficiencia y rentabilidad.

Se podría pensar que este avance tecnológico que han realizado el sector vacuno y porcino es extrapolable a otros sectores como el ovino y el caprino. Sin embargo, la disminución del consumo de carne de cordero, impulsada en parte por el auge de otros productos cárnicos, ha afectado negativamente las ganancias de los ganaderos ovinos. Las inversiones tecnológicas, que se justifican en granjas porcinas de gran escala, resultan ser inalcanzables para granjeros ovinos debido a la reducción en sus ingresos. Esta situación ha llevado a una disminución en la capacidad de inversión para mejorar la calidad, incrementar la producción y optimizar la eficiencia en el sector ovino. Este escenario ha resultado en la desaparición de numerosas granjas ovinas, que enfrentan desafíos en términos de rentabilidad y gestión.

El sector ovino en Aragón, mayoritariamente se centra en la producción de carne perteneciente a la certificación IGP (Indicación Geográfica Protegida) “Ternasco de Aragón”, es un pilar fundamental de la economía y la cultura la región. Para ser certificado como tal, el cordero debe cumplir estrictos criterios de calidad que incluyen aspectos de alimentación, peso y procesamiento.

Este proceso comienza con la selección de la raza ovina. Esta debe de ser la Rasa Aragonesa, la Ojinegra de Teruel, la Roya Bilbilitana, la Maellana o la Ansotana. Estas razas no solo son adaptativas a las condiciones geográficas y climáticas de Aragón, sino que también han sido objeto de programas de mejora genética, enfocados en optimizar su resistencia, calidad de carne y eficiencia reproductiva. Este manejo genético es crucial para mantener la sostenibilidad y productividad del rebaño.

Esta tesis se desarrolla alrededor de la raza Rasa Aragonesa, puesto que abarca el 86% de la población de cordero en Aragón. El 97% de esta raza se sitúa dentro del territorio de Aragón, ya que se extiende principalmente dentro del valle del Ebro. A 31 de diciembre de 2023 el censo de animales reproductores en de la raza en Aragón era de 280.362 en 387 explotaciones. Se trata de una raza con un sistema de producción semi-extensivo que tiene como cualidades una elevada rusticidad, instinto gregario, buen instinto maternal todo el año, capacidad lechera suficiente, capacidad de pastoreo y adaptación al medio difícil en que se explota.

Si nos centramos en la producción cárnica, se trata de una raza que produce un tipo de cordero con un mínimo de 40 días en lactancia, con un peso vivo entre 18-26 Kg (8 a 12,5 Kg. de peso canal fría).

Durante el proceso productivo, la cadena de valor se divide en tres etapas: Producción (crianza y alimentación), comercialización y venta (MARM, 2009). Cada una de estas fases involucra a distintos actores, cada uno con roles y desafíos específicos. Aunque este proceso ha permanecido constante en su esencia, ha experimentado evoluciones significativas con la introducción de innovaciones culturales y la sistematización de procedimientos específicos para fortalecer cada segmento de la cadena (De-Pablos-Heredero et al., 2020; Rivas et al., 2019).

La primera etapa comienza con el ganadero, quien desempeña un papel crucial en las fases iniciales: la crianza y gran parte de la alimentación del cordero. No obstante, esta etapa culmina en manos del cebadero, la entidad encargada de finalizar la alimentación y clasificar el cordero para su comercialización. Por último, entra en juego la comercializadora, que recibe la producción y la procesa para su posterior venta.

Para entender la situación actual del sector ganadero ovino en Aragón, es importante comprender los problemas a los que se enfrenta cada agente de la cadena. Por ello, se procede a analizar las problemáticas del proceso respecto al agente que las gestiona.

El peso y su influencia en la rentabilidad de las explotaciones

Uno de los factores que más repercute en la rentabilidad de una explotación es el control del peso. Específicamente en el sector ovino, el peso es una métrica crítica para diversas etapas en la vida del cordero, con especial énfasis en sus primeras fases de crecimiento (Brown et al., 2015). De hecho, monitorear el peso de las ovejas durante su gestación puede proporcionar predicciones valiosas sobre el peso de sus crías, dada la correlación directa entre ambos (Greenwood et al., 1998).

En el caso de la IGP “Ternasco de Aragón”, se calcula que los corderos por encima del peso correcto se venden por 1 euro menos que los corderos con el peso correcto y el coste de alimentación se estima en 3,5 euros más de lo habitual, mientras que un cordero por debajo del peso correcto consume 2 euros menos por alimento, pero se vende por casi 10 euros menos.

Debido a la importancia del control del peso en la ganadería, actualmente se están estudiando diferentes alternativas al pesaje tradicional que no estresen al animal y no interfieran en su rutina diaria. Por ello, la visión por computación se ha convertido en una de las técnicas más interesantes para alcanzar esta meta, ya que es más rápida y menos invasiva que las técnicas tradicionales (Vranken & Berckmans, 2017).

En este contexto, esta tesis aplicará técnicas de visión por computación para abordar esta problemática, ofreciendo una solución más rápida, precisa y menos invasiva para el monitoreo del peso en el ganado ovino. El uso de tecnologías avanzadas promete mejorar la eficiencia y rentabilidad de las explotaciones, optimizando el control y seguimiento del peso en cada etapa del crecimiento.

La grasa como factor clave en la calidad de la carne

El principal factor en la venta de carne es la calidad y ésta está estrechamente ligada al precio de la carne, por lo que se puede decir que para que el ganadero tenga una mayor rentabilidad a través de su explotación, debe cuidar diferentes aspectos a lo largo del crecimiento de

los animales para asegurar una óptima calidad de la carne. Se ha comprobado que la cantidad y calidad de la grasa de un animal contribuye a la percepción de mayor o menor calidad de la carne (Webb & O'Neill, 2008) y, en el caso del cordero, se ha demostrado que afecta al sabor de la carne (Realini et al., 2021).

Además, según la IGP “Ternasco de Aragón” la carne debe de cumplir unos estándares de calidad que van relacionados con el tipo de carne y la cantidad de grasa en la canal (Europeo, 2017). Si se cumplen estos dos requisitos, el ganadero obtendrá una remuneración económica por animal sustancialmente mayor que en el caso contrario.

En el cordero, no existen métodos automáticos que permitan medir la grasa del animal vivo antes del sacrificio y predecir la cantidad de grasa que tendrá en la canal. Para predecir cómo de engrasada estará la canal, los métodos comúnmente utilizados son la palpación de la cola del animal, la estimación visual y la experiencia del ganadero. Estos métodos no son adecuados para determinar la cantidad de grasa que tiene un animal, y mucho menos para clasificarla, ya que no son fiables ni objetivos.

Se han observado diferentes métodos no invasivos de medición de la grasa en otros sectores y especies. Estos incluyen desde mediciones externas del cuerpo del animal (H. J. Fernandes et al., 2010), hasta métodos que utilizan visión por computación con imágenes 3D (Weber et al., 2014) o imágenes de resonancia (Carabús et al., 2016), pasando por el uso de impedancia bioeléctrica (Avril et al., 2013) o el procesamiento de imágenes de ultrasonidos (Quaresma et al., 2013). Esto pone de manifiesto que la inteligencia artificial, por medio de la visión por computación, puede ser un campo en desarrollo dentro del sector que puede ayudar a mejorar la calidad de la carne.

Efectos del corte en la calidad del producto

En el cordero la calidad del producto viene definida por el color, la grasa y el corte de la pieza (Campo et al., 2016). Varias de estas variables pueden ser detectadas antes de su comercialización, elevando y

disminuyendo el precio de la pieza. En el caso del costillar del cordero, el corte de la pieza y el grosor es clave para que su venta se realice en un precio óptimo.

En Aragón y en el resto de España, las costillas de cordero son uno de los cortes más comunes y con mayor valor en el mercado. En Aragón, específicamente, debido a la tradición de consumo local, se acostumbra a solicitar las costillas con un corte muy específico y una presentación determinada. Esta precisión en el corte y la presentación encarece el proceso y eleva el precio final del producto debido a su complejidad. Por ello, es esencial mejorar el procesamiento para optimizar tanto la calidad como la velocidad del corte.

La técnica habitual usada en los mataderos es mediante cuchillas de corte automático, sin embargo, la morfología de los costillares de corderos no permite este tipo de corte. Cuando se utilizan estas cuchillas para cortar los costillares de corderos, el corte atraviesa varias costillas a la vez, generando un mal aspecto de la pieza y astillas, siendo peligroso para el consumidor.

Aunque existen tecnologías de corte que pueden adaptarse a esta situación, como el corte por chorro de agua, actualmente no existe un sistema que detecte las trayectorias para cortar adecuadamente el costillar. En este punto, la visión por computación puede aportar un nuevo punto de vista que permita mejorar este problema.

Además de los problemas mencionados anteriormente, que afectan a alguno de los agentes o a fases del proceso productivo de la cadena de valor ovina, existen factores comunes que dificultan la evolución hacia un sector más sostenible económicamente.

Dentro de estos factores, destaca la naturaleza de la especie. Se trata de una especie gregaria y con mucha actividad física, lo que requiere un manejo del rebaño mucho más complicado que otros sectores. También destaca la escasa tecnificación del sector. Esto se debe principalmente a la alta inversión que requieren la introducción de tecnología y la baja cualificación de los ganaderos y operarios en las nuevas tecnologías. Por otro lado, las herramientas disponibles, en muchas ocasiones no

están adaptadas correctamente a las necesidades del ganadero. Un diseño de las herramientas y servicios adecuados a los usuarios no solo facilitan el trabajo diario, sino que también pueden mejorar el bienestar animal y la sostenibilidad de las prácticas de manejo (Ritzler et al., 2021). Por último, otros problemas globales del sector son el bienestar animal y la sostenibilidad ambiental. Ambos conceptos tienen una relación muy estrecha con el nivel de intensificación de las explotaciones. En concreto, se ha comprobado que a medida que aumenta el nivel de intensificación, mejora el bienestar animal y disminuye la sostenibilidad ambiental (Parés et al., 2023)

Por ello, resulta esencial diseñar y desarrollar herramientas que permitan un equilibrio en la intensificación y modernización de las instalaciones ganaderas ovinas que permita mejorar la sostenibilidad económica de los ganaderos sin comprometer la sostenibilidad ambiental, garantizando un nivel de bienestar animal que no incida negativamente en la calidad del producto final.

En esta tesis, se investigará cómo aplicar inteligencia artificial, especialmente técnicas de visión por computación, para diseñar herramientas que optimicen las etapas de la cadena de valor ovina. Esto incluye el desarrollo de soluciones para controlar el peso, clasificar según el contenido de grasa, y crear herramientas que permitan el corte automático de costillares de cordero, ahorrando costes. El objetivo es encontrar un equilibrio entre la intensificación y la modernización de las explotaciones, promoviendo la sostenibilidad económica sin comprometer la sostenibilidad ambiental. Además, se busca garantizar un alto nivel de bienestar animal que no afecte la calidad del producto final. La implementación de estas tecnologías proporcionará un marco moderno y sostenible para los ganaderos, facilitando su trabajo diario y mejorando la rentabilidad y sostenibilidad de la producción.

2. Objetivos y estructura

2.1. Objetivos

Con todo lo expuesto anteriormente, el objetivo principal descrito en el título de esta tesis es la aplicación de visión por computación para el diseño y desarrollo de productos orientados para la mejora de la cadena de valor de productos ganaderos, más específicamente del sector ovino en Aragón. Para ello se intentarán dar solución a algunos de los problemas presentados en el apartado anterior mediante la aplicación de diferentes técnicas de visión por computación.

A continuación, se muestran los principales objetivos que se abordarán a lo largo de la tesis:

Obj. General. Generar nuevas herramientas adaptadas a las necesidades y el entorno de los agentes de la cadena de valor ovina.

Obj. 1. Diseñar y desarrollar una herramienta mediante técnicas de visión por computación para la estimación y el control del peso respetando el bienestar animal y la sostenibilidad ambiental.

Obj. 2. Diseñar y desarrollar una herramienta mediante técnicas de visión por computación para la detección del nivel de grasa en vivo del cordero y su posterior clasificación respetando el bienestar animal y la sostenibilidad ambiental.

Obj. 3. Desarrollar un sistema que permita la detección de las trayectorias de corte adecuadas en costillares de cordero mediante técnicas de visión por computación.

2.2. Estructura de tesis

Esta tesis se desarrolla a lo largo de diferentes capítulos donde se estudian en mayor profundidad los problemas analizados durante el proceso productivo de la cadena de valor ovina. Todos los estudios desarrollados se centran en la consecución de los objetivos previamente descritos. A lo largo de este documento podremos ver los siguientes contenidos:

Estado del arte

En este capítulo se proporciona una visión general del estado del arte de la inteligencia artificial (IA), sus campos y herramientas. Se examinará su implementación en el sector agroalimentario, resaltando los desafíos que enfrenta este sector, con un enfoque particular en el sector ovino, para luego mostrar algunas estrategias para la mejora del sector. Por último, se presenta el proceso técnico habitual de la visión por computación y las técnicas más comunes utilizadas en un proceso habitual de aplicación de la visión por computación.

Estimación y control del peso mediante técnicas de visión por computación

A lo largo del capítulo se destaca la importancia del peso para la rentabilidad y se propone el uso de la visión por computación para estimar el peso de los corderos de manera no invasiva. Se profundiza en el estudio de las características físicas de la raza de cordero Rasa Aragonesa, enfocándose en cómo estas características pueden ser correlacionadas con el peso y otros indicadores de salud y bienestar animal. Se desarrollan dos dispositivos: LambScan,

que utiliza imágenes 3D para estimar el peso del cordero, y Lamb-Track, una aplicación móvil para la identificación y seguimiento del peso del cordero desde su nacimiento hasta el sacrificio.

Clasificación de corderos según su nivel de engrasamiento mediante imágenes de ultrasonidos

Se detalla el desarrollo y la implementación de un prototipo para mejorar las labores en el cebadero, enfocado en la medición y clasificación de corderos basada en la cantidad de grasa. Se detalla el diseño y desarrollo del prototipo en el que se pesa y se bloquea al animal y del software específico para procesar la imagen capturada y estimar la cantidad de grasa en vivo, lo que permite una clasificación efectiva sin estresar al animal

Detección de trayectorias de corte en costillares de corderos mediante procesamiento de imágenes

En este capítulo se aplica la visión por computación al entorno de las comercializadoras, específicamente para mejorar el proceso de corte de costillares mediante técnicas de visión por computación. Se discute la importancia de un corte preciso y la relevancia de los cortes comunes de carne en el mercado. Se desarrolla un estudio que busca mejorar la precisión del corte de costillares de cordero, utilizando la detección de trayectorias óptimas de corte y un dispositivo de corte por chorro de agua, guiado por algoritmos de visión por computación para seguir las trayectorias detectadas.

Discusión

Se explora la importancia y las implicaciones de los hallazgos de los estudios realizados en el contexto actual del sector ovino, destacando cómo estas investigaciones contribuyen a abordar los desafíos presentes en la industria y a los objetivos planteados.

Conclusiones

Se subrayan la importancia de las herramientas de visión por computación en la cadena de valor ovina. Los cinco estudios realizados mejoran la productividad, sostenibilidad y bienestar ani-

mal. Al reducir el estrés en los animales y optimizar las prácticas, estas herramientas contribuyen a un manejo más sostenible y rentable en el sector ovino.

Resultados de la tesis

Se detallan los artículos de investigación, conferencias, proyectos e hitos alcanzados a lo largo del desarrollo de esta tesis doctoral.

3. Estado del arte

Dentro de este capítulo se desarrollará una revisión del estado del arte para ofrecer una visión completa de la evolución y el estado actual de la inteligencia artificial, destacando sus campos más relevantes y las herramientas impulsoras. Se examinará su implementación en el sector agroalimentario, haciendo hincapié en la ganadería de precisión (PLF), y se resaltarán los desafíos que enfrenta este sector, con un enfoque particular en el sector ovino. Luego, se mostrarán algunas estrategias para la mejora del sector. Por último, se presenta el proceso técnico habitual de la visión por computación, que ha sido el enfoque principal de la tesis, y se describen las técnicas más comunes utilizadas.

3.1. Inteligencia artificial

Dentro del contexto analizado anteriormente, una de las formas de conseguir la mejora en aspectos como la eficiencia, productividad, sostenibilidad y bienestar animal dentro de la cadena de valor ganadera es mediante la inserción de la inteligencia artificial dentro de los procesos de producción (Neethirajan, 2023).

La inteligencia artificial (IA) es un campo que se centra en la creación de programas informáticos capaces de realizar tareas similares a las que realiza la mente humana (C. Zhang & Lu, 2021). Esta disciplina científica, que abarca tanto el aprendizaje como el razonamiento lógico, ha experimentado un desarrollo significativo en los últimos años, hasta el punto de convertirse en un elemento esencial en numerosos sectores de nuestra sociedad.

La IA ha marcado un camino de evolución significativo desde que Alan Turing propuso las bases conceptuales de la computación y la IA a mediados del siglo XX (Turing, 1950). En su artículo de 1950, Turing exploró la posibilidad de que las máquinas pudieran pensar, introduciendo el “Test de Turing” como un criterio para evaluar la inteligencia de una máquina. Esta prueba desafía la capacidad de una máquina para imitar el comportamiento humano al grado de ser indistinguible de este en un formato de conversación. La propuesta de Turing abrió el camino para el desarrollo de sistemas que no solo procesan información, sino que también aprenden y toman decisiones, anticipando conceptos que se volverían centrales en la IA moderna. Esta tecnología emergente se formalizó como campo de estudio en 1956 durante una conferencia en la Universidad de Dartmouth, donde se acuñó por primera vez el término “inteligencia artificial” (McCarthy et al., 2006). Este evento fue el precursor de décadas de investigación y desarrollo, transformando la IA en un área prominente dedicada a emular las capacidades cognitivas humanas mediante máquinas.

Uno de los hitos más notables en la historia reciente de la IA fue el triunfo de AlphaGo sobre el campeón mundial de ajedrez en 2016 (Li Da Xu, 2013), un acontecimiento que no solo reavivó el interés mundial en la IA, sino que también demostró su capacidad para realizar tareas complejas, superando incluso a los expertos humanos en estrategias de juego. Este progreso ha impulsado no solo el desarrollo tecnológico sino también un impacto socioeconómico significativo, marcando el inicio de una nueva era en el desarrollo social y la mejora en la eficiencia laboral (Y. Lu & Xu, 2019).

Definiciones de la Inteligencia Artificial

IA es el término general para la ciencia de la inteligencia artificial. Utiliza ordenadores para simular comportamientos inteligentes humanos y entrena a los ordenadores para que aprendan comportamientos humanos como el aprendizaje, el juicio y la toma de decisiones (Li Da Xu et al., 2021). En la literatura, diversos autores han intentado definir la IA, convergiendo en la idea de que implica máquinas realizando tareas

inteligentes que previamente solo los humanos podían llevar a cabo (B. Huang et al., 2019). Algunas definiciones relevantes incluyen

- Según Peyrou et al. (2019), la IA es la capacidad de un programa informático para llevar a cabo tareas o procesos de razonamiento típicamente asociados con la inteligencia humana.
- Rohit Madan y Mona (2022) definen la IA como un conjunto de tecnologías digitales que permiten a las máquinas aprender y resolver problemas cognitivos de forma autónoma sin intervención humana.
- L. Duan y Xu (2012) consideran la IA como un proyecto de conocimiento que no solo adquiere y analiza conocimiento, sino que también estudia los métodos para expresarlo, empleando estos enfoques para simular actividades intelectuales humanas.
- Según L. Duan et al., (2009), la IA es una compilación de informática, lógica, biología, psicología, filosofía, entre otras disciplinas, y ha logrado avances significativos en áreas como el reconocimiento del habla, el procesamiento de imágenes y el procesamiento del lenguaje natural, así como en la demostración de teoremas automáticos y en la robótica.
- N. Duan et al. (2019) destacan que la IA desempeña un papel crucial en el desarrollo social, contribuyendo de manera revolucionaria a la mejora de la eficiencia laboral, la reducción de costos laborales, la optimización de estructuras de recursos humanos y la creación de nuevas demandas de empleo.

Aunque la IA está experimentando un auge en la actualidad, muchos investigadores iniciaron estudios relacionadas con la IA desde finales del siglo XX (Y. Xu et al., 2019). Con el paso del tiempo y gracias a los avances tecnológicos, la IA ha empezado a acelerar su desarrollo, demostrando un potencial significativo en diversos sectores y transformando de manera fundamental nuestras formas de vida (C. Huang et al., 2019). El progreso de la IA se ha convertido en una importante estrategia de desarrollo a nivel global, mejorando la competitividad nacional y manteniendo la seguridad (Rajkomar et al., 2018). En res-

puesta, numerosos países han implementado políticas preferenciales y han fortalecido la implementación de tecnologías claves y el desarrollo de talentos para posicionarse en la vanguardia de la competencia internacional (Lida Xu et al., 2008).

3.1.1. Campos de la inteligencia artificial

Según Samoili et al. (2020), el término “inteligencia artificial” que utilizamos hoy en día engloba numerosos elementos, conceptos y técnicas que se distribuyen entre una variedad de campos especializados. Estos campos han cobrado gran importancia dentro del desarrollo tecnológico actual, reflejando la complejidad y amplitud que la IA representa en el contexto moderno. La Fig. 3 presenta una lista de los campos más destacados de la IA, los cuales se describen a continuación.

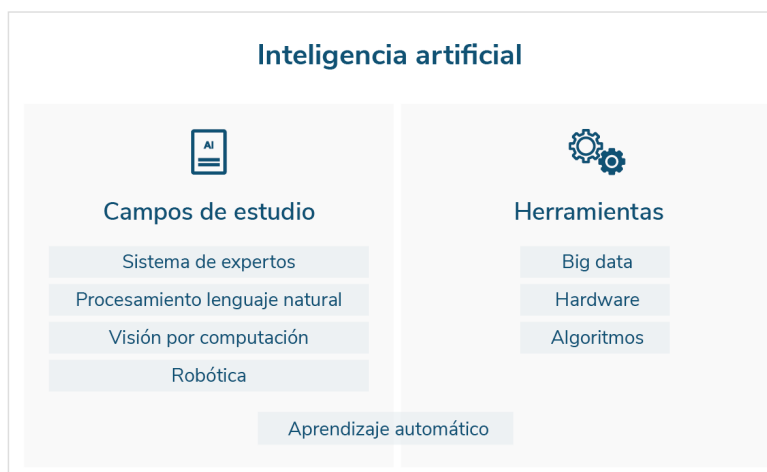


Fig. 3. Principales campos de la IA.

Fuente: Elaboración propia basada en Elbasi et al. (2023), Samoili et al. (2020) y Zhang & Lu, (2021).

Sistema experto (Experts systems):

Un sistema experto, uno de los primeros campos de investigación de la IA, es un programa informático inteligente que simula el conocimiento y los procesos de razonamiento de expertos humanos en un área específica (C. Zhang & Lu, 2021). Su uso está ampliamente extendido en campos como el diagnóstico médico, la prospección geológica y la industria petroquímica. Los sistemas expertos suelen englobar una variedad de sistemas de conocimiento (Miotto et al., 2017), caracterizados por integrar la experiencia de profesionales humanos para replicar sus procesos de pensamiento y resolver problemas complejos que requieren un alto nivel de especialización. Estos sistemas están diseñados para almacenar gran cantidad de información y gestionar procesos de razonamiento en áreas específicas, permitiendo la manipulación simultánea de conocimientos profesionales y experiencia. Su núcleo se basa en una base de conocimientos y un motor de razonamiento (Tung, 2019).

La implementación de un sistema experto comienza con el almacenamiento de conocimientos, experiencia e información de investigación de expertos en un campo específico, almacenándolos en bases de datos y bases de conocimientos. A continuación, mediante un intérprete y un motor de razonamiento, el sistema accede a esta información para ponerla a disposición de los usuarios según sea necesario. Los usuarios interactúan con el sistema a través de una interfaz persona-ordenador (Zappone et al., 2019). En el campo de la enseñanza, los sistemas expertos ofrecen ventajas como la eliminación de las restricciones de tiempo, espacio y el entorno emocional. De hecho, su uso está muy extendido en la educación a distancia, donde sus beneficios son ampliamente reconocidos (Pouyanfar et al., 2019).

Aprendizaje automático (Machine Learning):

El Machine Learning es un campo esencial dentro de la IA que se enfoca en permitir que los ordenadores adquieran conocimiento de manera autónoma (Young et al., 2018). Esta adquisición de conocimiento im-

plica que el conocimiento debe ser expresado y presentado a los ordenadores de manera adecuada para su procesamiento o que los propios ordenadores tengan la capacidad de adquirir y mejorar continuamente el conocimiento en la práctica. Este método se denomina aprendizaje automático (Li Liu et al., 2020).

El estudio del Machine Learning se realiza principalmente para (Z. Liu et al., 2015):

1. Investigar los mecanismos de aprendizaje humano y el proceso de pensamiento del cerebro humano.
2. Examinar los mecanismos de aprendizaje de las personas.
3. Desarrollar métodos de Machine Learning y establecer sistemas de aprendizaje para tareas específicas.

Este campo se sustenta en diversas disciplinas incluyendo ciencia de la información, ciencias del cerebro, neuropsicología, lógica y matemáticas difusas (Hu et al., 2021). Un enfoque destacado dentro del Machine Learning es el Deep Learning, que se basa en redes neuronales artificiales. Algoritmos comunes de Deep Learning incluyen la máquina de Boltzmann restringida (RBM), la red de creencias profundas (DBN), la red neuronal convolucional (CNN) y el autoencoder apilado. Estos métodos ayudan a descubrir las características de distribución de los datos combinando características de bajo nivel para formar categorías de atributos o características de alto nivel (Litjens et al., 2017).

Es habitual encontrar el uso de este campo en disciplinas como la medicina en la detección de enfermedades (Ali et al., 2021), en transporte en la optimización de rutas (Onyango et al., 2022), en el análisis de texto para la detección de los sentimientos de la ciudadanía (Gupta et al., 2021) o en producción para la detección de defectos en piezas (Chen et al., 2023).

Procesamiento de Lenguaje natural o NLP (Natural Language Processing):

El procesamiento del lenguaje natural (NLP) es un campo multidisciplinario dentro de la IA que se centra en la interacción entre los ordenadores y el lenguaje humano (Lauriola et al., 2022). Este campo busca desarrollar algoritmos y modelos que permitan a los ordenadores comprender, interpretar y generar lenguaje de manera similar a como lo hacen los humanos. Para ello, se aplican técnicas de aprendizaje automático y análisis lingüístico con el objetivo de realizar tareas como traducción automática, análisis de sentimientos, extracción de información, generación de texto, resumen automático y reconocimiento de voz (Pugalenthi et al., 2021). Además, el NLP integra conocimientos de lingüística, ciencias computacionales, lógica y matemáticas, enfrentándose a retos como la ambigüedad, el contexto, la polisemia y las sutilezas semánticas del lenguaje humano.

Los avances recientes en modelos de transformers*, como BERT (Bidirectional Encoder Representations from Transformers) (Devlin et al., 2018) y GPT (Generative Pre-trained Transformer) (T. B. Brown et al., 2020), han mejorado significativamente la capacidad de los sistemas de NLP para procesar y generar texto con precisión, expandiendo sus aplicaciones en diversas industrias. BERT es ideal para comprender el significado de una palabra en el contexto de una frase, mientras que GPT se enfoca más en la generación de texto coherente. Además, el desarrollo de aplicaciones como los primeros chatbots y asistentes avanzados como Siri o Alexa muestran la presencia creciente del NLP en nuestro día a día (Caldarini et al., 2022). Sin embargo, este campo también ha evolucionado hacia herramientas aplicadas a sectores específicos que buscan reducir el tiempo de trabajo y aumentar la rentabilidad de los servicios.

Transformers*: se trata de una arquitectura de red neuronal avanzada en el campo de la inteligencia artificial. Se utilizan principalmente para tareas de procesamiento del lenguaje natural (NLP) como traducción automática, generación de texto, y análisis de sentimientos. Fueron introducidos en un trabajo de Vaswani et al. (2017), titulado "Attention Is All You Need". Los transformers permiten procesar palabras, frases y documentos enteros de forma más efectiva que modelos anteriores.

Los sistemas NLP enfrentan desafíos de seguridad (Maedche et al., 2019), como los ataques de inyección de texto, donde un sistema puede ser manipulado para interpretar entradas malintencionadas. Esto podría permitir que alguien cambie el comportamiento del sistema o acceda a información sin autorización. Por ejemplo, en asistentes de voz como Alexa o Siri, podrían usarse para comprar productos sin permiso o revelar datos personales.

Visión por computación (Computer vision):

La visión por computación tiene como objetivo permitir que los ordenadores reconozcan y comprendan el mundo visual de manera similar a los humanos (C. Zhang & Lu, 2021). Esto se logra principalmente mediante algoritmos que identifican y analizan imágenes. En la visión por ordenador, las imágenes se dividen en píxeles que luego son procesados para extraer información. La segmentación de la imagen, juega un papel clave, ya que ayuda a comprender la temática detrás de los píxeles segmentados, permitiendo así el reconocimiento de personas, vehículos y otros objetos en una imagen (Szeliski, 2011). Las aplicaciones más comunes de la visión por computación incluyen el reconocimiento facial, utilizado ampliamente en sistemas de seguridad y aplicaciones móviles, y el reconocimiento de imágenes que permite desde la clasificación automática de fotografías hasta la interpretación de escenas urbanas para mapas digitales (Liangkai Liu et al., 2021; L. T. Tan et al., 2019).

Desde la introducción de AlexNet en 2012 (Krizhevsky et al., 2012), las mejoras en hardware y computación han permitido grandes avances en este campo. A partir de 2015, los métodos de procesamiento de imágenes basados en aprendizaje profundo han revolucionado la clasificación de imágenes, haciendo que el proceso sea más eficiente y efectivo. Entre las arquitecturas más utilizadas se encuentran VGG, ResNet (Red Neuronal Residual) y Startup, que pueden extraer características complejas para mejorar la precisión en la clasificación de imágenes y expandir el potencial de la visión por ordenador en diversos sectores. Este tema se abordará con mayor detalle en la [sección 3.3](#).

Robótica:

La robótica es una disciplina de la IA que se centra en el diseño, la fabricación y la aplicación de robots. Estos robots, sistemas equipados con tecnologías de percepción y actuación, interactúan con el mundo físico para realizar tareas específicas bajo la guía de algoritmos de IA (C. Zhang & Lu, 2021). El campo se dedica a estudiar cómo estos sistemas automatizados, impulsados por IA, pueden entender y manipular su entorno para ejecutar actividades complejas, emulando comportamientos humanos tales como la toma de decisiones y el aprendizaje. Este enfoque se alinea con el objetivo más amplio de la IA de desarrollar sistemas que operen de manera inteligente y autónoma.

Un robot es esencialmente una máquina capaz de simular comportamientos humanos. La investigación en robótica ha avanzado a través de tres generaciones (Jiaying Liu et al., 2018). La primera generación de robots es programable; diseñada para seguir instrucciones almacenadas que ejecutan secuencialmente las tareas predefinidas (L. Lu et al., 2018; Xing Li & Li, 1999; Yang et al., 2014). La segunda generación incluye robots adaptativos equipados con sensores básicos, como visuales y táctiles, que recogen información del entorno para que un procesador central controle sus acciones (W. Zhang et al., 2019). La tercera generación comprende los robots inteligentes (Sodhro et al., 2019), que poseen capacidades cognitivas comparables a las humanas y están dotados de sensores de alta sensibilidad (Sodhro et al., 2019). Estos robots superan las habilidades sensoriales humanas normales, analizando activamente la información percibida para adaptarse y responder a cambios en su entorno, lo que les permite llevar a cabo tareas complejas (Sünderhauf et al., 2018; Tambe et al., 2019).

3.1.2. Herramientas e impulsores

En el contexto de la IA, es indispensable contar con un conjunto robusto de herramientas y tecnologías que faciliten el desarrollo y la implementación de soluciones avanzadas. La IA se nutre del análisis de grandes volúmenes de datos, requiriendo plataformas que permitan la manipulación y el procesamiento eficiente de la información. Esto hace esencial el uso de tecnologías como **big data y plataformas de computación en la nube**, que proporcionan la infraestructura necesaria para almacenar y procesar datos a gran escala (C. Zhang, 2020).

Los avances en **algoritmos** son otro componente crucial. Estos algoritmos, especialmente en áreas como el aprendizaje automático y el aprendizaje profundo, permiten realizar tareas complejas que van desde el reconocimiento de imágenes hasta la traducción automática de idiomas. Su evolución constante impulsa el desarrollo de nuevas aplicaciones y capacidades en la IA (C. Zhang & Lu, 2021). Los algoritmos hacen posible la IA (Chi-Hsien & Nagasawa, 2019) y su evolución constante impulsa el desarrollo de nuevas aplicaciones y capacidades.

El **hardware específico**, como las unidades de procesamiento gráfico (GPU) y las unidades de procesamiento tensorial (TPU), juega un papel fundamental al acelerar el procesamiento de datos y hacer posible la ejecución eficiente de modelos de IA cada vez más complejos (Brynjolfsson & McAfee, 2017). Este hardware especializado es esencial para aprovechar al máximo el potencial de los algoritmos de IA.

Al comprender estos impulsores y tecnologías habilitantes, se puede apreciar cómo han evolucionado y adaptado para satisfacer las necesidades específicas de la investigación y la aplicación práctica de la IA. Además, es importante reconocer que algunos campos de IA, como el **aprendizaje automático** (Machine Learning), no es un área de estudio por derecho propio, sino que también actúa como impulsor y herramienta para el desarrollo de otros campos dentro de la IA. Un ejemplo de ello son los casos en los que el aprendizaje automático se utiliza para mejorar el rendimiento de otros campos como el NLP o la visión por computación (R. Wang et al., 2019). Esta interconexión entre los diferentes campos destaca la naturaleza interdisciplinaria y colaborativa de la IA.

3.2. Aplicaciones de la inteligencia artificial en el sector agroalimentario

El sector agroalimentario enfrenta una serie de desafíos complejos y críticos que afectan su sostenibilidad y capacidad para satisfacer la demanda global. Estos desafíos se agravan debido a la ineficiencia inherente de la industria y las crecientes exigencias de una economía y un clima en cambio (Panetto et al., 2020). Entre los problemas más significativos se encuentran el manejo eficiente de los recursos, la reducción de costos operativos y el impacto ambiental. Además, el crecimiento demográfico mundial, el cambio climático y la seguridad alimentaria son desafíos clave que requieren la adopción de innovaciones orientadas a la sostenibilidad (Latino et al., 2023). Estas innovaciones deben ser capaces de desarrollar nuevos conocimientos y remodelar tanto los métodos de producción como los modelos empresariales para enfrentar estos retos de manera efectiva.

A nivel europeo, programas como “De la granja a la mesa”, la “Estrategia de la UE sobre biodiversidad para 2030” y la iniciativa para “Intensificar la ambición climática de Europa para 2030” destacan entre las estrategias lanzadas por la Comisión Europea (Comisión Europea, 2020). Estas estrategias tienen como objetivo movilizar la investigación y la innovación para promover una transición justa y sostenible hacia sistemas económicos con impacto climático cero (Malorgio & Marangon, 2021).

El sector agroalimentario ha experimentado en los últimos años una tendencia positiva hacia la digitalización (Hernandez et al., 2017). El

desafío ahora es implementar estas tecnologías eficientemente. Los ordenadores, robots, sensores y tecnologías de sistemas inteligentes están cada vez más presentes en todos los procesos agrícolas, desde la maquinaria hasta los sistemas de toma de decisiones (Panetto et al., 2020). La integración de sistemas de apoyo a la toma de decisiones junto con redes y servicios avanzados basados en Internet es crucial, especialmente bajo el enfoque agroalimentario digital 4.0. Este enfoque no solo busca acelerar la adopción de la sostenibilidad y la gestión de la tierra, sino también mejorar la calidad de vida y la competitividad del sector (Hernández et al., 2018).

Estos esfuerzos coordinados y la adopción de tecnologías avanzadas son esenciales para abordar de manera efectiva los desafíos actuales y futuros del sector agroalimentario, garantizando sostenibilidad a largo plazo. La IA se presenta como una herramienta poderosa para abordar estos desafíos, ofreciendo soluciones innovadoras que permiten un enfoque más inteligente y sostenible para la agricultura y ganadería (Di Vaio et al., 2020). La IA puede mejorar la eficiencia mediante el análisis de datos masivos para identificar patrones y tendencias que los humanos no podrían detectar (Miranda et al., 2019).

Por ejemplo, en la agricultura, se utilizan actualmente muchos sistemas con sensorización del entorno, que junto a técnicas de Machine Learning permiten el control del riego, estabilización de temperatura y humedad (Adeyemi et al., 2018; Gu et al., 2021), dosificación de fertilizantes (Arai et al., 2018), o control del crecimiento (Shadrin et al., 2020). Asimismo, los sistemas inteligentes de detección de plagas y enfermedades pueden identificar problemas en cultivos a una escala granular, permitiendo intervenciones rápidas y focalizadas (Elbasi et al., 2023), lo que minimiza el uso de pesticidas y reduce costos. La IA también ayuda a mejorar la lucha frente al cambio climático, proporcionando predicciones más precisas de las condiciones meteorológicas y de las enfermedades emergentes, y ayudando a los agricultores a prepararse para eventos extremos (Weather & Chain, 2020).

En el área de la ganadería, las herramientas de IA han revolucionado el monitoreo y la gestión de la salud animal. Estas tecnologías permiten un seguimiento continuo de la condición de los animales, la detección

temprana de enfermedades y el ajuste automático de los planes de alimentación para maximizar la producción (Fuentes et al., 2022). Además de mejorar la rentabilidad, esta integración tecnológica ha estado estrechamente vinculada a la veterinaria, contribuyendo al bienestar animal y a la calidad del producto final. Aplicaciones como la visión por computación y técnicas avanzadas de aprendizaje automático han optimizado la detección y el monitoreo de enfermedades, aumentando la tasa de natalidad y mejorando las condiciones de vida de los animales (R. Wang et al., 2019).

La IA permite optimizar la cadena de suministro, haciendo que las operaciones sean más ágiles y capaces de adaptarse rápidamente a los cambios en la demanda (Alomar, 2022; Linaza et al., 2021). Mediante el análisis de datos históricos y en tiempo real, los algoritmos predicen la demanda futura y ajustan la producción y distribución, lo que reduce el desperdicio alimentario. Los sistemas de gestión de la producción también mejoran la eficiencia y la rentabilidad (Shaikh et al., 2022). En etapas avanzadas del proceso productivo, la visión por computación se implementa para identificar productos en mal estado o no deseados y llevar a cabo controles de calidad (Hemamalini et al., 2022). Esto garantiza que los productos cumplan con las normativas y estándares establecidos, reafirmando el compromiso de ofrecer lo mejor a los consumidores.

Desde hace algunos años, al igual que en medicina, se llevan utilizando diferentes técnicas de IA para detectar enfermedades en diferentes órganos del cuerpo de los animales. Habitualmente se utilizan técnicas de aprendizaje automático y visión por computación para la detección de enfermedades relacionadas con el corazón, los pulmones, el cerebro, el corazón o el hígado (Hennessey et al., 2022). Sin embargo, es un campo que está en pleno desarrollo, y que está comenzando a incorporarse en ganadería, ya que la mayoría de los avances se han realizado en el sector canino y felino.

La integración de tecnología en el entorno ganadero para aumentar la productividad, mejorar el bienestar y la salud animal, y reducir el impacto ambiental se conoce como “Ganadería de precisión” o PLF (Precision Livestock Farming) (Cox, 2003). A través de la captura, el análisis

y la transmisión en tiempo real de datos, estas tecnologías permiten el monitoreo individual o en grupo de los animales. El objetivo principal es asegurar una gestión eficiente y sostenible, optimizando el uso de los recursos disponibles mientras se prioriza el bienestar y la salud de los animales (Berckmans, 2014; Vranken & Berckmans, 2017).

3.2.1. Desafíos de la IA en el sector agroalimentario

En resumen, la IA ofrece un camino hacia la transformación del sector agroalimentario al permitir que las operaciones sean más eficientes y sostenibles frente a un entorno en constante cambio. La implementación de IA en este sector no está exenta de desafíos. El primero es la falta de datos de calidad. Los modelos de aprendizaje automático y otras técnicas de IA requieren grandes volúmenes de datos precisos para proporcionar predicciones útiles (Linaza et al., 2021). Sin embargo, muchas explotaciones agrícolas no cuentan con la infraestructura o el conocimiento para recolectar y organizar estos datos de manera efectiva. Además, existen variaciones en las prácticas agrícolas y las condiciones climáticas que hacen que la estandarización de datos sea un problema complejo de abordar (Niemann et al., 2011).

Por otro lado, otro de los principales retos para la aplicación de la IA incluye la escasa replicabilidad y la correspondiente dificultad para la recopilación sistemática de datos, ya que no hay dos campos exactamente iguales (Linaza et al., 2021). Otro desafío significativo es la resistencia de los productores a adoptar nuevas tecnologías (Carmela Annosi et al., 2020). Esto puede deberse a la percepción de altos costos iniciales, falta de confianza en la eficacia de las soluciones tecnológicas o a la dificultad para comprender los beneficios de la transformación digital (Ciruela-Lorenzo et al., 2020). En algunos casos, los productores también pueden temer que la digitalización provoque la pérdida de empleos o la dependencia de tecnologías externas (Pfeiffer et al., 2021).

Las limitaciones técnicas (Elbasi et al., 2023) también obstaculizan el despliegue de soluciones de IA. Las tecnologías de sensores y los sistemas de comunicación en áreas rurales pueden ser deficientes, lo que

dificulta la recopilación de datos en tiempo real. Además, el costo de los equipos especializados (Carmela Annosi et al., 2020), como drones y maquinaria automatizada, puede ser elevado para pequeños agricultores y productores.

Además de los desafíos comunes en el sector agroalimentario, como la sostenibilidad ambiental, la rentabilidad económica y el bienestar animal, el sector ovino enfrenta una serie de desafíos específicos que lo diferencian de otras áreas.

Uno de los principales desafíos es la peculiaridad de la especie ovina. Muchas tecnologías que son efectivas para otras especies no se pueden aplicar a las ovejas debido a sus características específicas. Los ovinos son animales gregarios y tienen un nivel de actividad física más elevado, lo que complica el manejo de los rebaños y lo hace más laborioso en comparación con otras especies. Además, la presencia de lana en los ovinos dificulta muchas de las tareas diarias que son más sencillas en bovinos y porcinos. Por otro lado, la cría de ovejas generalmente se lleva a cabo en sistemas extensivos o semi-extensivos, lo que implica que los ganaderos deben dedicar mucho más tiempo durante el desarrollo de los animales. Todos estos factores resultan en una menor rentabilidad económica para los ganaderos debido a la mayor inversión de tiempo.

Otra cuestión importante es la baja tecnificación en el sector. En la literatura se observa que las granjas tecnificadas son más eficientes, y aportan beneficios medioambientales y económicos (Lovarelli et al., 2020). Sin embargo, este sector no ha evolucionado adecuadamente en cuanto a tecnología se refiere. Las principales causas son la alta inversión que requieren estos sistemas y la baja cualificación de los ganaderos y operarios en las nuevas tecnologías. Debido al auge de otros sectores se ha producido un abandono de ganaderías ovinas. Por esta razón, aquellas que han sobrevivido tiene una población humana envejecida que esta poco preparada para el manejo de nuevas tecnologías, y en muchas ocasiones se posicionan en contra a la introducción de tecnologías en el proceso (Bewley & Russell, 2010).

Por último, existen dos problemas que afectan a diferentes puntos de la cadena de valor, la sostenibilidad y el bienestar animal. Ambos concep-

tos van ligados directamente a la intensificación de las instalaciones. Se ha comprobado que cuanto más intensificada está una explotación, mayores beneficios económicos se obtiene de los animales, sin embargo, en el mismo estudio se observa como la sostenibilidad ambiental es inversamente proporcional a la sostenibilidad económica de la explotación (Ripoll-Bosch et al., 2012).

En el caso del bienestar animal ocurre algo similar. Aunque existen más valores que afectan al bienestar animal, los aspectos más determinantes residen en las prácticas de manejo y en los métodos de producción. Hay estudios que demuestran que los animales que se crían y se producen en explotaciones intensificadas obtienen mejores valores en cuanto a la condición corporal y estado de salud, en cambio tienen más golpes y problemas de motricidad (Parés et al., 2023). Por otro lado, uno de los aspectos más importantes para el consumidor final español es conocer si se ha respetado el bienestar animal en el proceso de producción del producto. Existen estudios que demuestran que se trata de un tema de concienciación, más allá de la oferta y la demanda (Estévez-Moreno et al., 2021) y que estarían dispuestos a pagar un precio mayor por productos que mejoren el bienestar animal en su proceso de producción (María, 2006).

3.2.2. Estrategias para el manejo y mejora del sector ovino

Como se ha mencionado en la introducción, la raza Rasa Aragonesa, presenta una serie de desafíos específicos que requieren soluciones especializadas debido a sus características particulares. Estos problemas están vinculados principalmente con el control del peso de los corderos, la evaluación de la grasa en vivo, y el corte de las costillas una vez que los animales han sido llevados al matadero. La ausencia de herramientas específicas para el manejo, control y gestión de esta raza complica aún más estas tareas. Muchas de las herramientas de uso habitual no se han adaptado a las nuevas formas de manejo y control del animal. Esta falta de adaptación limita la competitividad del sector frente a sus competidores.

Un diseño de las herramientas y servicios adecuados a los usuarios no solo facilitan el trabajo diario, sino que también pueden mejorar el bienestar animal y la sostenibilidad de las prácticas de manejo (Ritzler et al., 2021). Para lograr un diseño efectivo, es crucial comprender las necesidades, deseos y limitaciones del usuario. El Diseño Centrado en el Usuario (DCU) (Norman, 1986) es una filosofía que busca desarrollar soluciones adaptadas a los usuarios finales. Este enfoque puede aumentar significativamente la eficiencia y productividad en el sector ovino, ya que, al situar al usuario en el centro del proceso, las soluciones serán más fácilmente adoptadas y valoradas. Comprender las características y desafíos del sector ovino, en particular de la raza Rasa Aragonesa, permitiría utilizar las herramientas de diseño centrado en el usuario para proporcionar soluciones efectivas que superen las dificultades señaladas anteriormente en la literatura.

Por otro lado, el DCU también puede ayudar a mejorar la tecnificación del sector, ya que los productos diseñados centrados en el usuario enfocados en el uso sencillo influye en la adopción o abandono del dispositivo (Johnson et al., 2011; Tang & Patel, 1994). Si los ganaderos encuentran que una herramienta es intuitiva y resuelve un problema concreto, es más probable que la adopten y la integren en sus prácticas diarias. Este enfoque también ayuda a reducir errores en la operación de herramientas y equipos (Walden et al., 2020), lo que mejora la seguridad y puede reducir los costos asociados con el mal uso de equipamiento o la pérdida de ganado.

Las soluciones empleadas hasta ahora en el sector agroalimentario han dependido principalmente del uso de sensores. Aunque estos dispositivos aportan datos valiosos, su implementación frecuentemente requiere intervención humana directa o modifica el entorno natural de los animales, alterando su comportamiento habitual. Por ejemplo, es común la incorporación de sistemas que controlan la alimentación mediante sensores de pesado o por el monitoreo del número de veces y la duración de las comidas del animal (Oliveira et al., 2018). Estos dispositivos no solo optimizan la administración del alimento sino que también proporcionan información crucial sobre los hábitos alimenticios, mejorando el desarrollo animal y la rentabilidad de la alimentación suministrada.

Además, otra aplicación frecuente es la integración de sistemas de regulación de temperatura, que permiten un control ambiental detallado y adaptativo. Mantener las condiciones ideales para el bienestar y desarrollo de los animales es crucial, y asegurar que el ambiente se mantenga a una temperatura óptima favorece su crecimiento y salud. Investigaciones han demostrado que los animales que se desarrollan en condiciones térmicas ideales muestran una mayor eficiencia productiva (Ahmad et al., 2019; Tresoldi et al., 2019).

También es común el desarrollo de dispositivos wearable para los animales. Estos wearables se utilizan para diversos fines, pero predominan aquellos destinados a monitorear el estado de salud del animal, ya sea midiendo sus constantes vitales (Neethirajan, 2017) o detectando su posición y movimiento (Achour et al., 2019). La utilidad de estos dispositivos radica en su capacidad para proporcionar datos en tiempo real sobre el estado del animal, permitiendo predecir y tratar posibles enfermedades con antelación.

Estas herramientas, aunque útiles, subrayan la necesidad de desarrollar sistemas que minimicen la intervención física y el impacto en el comportamiento natural de los animales. En este contexto, la visión por computación emerge como una solución avanzada en la ganadería de precisión, ya que permite la recopilación de datos sin invadir el entorno del animal ni afectar su bienestar, facilitando una observación continua sin estímulos externos y proporcionando una visión más auténtica del comportamiento natural de los animales.

La integración de cámaras en el entorno animal posibilita la observación continua sin estímulos externos, proporcionando una perspectiva auténtica del comportamiento de los animales. Esto permite monitorear patrones como la frecuencia de alimentación o consumo de agua, así como la duración de estas actividades. Además, esta tecnología ha demostrado ser eficaz para analizar comportamientos relacionados con el bienestar animal, como la agresividad, el tiempo de descanso y las anomalías en el movimiento, lo que facilita la detección temprana de enfermedades. Los estudios realizados con cámaras 2D y 3D han demostrado la eficacia de la visión por computación en el entorno agroalimentario (Achour et al., 2020; Nasirahmadi et al., 2017).

Esta avanzada capacidad de visión por computación se alinea perfectamente con las necesidades emergentes del sector agroalimentario, donde se busca minimizar la intervención humana manteniendo un monitoreo preciso y efectivo. Al implementar cámaras que operan de manera autónoma y discreta, se obtiene información valiosa sobre el comportamiento natural de los animales, mejorando no solo la gestión y el cuidado de los mismos, sino también optimizando los procesos de producción y garantizando un mayor respeto por el bienestar animal. Estas innovaciones representan un cambio significativo en la manera en que los animales son observados y gestionados en granjas, promoviendo prácticas más éticas y sostenibles.

Esta tecnología se presenta como una solución innovadora para abordar desafíos específicos de la raza Rasa Aragonesa. Estos desafíos incluyen la precisión en el control del peso de los corderos, la evaluación efectiva de la grasa en vivo, y la mejora en el proceso de corte de las costillas en el matadero.

En el ámbito del control de peso, investigaciones previas han aplicado tecnologías de visión por computación para estimar el peso de animales como cerdos y vacas Holstein utilizando imágenes procesadas y análisis mediante redes neuronales artificiales (Kuzuhara et al., 2015; Nir et al., 2018; Tasdemir et al., 2011; Y. Wang et al., 2008; Yongsheng Wang et al., 2006). En el sector ovino, la adopción de técnicas avanzadas es limitada. Actualmente, solo una minoría de los ganaderos emplea métodos regulares de pesaje, y la mayoría lo hace de manera manual, lo cual puede ser inexacto y estresante para los animales (Adzitey, 2011; Ferguson & Warner, 2008; Jones et al., 2011).

En cuanto a la evaluación de la grasa, aunque existen tecnologías para la clasificación automática de la grasa en canales de vacuno y cerdos (De La Iglesia et al., 2020; Lucas et al., 2017), estas técnicas podrían extenderse al sector ovino para garantizar una clasificación precisa que influya positivamente en la calidad y el valor del producto final justo antes del sacrificio.

Por último, en el proceso de corte, la implementación de tecnología de visión por computación podría optimizar la precisión en las comercia-

lizadoras. Actualmente, el uso de cuchillas automáticas está limitado por la fisonomía variable de los costillares de cordero, lo que puede resultar en cortes imprecisos y astillados, afectando la presentación y la seguridad del producto (Scozzafava et al., 2016). La visión por computación podría ofrecer una alternativa para realizar cortes más precisos y seguros, mejorando la estética y el valor económico de la carne en los puntos de venta.

Esta integración de la visión por computación no solo responde a las necesidades específicas de la raza Rasa Aragonesa, sino que también se alinea con las tendencias actuales en la ganadería de precisión, promoviendo prácticas más eficientes y sostenibles que benefician tanto al ganadero como al consumidor final. Además, en los últimos tiempos, la visión por computación se ha convertido en una tecnología más accesible, lo que facilita su implementación y amplía su impacto en el sector.

3.3. Desarrollo del proceso de visión por computación

Dado que la visión por computación es un componente clave para evaluar el estado del sector ovino y, en particular, de la raza Rasa Aragonesa, esta sección presentará el proceso técnico necesario para la adquisición de imágenes, el preprocesamiento y la segmentación de los elementos relevantes, así como la extracción de datos para su posterior procesamiento mediante diversos algoritmos. Además, se analizará la implementación y la importancia del aprendizaje automático y profundo en estos procesos para la extracción y gestión de datos.

3.3.1. Adquisición de imágenes

En cualquier proceso de visión por computación, el primer paso es la obtención de los datos visuales. Esta adquisición viene definida por las necesidades de los datos de salida y por lo tanto por el tipo de dato que se necesite obtener al final del proceso. Existen dos formatos de adquisición de imágenes, en formato de imagen estática o en formato de video. Este último formato permite el procesamiento de la imagen a tiempo real si así lo deseamos o necesitará un preprocesado para convertirlo en el primer formato. En cualquiera de los casos lo más habitual es encontrar imágenes formadas por matrices de dos dimensiones en escala de grises (2D) o formadas por matrices de tres dimensiones si estas se componen de color y/o profundidad (3D).

Los dispositivos más comunes para la adquisición de imágenes suelen ser cámaras que se pueden encontrar en dispositivos móviles o cámaras convencionales de foto y video. Sin embargo, en muchas ocasiones la finalidad requiere de datos más específicos que solo pueden ser captadas por cámaras técnicas. Dentro de este espectro de dispositivos, es muy habitual encontrar cámaras con sensor de profundidad. Aunque este tipo de cámara ya venga incorporada en algún dispositivo móvil lo normal es capturar las imágenes con cámaras especializadas como puede ser Microsoft Kinect (Lachat et al., 2015), Intel Realsense (Siena et al., 2018) o Zed de Stereolabs (Tadic et al., 2022). Esta última, al igual que otros modelos en los últimos años dispone de tecnología LIDAR (Light Detection and Ranging, o Detección y Rango por Luz) (Jaboyedoff et al., 2012). Esta tecnología es un método de detección y medición que utiliza pulsos de luz láser para examinar y mapear objetos o superficies, lo que permite determinar la distancia y la forma de los objetos, generando datos en forma de mapas 3D muy detallados.

Además de estas cámaras, en casos todavía más especializados, se pueden utilizar cámaras térmicas (Villa et al., 2020), rayos X (Rafiei et al., 2023) o dispositivos de ultrasonidos (S. Liu et al., 2019). En estos casos, este tipo de cámaras permite la captura de imágenes de zonas localizadas a las que el ojo humano no tiene acceso, permitiendo una valoración de estas zonas sin intervenir en el bienestar del sujeto. Estas imágenes suelen variar en color, intensidad, brillo o saturación según los elementos que se capturen (Fig. 4).

Además de la tipología de imagen para satisfacer el tipo de datos necesarios para la finalidad del estudio, también se ha de tener en cuenta la colocación de la cámara. En la mayoría de las situaciones es necesario un soporte específico para mejorar la calidad de los datos obtenidos. Muchos de estos soportes consisten en fijaciones o pequeños sistemas de anclaje que permite al usuario modificar la altura, ángulo o posición de la cámara. Hay ejemplos de cámaras incluidas en dispositivos portátiles como móviles o gafas (Betancourt et al., 2014; Jeelani et al., 2018), o cámaras manejadas autónomamente por dispositivos robóticos (Álvarez-Aparicio et al., 2021; Sheu & Tsai, 2017) o incluso ancladas a dispositivos aéreos como drones (Irizarry & Costa, 2016; Kim & Kim, 2018).




Fig. 4. Tipo de imagen. A. Imagen 2D. B. Imagen 3D (color). C. Imagen 3D (profundidad). D. Imagen térmica. E. Imagen de rayos. F. Imagen de ultrasonidos.

Fuente: Elaboración propia.

Por otro lado, un variable importante a tener en cuenta en la adquisición de datos, es la iluminación. Depende de la situación, o del entorno, muchas veces las condiciones de iluminación no son las adecuadas para una toma de datos correcta u óptima. En algunas ocasiones es necesario obtener todas las imágenes con el mismo tipo de iluminación ([Elango & Karunamoorthy, 2008](#)), sin embargo, en otras necesitamos todo lo contrario, iluminaciones contrarias, con mucha iluminación y con mucha oscuridad ([Mahmood et al., 2021](#)).

Teniendo en cuenta todas estas situaciones, en muchas ocasiones las imágenes tomadas no siempre tienen la calidad deseada. Debido a la colocación de la cámara, al entorno o a la iluminación, muchas veces las imágenes tienen ruido, o no se consigue captar la región de interés adecuadamente. Por ello, y a veces exclusivamente porque la tipología de la imagen y los datos necesarios lo requieren, es necesario realizar un filtrado y/o un preprocesado de las imágenes captadas ([He et al., 2013](#)).

3.3.2. Preprocesado

En el ámbito de la visión por computación, es esencial considerar diversos factores que pueden influir en la calidad y claridad de las imágenes. Elementos como el ruido, las vibraciones y el desplazamiento de los objetos en la imagen pueden alterar la interpretación correcta de la misma, haciendo esencial un paso de preprocesado antes de cualquier análisis posterior.

Uno de los métodos más comunes en el preprocesado es el recorte de la imagen, centrando la atención en una región específica de interés, ya que en muchas ocasiones los resultados mejoran cuando solo se estudian pequeñas porciones de la imagen (Fernández-López et al., 2014). Cuando se trabaja con videos, esta técnica puede ampliarse a recortar segmentos enteros de un clip o a seleccionar y extraer fotogramas particulares que sean relevantes para el objetivo del análisis.

El color, por otro lado, desempeña un papel crucial en cómo se interpreta una imagen. Aunque las imágenes a menudo se presentan en el espacio de color RGB, hay ocasiones en las que es beneficioso cambiar a otros formatos de color, como HSI, HSV o incluso a escala de grises. Estos cambios permiten abordar ciertos desafíos, como problemas de definición, o enfatizar detalles específicos en una imagen que de otra manera podrían pasarse por alto. En muchas ocasiones para mejorar los resultados posteriores, se somete a la imagen a una corrección del histograma mediante ecualizaciones del histograma adaptativas o CLAHE (Contrast Limited Adaptive Histogram Equalization) (Pizer et al., 1990).

Otro desafío en el procesamiento de imágenes es la cantidad y consistencia de los datos. No siempre se obtiene un conjunto de datos amplio y diverso que permita un análisis exhaustivo. Para superar este obstáculo, es común emplear técnicas que aumenten la cantidad de datos disponibles. Estas técnicas incluyen rotaciones de la imagen, recortes aleatorios y modificaciones en la forma, como estiramientos o compresiones (Shorten & Khoshgoftaar, 2019). Estas transformaciones no solo enriquecen el conjunto de datos, sino que también pueden ayudar a mejorar la robustez de los modelos entrenados con estos datos.

3.3.3. Segmentación

Se denomina segmentación al proceso de dividir una imagen en diferentes partes o regiones, generalmente para identificar objetos, texturas u otras características significativas. A estos elementos se les denomina regiones de interés (ROI) de la imagen. Existen diferentes tipos de segmentaciones que se pueden agrupar en, “semántica”, cuando todos los píxeles de la imagen se clasifican en categorías e “instancias” cuando además de la clasificación por categorías también se anotan los objetos. Esto hace que en el primer caso todas las sillas de una imagen pertenezcan a la categoría sillas, pero no se pueda identificar que silla es diferente a otra, mientras en el segundo caso cada silla tiene un identificador que las distingue.

En ambos casos, la máscara de los objetos dota de información que permite identificar esos píxeles necesarios para la categorización de un ítem. La máscara de un objeto es la matriz binaria del mismo que se utiliza como filtro o plantilla para aplicar otras operaciones a áreas específicas de la imagen. De ella se puede conseguir, el área (calculando el número de píxeles), el bounding box (obteniendo el contorno), la elipse que lo circunscribe, o los ejes de la misma.

Las técnicas tradicionales más comunes para obtener dicha máscara es la obtención del umbral entre píxeles blancos y negros, como por ejemplo el método Otsu (Otsu, 1979), el cual identifica el umbral medio de dichos píxeles según el histograma de la imagen. Otro tipo es la segmentación por detección de bordes con diferentes técnicas de detección como Sobel (Daponte & Fox, 1988; Z. Wang et al., 2018) o Canny (Canny, 1986; Jian Liu et al., 2022) o la segmentación por clustering en la que se clasifican los píxeles según la similitud con sus vecinos (Coleman & Andrews, 1979; Mittal et al., 2022; Rafiei et al., 2023).

3.3.4. Machine Learning y Deep Learning

Estos procesamientos de la imagen permiten al usuario disponer de un amplio conjunto de datos. Sin embargo, en muchas ocasiones esta cantidad de datos supera la capacidad de análisis y procesamiento del ser humano. Es aquí donde entra en juego la tecnología de computación, siendo los ordenadores herramientas indispensables para analizar y extraer información valiosa de estos conjuntos de datos.

El método predominante para tratar estos datos es el Machine Learning, que, mediante el uso de algoritmos específicos, tienen la capacidad de aprender y mejorar su desempeño de forma autónoma, sin intervención humana directa (Samuel, 1959). Sin embargo, el Machine Learning en ocasiones precisa una estructuración o procesamiento previo de los datos. Dependiendo de la cantidad de datos de los que dispongamos, esto puede volverse una tarea tediosa.

En este aspecto, gracias a las mejoras computacionales de los últimos años, el Deep Learning ha revolucionado este campo, ya que permite el trabajo con datos en bruto y con una mayor cantidad de datos. El término Deep Learning, acuñado por Rina Dechter (1986), hace referencia a las redes neuronales artificiales profundas, que son estructuras computacionales inspiradas en la manera en que las neuronas en el cerebro humano procesan la información. Estas redes, conformadas por múltiples capas de nodos o “neuronas”, son expertas en manejar y aprender de grandes cantidades de datos, incluso si estos son no estructurados o altamente complejos.

La principal diferencia entre ambos procesos es que el modelo de Machine Learning necesita alimentar al modelo con la imagen y un vector de características obtenidas con los métodos previamente descritos. Un vector de características es la representación numérica que contiene las propiedades o atributos más relevantes de un objeto, instancia o conjunto de datos. Por el contrario, el Deep Learning solo necesita la propia imagen como dato de entrada al modelo.

A estos últimos modelos de procesamiento de imágenes se los conoce como redes neuronales convolucionales (CNN). Estas redes toman su

nombre de la operación de convolución, que implica la aplicación de un filtro o núcleo específico a la imagen para extraer características relevantes (Kurek et al., 2017). Este concepto comenzó a desarrollarse con LeNet la que es considerada la primera CNN (Lecun et al., 1998), y se consolidó con AlexNet la cual introdujo el procesamiento mediante GPU (Krizhevsky et al., 2012). A partir de las arquitecturas de CNN han ido experimentando cambios resaltan VGG (Simonyan & Zisserman, 2015), GoogleNet (Szegedy et al., 2015), ResNet (He et al., 2016) y EfficientNet (M. Tan & Le, 2019).

Sin embargo, una limitación inherente de las CNNs es su necesidad de grandes conjuntos de datos etiquetados para entrenarse de manera efectiva. Ante este desafío, surge una técnica conocida como aprendizaje por transferencia (Guo et al., 2018). Esta estrategia implica tomar modelos que ya han sido entrenados en vastos conjuntos de datos y después refinarlos o adaptarlos usando un conjunto de datos más pequeño y específico para el problema en cuestión.

Las arquitecturas de detección de objetos basadas en redes neuronales se clasifican principalmente en dos categorías: redes de dos etapas y redes de una sola etapa. Las redes de dos etapas, como R-CNN (Girshick et al., 2014), Fast R-CNN (Girshick, 2015) y Faster R-CNN (Ren et al., 2017), realizan la detección en dos pasos distintos, primero proponiendo regiones de interés y luego clasificando los objetos dentro de estas regiones, lo que las hace más precisas pero generalmente más lentas. Por otro lado, las redes de una sola etapa, como YOLO (Redmon et al., 2016), SSD (W. Liu et al., 2016) y RetinaNet (Lin et al., 2017), realizan la detección y clasificación de objetos en una única pasada, ofreciendo velocidades de procesamiento más rápidas a costa de una precisión ligeramente reducida.

A lo largo de la evolución reciente en el campo de la IA, es notable que la mayoría de las investigaciones se han centrado en las especies de mayor consumo como el porcino y el vacuno. Sin embargo, este avance tecnológico no se ha reflejado en el sector ovino con la misma intensidad, especialmente en la raza Rasa Aragonesa, donde la aplicación de tecnologías avanzadas ha sido limitada. Dada esta situación y las problemáticas específicas observadas en este sector, la implementación de

tecnologías como la visión por computación, apoyada en el aprendizaje automático, se presenta como una solución prometedora que puede adaptarse a las necesidades particulares del sector ovino. Esta adaptación no solo fomentaría el bienestar animal y la sostenibilidad, sino que también impulsaría la rentabilidad y eficiencia del sector.

Este enfoque es el fundamento de la presente tesis, que se dedica a desarrollar y validar herramientas de IA específicamente diseñadas para la raza Rasa Aragonesa. La investigación aborda este vacío en la literatura y en la aplicación práctica, ofreciendo una serie de estudios que no solo prueban la viabilidad de estas tecnologías en el sector ovino, sino que también establecen un modelo para su implementación futura. A continuación, se detallarán las investigaciones desarrolladas, evidenciando cómo cada una contribuye a la solución de los problemas identificados y a la mejora general del manejo ovino.

4. Estimación y control del peso mediante técnicas de visión por computación

El peso es uno de los factores clave en las primeras fases de producción del cordero. Como se ha mencionado con anterioridad, se trata de uno de los aspectos que más influyen en la rentabilidad de una explotación, y que, actualmente no se controla adecuadamente. El problema de la falta de control del peso en corderos viene dado por la inexistencia de herramientas que faciliten la tarea al ganadero. Las herramientas habituales no están adaptadas al entorno y generan demasiado estrés en los animales. Esto a su vez empeora el manejo y el bien estar animal, provocando una peor calidad del producto final (Adzitey, 2011; Ferguson & Warner, 2008).

Para evitar estas situaciones, es necesaria una transformación tecnológica del sector, aunque esto implica una inversión económica y para muchos ganaderos, estos costes iniciales no entran dentro de sus posibilidades. A esto se suma una tradicional reticencia por parte de algunos ganaderos a adoptar tecnologías emergentes, un factor que ha entorpecido la modernización de las instalaciones ovinas y la optimización de su rendimiento (Ruan et al., 2019). Sin embargo, en la actualidad, la accesibilidad y los costes de estas tecnologías son cada día menores, lo que abre una nueva puerta a un tipo de ganadería que en muchas especies animales está muy extendida: la ganadería de precisión.

En este contexto, el presente capítulo aborda diferentes soluciones tecnológicas basadas en técnicas de visión por computación que permitan

al ganadero pesar sus corderos con un bajo coste, un mínimo esfuerzo y sin generar estrés al animal, favoreciendo la innovación y revitalizando el sector ovino en Aragón, particularmente en áreas de crianza y alimentación del cordero.

4.1. Morfometría de la raza de cordero Rasa Aragonesa

Para abordar de manera efectiva los objetivos delineados previamente, resulta esencial tener un entendimiento profundo de la morfología de los animales que constituyen el núcleo de nuestro estudio. Tal como se ha señalado, esta investigación se concentra en fortalecer y comprender el sector ovino, específicamente enfocándose en la raza Rasa Aragonesa, que forma parte de la IGP “Ternasco de Aragón”.

Desde la perspectiva de la visión por computación, uno de los factores cruciales es entender la correlación entre las características físicas del sujeto de estudio y las variables que se buscan anticipar.

Para desarrollar soluciones tecnológicas adaptadas y alineadas a las necesidades del sector que permitan predecir el peso de los corderos a través de visión por computación, es esencial encontrar una correlación entre el peso y ciertas medidas morfométricas del animal. Una revisión bibliográfica ha revelado la existencia de numerosos estudios que han formulado modelos y algoritmos para estimar el peso en vivo de un animal basándose en ciertas medidas morfométricas (Afolayan et al., 2006; Atta & El Khidir, 2004; Sowande & Sobola, 2008; Topal & Macit, 2004; Yilmaz et al., 2012).

Por último, al enfocarnos en las medidas específicas de la raza Rasa Aragonesa, podemos adquirir un conocimiento más profundo y detallado sobre la morfología del cordero. Esta información resultará muy valiosa al diseñar herramientas tecnológicas adaptadas a las diversas etapas de la cadena productiva.

4.1.1. Adquisición de datos

Para la realización de este estudio morfométrico se tomaron medidas a 86 corderos de la raza Rasa Aragonesa. Teniendo en cuenta las especificaciones de la IGP “Ternasco de Aragón”, se intentaron que los corderos seleccionados para el estudio cumplieren con el rango de peso (18-26 kg, 8-12,5 kg d peso en canal fría). Los corderos que se han estudiado tenían un peso medio de 22,31 Kg con una desviación típica de 3,36 Kg, un peso máximo de 30,1 Kg y un peso mínimo de 15,2 Kg.

Inicialmente se tomaron diferentes medias del cordero entre las que se encontraban las siguientes: altura de cruz (A), perímetro torácico (PT), perímetro máximo (PM) y perímetro posterior (PP), anchura delantera (AD) tomada justo detrás de las patas delanteras, anchura máxima (AM) tomada en la parte más prominente del lomo y anchura trasera (AT) tomada justo delante de las patas traseras y longitud del cuerpo tomada desde la cruz a la grupa (L), como se observa en la Fig.5. Sin embargo, posteriormente se rechazaron las medidas altura a la cruz, perímetro torácico, perímetro máximo y perímetro posterior, ya que eran medidas imposibles de obtener mediante una imagen cenital del cordero.



Fig. 5. Esquema de las medidas tomadas.
Fuente: Elaboración propia.

Para cada una de estas medidas se realizaron tres mediciones y posteriormente se calculó la media aritmética de las mismas. Para evitar cualquier tipo de sesgo en la evaluación, todas las medidas fueron tomadas por un mismo técnico con el uso de las mismas herramientas y en todos los casos fue asistido por un veterinario para la manipulación del animal durante las mediciones como se puede ver en la Fig.6. Asimismo, todos los corderos fueron pesados en una báscula electrónica que tomaba 20 medidas en 6 segundos y que calculaba el valor medio de todas ellas, dato que fue registrado como peso final de cada cordero.

Todas las medidas, tanto de peso como morfométricas, fueron tomadas a la misma hora del día, entre las 11:00 y las 13:00 h, cuidando que todos los corderos estuvieran en las mismas condiciones de alimentación e hidratación.



Fig. 6. Posición y herramientas de la toma de medidas en el cebadero.

Fuente: Elaboración propia.

4.1.2. Algoritmo de estimación de peso

Inicialmente, se realizó un modelo lineal general a partir del sexo y el conjunto de variables morfométricas mencionadas en el apartado anterior a las que se añadió una nueva denominada Área media y que consiste en el cálculo aproximado del área de la superficie del lomo del animal realizado con la combinación de varias de las variables anteriores.

Se efectuó en una primera fase de análisis un proceso de selección de variables basado en la metodología propuesta por [Collet \(2015\)](#) y en los métodos stepwise. El criterio para la selección de las variables fue el cambio en el coeficiente de determinación ajustado y que pudieran ser tomadas en una imagen cenital del animal. El modelo definitivo se realizó con las siguientes variables: género, longitud media, anchura delantera y anchura trasera.

Posteriormente se realizó un análisis exploratorio mediante el gráfico de residuos y el estadístico de Cook para la detección de observaciones atípicas e influyentes que afectaban al ajuste del modelo.

Se partió del conjunto de 86 medidas comentadas anteriormente y después del filtrado de observaciones el conjunto de datos para la construcción del modelo definitivo fue de 70 observaciones con un rango de pesos de 15,2 a 26 kg. El coeficiente de determinación ajustado del modelo final para las 70 observaciones fue del 91%. En cuanto a los pesos estimados por el modelo, el rango de pesos predichos fue de 16.18 y 25,88.

Los coeficientes del modelo se muestran en la Tabla 1.

El porcentaje de error medio fue del 3,3% con una desviación típica del 2,5. 19 medidas (27%) presentaron porcentajes de error superiores al 5%, y sólo una medida llegó a un porcentaje de error superior al 10%, que se corresponde con el valor de pesos inferior (15,2 Kg). De estas 19 medidas con porcentaje de error superior al 5%, 4 de ellas eran para pesos superiores a 24 Kg y 6 para observaciones inferiores a 18 Kg.

Variable	Coefficiente
Constante	-19,03913
Sexo (Macho=0, Hembra=1)	-0,297551
Longitud	0,6990537
Anchura delantera	0,777179
Anchura trasera	0,3593045

Tabla 1. Coeficientes del modelo.

Fuente: Elaboración propia.

Los resultados obtenidos son claramente prometedores, aunque resulta indispensable para obtener una mejor aproximación del cálculo del peso del modelo el medir un mayor número de corderos, especialmente en la zona de los extremos de los pesos de interés, ya que como se puede ver en la Fig. 7, es donde se tiene un menor número de ejemplares y es donde el modelo comete errores más significativos.




Fig. 7. Distribución de las frecuencias de los corderos utilizados para la realización del modelo.

Fuente: Elaboración propia.

Los resultados han demostrado que aunque las medidas del perímetro torácico funcionan correctamente para la estimación del peso de otras razas de ovejas (Topal & Macit, 2004; Yilmaz et al., 2012), otras medidas, en este caso medidas cenitales en corderos de raza Rasa Aragonesa, tienen una relación directa con el peso y el error en la estimación es lo suficientemente bajo para que se considere adecuado.

4.1.3. Conclusiones

La captura de datos y medidas antropomórficas de la raza Rasa Aragonesa ha permitido conocer mejor sus proporciones y sus características siempre alrededor de los pesos estimados por la IGP “Ternasco de Aragón”. Este conocimiento servirá como apoyo a la hora de desarrollar diferentes dispositivos, o gadgets que requieran la morfología del cordero.

Además, con los datos obtenidos en este estudio morfométrico se pudo crear un modelo para poder estimar el peso de un cordero vivo a partir de una serie de medidas de su anatomía. Como se ha visto en los resultados, la relación más fuerte entre las medidas tomadas y el peso del cordero es el área cenital.

Esto podría permitir la creación de dispositivos que, a partir de las imágenes tomadas desde un punto de vista cenital, obtendrá las medidas morfométricas del animal para estimar su peso mediante el modelo calculado, minimizando así el estrés que sufre actualmente al ser manipulado con las manos y separado del resto del rebaño (Ferguson & Warner, 2008). De la misma forma, se disminuirá el esfuerzo del ganadero y se intentará reducir el tiempo que en este proceso. Por último, se espera poder disminuir el error actual en la medida del pesaje, que es lo que repercutirá directamente en la economía del ganadero y podría convertirse en el mayor incentivo para dar el primer paso hacia la tecnificación del sector.

4.2. LambScan: dispositivo de estimación del peso en vivo del cordero mediante imágenes 3D

Las correlaciones encontradas en el apartado anterior facilitaban la incorporación de técnicas de visión por computación al pesaje de corderos. Sin embargo, el reto era diseñar un dispositivo que cubriese las necesidades del ganadero, de bajo coste, respetase el bienestar animal y mejorase el error en la medida actual.

Como se ha mencionado en la introducción, muy pocos ganaderos pesan habitualmente a sus animales y la gran mayoría lo hace con medios manuales o a simple vista (Jones et al., 2011). Para solventar este problema, hay muchos ejemplos exitosos en otras especies con diferentes tecnologías de visión por computación (Kuzuhara et al., 2015; Nir et al., 2018; Song et al., 2014; Spoliansky et al., 2016; Tasdemir et al., 2011; Vieira et al., 2015; Y. Wang et al., 2008; Yongsheng Wang et al., 2006). Sin embargo, no se han encontrado soluciones significativas en corderos.

En este contexto, en los siguientes apartados se describe el proceso de desarrollo del dispositivo generado para estimar el peso en vivo del cordero mediante imágenes cenitales 3D.

4.2.1. Adquisición de imágenes

Para la realización de este estudio se tomaron fotografías cenitales de 272 corderos de la raza Rasa Aragonesa. Debido a los estándares establecidos por la IGP “Ternasco de Aragón” se intentó que todos los corderos registrados estuvieran dentro del intervalo de peso entre 18-26 kg de peso. Los corderos estudiados tenían un peso vivo medio de 22,64 kg con una desviación típica de 3,6 kg, un peso máximo de 27,7 kg y un peso mínimo de 13,5 kg.

Todos los corderos se registraron en las mismas condiciones. Dos técnicos asistidos por dos veterinarios grabaron todas las imágenes obtenidas en todos los casos para que la muestra no se viera afectada por la forma en que se trató a los animales. En el proceso de registro se siguió siempre el mismo orden.

El procedimiento de registro consistía en primer lugar en pesar al cordero en una báscula electrónica donde se le realizaban 20 pesadas en 6 segundos y se obtenía la media de esas mediciones. En el mismo proceso se identificaba al cordero mediante un crotal y se seleccionaba su sexo.

Posteriormente, los corderos registrados se introducían en un pequeño corral en grupos de tres para que la grabación fuera más limpia, mientras el técnico tomaba las imágenes desde el corral contiguo para no tener ningún tipo de contacto con el animal, y así conseguir que los animales estuvieran más tranquilos.

El equipo utilizado para la captura de las imágenes, que es el mismo que el dispositivo desarrollado, puede verse en la Fig. 8. Consiste en una cámara 3D (1) conectada a un ordenador (4) mediante un cable USB (5), sujeta por un monopode (2) y el ordenador por un arnés (3). De este modo, un solo usuario puede manejar el dispositivo con total autonomía. El ordenador utilizado para las grabaciones fue un Lenovo ThinkPad L380, con CPU Intel® Core™ i7 8550U, pantalla táctil FHD IPS de 13,3”, resolución 1920 × 1080, GPU Intel® UHD 620, RAM 8 GB DDR4, disco duro 512 GB SSD PCIe y USB 3.0, mientras que la cámara fue una Intel RealSense D435.




Fig. 8. Elementos del dispositivo, colocación en relación con el cordero y el dispositivo propiamente dicho.
Fuente: Elaboración propia.

El dispositivo se diseñó de forma que no suponga un gran coste para el ganadero. El software funciona en cualquier ordenador convencional y la cámara es de bajo coste. El resto de los elementos no suponen un coste significativo respecto al coste del ordenador y la cámara.

Los corderos se grabaron con el sistema descrito persiguiendo un punto de vista cenital mientras el animal está de pie sin restricciones de movimiento. Las grabaciones se guardan utilizando el formato de archivo ROSBAG que recoge toda la información de la cámara en funcionamiento. Esto nos permite utilizar estas grabaciones como dispositivos virtuales en la fase de análisis.

4.2.2. Procesamiento de la imagen

Los archivos obtenidos en formato ROSBAG se procesaron para extraer las imágenes RGB y las imágenes de profundidad. Estos archivos se procesaron utilizando librerías de procesamiento de imágenes que facilitan las funciones necesarias para la segmentación y clasificación de las imágenes (Bradski, 2000; Van Der Walt et al., 2014). Los primeros pasos en la selección de las imágenes consistieron en realizar operaciones morfológicas. Como se observa en la Fig.9, partiendo de la imagen




Fig. 9. Operaciones morfológicas realizadas en las imágenes de vista superior de los corderos.

Fuente: Elaboración propia.

de profundidad original (A), lo primero que se hace es la eliminación del fondo mediante la profundidad (B), luego se eliminan los objetos pequeños (C) y por último se eliminan los componentes conectados etiquetados de menor superficie (D), dando lugar a la máscara (E).

Después, a partir de la máscara resultante, se obtuvo el área en mm^2 utilizando la media de las profundidades del píxel de la máscara. Esta media se obtuvo gracias a una biblioteca de la cámara que facilitó la obtención de las coordenadas del cordero y, por tanto, del área de la imagen cenital.

Se realiza un cribado para descartar aquellos fotogramas en los que un cordero no está presente, un cordero no está completamente dentro de los límites de la fotografía, aparecen varios corderos en la misma imagen, el punto de vista de la cámara es lateral en lugar de cenital, o las

paredes y vallas interfieren y se detectan erróneamente como parte del animal.

La mediana del área de la toma cenital de cada cordero se considera, junto con la característica del sexo, como predictores. El peso real medido por una balanza electrónica se utiliza como valor objetivo en la fase posterior de aprendizaje automático.

4.2.3. Algoritmo de aprendizaje automático

El cálculo de los algoritmos de regresión se llevó a cabo utilizando un entorno Python 3.6 ([van Rossum, 1995b](#)) y las principales bibliotecas utilizadas son Scikit-Learn ([Varoquaux et al., 2015](#)) y PipeGraph.

El conjunto de datos se divide en un conjunto de entrenamiento y un conjunto de prueba. Este último se utiliza como conjunto de espera para evaluar la capacidad del mejor regresor para generalizar cuando se le presentan nuevos casos. El primero se utiliza para entrenar un conjunto de regresores mediante una búsqueda exhaustiva con una estrategia de validación cruzada. Los regresores se modelizan como un objeto PipeGraph siguiendo el diseño que se muestra en la Fig. 10. Los 5 pasos de este PipeGraph son:

1.Selector: Un divisor que descompone la matriz de datos de entrada en componentes seleccionados. Divide la característica de sexo de la característica de área para que la primera pueda utilizarse en el paso “Multiple Class regressor” como selector con el fin de multiplicar los datos de entrada y entrenar un modelo diferente para cada sexo.

2.Características polinómicas: Este paso expande la dimensionalidad de sus datos de entrada añadiendo las potencias y subproductos de las características con el fin de ajustar modelos predictivos polinómicos.

3.Escalador: Un paso de preprocesamiento que escala las características de los datos de entrada a un intervalo común.

4.Regresor de clases múltiples: Capaz de proporcionar un modelo de regresión diferente para machos y hembras.

5.Calificador neutro: Permite al gráfico proporcionar un valor de puntuación cuando lo solicita la función “GridSearchCV” de Sci-kit-Learn.

Los algoritmos de regresión a evaluar son: Linear Regression, Ridge, Lasso, Elastic Net, Support Vector Machines y Random Forest.

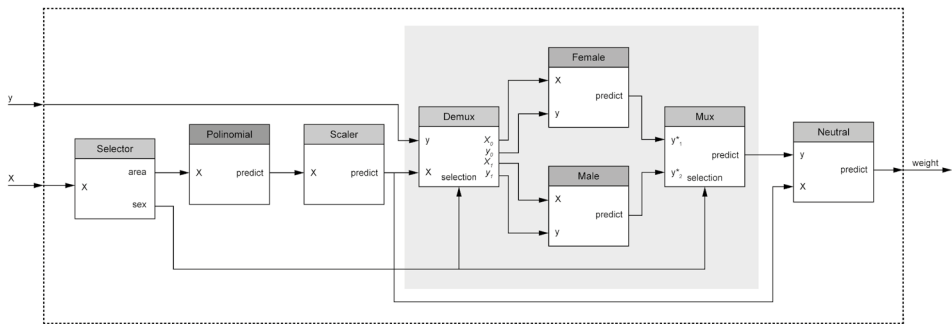


Fig. 10. El sistema de la figura detalla el flujo de los datos a través de los distintos procesos que construyen el modelo predictivo.

Fuente: Elaboración propia.

Se grabó un total de 272 corderos con el sistema 3D descrito anteriormente. Las grabaciones de vídeo comprendían 147.879 fotogramas. La presencia de un cordero se detectó en 13.406 fotogramas porque la reacción de los animales ante la presencia del operador de cámara era a menudo moverse sin descanso a gran velocidad, lo que dificultaba la obtención de tomas limpias. De ellos, 8.392 fotogramas contenían un cordero con todo el cuerpo dentro de los límites de la fotografía, lo que redujo de nuevo el número de fotogramas válidos debido a las dificultades asociadas a la filmación de animales corriendo en patrones aleatorios. De ellos, se obtuvieron 520 fotogramas de 64 corderos tras filtrar las apariciones múltiples de corderos o las interferencias con las paredes. La Fig. 11 muestra dos ejemplos de esos fotogramas válidos. Obsérvese que en el experimento se permitieron diferentes formas, sin limitar el entrenamiento únicamente a formas rectas.




Fig. 11. RGB (modelo aditivo de color), profundidad, máscara e imágenes segmentadas de dos corderos diferentes).

Fuente: Elaboración propia.

El conjunto de datos se dividió en un conjunto de entrenamiento compuesto por el 90% de las imágenes y un conjunto de prueba compuesto por el 10% restante. La Fig.12 muestra el diagrama de dispersión de peso frente a área utilizando el conjunto de entrenamiento. La búsqueda de la cuadrícula de hiperparámetros con validación cruzada se realizó considerando una validación cruzada triple. El parámetro de grado de las características polinómicas se evaluó con valores comprendidos entre 1 y 5.

Para el “GridSearchCV” con validación cruzada triple, se han comparado 6 modelos diferentes. Estos modelos fueron: Linear Regression, Ridge regression, Lasso, Elastic Net, Support Vector Machines (SVM) y Random Forest.

La Tabla 2 muestra los resultados de realizar el GridSearch con validación cruzada triple. Con esto podemos ver cuál de los métodos evaluados tiene el mejor rendimiento cuando una nueva medida de peso entra en el modelo. Como podemos ver en la Tabla 2, el modelo más simple; la Linear Regression, es el modelo que consigue el mejor rendimiento con las siguientes formulas dependiendo del sexo:

$$y = mx + b$$

$$\text{peso (hembras)} = 0.00011712 \cdot \text{área} - 13.28280676$$

$$\text{peso (machos)} = 0.00010781 \cdot \text{área} - 9.52865605$$




Fig. 12. Conjunto de datos de entrenamiento que compara el área cenital con el peso del cordero.

Fuente: Elaboración propia.

Prueba media	
Regresores	Puntuación
Linear Regressor	-6.69
SVR ¹	-7.18
Random Forest Regressor	-8.96
Ridge	-8.97
Elastic Net	-13.50
Lasso	-13.50

Tabla 2. Comparación del rendimiento del aprendizaje para predecir el peso del cordero basado en el error cuadrático medio negativo obtenido de la validación cruzada de 10 veces.

Fuente: Elaboración propia.

El error absoluto medio del regresor lineal es de 1,47 Kg en el conjunto de entrenamiento y de 1,23 Kg en el conjunto de prueba.

El algoritmo desarrollado para el modelo descrito anteriormente ha permitido diseñar un software que estima el peso de un cordero con un error medio inferior al 6% en tiempo real.

4.2.4. Desarrollo del dispositivo

El dispositivo final, LambScan, es el mismo que se ha mencionado en el apartado 4.2.1. compuesto por un arnés para sujetar el ordenador, un monópode que sujeta la cámara 3D y permite regular la distancia de la cámara al objetivo. Por último, un cable USB que conecta la cámara con el ordenador y la alimenta (Fig. 8). El dispositivo está diseñado para que un solo operario pueda realizar la estimación del peso de los corderos. La longitud del monópode permite al usuario poder tomar las imágenes desde un punto más alejado, en ocasiones desde otro corral. Esto hace que los corderos estén más tranquilos y sufran menos estrés, facilitando la labor al usuario para la captura de una imagen correcta para la estimación y colaborando en el bienestar animal al disminuir la interacción con el cordero.




Fig. 13. Vista superior de un cordero en la interfaz final del software desarrollado.

Fuente: Elaboración propia.

Por otro lado, se desarrolló el software que permite la estimación del peso en tiempo real. El software se ha desarrollado en Python 3.6 y la interfaz se diseñó con la librería Kivy. Como se puede observar en la Fig. 13, la interfaz es muy clara, con los campos bien delimitados para que el ganadero no tenga ninguna dificultad a la hora de interactuar con la aplicación. Teniendo en cuenta el entorno en el que se desarrolla la actividad y movilidad de los corderos, los botones de la aplicación se diseñaron con un tamaño grande permitiendo que el ganadero no tenga que mirar los botones para pulsarlos y centre su atención en la pantalla.

Para que el ganadero tenga una buena retroalimentación de cuándo una imagen capturada es correcta para la estimación del peso, cada vez que el software captura una imagen correcta, el fondo se atenúa y el cordero se inscribe en un cuadrado verde.

Secuencia de uso

Una vez el operario tiene el dispositivo sujeto al cuerpo, deberá introducir el crotal del animal (si se quiere guardar la identificación del mismo) y su sexo. A partir de ahí el operario apuntará cenitalmente al lomo del cordero intentando que el cordero este contenido dentro de la pantalla. Cuando el dispositivo detecta una imagen correcta del cordero, se muestra un rectángulo verde que enmarca al cordero (como se puede ver en la Fig. 13). Al mismo tiempo en el campo “Peso” se mostrará el peso del animal a tiempo real que podrá cambiar cada vez que detecta una imagen buena.

Cuando el número mostrado en el peso deja de fluctuar, el operario puede considerar el peso como bueno y pulsar el botón “Stop” para parar de tomar medidas y después pulsar el botón “Guardar” para que el valor del peso junto con el crotal, el sexo y la fecha y hora se guarden en un archivo .csv.

Si se quiere volver a realizar una pesada nueva, el operario deberá pulsar el botón “Start” para reestablecer el valor del peso a 0 y volver a comenzar con el proceso. Por último, se puede modificar el valor de captura de la profundidad si se tuviese problemas capturando elemen-

tos del suelo u otros elementos externos, cambiando los valores “Alcance mínimo” y “Alcance máximo”.

4.2.5. Conclusiones

Este dispositivo está alineado con la consecución del objetivo 1, expuesto en los objetivos de esta tesis, generando una nueva herramienta para el ganadero que permita mejorar la precisión actual en la medida del ganadero y ayude en el desarrollo tecnológico y económico de la explotación.

Gracias a las ventajas conseguidas con la aplicación de técnicas de visión por computación, se propone un dispositivo de fácil manejo y rápido aprendizaje, que no requiere conocimientos avanzados y que utiliza herramientas que el ganadero ya utiliza. El dispositivo solo necesita una cámara 3D de bajo coste, en torno a los 200 euros, y el software funciona en cualquier ordenador convencional como el que tienen los ganaderos en sus explotaciones. Esto, unido a una interfaz gráfica sencilla y de fácil manejo, hace del dispositivo un buen aliciente para mejorar el proceso de pesaje sin que suponga una inversión desproporcionada, acorde con la economía del sector.

Aunque el dispositivo mejora sustancialmente el proceso actual, mejorando la precisión en el pesaje con un error menor a 6% y aportando una herramienta adaptada al entorno, al ganadero y al animal, tiene ciertas limitaciones que deberán estudiarse más adelante. La principal limitación del sistema es la incapacidad de captar imágenes de corderos pegados a una superficie vertical o a otro cordero. Teniendo en cuenta la naturaleza gregaria y asustadiza de la especie, esto dificulta mucho la captura de datos.

4.3. LambTrack: Aplicación de monitorización del peso y seguimiento del crecimiento del cordero mediante imágenes

Aunque LambScan cumple las especificaciones previstas y el resultado se amolda perfectamente a la situación económica del ganadero y a la situación del sector, tenía varios puntos mejorables que hacían que el dispositivo no fuese todo lo útil que se pretendía.

El primero de los inconvenientes era que, a pesar de su utilidad, el dispositivo era aparatoso y pesado. Después de unas horas de uso la fatiga en el ganadero era considerable. Para poder mejorar la aceptación tecnológica del sector y la tecnificación de los procesos en el entorno ovino, es necesario que las herramientas proporcionadas tengan un fácil manejo, portabilidad y un diseño adaptado a las necesidades del usuario. Se ha observado que el diseño es un elemento de innovación y puede ser un factor de dinamización dentro de la industria agroalimentaria (González-Yebra et al., 2019). Aunque actualmente está más presente el diseño gráfico, cada vez se observan más aplicaciones dentro de esta industria. En este sentido y dentro de la PLF, el diseño industrial tiene un papel fundamental. Un buen desarrollo de los dispositivos, centrado en la actividad a realizar y en el usuario, facilita la adopción de la tecnología y un menor abandono (Johnson et al., 2011; Tang & Patel, 1994).

El segundo inconveniente de LambScan es que, aunque su precisión es buena, incluso mejor que sus competidores en otros sectores, esa precisión solo era posible de alcanzar cuando el cordero estaba completa-

mente aislado. En los casos en los que el cordero está pegado a otro o está pegado a un elemento vertical, LambScan no permite estimar el peso. Este inconveniente también repercute en el tiempo de pesaje ya que hay que encontrar el momento adecuado para captar las imágenes.

Por otro lado, aunque en menor rango de importancia, LambScan permite registrar los datos obtenidos referidos a un crotal o número de referencia. Sin embargo, la disposición del dispositivo y la movilidad del animal hace muy tediosa la tarea de averiguar el crotal del animal al que se le va a estimar el peso. Generalmente esta tarea acaba necesitando la ayuda de un segundo operario, ralentizando y encareciendo el proceso. Cualquier herramienta que mejore este aspecto se adaptará mejor a la situación del ganadero mientras desarrolla esa tarea.

Aunque el peso sea un factor determinante en la ganancia y rentabilidad del cordero dentro de la IGP “Ternasco de Aragón”, el control y la monitorización del peso es determinante para la salud y el bienestar animal. El seguimiento del peso del cordero desde su nacimiento al sacrificio permite detectar alguna anomalía en la alimentación o alguna enfermedad en algún cordero (Segerkvist et al., 2020). Además, se ha mencionado anteriormente que ayuda a prever la capacidad de supervivencia de las crías (Greenwood et al., 1998; Hatcher et al., 2008) y a mejorar la calidad del producto final (Ramirez-Retamal & Morales, 2014). Todo ello hace pensar que, dentro del sector, y más concretamente en este eslabón de la cadena de valor, es primordial llevar a cabo un control, seguimiento y monitorización del peso de cada cordero.

En los siguientes apartados se describe el desarrollo una aplicación móvil que permite identificar al cordero, estimar su peso y monitorizarlo desde su nacimiento al sacrificio.

4.3.1. Adquisición de imágenes

La aplicación móvil desarrollada dispone de tres funciones principales, identificar, estimar y monitorear el peso del cordero. Para las dos últimas fue necesario tomar datos de corderos. Por ello, en este estudio, la toma de datos se dividió en dos fases diferenciadas en estas dos funcionalidades.

Para conseguir monitorear al cordero, era necesario saber en qué peso se encontraba cada cordero durante su crecimiento y si ese peso estaba dentro de los límites normales para su edad. Con este fin, se elaboraron gráficas de crecimiento que permitiesen al ganadero saber en todo momento en qué estado se encontraba cada cordero de su rebaño.

Para poder llevar a cabo estas gráficas, se tomaron pesos de 240 corderos desde su nacimiento hasta su sacrificio. Los corderos de raza Rasa Aragonesa pertenecían diferentes ganaderías y en diferentes localizaciones de Aragón para intentar conseguir una muestra que abarcara la




Fig. 14. Gráficas de crecimiento de peso durante 70 días desde el nacimiento. Parto múltiple de hembras (Arriba), parto múltiple de machos (Abajo). Percentil 99 (rojo), percentil 50 (verde), percentil 1 (azul).

Fuente: Elaboración propia.

mayor cantidad de condiciones climáticas posibles. De los 240 corderos 116 eran hembras y 124 machos, 134 provenían de partos múltiples y 106 de partos simples. Estos datos se utilizaron para elaborar 4 graficas de crecimiento identificando en ellas los percentiles 99, 50 y 1 como se puede ver en la Fig. 14. Estas gráficas correspondían a ambos sexos y ambos tipos de parto.

Todas las pesadas se realizaron mediante dinamómetro y en las mismas condiciones y con los mismos trabajadores. En el proceso de registro se siguió siempre el mismo orden.

Por otro lado, teniendo en cuenta las especificaciones de las nuevas funcionalidades, se tomaron imágenes que más adelante se utilizarían para entrenar el modelo de predicción de peso. Esta toma de datos se dividió en dos fases, una primera fase en la cual se capturaron imáge-



Fig. 15. Set de toma de fotografías.
Fuente: Elaboración propia.

nes de 36 corderos con pesos dentro del rango especificado por la IGP “Ternasco de Aragón” (18–26 kg), de los cuales 18 eran machos y 18 eran hembras. Y una segunda fase en la que se tomaron imágenes de 12 corderos a los 15 días de su nacimiento y se repitió este proceso cada dos semanas hasta su sacrificio para ver su evolución con un peso mínimo de 6,5 kg y un máximo de 21,7 kg. En este caso, debido a la disponibilidad de corderos eran 7 hembras y 5 machos. En esta segunda fase se tomaron todas las imágenes a los mismos 12 corderos iniciales en las mismas condiciones ambientales y con los mismos operarios.

Para conservar las condiciones anteriormente señaladas, todas las imágenes se tomaron en el mismo set. Este set consistía en un corral de 1 x 1,5 metros que se recubrió con una goma negra, adecuada para que no generara zonas de reflexión de luz en la imagen y permitiese distinguir al cordero. Se preparó un armazón de PVC que permitía captar todo el corral en la misma escena colocando la cámara 3D a una altura de 2,05 metros (Fig. 15). La cámara utilizada fue una IntelReal Sense 435i, el mismo modelo que el utilizado en LambScan.

4.3.2. Procesamiento de la imagen

Para la estimación del peso, en este caso, al ser una aplicación de los datos destinada a un formato móvil, era necesario remover la información 3D de la imagen ya que, en el futuro, solo se tendría como entrada una imagen 2D. Por este motivo, aunque los datos obtenidos fuesen en formato ROSBAG, los datos se sometían a un procesamiento para obtener las imágenes RGB. Todos los archivos se procesaron con librerías apropiadas para la segmentación y clasificación de las imágenes (Bradski, 2000; Van Der Walt et al., 2014).

Una vez obtenidas las imágenes RGB, el primer paso fue eliminar las imágenes no válidas, es decir, aquellas en las que el cordero estaba en una posición en la que no se va a encontrar habitualmente, como a dos patas o tumbado. También se eliminaron aquellas en las que aparecían partes del operario.

Todas las imágenes se sometieron a operaciones morfológicas para obtener una máscara clara del cordero. Primero se binarizaron mediante

un filtro Otsu (Otsu, 1979), se eliminaron los objetos pequeños para eliminar ruidos, se etiquetaron los elementos, se seleccionaron los de mayor tamaño y por último se eliminaron aquellos elementos que estaban en contacto con un lado de la imagen ya que correspondían a efectos de la luz sobre el set.

La imagen definitiva del cordero después del cribado se considera, junto con la característica del sexo, como predictores. El peso real medido por una balanza electrónica se utiliza como valor objetivo en la fase posterior de aprendizaje automático.



Fig. 16. Operaciones morfológicas. (Izquierda). Máscara. (Derecha). Imagen original.

Fuente: Elaboración propia.

4.3.3. Algoritmo de aprendizaje automático

El cálculo de los algoritmos se llevó a cabo utilizando un entorno Python 3.6 (van Rossum, 1995a) y la principal biblioteca utilizada de Scikit-Learn (Varoquaux et al., 2015).

Para la estimación del peso se entrenó la red neuronal GoogLeNet (Inception v1) (Szegedy et al., 2015). Además de las imágenes de corderos, se añadieron al entrenamiento imágenes de suelo, y se etiquetaron todas las imágenes para identificar si en la imagen existía cordero o no. De esta forma se facilita la estimación y mejora la precisión del modelo, descartando aquellas imágenes de entrada dudosas.

Tras el cribado descrito en el apartado anterior, se trabajó con 148268 fotogramas validos a los que se le añadieron 196712 fotogramas de

suelo para ayudar al sistema a seleccionar entre un cordero y cualquier otro elemento de la imagen.

Arquitectura del modelo:

El modelo comienza con dos entradas. La primera es una entrada de imagen con dimensiones (altura: 224, ancho: 224, canales: 3). Estas imágenes son procesadas inicialmente por una capa de extracción de características, que utiliza el modelo pre-entrenado Inception V1 (Fig. 17) para transformar las imágenes en un conjunto comprimido de características relevantes.

La segunda es una entrada escalar que representa el sexo del cordero.

Posteriormente, las características extraídas de la primera entrada (la imagen) y el valor escalar del sexo son combinadas en una sola estructura de datos. Esto permite que el modelo utilice tanto información visual como numérica para realizar sus predicciones.

A partir de aquí, el modelo pasa por dos capas densas que procesan la información combinada. El objetivo de una capa densa es transformar las entradas mediante una combinación lineal seguida de una función de activación no lineal, permitiendo al modelo aprender representaciones complejas de los datos.

Primera Capa Densa:

Primero se determina dinámicamente el número de neuronas que la componen por la búsqueda de hiperparámetros. Posteriormente se introduce una función de activación ReLU (Rectified Linear Unit) (Agarap, 2018), que introduce no linealidad al modelo, permitiendo aprender patrones más complejos. Se realiza una regularización, que penaliza los coeficientes grandes de la función de activación y ayuda a prevenir el sobreajuste. Y por último se añade un “Dropout” del 50%, que aleatoriamente “apaga” una fracción de las neuronas durante el entrenamiento, que también ayuda a combatir el sobreajuste.

Segunda Capa Densa:

Sigue la misma estructura que la primera capa pero en este caso el número de neuronas que la compone, también determinado por la búsqueda de hiperparámetros, no es mayor que el número en la primera capa. La introducción de una segunda capa densa (o incluso más capas) en una red neuronal tiene varios beneficios y objetivos en el proceso de aprendizaje y la capacidad de generalización del modelo. Al agregar una segunda capa densa, el modelo puede aprender combinaciones no lineales de estas combinaciones lineales, lo que permite capturar relaciones más complejas y patrones en los datos mejorando significativamente el rendimiento del modelo.

Capa de Salida:

Está compuesta de dos neuronas correspondientes a las dos salidas del modelo, el peso y la detección de si hay cordero o no.

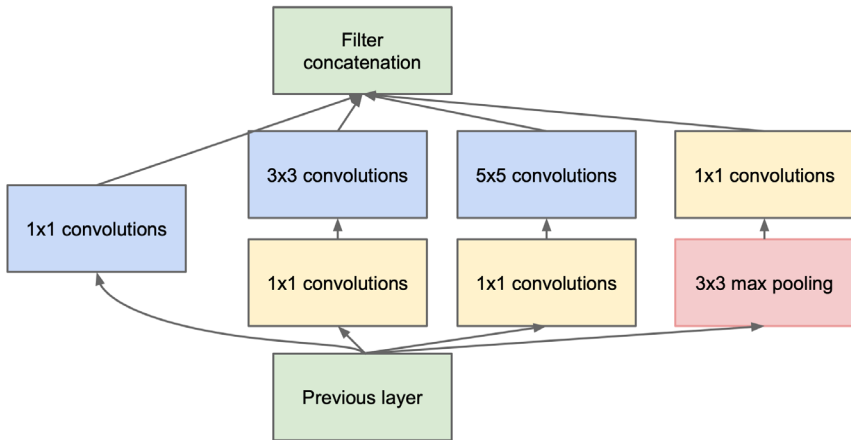


Fig. 17. Módulo Inception V1.

Fuente: Szegedy et al., 2015

El conjunto de datos final se dividió en un conjunto de entrenamiento compuesto por el 70% de las imágenes y un conjunto de prueba compuesto por el 30% de las restantes. El primero se utiliza para entrenar el modelo explicado anteriormente.

El algoritmo desarrollado para el modelo descrito anteriormente ha permitido diseñar un software que estima el peso de un cordero con un error medio inferior al 10,9 % en desde el nacimiento del cordero. Dentro del intervalo de pesos estipulado por el IGP “Ternasco de Aragón”, el error medio es inferior al 5,9 %. Esto se debe a una menor cantidad de datos suministrados al modelo inferior a los 18 kg.

4.3.4. Software y funcionalidades de LambTrack

Como se ha comentado anteriormente, la aplicación móvil desarrollada, LambTrack, además de mejorar la portabilidad de LambScan, añade funcionalidades que mejoran el rendimiento en el día a día del gana-

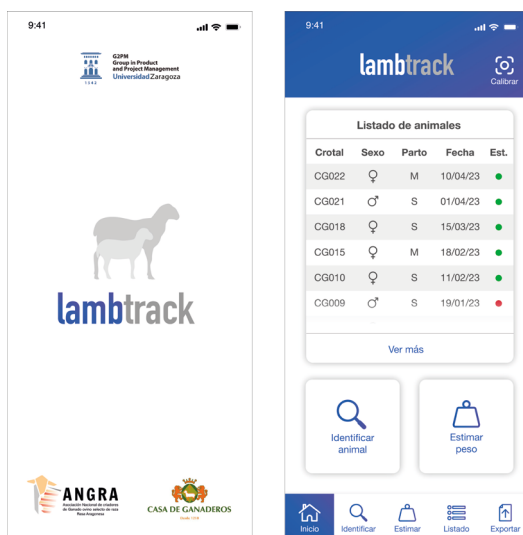


Fig. 18. Interfaz de LambTrack.

Fuente: Elaboración propia.

dero. Al igual que se hizo con LambScan, se ha mantenido una estética sencilla, limpia y clara que permita realizar las funcionalidades designadas con facilidad para el ganadero, teniendo en cuenta el entorno en el que se va a realizar la acción, la explotación ganadera (Fig. 18).

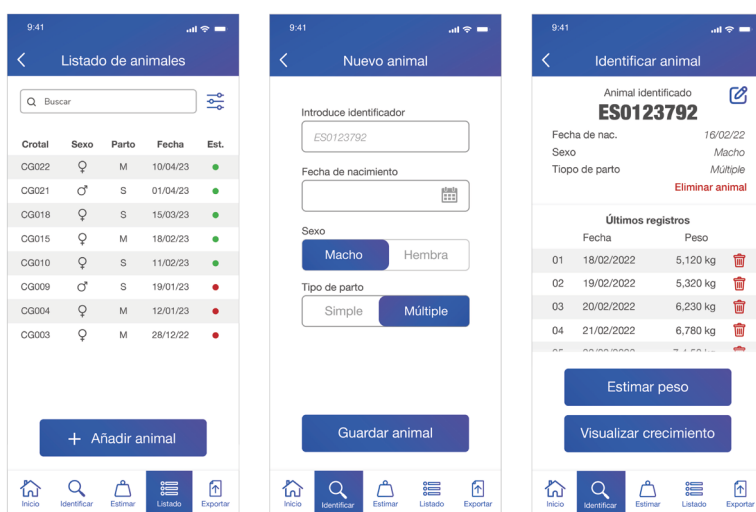


Fig. 19. Creación de perfil.
Fuente: Elaboración propia.

Una de las principales funcionalidades añadidas respecto al primer dispositivo, es el de poder hacer un perfil de cada animal, donde se pueden ir almacenando las pesadas estimadas y se puede ver su evolución, como se observa en la Fig. 19.

Una innovación importante en el sector y respecto a LambScan, es la posibilidad de poder identificar el crotal del cordero mediante una etiqueta de NFC cercando el móvil a la oreja del cordero. Se puede observar el funcionamiento de identificación en la Fig. 20.

Para realizar un pesada, teniendo en cuenta que la altura a la que se realiza la pesada es desconocida y es un parámetro crucial para la precisión de la aplicación, se ha de realizar una calibración previa. Esta calibración ha de hacerse tomando una imagen de un cordero de peso conocido y rellenando el campo de peso con la información.

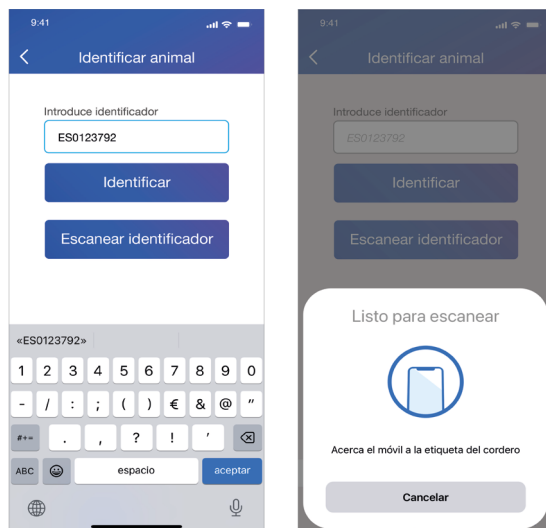


Fig. 20. Identificación mediante NFC.
Fuente: Elaboración propia.

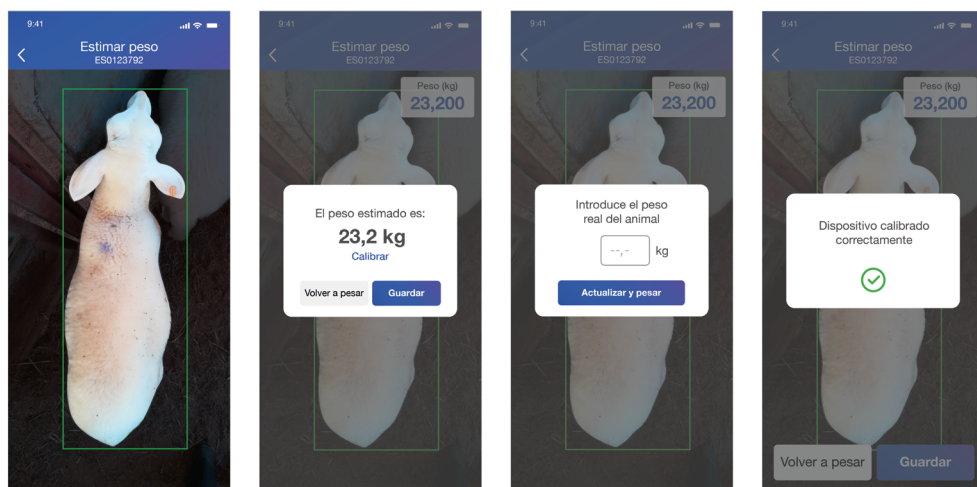


Fig. 21. Calibración y estimación de pesada.
Fuente: Elaboración propia.

Una vez calibrada la aplicación, no es necesario volver a calibrar cada vez que se realiza una estimación. Para realizar la estimación de peso, se puede pesar previamente al cordero y después identificarlo mediante NFC, o se puede acceder desde el perfil del animal si se sabe se tiene ya identificado previamente el cordero, ya sea manualmente o mediante NFC. Este proceso se puede observar en la Fig. 21.

Otra funcionalidad añadida y para la que se tomaron los datos de crecimiento como se explica en el apartado 3.2.1., es la visualización del crecimiento en peso del animal y su comparación con los percentiles respecto a su sexo y su tipo de parto. A esta función se accede desde el perfil del animal y se puede ver tanto en horizontal como en vertical (Fig. 22).



Fig. 22. Visualización del crecimiento y exportación de datos.
Fuente: Elaboración propia.

Por último, LambTrack mantiene la posibilidad de exportar los datos a un formato de hoja de cálculo, pero además el usuario podrá ver una lista de cada cordero dentro de la aplicación, así como poder ver la información de cada animal.

Secuencia de uso

La primera acción a realizar para que LambTrack funcione correctamente, será la calibración de la aplicación. Para ello se tomará una imagen de un cordero del que conozcamos su peso y se introducirá el peso en el diálogo que aparece después de tomar la foto. Si se quiere mejorar la precisión también se puede calibrar el suelo en el que se realizan las estimaciones de peso. Para ello el proceso es el mismo salvo que en el cuadro de diálogo, habrá que indicar que no existe cordero dentro de la imagen.

Una vez calibrado el sistema, el proceso de estimación se puede realizar de varias formas. La primera de ellas será creando primero el perfil del animal. Para ello se añadirá manualmente el animal, bien escaneando el crotal mediante NFC o introduciendo manualmente el código. Se indicará si es macho o hembra, el día de nacimiento y el tipo de parto del que procede el animal. Una vez generado el perfil, se podrá acceder desde su perfil a sus pesadas, la visualización del crecimiento y se podrá realizar la estimación.

Para realizar la estimación, solo deberá colocarse el móvil de forma que el cordero aparezca completamente en la pantalla del móvil. Pasados unos pocos segundos el móvil tomará una imagen y nos estimará su peso. Esta estimación podrá ser rechazada si nos parece óptima o guardada en caso contrario, lo que generará una pesada nueva dentro del perfil del animal.

Todo este proceso podrá realizarse en el orden inverso, es decir, sin haber generado el perfil, se puede estimar el peso del cordero y, al guardar al peso, el operario tendrá que indicar el crotal al que pertenece el peso que se acaba de estimar. Si ese crotal existe en la base de datos, la pesada se generará automáticamente en su perfil, si no existe, comenzará el proceso de generación del perfil del animal.

Por último, el operario podrá ver un listado actualizado de los corderos de su rebaño desde donde podrá acceder al perfil de cada animal y visualizar su crecimiento comparando con los percentiles según su sexo y tipo de parto.

La aplicación también tiene la función de exportar los datos a una hoja de cálculo y está preparada para una futura integración de los datos en una plataforma online.

4.3.5. Conclusiones

Este dispositivo está alineado con la consecución del objetivo 1 expuesto en los objetivos de esta tesis, generando una nueva herramienta al ganadero que mejora las existentes hasta el momento en portabilidad, precio y funcionalidades, adaptándose más al trabajo diario del ganadero y facilitando su incorporación tecnológica al sector.

La introducción de Deep Learning en el proceso de estimación del peso permite el procesamiento en un dispositivo móvil sin cámara de profundidad. Además, permite la estimación de peso con elementos verticales pegados al cordero y sin la necesidad del uso de la imagen de profundidad para su cálculo. Todo esto hace que el pesaje se convierta en un proceso más intuitivo, con un dispositivo que cualquier ganadero tiene y con un precio menor que LambScan. De esta forma también se elimina el peso del dispositivo, convirtiéndolo en un proceso más liviano y rápido.

Por otro lado, el ganadero puede tener una imagen clara y actualizada del estado de su rebaño y del crecimiento y evolución de cada uno de sus corderos. Esto permite al ganadero identificar problemas de alimentación o enfermedades que hagan que sus corderos no crezcan adecuadamente. Las funcionalidades añadidas respecto a LambScan y la fácil accesibilidad del dispositivo unido a un manejo sencillo y optimizado para el dispositivo móvil, hacen de LambTrack una opción más viable y mejor adaptada al entorno y al usuario.

5. Clasificación de corderos según su nivel de engrasamiento mediante imágenes de ultrasonidos

Dentro de la cadena de valor ovina se ha visto que hay cuatro partes claramente diferenciadas. Sin embargo, si se intenta vincular esas fases con agentes que participan en el proceso, estas no se corresponden de igual manera. Parece lógico pensar que el ganadero comprende las dos primeras fases, crianza y alimentación, pero, dentro del sector ovino, esta última fase se separa en dos agentes diferentes. Es aquí donde entra en juego el segundo agente de la cadena, el cebadero. El objetivo principal de un cebadero es terminar la alimentación de los corderos hasta el punto necesario en el que los corderos son enviados al matadero respetando el bienestar animal en unas condiciones óptimas para su desarrollo y alimentación. Por otro lado, es aquí donde comienza la producción, ya que es en el cebadero donde se clasifican los corderos según su destino en la producción.

Este último proceso, característico de cualquier explotación ganadera, y más concretamente de un cebadero, es la clasificación de los animales según su peso y sexo antes del sacrificio. Esto permite a los cebaderos clasificar a los animales según las especificaciones de calidad de la carne y ajustar así el precio por animal en función de la calidad futura esperada. Sin embargo, la calidad de la carne viene determinada por el tipo de la carne, su color y la cantidad de grasa (Europeo, 2017). Aunque son valores que están ligados al sexo y al peso, hay otros como la alimentación, el movimiento del cordero o el manejo que también pueden modificar la cantidad de carne (Aguayo-Ulloa et al., 2013; Lefaucheur, 2010).

Actualmente los procesos de valoración de la grasa se realizan en el matadero, comprobando la cantidad de grasa de animal en canal mediante la interpretación de un experto sin ninguna medida objetiva. Esto hace que el ganadero no reciba una valoración adecuada respecto a la calidad de la carne si no que la recibe respecto al peso antes del sacrificio, afectando a la rentabilidad económica de la explotación. Para que el ganadero tenga una valoración justa del cordero, debería clasificarse previamente según su nivel de grasa en vivo. Esta clasificación existe en otras especies (Lucas et al., 2017), pero no existe en corderos.

Por otro lado, el control de la grasa puede ayudar a controlar la alimentación de los animales y la detección de algún comportamiento anómalo en el rebaño. Un mal desarrollo de la grasa en el cordero puede deberse a la cantidad de actividad física del cordero o a una mala alimentación, ambas dos podrían ser causadas por alguna enfermedad.

En este contexto, el presente capítulo aborda el reto de generar soluciones tecnológicas basadas en técnicas de visión por computación que permitan al cebadero mejorar su proceso de clasificación. Para ello, se pretende generar un método de detección de la cantidad de grasa en vivo del cordero lo más adaptada posible al proceso actual de trabajo, sin generar estrés al animal para proporcionar una mayor capacidad de control sobre el estado de los corderos en su proceso de alimentación.

5.1. LAUS: Dispositivo para la clasificación de corderos según su nivel de grasa mediante imágenes de ultrasonidos

En la introducción de esta tesis se nombran diferentes tecnologías utilizadas para medir la grasa en animales. Mediciones externas del cuerpo del animal (Fernandes et al., 2010), tecnología óptica 3D (Weber et al., 2014) o imágenes de resonancia (Carabús et al., 2016), impedancia bioeléctrica (Avril et al., 2013) o ultrasonidos (Quaresma et al., 2013).

El método utilizado debe cumplir ciertos requisitos. Tiene que adaptarse a la movilidad del cordero. Debe ser un proceso rápido y preciso que ayude a minimizar el tiempo de la clasificación y estrese lo menos posible al animal. Y por último tiene que ser un método no invasivo. Teniendo en cuenta las estas características, su situación económica del sector ovino y el estrés de las otras tecnologías revisadas, la tecnología de ultrasonidos podría ser la que mejor se adapte a las necesidades del proceso y al estado del sector.

El uso de esta tecnología se ha visto reflejado en diferentes artículos de investigación destinados a medir la grasa corporal en diferentes especies (Greiner et al., 2003; Houghton & Turlington, 1992; Quaresma et al., 2013). En muchos de ellos, se ha encontrado que la medición de la grasa corporal está directamente relacionada con el peso del animal, el sexo o incluso con medidas externas del animal. En el caso de los corderos, se ha demostrado previamente que esta tecnología podría ser eficaz para predecir la cantidad de grasa en animales vivos, ya que tiene

una muy buena correlación con la medición real en la canal del animal (Delfa et al., 1991; Dias et al., 2020).

Sin embargo, esta tecnología se caracteriza por la captación de imágenes con cualidades muy específicas. La principal característica es la ausencia de color, todas estas imágenes son en blanco y negro, identificando los tejidos sólidos en blanco como los huesos y los líquidos en negro. Dependiendo de la densidad del tejido, la tonalidad es más oscura o más clara. En el caso de la grasa, debido a su densidad, es blanca.

En los siguientes apartados se describe el desarrollo de un método automatizado no invasivo, rápido y cómodo para la clasificación de corderos según su grasa en vivo mediante el procesamiento de imágenes de ultrasonidos. Esto se realiza mediante un dispositivo de bloqueo y un software de procesamiento y predicción de la cantidad de grasa en vivo.

5.1.1. Adquisición de imágenes

Para alcanzar el objetivo planteado en este estudio fue necesario recopilar datos sobre la relación entre la medida tomada con el dispositivo de medición y la medida real. Para ello, se procesaron 151 corderos de entre 19 y 27,6 kg de peso, de los cuales 79 eran machos y 72 hembras.

Todas las mediciones se realizaron en corderos de la raza Rasa Aragonesa en las mismas condiciones de alimentación, iluminación y crecimiento. Todas ellas fueron realizadas por los mismos operarios.

En cada una de ellas se realizaron mediciones de peso vivo y se tomaron diferentes imágenes y vídeos con un ecógrafo entre la tercera y cuarta vértebra lumbar, ya que se considera la zona más relevante para ver la grasa en corderos vivos (Delfa et al., 1989). El ecógrafo utilizado fue el SS-1S Ultrasound Scan, con una ganancia de 66 dB y una frecuencia de 5MHz.

Una vez tomadas las imágenes de todos los corderos, se procedió a medir manualmente la grasa de cada cordero según la escala proporcionada por el ecógrafo.

Actualmente, según el [Europeo \(2017\)](#) se considera que una canal es de calidad cárnica de primera si tiene un color de carne rosa y una cantidad de grasa entre 2 y 3 en la escala proporcionada por la normativa, teniendo en cuenta el peso de la canal. Esta escala se compone de 5 niveles: 1- No graso, 2- Poco cubierto, 3- Cubierto, 4- Graso y 5- Muy graso.

Para relacionar el nivel de grasa mostrado por el ecógrafo con esta escala, se tuvo en cuenta que todos los corderos a los que está destinado el aparato y los utilizados para el experimento son corderos destinados al sacrificio. Por lo tanto, se realizó una medición de la grasa con el ecógrafo el día antes del sacrificio y un experto midió y valoró la canal del mismo cordero un día después del sacrificio según la escala mencionada (Fig. 23). De este modo fue posible relacionar los milímetros calculados a partir de las imágenes ecográficas con la clasificación del experto.

Una vez determinada esta relación, el objetivo era automatizar la clasificación. Para ello, el software utiliza diferentes técnicas de procesamiento de imagen, que se explican más adelante, de forma que se muestra al operador el nivel de grasa que tiene el animal en el momento de capturar la imagen.




Fig. 23. Comparación de la imagen por ultrasonidos frente al corte de la canal de cordero. (Izquierda) Área de grasa subcutánea captada con el ecógrafo. (Derecha) Capa de grasa observada en la canal del mismo animal post mortem.

Fuente: Elaboración propia.

5.1.2. Procesamiento de la imagen

El mencionado cálculo de la cantidad de grasa en animales vivos se realizó mediante la captura de imágenes JPG y vídeos MP4, de las que se seleccionaron las imágenes correctas, es decir, las que tenían la parte superior mejor definida. Sin embargo, antes de evaluar si una imagen es correcta o no, es necesario entender qué aspecto tiene la imagen de salida de la ecografía. La Fig. 24 muestra una imagen original recién capturada del ecógrafo. La imagen se compone de 3 partes bien diferenciadas. Una zona superior blanca que representa la grasa subcutánea (1), una zona intermedia negra que representa el tejido muscular (2) y, por último, una zona inferior con áreas blancas que representa la apófisis transversa. Como el objetivo era localizar la zona de grasa en el cordero, lo primero que hicimos fue recortar la foto para aislar la región de interés, la superior, minimizando el ruido causado por las otras partes de la foto.




Fig. 24. Imagen de entrada del ecógrafo. 1. Área de grasa 2-Tejido muscular
3 - Ápofisis transversa
Fuente: Elaboración propia.

Una vez seleccionada la imagen, se preprocesó para detectar con mayor precisión la capa de grasa real, como se muestra en la Fig. 25. En primer lugar, se la imagen preprocesa utilizando desenfoque con un kernel de 5 por 5 píxeles y, a continuación, se mejoran las regiones blancas aplicando CLAHE (Pizer et al., 1990) para ayudar a la posterior binarización con filtro Otsu (Otsu, 1979) (A). Una vez diferenciada la región de interés (ROI) del resto de la imagen, se eliminaron los objetos pequeños y se etiquetó el resto de los objetos (B). El siguiente paso consistió en eliminar todos los objetos etiquetados más pequeños para seleccionar el más grande, que representaba la grasa (C). Una vez segmentado, el objeto final se dilató y erosionó para obtener una imagen más nítida y recta del nivel de grasa (D). Todas estas operaciones de procesado de imagen se realizaron utilizando las librerías Opencv y Scikit-Image para Python (Bradski, 2000; Van Der Walt et al., 2014)

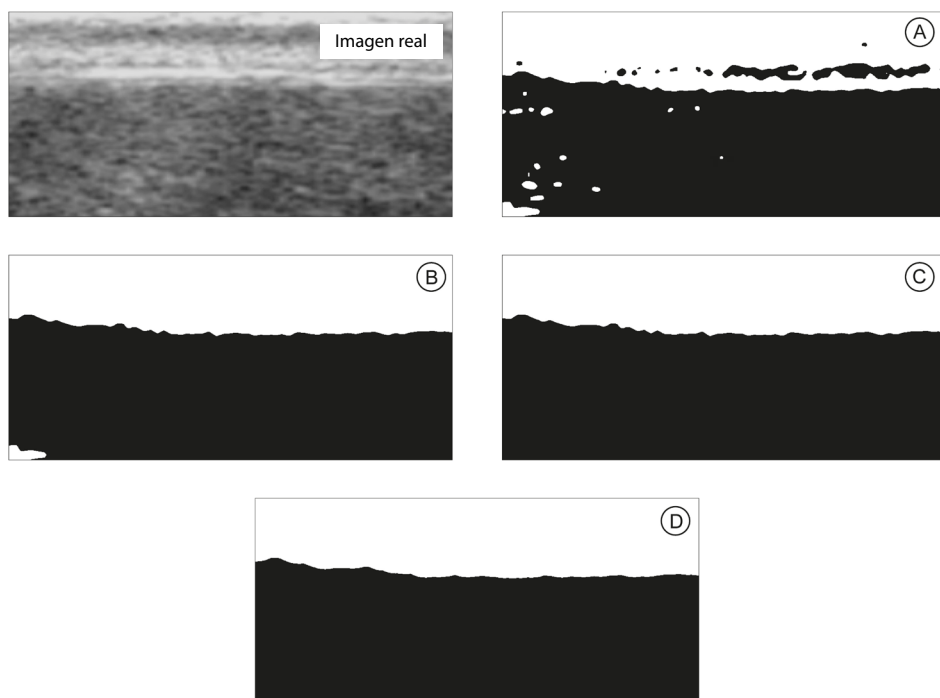


Fig. 25. Procesamiento de la imagen.

Fuente: Elaboración propia.

Una vez obtenida la imagen final (D) del proceso anterior, el siguiente paso es comprobar si la imagen detectada es correcta o no. La principal razón para descartar una imagen de grasa es que la línea inferior que determina dónde termina la zona grasa del animal no sea lo suficientemente recta. Una línea demasiado inclinada puede indicar dos cosas, o bien que la medición no se está realizando en la zona correcta del animal (Delfa et al., 1989), o bien que el ecógrafo está mal colocado o inclinado, generando una imagen ruidosa o distorsionada

Para averiguar automáticamente si la imagen es válida o no, se analiza el número de píxeles blancos y negros por línea en la imagen (Fig. 26). Para ello, se definen secciones horizontales a través de la altura de la imagen para obtener el porcentaje de píxeles blancos por sección. Estas secciones horizontales se filtran considerando las regiones cuya diferencia es inferior al 5% con las regiones cercanas. Cuando la inclinación de la pendiente del 100% al 0% de píxeles blancos es superior al 8, se considera que la imagen es mala, ya sea por una mala pendiente

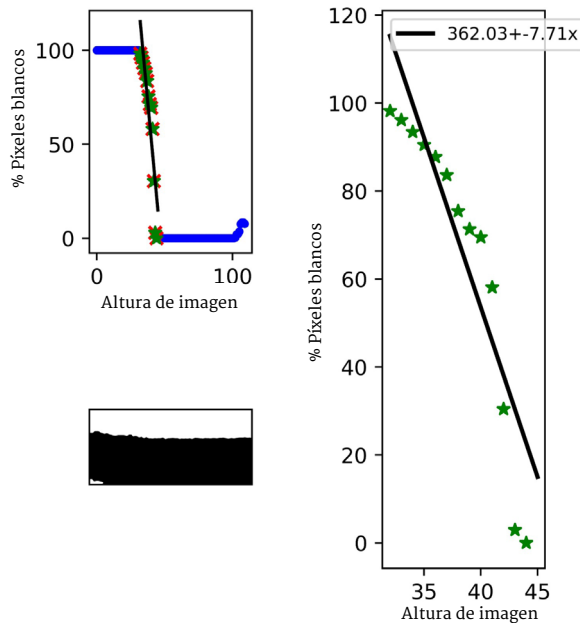


Fig. 26. Ejemplo de la pendiente del % de píxeles blancos de una imagen.

Fuente: Elaboración propia.

de la línea de grasa o porque la zona inferior no es lo suficientemente recta como para obtener una medición precisa de la imagen. Se eligió este factor como límite para determinar que una imagen era correcta, ya que se observó que las mediciones obtenidas con el ecógrafo comparadas con la medición real de la grasa medida en la canal del cordero no se correspondían adecuadamente con las imágenes que tenían pendientes superiores a las mencionadas.

Una vez seleccionada la imagen correcta, se calcula la cantidad de grasa del animal. Para ello, se calcula la mediana de la altura en píxeles de la última línea de grasa. La mediana de esta línea es la altura en píxeles del ROI que, con la equivalencia en mm del ecógrafo, permite determinar el espesor de grasa del animal en tiempo real.

El valor obtenido de la zona blanca se utilizó a continuación para determinar el estado (No graso, Poco cubierto, Cubierto, Graso y Muy graso) del nivel de grasa del animal en función de su sexo y peso. Esta valoración se efectuó comparando lo obtenido con la valoración realizada por el experto observando la misma canal que el cordero estudiado, como se ha indicado anteriormente.

5.1.3. Algoritmo de aprendizaje automático

Análisis de los datos del modelo

El análisis de los datos recogidos durante el proceso de cálculo de la cantidad de grasa de los corderos reveló tendencias interesantes relacionadas con varios factores, entre ellos los milímetros de grasa medidos manualmente, el peso del animal y su sexo. En particular, se observó que la mayoría de los corderos cuyo peso vivo estaba dentro del intervalo establecido por la IGP “Ternasco de Aragón” (entre 19 y 26 kg) y que tenían entre 3,5 y 5,5 mm de grasa se encontraban en un estado “Cubierto” para la venta, según indicó el experto consultado en este estudio (Fig. 27).

Además, los datos también mostraron que las hembras tenían tendencia a presentar más casos de “Muy Graso” que de “No Graso”, mientras

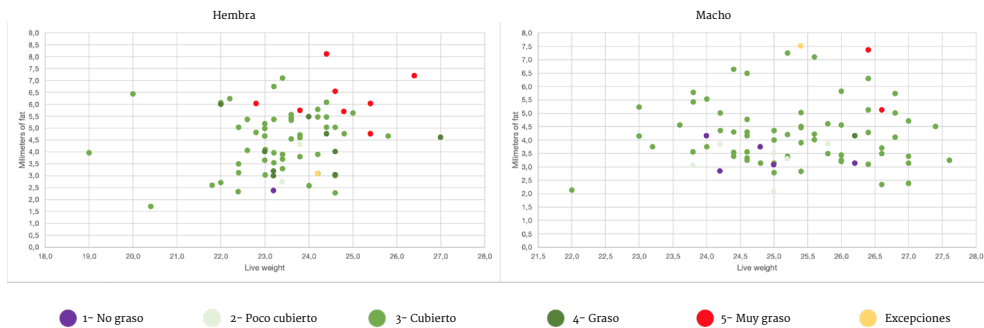


Fig. 27. Comparación de mm de grasa y peso por sexo.
Fuente: Elaboración propia.

que en los machos ocurría lo contrario. Estos resultados podrían ser útiles para simplificar el proceso de medición de la grasa en la manga de manejo, permitiendo a los ganaderos utilizar esta información para ajustar las mediciones en consecuencia y obtener una mayor precisión en el cálculo de la cantidad de grasa de los animales.

Uno de los objetivos a tener en cuenta durante el proceso de medición es evitar ralentizar el actual proceso de clasificación de corderos en los cebaderos. Es obvio que, al añadir una estación de clasificación adicional en el recorrido de la manga, este proceso se volverá más lento de lo que es actualmente. Sin embargo, con los datos obtenidos podemos intentar acelerar el paso por la nueva estación. Como puede verse en la Fig.27, hay grupos de corderos cuya definición es muy clara. Por ejemplo, en los machos se puede observar como la mayoría de los corderos de más de 25 kg de peso están en el grupo “Cubierto” independientemente de los mm de grasa corporal que tengan. Sin embargo, si nos fijamos en el sexo del animal, podemos ver que las hembras de más de 24 kg están en un 67% fuera del rango óptimo de grasa que determina la calidad de la carne de primera, es decir, “Graso” o “Muy Graso”. A partir de 25 kg, este porcentaje aumenta hasta el 86%. Esto puede permitir a los ganaderos/usuarios evitar mediciones innecesarias, y medir sólo corderos en el límite de los grupos cuyos niveles de grasa pueden ser dudosos.

Como puede observarse en la Fig. 27, los datos obtenidos en el estudio corresponden en su mayoría a corderos cubiertos de grasa. Esto es lógico, ya que los corderos cuya grasa se quiere medir van al matadero con la intención de pertenecer a la IGP “Ternasco de Aragón” y si se quiere maximizar la rentabilidad de cada pieza, es necesario tener unos valores de grasa adecuados. Teniendo en cuenta la situación en la que se ha realizado el estudio, es normal encontrar una descompensación de datos entre las cinco categorías.

Como primer paso para la clasificación, se realizó una validación cruzada para comprobar cuál era el método de clasificación más preciso. Sin embargo, debido a la descompensación de los datos de la muestra, éstos se prepararon previamente realizando un sobremuestreo mediante la técnica SMOTE: Synthetic Minority Over-sampling Technique (Chawla et al., 2002). Se evaluarón los siguientes algoritmos de regresión: Logistic Regression, Support Vector Machines, Decision Tree, Gradient Boosting, Random Forest y KNN. El resultado de la validación cruzada puede verse en la Tabla 3, que muestra que el método de clasificación más preciso es KNN (k-nearest neighbors). KNN es un algoritmo de aprendizaje automático que clasifica datos nuevos basándose en la similitud con los datos más cercanos del conjunto de entrenamiento. El conjunto de datos se distribuyó con una proporción 80-20 entre el conjunto de entrenamiento y el de validación. En la Tabla 4 puede verse la matriz de confusión con los resultados de la clasificación en el conjunto de validación, con una precisión global del 74,5%.

Si dividimos los datos en dos grupos, carne de buena calidad para pertenecer a la IGP “Ternasco de Aragón” según el Europeo (2017) (Poco Cubierto y Cubierto), y un segundo grupo que es el resto de carne con diferente contenido graso (No graso, Graso y Muy Graso), podemos ver como la precisión de la predicción mejora sustancialmente respecto a la precisión media llegando incluso a alcanzar el 83% en el grupo de datos “Poco Cubierto” y “Cubierto”.

Precisión del método de clasificación	
Métodos	Precisión
Logistic Regression	0.550
SVM	0.618
Decision Tree	0.706
Gradient Boosting	0.737
Random Forest	0.770
KNN	0.775

Tabla 3. Comparación de la precisión de los métodos de clasificación de validación cruzada.

Fuente: Elaboración propia.

Matriz de confusión					
Datos reales	Predicción de datos				
	NG	PC	C	G	MG
No graso	32	9	2	1	0
Poco cubierto	5	22	3	1	0
Cubierto	6	2	33	5	0
Graso	1	3	0	29	5
Muy graso	0	0	0	8	33

Abreviaciones: NG = No graso; PC = Poco cubierto; C = Cubierto; G = Graso; MG = Muy graso

Tabla 4. Matriz de confusión de la clasificación en el conjunto de validación.

Fuente: Elaboración propia.

5.1.4. Desarrollo del dispositivo

Este dispositivo se desarrolló en dos fases distintas porque el resultado consta de dos partes diferentes, un producto físico y el software necesario para alcanzar los objetivos del estudio. La primera fase del estudio consistió en el diseño y fabricación de un prototipo de dispositivo de bloqueo que pudiera integrarse fácilmente en la manga de manejo

de un cebadero. Para alcanzar este objetivo, se tuvieron en cuenta las dimensiones y características de la rampa de manipulación, así como la necesidad de minimizar el estrés del animal durante el proceso de medición de la grasa. El dispositivo de bloqueo debía permitir al operario pesar e inmovilizar al cordero de forma suave y eficaz, sin causarle ningún daño, con el fin de obtener mediciones precisas de la cantidad de grasa de su cuerpo.

En la segunda fase del estudio, se diseñó y desarrolló un software específico para calcular la cantidad de grasa del animal con precisión y en tiempo real para clasificar los corderos. Este software debía ser capaz de visualizar la imagen que el operario capta de la grasa del cordero e indicar cuánta grasa tiene el animal en vida.

Diseño y fabricación del prototipo

Como se puede observar en la Fig. 28, el prototipo está formado por dos zonas claramente diferenciadas, la primera es la entrada del cordero y la segunda donde se encuentran todos los mandos de accionamiento, el dispositivo de bloqueo y el peso.




Fig. 28. Partes y funcionamiento del dispositivo de bloqueo del cordero.
Fuente: Elaboración propia.

La primera zona imita la forma, el tamaño y el aspecto de una sección de manga de un cebadero. Se diseñó así para que el cordero se familiarizara con el prototipo al entrar en una zona conocida y para minimizar su estrés, de modo que las mediciones puedan realizarse con un animal mucho más relajado.

La segunda zona consta de una báscula en la parte inferior, una pared giratoria que presiona al cordero para inmovilizarlo y una serie de compuertas que impiden que el cordero avance o retroceda fuera de la rampa. Además, en esta segunda zona, también se encuentran todos los elementos con los que interactúa el operario, los actuadores del dispositivo de bloqueo, la tableta y el ecógrafo. Como se puede observar en los dibujos de la Fig. 27, el sistema de accionamiento del dispositivo de bloqueo es neumático, haciendo uso de dos cilindros que abren o cierran la compuerta cuando los mandos son accionados por el operador.

Para el desarrollo de ambas zonas fue necesario conocer las medidas de un cordero en el rango de peso en el que se encontrarían en el momento de la medición de la grasa. Se tomaron medidas de la cadera, el hombro, la cintura y la altura a la cruz de 70 corderos de entre 15,2 kg y 26 kg. Se utilizaron estos corderos porque el rango establecido por la IGP “Ternasco de Aragón” es de 19 a 26 kg de peso vivo, lo que hace que este sea el rango más común de pesos de sacrificio en Aragón.

Estas medidas, junto con la anchura y altura de la manga descritas anteriormente, sirvieron para dotar a la estación de medición de un diseño adaptado a la forma real del cordero y a la posición habitual de un operario manejando la manga (Fig.29).

El software y la interfaz de la aplicación para tableta se han desarrollado con Android Studio, aunque la mayoría de las pruebas se habían realizado previamente en Python 3.6 (van Rossum, 1995b). Como puede verse en la Fig. 29, la interfaz permite al operario del cebadero interactuar con ella fácilmente, teniendo en cuenta que una mano estará ocupada con el ecógrafo. El diseño del software se ha realizado teniendo en cuenta las especificaciones de la aplicación nativa del ecógrafo y la posición en la que el operario realiza la medición. Teniendo esto en cuenta, se ha decidido que los botones sean de gran tamaño para evitar errores al



Fig. 29. Bloqueador ovino.
Fuente: Elaboración propia.

pulsarlos. La función principal de la aplicación es mostrar en tiempo real la imagen de la grasa del cordero. Para facilitar la interacción del usuario con la aplicación, todos los botones de control se han colocado en la parte derecha de la interfaz, como se puede ver en la Fig. 30. Se eligió esta disposición porque la tableta está colocada en el lado derecho del prototipo, mientras que los controles para manejar la bloqueadora están en el lado izquierdo del puesto del operador.

Además, para facilitar la captura de una imagen correcta, se ha diseñado un indicador rojo y verde que indica al usuario si la imagen es correcta según la validación de la imagen con el método explicado anteriormente. De este modo, el operador sólo tiene que comprobar el peso que aparece en la pantalla, seleccionar el sexo y analizar una imagen que ya es buena para medir la grasa. De esta forma, la única interacción que el operario tiene con la aplicación a nivel táctil es seleccionar el sexo, asignar un nombre o crotal al cordero si así lo decide, comprobar que la imagen seleccionada es buena y, si es necesario, guardar la medición en

un fichero (.csv). Si ninguna de estas acciones es necesaria, el operador puede realizar todo el proceso pulsando el botón del propio ecógrafo y seleccionando el sexo.




Fig. 30. Interfaz de la aplicación.

Fuente: Elaboración propia.

Secuencia de uso

El primer paso para poder realizar una medición correcta es pesar el cordero en el dispositivo de bloqueo y, una vez obtenido el peso, bloquear el cordero. Este proceso, se realiza automáticamente antes de cerrar el dispositivo de bloqueo mediante el peso instalado en la parte inferior. Una vez pesado, el cordero queda bloqueado por la acción de la pared giratoria del prototipo, que se acciona neumáticamente mediante el botón “Cerrar” situado en el panel de control a la izquierda del operario. Antes de pulsar el botón, el operario debe asegurarse de que el cordero está en la posición correcta, como se muestra en la Fig. 31. La pared giratoria se ajusta para proporcionar la presión necesaria sin causar daños al animal, gracias a una cubierta de goma flexible que cubre la pared para protegerla. De este modo, el cordero queda inmovilizado para permitir una medición precisa de la grasa sin dañarlo.



Fig. 31. Cordero bloqueado.

Fuente: Elaboración propia.

Una vez inmovilizado, el operario aplica alcohol en la parte baja de la espalda y presiona ligeramente el ecógrafo contra la piel del cordero. Durante este proceso, el operador podrá observar en tiempo real la imagen captada por el ecógrafo en la aplicación. Para que el operador pueda diferenciar si la imagen que está tomando es correcta para una buena medición, siempre está visible una alerta que se ilumina en verde o rojo dependiendo de si la imagen es correcta o no. Cuando la imagen es correcta, el operador sólo tiene que pulsar un único botón del ecógrafo. Si es necesario, la aplicación tiene la opción de guardar los datos del cordero en una hoja de cálculo que puede exportarse para su posterior análisis.

En función del peso obtenido, el sexo seleccionado y la medición de la grasa, la aplicación muestra la clasificación del cordero según [Europeo \(2017\)](#) y el actuador abrirá la puerta adecuada para la correcta clasificación del cordero.

5.1.5. Conclusiones

Este dispositivo está alineado con la consecución del objetivo 2 expuesto en los objetivos de esta tesis, generando un método de clasificación inexistente en el sector ovino que se adapta a la forma de la manga de manejo actual y se integra adecuadamente en el proceso habitual de trabajo de un cebadero.

La aplicación de técnicas de visión por computación permite al operario saber si la imagen de análisis está tomada correctamente en tiempo real. Esto hace que el proceso de estimación de la medida de grasa sea más rápido, minimizando el tiempo que el cordero está bloqueado. A pesar de que pueda parecer que el bloqueador aumenta el estrés que sufre el animal en el proceso, se observó que los animales estaban mucho más tranquilos y relajados que cuando se realiza este mismo proceso manualmente.

Aunque este dispositivo genere un nuevo método de clasificación que ayudará a ajustar adecuadamente el precio recibido por cordero y contribuya a una mejor sostenibilidad económica del sector, la precisión actual del modelo no es la deseada. Para mejorar la precisión del modelo se necesitaría animales con poca grasa o muy engrasados. Sin embargo, es algo difícil de conseguir, ya que para conseguir un buen resultado es necesario medir la grasa de un cordero antes y comprobarla en la canal. El mayor problema en este proceso es que los animales que va a matadero suelen ir muy cerca de los valores estándares de buena calidad de la carne lo que disminuye mucho el número de casos en los extremos.

6. Detección de trayectorias de corte en costillares de corderos mediante procesamiento de imágenes

El corte de una pieza de carne, es uno de los principales factores que determinan la calidad del producto final (Campo et al., 2016). En el caso del cordero, y más específicamente en Aragón, esa calidad se refleja sobre todo en una de las piezas mejores valoradas, las costillas. No obstante, la forma en la que se realiza el corte varía respecto a otras especies debido a su morfología.

Los costillares de las especies de consumo más habituales tienen morfologías muy diferentes. En la Fig. 32 se pueden observar las principales diferencias entre los costillares de ternera, cerdo y cordero. Como se puede ver detenidamente, el costillar de cordero tiene una cierta curvatura en las primeras costillas, así como diferentes cambios de dirección a lo largo del costillar. Estas peculiaridades son las que hacen del costillar de cordero un desafío en el corte en serie automático.

Como se ha mencionado en la introducción, actualmente estos cortes es habitual hacerlos con cuchillas capaces de realizar este proceso en poco tiempo. Sin embargo, debido a la morfología del costillar de cordero,



Fig. 32. Ejemplos de costillares de diferentes especies. De izquierda a derecha. Costillar de Ternera, costillar de cerdo y costillar de cordero.

Fuente: Elaboración propia.

visible en la Fig. 31, este corte en el cordero provoca cortes en diferentes costillas, astillados y una negativa imagen de presentación del producto. Todo esto repercute en la calidad del producto final, minimizando su valor económico debido a su presencia y aspecto en los puntos de venta (Scozzafava et al., 2016).

Estos inconvenientes hacen que el valor de los costillares de corderos se devalúe por su bajo consumo, rebajando la importancia de esta pieza para el comercializador. En Aragón, con la larga tradición en cuanto al consumo de cordero, es difícil de encontrar fuera de los cortes manuales del costillar de cordero troceado por costillas, ya que para los hipermercados no es rentable debido a que no pueden vender una pieza con una calidad tan baja. Esto le añade mucho valor a la capacidad de industrialización de los mataderos que permitan adaptarse a la tecnificación que precisan este tipo de procesos.

Teniendo en cuenta lo expuesto anteriormente, este capítulo expone un estudio que tiene como objetivo mejorar el corte actual de los costillares de corderos adscritos a la IGP “Ternasco de Aragón” mediante el uso de técnicas de visión por computación, con el fin de facilitar y extender el consumo del cordero.

6.1. Detección de trayectorias de corte en costillares de corderos

Para conseguir un corte adecuado del costillar que permita separar las costillas individualmente, es necesario una tecnología que permita cortar siguiendo trayectorias similares a las realizadas por un corte manual. Dentro de estas características podríamos encontrar tecnologías de corte mecánico corte con cuchillas acopladas a un brazo de 3 ejes, o corte por chorro de agua ya que son los tipos de corte que no dañarían la pieza a nivel alimenticio. Ambas tecnologías usan trayectorias en el espacio que permiten realizar cortes curvados. Entre ambas tecnologías, aunque ambas dos han demostrado ser completamente viables para el corte de carne, la segunda no necesita anclaje del producto y tiene una merma de carne menor, siendo más rentable.

El corte por chorro de agua puede cortar prácticamente cualquier material, sin embargo, a medida que aumenta la dureza del material a cortar, es necesario aplicar un abrasivo que permita profundizar en el corte. Teniendo en cuenta que es un producto alimenticio de consumo, el abrasivo ha de ser compatible con el producto, evitando que produzca cambios significativos en el sabor y calidad de la carne. Se ha demostrado que el hielo (McGeough, 2016) o la sal concede una potencia de corte adecuada para cortar un hueso de animal sin perjudicar en absoluto el sabor de la carne (J. Wang & Shanmugam, 2009).

Por estas razones, es necesario proporcionar una trayectoria fiable que permita el corte adecuado de cada costilla. Para ello, se ha observado como la visión por computación es un elemento diferenciador que puede adaptarse a sujetos completamente distintos. Este tipo de análisis de piezas solidas mediante técnicas de visión por computación se han

utilizado anteriormente en diferentes ámbitos industriales. Entre ellos destacan detección de desperfectos en piezas industriales mecanizadas (R. Liu et al., 2017; Riego et al., 2021), desperfectos en pinturas (Xu et al., 2020) o, enfocado en ámbito animal, se pueden encontrar estudios que detectan impurezas en la carne mediante rayos X (Zhao et al., 2008).

En los siguientes apartados se describe el proceso de desarrollo de la identificación de las trayectorias de corte del costillar de cordero óptimas para su corte mediante chorro de agua.

6.1.1. Adquisición de imágenes

El primer paso y el mayor inconveniente a la hora de detectar las trayectorias de corte, es la imagen de partida. Esta imagen es clave para una correcta detección, por lo que es importante optimizar la forma en la que se adquieren las imágenes. Para el desarrollo de este estudio se desarrollaron 3 experimentos debido a las posibilidades existentes para la detección de las costillas. Partiendo del objetivo del estudio “identificar las trayectorias correctas de corte”, el obstáculo principal para el corte es evitar la zona del hueso de la costilla, respetando de esta manera la forma de la costilla y, por lo tanto, equiparando la calidad del corte al del corte tradicional manual.

La mayor diferencia en la adquisición de este tipo de imágenes es el tipo de captura de la imagen y la iluminación de la misma. Teniendo en cuenta las características del producto se descartan las cámaras termográficas ya que el producto es un producto cárnico post-mortem con una temperatura uniforme. Según las hipótesis planteadas para el desarrollo del producto, se plantean tres posibilidades distintas de adquisición de imágenes.

La primera de las posibilidades de adquisición de imágenes es mediante una cámara 3D, e iluminación led ambiental de color blanco. La cámara utilizada fue una Intel RealSense D435.

La segunda opción, parte de la premisa de diferenciar mejor las zonas blancas de la pieza que son las costillas y la grasa. Para ello, se utiliza la misma cámara que en el experimento anterior pero esta vez con luz negra como iluminación principal.

Por último, el último experimento se realiza en una cabina de rayos-x y sin iluminación adicional ya que esta tecnología no lo necesita. En este caso se elige esta tecnología ya que permite identificar las zonas solidas de las blandas, entre ellas, las costillas y la columna del cordero.

En los dos primeros casos, se fabrica un set de grabación que permita iluminar el costillar homogéneamente para no generar ningún tipo de sombra que perjudique el posterior procesamiento. El set se trata de una caja abierta por una de sus caras de tamaño suficiente para que la cámara capte perfectamente el costillar como se observa en la Fig. 33. En ambos casos, la cara abierta de la caja se tapa en el momento de la captación para que no entre luz del exterior.




Fig. 33. Set de adquisición de imágenes.

Fuente: Elaboración propia.

Durante las primeras pruebas realizadas, se observa en ambos experimentos que la luz es demasiado intensa y provoca brillos en varias partes del costillar. Estos brillos perjudican al procesado ya que en muchas ocasiones se confunden con las costillas por su parecido en el color. Para evitar dichos brillos, se hace una segunda prueba con difusores de luz colocados entre el led y la pieza de carne. El resultado son tonos más mates que eliminan los brillos anteriores como se puede observar en la Fig. 34.




Fig. 34. Imágenes capturadas con y sin difusor.

Fuente: Elaboración propia.

En el caso de los rayos X, se modificaron los parámetros de contraste y brillo de la máquina para que la captación de la imagen fuese la más adecuada y se diferenciase suficientemente bien las costillas del resto de tejidos.

En los dos primeros experimentos, se realizaron fotografías 73 costillares en ambas direcciones generando un total de 47 imágenes con iluminación led y 26 con iluminación de luz negra. De estas imágenes fueron con difusor 32 en el caso del led y 16 en el caso de la luz negra. En cuanto a los rayos X se capturaron 10 imágenes de dos costillares diferentes.

6.1.2. Procesamiento de la imagen

En esta fase, se realizaron distintos procesamientos previos dependiendo de las imágenes de entrada capturadas como se explica en el apartado anterior. Sin embargo, en todos los casos se realiza un pre-procesado de la imagen que facilite el resto de las técnicas utilizadas para el procesamiento.

Las primeras fases en todos los procesados de la imagen es aislar el costillar del resto del entorno de la imagen, ya que el entorno en el que se realizan los dos primeros experimentos (de color blanco) y el tercero (de color negro) son muy similares a partes que en el futuro se podría querer destacar o descartar. Para ello en los dos primeros experimentos se utiliza la imagen de profundidad del costillar para binarizar según los colores captados por la profundidad y de esta forma poder detectar la localización del costillar en la foto (Fig. 35). Esta binarización se realiza entre el rango de colores HSV, aislando el costillar (A). Posteriormente, se eliminan elementos pequeño y elementos en contacto con los bordes para la obtención de la máscara (B). Con la máscara del costillar obtenida se extrapola esa posición a la imagen RGB y se le dota de un margen de 20 px al bounding box del costillar, obteniendo así una imagen de menor tamaño, pero sin elementos externos al costillar (C).




Fig. 35. Procesamiento inicial de la imagen mediante la imagen de profundidad.
Fuente: Elaboración propia.

En el caso de los rayos X se realiza una binarización Otsu (Otsu, 1979) y se realiza un recorte de la imagen a 20 px del borde del bounding box (Fig. 36).

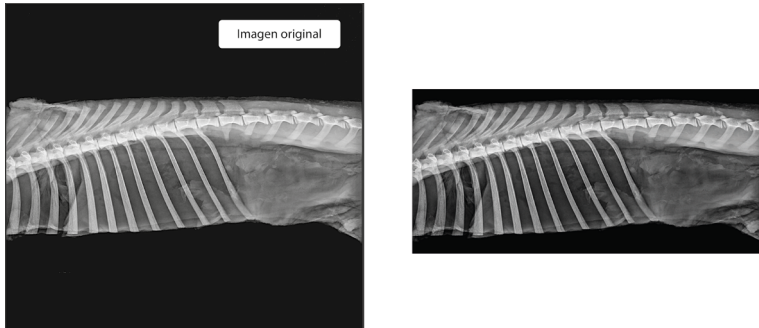


Fig. 36. Recorte de la imagen de rayos X.
Fuente: Elaboración propia.

A partir de esta imagen, en los dos primeros experimentos, se realiza una corrección del histograma mediante método CLAHE (Pizer et al., 1990) para intentar destacar más los colores blanco del resto como se observa en la Fig. 37.




Fig. 37. Corrección de color.
Fuente: Elaboración propia.

Una vez obtenido el contraste deseado, se binariza el costillar con el fin de detectar las áreas que corresponden a las costillas. Una vez binarizada la imagen, se descartan las áreas más grandes que pertenecen a una vez obtenido el contraste deseado, se binariza el costillar con el fin de detectar las áreas que corresponden a las costillas mediante el método Otsu (Otsu, 1979) (A). Se descartan las áreas más grandes que pertenecen a las zonas de grasa de la imagen, y se descartan también las áreas con una base mayor a la altura, eliminando así las vértebras de la columna y elementos que claramente no son verticales (B). Por último, se eliminan pequeñas áreas pertenecientes a pequeños cúmulos de grasa o manchas mediante la erosión y dilatación de los elementos (C). Posteriormente se vuelve a limpiar la imagen de elementos pequeños obteniendo así todas las costillas del costillar (D) (Fig. 38).




Fig. 38. Proceso de detección de costillas mediante iluminación led y luz negra.
Fuente: Elaboración propia.

En el caso del tercer experimento, se binarizó la imagen para eliminar las zonas grises intermedias. En este caso la costilla se observaba perfectamente unida a las vértebras, por lo que la forma de abordar el

problema cambiaba el enfoque de trabajo. Para eliminar las vértebras y obtener el área de las costillas primero se localizó la columna con diferentes parámetros de binarización (A). Y se agruparon (B) para posteriormente recortar la imagen obteniendo la zona donde se encuentran las costillas (C). De esta forma se podía eliminar todas las zonas blancas de la imagen original desde la columna hacia el exterior del costillar (Fig. 39).




Fig. 39. Detección de la columna en el costillar.

Fuente: Elaboración propia.

El último procesado de la imagen fue eliminar pequeños defectos de la imagen y seleccionar los componentes con una distribución vertical, es decir con menos base que altura, obteniendo así una imagen clara de las costillas (Fig. 40).




Fig. 40. Detección de costillas.
Fuente: Elaboración propia.




Fig. 41. Comparación de las costillas detectadas entre los diferentes supuestos.
Fuente: Elaboración propia.

6.1.3. Algoritmo de detección de trayectorias

El último paso para la detección de las trayectorias es el dibujo de las líneas por donde tendrá que cortar la máquina. Para ello, en los 3 experimentos se utiliza el mismo algoritmo, ya que se parte de la misma imagen, el costillar con las costillas detectadas (Fig. 41).

Teniendo en cuenta que el producto final que nos encontramos actualmente en una carnicería son costillas de aproximadamente 1 cm de grosor rectas, con este último paso se pretende conseguir el corte más óptimo recto sin dañar ningún hueso de costilla. Para ello primero se localizan los puntos medios entre el lado derecho de una costilla y el lado izquierdo de la siguiente, consiguiendo la curva media entre la forma de las costillas (Fig. 42).

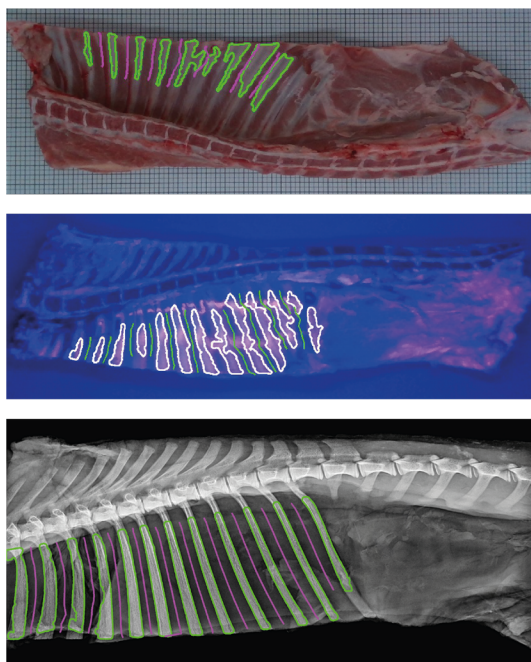


Fig. 42. Curva intermedia entre los laterales de las costillas.
Fuente: Elaboración propia.

Después se realiza una regresión lineal de los puntos intermedios para obtener la línea recta que pasa por el medio de la costilla sin tocar ninguna de las dos costillas. Estas líneas se alargan hasta tocar con el punto más cercano por arriba y por abajo del bounding box del costillar (Fig. 43).




Fig. 43. Trayectorias de corte del costillar completo.

Fuente: Elaboración propia.

6.1.4. Resultados

Como se ha podido observar a lo largo de los experimentos, cada tipología de adquisición de imágenes interfiere en la aplicación de diferentes técnicas de visión por computación. Además, observando la problemática de cada tipo de imagen y los resultados obtenidos, podemos ver como el último experimento tiene una mayor precisión a la hora de lo-

calizar las trayectorias en la zona de las costillas. En el caso de los dos primeros experimentos se consigue una detección entre 7 y 9 trayectorias de corte entre costillas de 11 posibles, mientras que en el tercer experimento se detectan todas a la perfección. Hay que destacar, que los motivos por los que no se detectan adecuadamente las trayectorias en los dos primeros casos están ligados al estado de la pieza. En la mayoría de las ocasiones la pieza esta manchada o tiene exceso de elementos grasos que interfieren con las costillas. Entre los primeros experimentos, se observa mayor nitidez y claridad en el caso de la iluminación led, facilitando el procesado, sin embargo, son factores que no afectan al resultado final ya que los resultados son similares.

A la hora de incorporar estas soluciones a la metodología de trabajo del matadero, el dispositivo desarrollado deberá adaptarse a las diferentes soluciones acordes con el tipo de adquisición de imágenes que se elija finalmente.

En el caso de elegir un tipo de adquisición de imágenes similar al de los dos primeros experimentos y siempre teniendo en cuenta que el dispositivo deberá ir dentro de la cadena de procesado de un costillar, este deberá tener una estación previa de captura de la imagen con la iluminación controlada como la que se propone en los apartados anteriores donde se realizará la captura de la imagen y se procesaran las imágenes obtenidas para dotar a la máquina de corte de las coordenadas necesarias para realizar el corte adecuadamente.

Esta estación podría estar dentro de una misma cinta de transporte para que la base donde apoye el costillar sea la misma durante la captura y durante el corte, y no necesitar así un punto de control en el costillar que permita la localización del costillar en la nueva base.

En el caso de la elección de la tecnología de rayos X, el sistema variaría ya que la zona de captura de las imágenes deberá ser una cabina plomada en la que intervendría un operario formado y con la seguridad necesaria para el manejo de la tecnología. Aunque claramente los resultados con esta tecnología son superiores al resto de experimentos, es verdad que el coste del dispositivo aumentaría drásticamente y necesitaría de un operario cualificado para su manejo.

Método de corte

Este estudio parte de la necesidad de generar un corte correcto de costillares de cordero orientado a su corte mediante chorro de agua. El corte por chorro de agua es una tecnología que se ha probado previamente en el corte de carne (Alitavoli & McGeough, 1998; J. Wang & Shanmugam, 2009). En este segundo caso, se ha utilizado sal como abrasivo para poder cortar el hueso del animal. Este tipo de corte se adaptaría al problema planteado en este estudio. Además, la sal permite que el desperdicio de carne en el corte sea mucho menor que con una cuchilla como se hace habitualmente. También se ha demostrado que el corte con sal como abrasivo no afecta al sabor de la carne y por lo tanto no disminuye la calidad apreciada por el usuario (J. Wang & Shanmugam, 2009).

Por otro lado, el corte por chorro de agua permite realizar diferentes trayectorias de corte al mismo tiempo, lo que se adaptaría perfectamente a la morfología del costillar de cordero, el cual tiene una trayectoria diferente por cada costilla. A pesar de ello, disponiendo de las trayectorias de corte de cada costillar, se podría implementar un sistema de corte por cuchillas que pudiese adaptarse a las trayectorias de corte.

6.1.5. Conclusiones

El estudio está alineado con la consecución del objetivo 3 expuesto en los objetivos de esta tesis, generando una nueva opción al matadero que permita mejorar la precisión actual del corte utilizando un método automático, ayudando en el desarrollo tecnológico y económico del sector.

La posibilidad de detectar las trayectorias de las costillas de forma automática mediante procesamiento de imagen abre un campo al desarrollo de dispositivos de corte, no solo en el sector ovino sino en otros sectores. A partir de las trayectorias detectadas, se podrían diseñar diferentes métodos o estaciones de corte ayudando al desarrollo tecnológico del matadero, optimizando sus procesos y por lo tanto mejorando la salud económica del proceso.

La mejora de la presencia del producto final conseguida con estas trayectorias, mejoraría la venta del producto y revalorizaría su precio, haciéndolo atractivo a grandes superficies, expandiendo el producto a todo tipo de usuarios. De esta forma se contribuiría a la expansión de la IGP “Ternasco de Aragón” fuera del territorio promocionando su producto estrella, las costillas.

7. Discusión y líneas futuras de trabajo

7.1. Discusión

El sector ganadero ovino está atravesando un periodo de incertidumbre y declive en los últimos años debido a un descenso en el consumo en la población española (SG de Producciones Ganaderas y Cinegéticas, 2023). Dentro de este escenario, la productividad, la sostenibilidad económica y ambiental y el bienestar animal toman un carácter de mayor importancia para la supervivencia del sector. La tecnificación o la incorporación de técnicas de PLF al desempeño de tareas cotidianas mejoran estos factores (Berckmans, 2014). Sin embargo, para poder añadir estos elementos, es necesario que los proyectos desarrollados dentro el sector, estén adecuados a los usuarios, a los animales y a las características e intereses del sector.

A lo largo de esta tesis se han desarrollado diferentes investigaciones cuya finalidad es cumplir con los objetivos descritos inicialmente ayudando al desarrollo del sector. Los objetivos propuestos están alineados con los problemas encontrados en cada uno de los agentes que participan en la cadena de valor del producto ovino en Aragón, más concretamente con el manejo de la raza Rasa Aragonesa.

La importancia del peso

Uno de los factores más importantes encontrados a la hora de monitorizar la actividad del cordero y de mejorar la rentabilidad de las explotaciones es el control del peso. La precisión en la estimación del peso es de suma importancia durante las diferentes fases de crecimiento del

animal. El peso permite al ganadero controlar el crecimiento del animal (Greenwood et al., 1998; Hatcher et al., 2008), detectar animales enfermos (Segerkvist et al., 2020) y, en el caso de la IGP “Ternasco de Aragón”, determina el valor económico de cada animal cuando se envía a sacrificio.

En la actualidad, al utilizar una balanza electrónica, el cordero debe ser aislado de los demás animales y confinado en un recinto que limite su movilidad para asegurar una medición precisa del peso. En otros casos, se emplea una báscula romana o un dinamómetro, lo que implica colgar al cordero en arneses que no están diseñados de forma ergonómica para su morfología. Esta manipulación provoca un alto nivel de estrés para el animal y, particularmente con la báscula romana, existe el riesgo de que sufra golpes durante el pesaje.

En este punto, la visión por computación toma especial relevancia en el proceso de pesaje, ya que permite la extracción de diferentes características del animal sin interferir en sus hábitos. En la [sección 4.1 del capítulo 4](#) de esta tesis se demuestra que las medidas exteriores del cordero, especialmente el área cenital del animal tiene una correlación directa con su peso. La correlación entre medidas morfométricas específicas y el peso de los corderos, demostrada en la investigación, resalta la potencialidad de técnicas no invasivas para el monitoreo de la salud y el crecimiento de los animales. Este enfoque se alinea con estudios anteriores que han establecido la utilidad de las medidas morfométricas para estimar el peso en vivo de diferentes especies, facilitando así una gestión más eficaz sin comprometer el bienestar animal (Afolayan et al., 2006; Atta & El Khidir, 2004). Además, esto facilita la incorporación de técnicas más avanzadas para su cálculo mediante visión por computación permitiendo el uso de modelos predictivos para estimar el peso en vivo. Este hallazgo es clave para el desarrollo de los estudios descritos en el capítulo 4.

Estos estudios están alineados con la consecución del objetivo 1 de la tesis: **Diseñar y desarrollar una herramienta mediante técnicas de visión por computación para la estimación y el control del peso respetando el bienestar animal y la sostenibilidad ambiental.** En las secciones [4.2](#) y [4.3](#) del [capítulo 4](#), de desarrollan dos aplicaciones destina-

das a la estimación y control del peso a través de técnicas de visión por computación. Ambas aplicaciones, tanto LambScan como LambTrack, dotan al ganadero de una herramienta inexistente en el sector que permite estimar el peso del cordero en vivo con un error inferior al 6% a través de dos dispositivos de fácil uso y bajo coste. LambScan propone un dispositivo eficiente, pero poco adaptado al entorno de trabajo, características que mejora LambTrack al tratarse de una aplicación para dispositivos móviles. Además, LambTrack no solo permite el pesaje del cordero, sino que también permite al ganadero mantener un seguimiento del crecimiento de todo su rebaño. Ambos procesos de pesaje se realizan con una distancia sobre el cordero lo que reduce el tiempo en el pesaje y el esfuerzo que realiza el ganadero, ya que no tiene que interactuar con el cordero en el proceso. Todo esto ayudará a que el ganadero pueda realizar mejor otras actividades y por lo tanto ayudará a mejorar su salud mental y el trato a sus animales (Hostiou et al., 2017).

En la literatura, se encuentran investigaciones que han aplicado enfoques similares al pesaje de animales, principalmente en vacas y cerdos (Kuzuhara et al., 2015; Nir et al., 2018; Song et al., 2014; Wang et al., 2006). Estos estudios han obtenido buenos resultados y demuestran el valor de la visión por computación en el pesaje de estos animales.

Los estudios realizados para la estimación del peso no logran mejorar significativamente la precisión en comparación con los estudios anteriormente nombrados en los sectores porcino y vacuno, aunque sí muestran notables avances. Esto se debe a que el sector ovino presenta desafíos únicos, como la alta movilidad y el comportamiento gregario de los corderos, lo que complica capturar imágenes de calidad de un solo animal. El pesaje añade otra complicación, ya que puede afectar la precisión de las mediciones morfométricas. A pesar de estos desafíos, los resultados son comparables a los de otras especies, lo que representa un éxito considerable en la adaptación de la visión por computación al manejo de corderos.

Por otro lado, LambTrack es una aplicación que se puede instalar en cualquier dispositivo móvil, proporcionando a los ganaderos una herramienta económica para estimar el peso de los corderos. Se diseñó prestando especial atención a las condiciones de trabajo del ganadero,

mediante la filosofía del DCU. Este enfoque implica comprender profundamente las necesidades, desafíos y comportamientos de los usuarios para diseñar una aplicación intuitiva y fácil de usar, que se adapte perfectamente al sector. Así, LambTrack está diseñada para integrarse sin problemas en las prácticas diarias del manejo ovino

Aunque LambTrack fue desarrollado para solucionar los problemas de LambScan, tales como el peso del dispositivo y su falta de ergonomía, también enfrenta limitaciones. Por ejemplo, la naturaleza gregaria de los corderos hace que aislar a un solo animal para la toma de fotos sea complicado. LambTrack necesita capturar imágenes de un solo cordero para medir su peso, ya que no diferencia entre varios corderos cuando se encuentran juntos frente a la cámara.

Para desarrollar un modelo preciso basado en visión por computación, es fundamental contar con un conjunto amplio y homogéneo de imágenes. En el caso del algoritmo de LambTrack, se requería capturar imágenes de corderos en distintos tamaños y pesos. Aunque el número de imágenes recopilado fue suficiente para realizar una estimación con un error absoluto medio inferior a 5,9% en los pesos del IGP “Ternasco de Aragón, este error aumentaba al 10,9% cuando se tenían en cuenta los corderos de menor peso. La base de datos utilizada para desarrollar el algoritmo incluye pocas imágenes de corderos que pesen menos de 18 kg, lo que afecta a la precisión del sistema con animales más pequeños. Estas limitaciones reflejan la complejidad de implementar tecnologías de visión por computación en el sector ovino y destacan la necesidad de mejorar la recolección y el análisis de datos para optimizar el rendimiento de estas herramientas en futuras investigaciones.

El control de la grasa y la calidad de la carne

En ganadería, la calidad y el precio de la carne son factores críticos, especialmente en el sector ovino, donde los márgenes de beneficio son menores en comparación con otros sectores.

En el cordero perteneciente al IGP “Ternasco de Aragón”, esta calidad viene dada por el color y la cantidad de grasa en la canal. Esta grasa se mide en cinco rangos diferentes, de los cuales solo dos se consideran como parte de una calidad apropiada para el IGP (Europeo, 2017). Además la grasa es un factor que afecta al sabor (Realini et al., 2021) e influye en la percepción del usuario sobre la calidad de la carne (Webb & O’Neill, 2008). Sin embargo, aunque existen sistemas para medir la cantidad de grasa post-mortem, no existen formas de predecir automáticamente la cantidad de grasa del cordero en vivo antes del sacrificio. Como se ha visto en el estado del arte, en varios estudios realizados en otros sectores ganaderos se han encontrado resultados satisfactorios mediante el uso de imágenes para medir la grasa en vivo (Avril et al., 2013; Carabús et al., 2016; Quaresma et al., 2013; Weber et al., 2014).

En el caso del cordero, esta estimación debe realizarse en los últimos días del cordero antes del sacrificio. Por lo tanto, se requiere que esta acción forme parte del proceso de trabajo del cebadero. A partir de esta premisa se desarrolla el estudio del capítulo 5, alineado con el objetivo 2 de la tesis: **Diseñar y desarrollar una herramienta mediante técnicas de visión por computación para la detección del nivel de grasa en vivo del cordero y su posterior clasificación respetando el bienestar animal y la sostenibilidad ambiental**. En este capítulo se desarrolla una herramienta de clasificación de corderos por su nivel de engrasamiento mediante técnicas de visión por computación aplicadas a imágenes obtenidas mediante ultrasonido.

Esta herramienta representa una novedad en la producción ovina, donde tradicionalmente la medición de grasa se realizaba solo post-mortem. Al ofrecer una solución para la estimación precisa antes del sacrificio, la herramienta no solo mejora la gestión de la calidad de la carne, sino que también valida el uso de visión por computación en la evaluación de parámetros de calidad en el sector.

Además, el uso de técnicas de visión por computación en el software ha permitido crear una aplicación sencilla y de rápido procesamiento que requiere mínima interacción por parte del operador. Esta eficiencia es crucial para reducir el tiempo de cada medición, aumentando así la

rapidez del proceso y mejorando la productividad de los procesos del cebadero (Berckmans, 2014; Tullo et al., 2019). Este avance tecnológico también contribuye al bienestar animal y a la sostenibilidad en la producción ganadera, pues al integrar el monitoreo del nivel de grasa dentro del proceso de trabajo diario se reduce el manejo físico y el estrés en los animales.

La capacidad de clasificar corderos según su nivel de grasa en vivo mejora la consistencia de la calidad del producto final (Webb & O'Neill, 2008), crucial en el sector ovino debido a los márgenes de beneficio estrechos. Esta clasificación precisa beneficia tanto a los productores al optimizar la rentabilidad como a los consumidores, asegurando que reciban productos de alta calidad. Esta herramienta establece un nuevo estándar para la producción ovina y abre caminos para futuras investigaciones científicas en este campo.

Aunque varias investigaciones (Delfa et al., 1995; Ripoll et al., 2009) han demostrado que el uso de imágenes de ultrasonido puede estimar la cantidad de grasa en la canal del cordero antes del sacrificio, esta tecnología no se ha implementado en un proceso de clasificación acorde con los estándares de calidad de la carne. El proyecto desarrollado en esta tesis clasifica la grasa en categorías como “No Graso”, “Poco cubierto”, “Cubierto”, “Graso” y “Muy Graso” (Europeo, 2017). proporcionando a los cebaderos un nuevo método de clasificación que no existía anteriormente.

Como se ha mencionado anteriormente, para desarrollar un modelo preciso es fundamental contar con una gran cantidad de datos. En este estudio, los datos se tomaron un día antes del sacrificio, lo que resultó en una mayoría de corderos dentro del rango “Cubierto”. Esto provocó un desequilibrio significativo, con una escasez de corderos en los rangos “No Graso” y “Muy Graso”. Por lo tanto, es necesario recopilar nuevos datos para ajustar el algoritmo correctamente.

Otra de las dificultades de este proyecto es la identificación y selección del punto adecuado para medir la grasa. La precisión en la medición de la grasa depende en gran medida de encontrar el punto correcto, ya que la distribución de la grasa puede variar considerablemente entre

diferentes partes del animal. Además, la posición del ecógrafo es crucial; si se coloca incorrectamente, puede dar un resultado no válido. La variabilidad anatómica entre los corderos y la dificultad de localizar de manera consistente el mismo punto de medición en cada animal complican esta tarea. Por ello, es necesario contar con operadores con la habilidad y experiencia suficiente para identificar el punto adecuado y tomar imágenes claras y consistentes. Las variaciones en la técnica de los operadores, así como la cooperación de los corderos durante el proceso, pueden afectar la calidad de las imágenes obtenidas y, por ende, la precisión de las mediciones de grasa. Además, la lana de los corderos también influye y ralentiza esta tarea, ya que puede interferir con la obtención de imágenes claras y precisas.

Por último, a pesar de que con este sistema se minimiza la interacción humana, el cordero debe de pasar por la situación de bloqueo, lo que puede generar estrés en el animal. Aunque se ha comprobado que durante el bloqueo el animal no intenta luchar y esta más tranquilo que con otras sujeciones, el bloqueo no deja de ser un proceso que interfiere en la actividad del cordero habitual pudiendo afectar al bienestar del animal.

Estas dificultades subrayan la importancia de desarrollar métodos estandarizados y capacitaciones específicas para los operadores, con el fin de minimizar las variaciones y mejorar la precisión del sistema. Reconociendo la necesidad de contar con personal especializado, el sistema implementa una función innovadora que evalúa la calidad de la imagen antes de proceder con la clasificación de la grasa. Esta característica permite verificar si la imagen capturada cumple con los criterios necesarios para una clasificación precisa, asegurando así que solo se procesen imágenes de alta calidad. Esto no solo mejora la confiabilidad de las mediciones, sino que también optimiza el flujo de trabajo al reducir la necesidad de repetir capturas de imágenes, brindando una solución eficaz a uno de los principales retos del proyecto.

La calidad del producto en el punto de venta

La calidad de la carne, aunque esencial, no es el único factor que determina el valor del producto en el punto de venta. La apariencia y presentación también juegan un papel crucial (Scozzafava et al., 2016). Actualmente, las comercializadoras carecen de tecnologías adaptadas a la morfología de los costillares de cordero. Las cuchillas automáticas, efectivas en otros productos, no son adecuadas para los costillares de cordero, provocando fracturas y astillas que afectan la presentación del producto. Por ello, los cortes manuales, aunque costosos y lentos, siguen siendo la técnica más utilizada.

En la literatura, se ha observado como el corte por chorro de agua es una tecnología que podría adaptarse perfectamente a un sistema de corte automático de carne (Trieb, 2005) con las especificaciones necesarias para el corte de costillares. Además, se ha comprobado la eficacia de esta tecnología en distintos tipos de carne (Alitavoli & McGeough, 1998; J. Wang & Shanmugam, 2009). Sin embargo, para automatizar el corte mediante chorro de agua, se requiere previamente de una detección de las trayectorias de corte. Por ello, en el capítulo 6 se desarrolla un estudio que se alinea con el objetivo 3 de esta tesis: **Desarrollar un sistema que permita la detección de las trayectorias de corte adecuadas en costillares de cordero mediante técnicas de visión por computación.** En este estudio, se desarrollaron algoritmos de detección mediante visión por computación con tres tipos de adquisición de imágenes: led, luz negra y rayos X.

Dentro de la literatura, se encuentran muy pocos estudios que aborden la detección de trayectorias para el corte de carne. Algunos ejemplos encontrados en la literatura incluyen métodos que utilizan rayos X y la reconstrucción de imágenes 3D en pollos (Daley et al., 2005), así como técnicas que reconocen imágenes y detectan trayectorias de corte mediante imágenes a través de una cámara estereoscópica en cerdos (Cong et al., 2021).

A pesar de la existencia de estos métodos en otras especies, no se han encontrado estudios específicos para costillares de cordero, que es el enfoque de este estudio. La aplicación de tecnología de visión por computación para la detección de trayectorias de corte en costillares de cordero es un enfoque novedoso y prácticamente inexplorado. La falta de precedentes en este ámbito implica que hay pocos estudios comparativos para guiar o validar los resultados, lo que representa tanto un desafío como una oportunidad para abrir nuevos caminos

en la investigación y el desarrollo. La innovación de este proyecto no solo radica en su enfoque único, sino también en su potencial para establecer nuevas metodologías y estándares en la automatización del corte de carne, contribuyendo significativamente al avance tecnológico en la industria alimentaria.

Este estudio presenta varias ventajas significativas en términos de resultados. La técnica de rayos X ha demostrado proporcionar resultados perfectos, asegurando cortes exactos y consistentes, esenciales para mantener la calidad y presentación del producto final. Esta innovación posiciona al proyecto a la vanguardia de la tecnología aplicada en el procesamiento de carne y demuestra un potencial considerable para automatizar el proceso de corte, aumentando la eficiencia de producción y reduciendo costos laborales a largo plazo. Al mejorar la detección de trayectorias de corte, se minimiza el error humano, crucial para mantener la precisión en la calidad del producto. Además, el sistema ha mostrado ser adaptable en ciertas configuraciones, lo que sugiere que, con ajustes y mejoras, puede ser aplicable de manera más amplia. Finalmente, el proyecto contribuye al conocimiento científico y técnico en el campo de la tecnología de procesamiento de alimentos, proporcionando datos valiosos y perspectivas para futuras investigaciones y desarrollos en el sector.

A pesar de la notable innovación del proyecto, este enfrenta varias limitaciones. Aunque los resultados obtenidos mediante el uso de rayos X son perfectos, el dispositivo necesario es significativamente costoso y requiere de formación específica de los operarios para su uso, limitando su aplicación práctica. Las otras dos técnicas de adquisición de imágenes, led y luz negra presentan resultados significativamente inferiores. Los errores en estas técnicas suelen deberse al estado de la pieza, que a menudo llega manchada de sangre o con excedentes de grasa que perjudican la calidad de la imagen capturada, provocando pérdidas de información necesaria para una correcta detección de trayectorias. Por lo tanto, esto nos lleva a la conclusión de que las imágenes deben ser de muy alta calidad para asegurar la correcta captura de las trayectorias de corte.

La especificidad de la tecnología de detección y corte también presenta desafíos, ya que debe adaptarse a la morfología única de los costillares

de cordero. Aunque en teoría esto puede lograrse, en la práctica resulta ser considerablemente complicado, incluso si las trayectorias de corte están perfectamente definidas. La variabilidad anatómica entre los corderos y la dificultad para localizar consistentemente el mismo punto de medición complican aún más el proceso, añadiendo otra capa de desafío al intentar estandarizar y automatizar este sistema de corte.

Los desafíos que enfrentan los métodos basados en imágenes RGB con iluminación de luz negra y led pueden abordarse mediante el desarrollo de técnicas de preprocesamiento de la pieza que eliminen el exceso de grasa y la sangre que interfieren con la detección precisa. Futuras investigaciones deberían centrarse en refinar este preprocesamiento y evaluar su impacto en la viabilidad técnica y económica del sistema propuesto. De esta manera, se puede avanzar hacia un proceso de corte automatizado más preciso, rentable y alineado con los estándares de calidad en la industria alimentaria.

El Diseño Centrado en el Usuario como paso hacia la tecnificación

Como se ha observado en la literatura de otros sectores ganaderos, la tecnificación de los mismos, y la aplicación del PLF en concreto, mejora el rendimiento de las explotaciones ganaderas (Berckmans, 2014; Tullo et al., 2019). Para lograr esta tecnificación del sector ovino, es necesario generar herramientas de fácil manejo y rápido aprendizaje, que permitan solucionar algunos de los problemas a los que se enfrenta los agentes de la cadena de valor. Esto contribuirá a mejorar la predisposición del usuario a utilizar las nuevas tecnologías (Kaler & Ruston, 2019). Además, esta predisposición se refuerza cuando el incentivo para usar tecnología es una buena relación entre el coste y el beneficio que ofrecen estos dispositivos (Bewley y Russell, 2010).

Por ello, los estudios realizados están alineados con el objetivo general de la tesis: **Generar nuevas herramientas adaptadas a las necesidades y el entorno de los agentes de la cadena de valor ovina**. Las herramientas desarrolladas a lo largo de esta tesis se han diseñado teniendo en cuenta las necesidades del usuario, su entorno y situación económica. Para todas las herramientas diseñadas se utilizaron técnicas especí-

ficas de DCU. Se realizaron entrevistas a todos los agentes involucrados en los procesos de uso. En las fases finales del desarrollo se realizaron pruebas mediante prototipos para comprobar que las herramientas cumplieran con la función propuestas y para comprobar la interacción de los usuarios con las interfaces. Esto permitió optimizar las interfaces, minimizando procesos innecesarios, generando así aplicaciones con un manejo sencillo y fluido. Esto favorece a la incorporación de estas herramientas al entorno de trabajo (Johnson et al., 2011; Tang & Patel, 1994), produciendo soluciones tecnológicas avanzadas pero de fácil comprensión entre la población envejecida del sector. Adicionalmente, todas las soluciones desarrolladas son de bajo coste mejorando la relación coste/beneficio que ayudará a la tecnificación del sector.

Prácticas no invasivas y bienestar animal

Tal y como señala Ferguson y Warner (2008), la minimización del estrés y la mejora del bienestar animal son factores cruciales para optimizar la producción y la calidad del producto final. En este contexto, la implementación de visión por computación representa un avance significativo en la ganadería, ya que reduce el manejo físico de los animales, lo que conlleva un método menos invasivo. Al reducir el contacto humano, esta técnica contribuye a mejorar las condiciones de vida de los corredos y a respetar las tendencias actuales hacia prácticas que priorizan la integridad y el bienestar animal en la producción ganadera.

El manejo invasivo ha demostrado causar estrés en los animales, lo que reduce su rendimiento productivo (Collier et al., 2006; Estevez, 2007; Mitlöhner et al., 2001). El estrés también puede tener efectos drásticos en la salud de los animales, aumentando el riesgo de enfermedades y mortalidad (Duff & Galyean, 2007; Fitzgerald et al., 2009; Vecerek et al., 2006). Además, afecta negativamente a la calidad de los productos alimenticios (Ferguson & Warner, 2008; Hughes et al., 1986), lo que resalta la necesidad de adoptar prácticas menos estresantes e invasivas.

Los estudios descritos en esta tesis están alineados con la necesidad de minimizar el estrés del animal existente en la literatura, generando herramientas que permiten un manejo más respetuoso con el bienestar

animal que las técnicas tradicionales. Al utilizar técnicas de visión por computación para monitorear y estimar el peso o el nivel de grasa de los animales, se minimiza el estrés asociado al contacto directo, lo que tiene el potencial de mejorar la calidad de vida de los corderos y, en consecuencia, la calidad del producto final. Sin embargo, el proceso de clasificación de grasa requiere del bloqueo del animal, lo que perjudica su bienestar. Aunque se haya conseguido minimizar el contacto humano, no se ha podido eliminar el estrés sufrido por el animal al completo. La aclimatación cuidadosa de los animales jóvenes al manejo y la sujeción puede ayudar a reducir el estrés por miedo, mejorando tanto la productividad como el bienestar (Grandin & Shivley, 2015). Así, estas técnicas satisfacen la necesidad urgente de adoptar prácticas menos estresantes e invasivas, resaltando el potencial de la tecnología para transformar el manejo ganadero en un proceso más eficiente, ético y alineado con las tendencias actuales que priorizan la integridad y el bienestar animal.

Más allá de mejorar el bienestar animal, las tecnologías de imagen también benefician a las explotaciones al proporcionar un monitoreo preciso y eficiente del crecimiento de los corderos. Esto permite a los ganaderos tomar decisiones informadas sobre la alimentación, el manejo y las estrategias de mercado, lo que lleva a una gestión más eficaz de los recursos. Además, la capacidad de recopilar y analizar datos detallados sobre características individuales y rendimiento de los corderos facilita la mejora genética. Los ganaderos pueden utilizar esta información para tomar decisiones de cría que apunten a mejorar características genéticas específicas, como la tasa de crecimiento, la lactancia, la calidad de la carne y la resistencia a enfermedades, potenciando así la mejora genética de la raza y contribuyendo a la sostenibilidad a largo plazo de la explotación. La integración de la tecnología en la ganadería, particularmente para la estimación del peso mediante imágenes y modelos computacionales, refleja un enfoque de producción más sostenible y eficiente, que responde a las demandas actuales del sector (Berckmans, 2014).

7.2. Líneas futuras de trabajo

Los estudios desarrollados en esta tesis abren paso a la exploración de estrategias para mejorar la calidad y la precisión de las técnicas empleadas en la monitorización y manejo de corderos. A continuación, se detallan propuestas para expandir la eficacia de las herramientas desarrolladas, asegurando que los avances tecnológicos continúen contribuyendo significativamente al sector ovino.

Para incrementar la precisión de los modelos desarrollados en esta investigación, como LambTrack y LAUS, es fundamental ampliar y diversificar el conjunto de datos con el que trabajan estos sistemas. Esto implica no solo incrementar el número de imágenes en los rangos de peso que están menos representados, sino también enriquecer la base de datos con imágenes capturadas en diferentes etapas de crecimiento de los animales. Particularmente para LAUS, es esencial obtener datos de corderos en los estados “No Graso” y “Muy Graso”, que actualmente están subrepresentados, para afinar adecuadamente la precisión del modelo.

Además, es crucial trabajar en el desarrollo de un software de estimación más robusto. Esto incluye la mejora en el aislamiento de imágenes de corderos dentro de un rebaño, lo que permitiría evaluaciones más precisas sin las interferencias habituales de otros animales o barreras físicas como las vallas. Para esto, se pueden emplear técnicas avanzadas de segmentación de imágenes y algoritmos de aprendizaje profundo que mejoren la capacidad de distinguir a los corderos del fondo, de otros elementos disruptivos mejorar la detección en condiciones de luz variable y reducir el ruido en los datos recogidos

El siguiente paso lógico parece ser establecer un sistema de feedback continuo que permita utilizar los datos recopilados para refinar y mejorar constantemente los algoritmos de procesamiento de imágenes. Este sistema de retroalimentación asegurará que los modelos se ajusten y optimicen continuamente, basándose en los resultados reales obtenidos, para mejorar su eficacia y precisión en entornos reales.

En el caso del corte de costillas, actualmente se está trabajando en la mejora de la adquisición de imágenes de los dos primeros supuestos y en la incorporación de software de detección a un sistema de corte mediante chorro de agua. Debido a las dificultades por la morfología del costillar y las diferencias entre cada uno de los costillares de cordero se debe explorar otras tecnologías de corte que puedan ser más eficaces. Estas tecnologías pueden ayudar a mejorar la eficiencia y la calidad del proceso de corte, minimizando el desperdicio y asegurando una presentación óptima del producto final.

Para favorecer la implementación de las técnicas desarrolladas en el sector ovino, es imprescindible demostrar su efectividad y beneficios de manera tangible. Realizar estudios comparativos de eficacia entre las técnicas tradicionales y las innovaciones introducidas puede proporcionar evidencia de mejoras en precisión, eficiencia y bienestar animal.

Otro aspecto fundamental es evaluar el impacto de estas tecnologías en el bienestar animal. Realizar estudios detallados que midan los niveles de estrés y observen los comportamientos de los animales antes y después de la implementación de las nuevas técnicas puede proporcionar insights valiosos sobre sus efectos positivos en el bienestar animal. La obtención de estos resultados no solo reforzaría la validez de las tecnologías desde una perspectiva de eficiencia, sino que también destaca su contribución a mejorar las condiciones de vida de los animales involucrados, lo cual es un aspecto crítico para su aceptación por parte de los ganaderos y la sociedad en general.

Con la evolución de las tecnologías desarrolladas en esta tesis, como LambScan y LambTrack, se han abierto nuevos horizontes para futuros proyectos que podrían transformar aún más la gestión de rebaños ovinos. Se están iniciando dos nuevos desarrollos significativos. El prime-

ro involucra un sistema de estimación de peso mediante imágenes 3D, adaptado específicamente para integrarse en la manga de un cebadero. El manejo individualizado que sufre el cordero dentro de la manga de manejo de un cebadero, abre la puerta a la identificación electrónica. A diferencia del sistema NFC, actualmente utilizado en LambTrack, que requiere proximidad física para la recopilación de datos, en este nuevo desarrollo se plantea la investigación y posible implementación de tecnologías RFID. Estos sistemas permitirían la recolección automática y precisa de datos de cada animal optimizando el proceso y reduciendo el manejo físico.

El segundo proyecto planea la instalación de cámaras sobre los corrales que, mediante la captura de imágenes aéreas, permitirían pesar y monitorizar el crecimiento del conjunto de corderos. Este sistema permitiría controlar el peso de los corderos por lotes en corrales controlados, facilitando un seguimiento más eficiente y menos estresante para los animales. Este enfoque no solo mejora la eficiencia al evitar el pesaje individual, sino que también proporciona datos valiosos para realizar análisis estadísticos y asegurar un crecimiento uniforme dentro del lote.

Además, se evaluará la escalabilidad de los estudios y tecnologías desarrolladas para aplicarlos en otras razas de cordero y posiblemente en otros sectores ganaderos. La realización de pruebas piloto en diferentes contextos geográficos y económicos podría ayudar a validar la adaptabilidad y eficacia de las soluciones propuestas, explorando su potencial para revolucionar la gestión y el bienestar animal más allá del contexto ovino.

Estas iniciativas no solo refuerzan el impacto práctico y científico de la investigación actual, sino que también inician el camino hacia una ganadería más sostenible y tecnológicamente avanzada. Al seguir desarrollando y adaptando estas tecnologías, se puede esperar un futuro donde la precisión, la eficiencia y el bienestar animal sean los pilares de la producción ganadera. Estos esfuerzos conjuntos marcan un compromiso continuo con la innovación y la mejora continua, estableciendo un nuevo estándar para la industria y abriendo innumerables posibilidades para futuras investigaciones y desarrollos.

8. Conclusiones

Esta tesis ha demostrado un compromiso riguroso con la mejora de la monitorización y manejo de rebaños ovinos, mostrando cómo la implementación de tecnologías avanzadas puede mejorar significativamente la gestión y el bienestar en el sector y el trabajo de los agentes de la cadena de valor ovina. Los objetivos planteados se han cumplido a lo largo de cinco estudios de investigación en los que se han diseñado y desarrollado diferentes herramientas y productos que mejoran la productividad, la sostenibilidad económica y ambiental y el bienestar animal. Todos ellos han utilizado técnicas de visión por computación e inteligencia artificial en su desarrollo generando nuevas formas de manejo, optimizando las prácticas de los agentes y mejorando la competitividad respecto a otros sectores ganaderos.

El primer objetivo de la investigación se centró en el desarrollo de herramientas avanzadas para la estimación y control del peso mediante técnicas de visión por computación, resultando en la creación de sistemas como LambScan y LambTrack. Estas herramientas han transformado la forma en que se maneja el peso en el cordero, permitiendo mediciones precisas sin el estrés asociado con los métodos convencionales. La implementación de estos sistemas ha mejorado notablemente la precisión en la medición del peso, ofreciendo una solución menos invasiva y más alineada con las prácticas de bienestar animal.

En cuanto al segundo objetivo, que se centra en diseñar y desarrollar una herramienta mediante técnicas de visión por computación para la detección del nivel de grasa en vivo del cordero y su posterior clasificación, se ha logrado con éxito con la creación de LAUS. Esta herramienta

innovadora emplea visión por computación para detectar y clasificar de manera no invasiva el nivel de grasa en los corderos. Gracias a esta tecnología, se puede evaluar con precisión el estado de grasa de los animales, mejorando la eficiencia de las prácticas de manejo y el bienestar animal, al evitar métodos de evaluación más intrusivos.

El tercer objetivo implicó el desarrollo de un sistema capaz de identificar las trayectorias de corte adecuadas en costillares de cordero mediante el uso de tecnologías de visión por computación. Este avance ha permitido determinar con precisión las trayectorias óptimas para el corte, posibilitando que, un proceso anteriormente manual y dependiente de la habilidad del operario, se pueda realizar en el futuro de forma automática. La adaptación de esta tecnología a la morfología específica de los costillares de cordero ha sido un hito significativo, mejorando la eficiencia de los procesos en la comercializadora y facilitando cortes más precisos y consistentes.

Finalmente, el objetivo general de generar nuevas herramientas adaptadas a las necesidades y el entorno de los agentes de la cadena de valor ovina se ha alcanzado a través del desarrollo de los estudios detallados a lo largo de esta tesis doctoral. La adaptación de cada herramienta a las necesidades específicas del sector ovino y la consideración del enfoque de DCU en su creación han asegurado que las tecnologías no solo sean eficaces, sino también integrables en las prácticas diarias de los ganaderos. Aunque algunas de las prácticas implementadas o mejoradas se pueden encontrar en otros sectores ganaderos, el estado del sector ovino, la situación económica actual y el tipo de comportamiento y manejo de los corderos hacen que la incorporación de nuevas herramientas sea un desafío. Por este motivo, se han diseñado estas herramientas desde el punto de vista del usuario y su entorno, generando dispositivos adaptados a las necesidades económicas y la tipología de trabajo. Esta aproximación ha facilitado una adopción más amplia y efectiva de las tecnologías, mejorando la productividad, la sostenibilidad económica y el bienestar animal.

En el ecosistema actual, que evoluciona hacia una mayor sostenibilidad ambiental y bienestar animal, es importante generar herramientas que aporten soluciones en esta línea. Los estudios realizados en esta tesis

están diseñados para minimizar el estrés que sufre el animal en su crecimiento y desarrollo. Para ello, se han intentado eliminar todas las fases de los procesos que generaban un mayor estrés y toda la interacción posible con los humanos, generando mayor sensación de libertad. Una mejora en el bienestar animal produce productos de mejor calidad en el mercado y esto mejora la rentabilidad económica.

En conjunto, los resultados de esta tesis subrayan el éxito de integrar enfoques tecnológicos avanzados en la ganadería ovina, destacando cómo la aplicación cuidadosa de la visión por computación e inteligencia artificial puede traer mejoras sustanciales en la productividad, sostenibilidad y bienestar. Estos logros no solo validan la investigación realizada, sino que también establecen una base sólida para futuras innovaciones en el sector.

9. Resultados de la tesis

A continuación, se detallan las contribuciones obtenidas a lo largo del desarrollo de esta tesis:

Artículos en revistas indexadas

Samperio, E., Lidón, I., Rebollar, R., Castejón-Limas, M., & Álvarez-Aparicio, C. (2021). Lambs' live weight estimation using 3D images. *Animal*, 15(5), 100212. <https://doi.org/10.1016/j.animal.2021.100212>

Riego, V. & Sánchez-González, L. & Fernández-Robles, L. & Rebollar, R. & Samperio, E. (2024). A non-stressful vision-based method for weighing live lambs. *Logic Journal of IGPLA*. (Aceptado)

Artículos en revisión

Samperio, E., Rebollar, R., Lidón, I., Castejón-Limas, M., & Riego del Castillo, V. Method of live classification of lambs according to fat levels using ultrasound imaging. *Journal of Animal Science and Biotechnology*.

Artículos en actas a congresos

Samperio, E., Díez Calvo, S., Heras Romanos, E., Lidón López, I., & Rebollar Rubio, R. (2020). Creation of a lamb morphometric measurement algorithm for the automation of weighing through 3D image processing. Proceedings from the International Congress on Project Management and Engineering, July, 923–931.

Samperio, E., Heras-Romanos, E., Gil-Pérez, I., Manchado Pérez, E. J., & Sanz Segura, R. (2021). Design of a prototype to classify lambs according to their live fat level using ultrasound image capture. Proceedings from the International Congress on Project Management and Engineering, 2021-July(July), 848–858.

Samperio, E., Gil-Pérez, I., Rebollar, R., & Lidón, I. (2023). From lambscan to lambtrack, the evolution of weighing in ovine livestock farming. Proceedings from the International Congress on Project Management and Engineering, July, 2019–2028. <https://doi.org/10.61547/3408>

Premios

Algunos de los estudios desarrollados en esta tesis formaron parte de proyectos que fueron galardonados con premios en la Feria Internacional para la Producción Animal (FIGAN). A continuación, se detallan los premios conseguidos:

Premio a Novedad Técnica en la FIGAN 2019

Por el desarrollo de LambScan (Sección 4.2), el cual está vinculado al Programa de Desarrollo Rural GCP2018-002100, con ANGRA (Asociación Nacional de criadores de Ganado ovino selecto de raza Rasa Aragonesa) y Casa de Ganaderos de Zaragoza S.C.L. como promotores del proyecto.

Premio a Novedad Técnica en la FIGAN 2021

Por el desarrollo de LAUS (Sección 5.1), el cual está vinculado al Programa de Desarrollo Rural GCP2018-002100, con ANGRA, Casa de Ganaderos de Zaragoza S.C.L. y Franco y Navarro S.A. como promotores del proyecto.

Premio a Mejora Técnica en la FIGAN 2023

Por el desarrollo de LambTrack (Sección 4.3), el cual está vinculado al Programa de Desarrollo Rural GCP2019-003500, con ANGRA y Casa de Ganaderos de Zaragoza S.C.L. como promotores del proyecto.

Proyectos

Los estudios realizados han sido los resultados de los siguiente proyectos de investigación vinculados al Programa de Desarrollo Rural del Gobierno de Aragón:

GCP2017 -2700 - “Diseño y desarrollo de un sistema para pesaje de corderos de raza Rasa Aragonesa mediante imágenes 3D”

GCP2019-003500 - “Monitorización de la evolución del crecimiento de los corderos de raza Rasa Aragonesa para la detección de enfermedades y adecuación de la alimentación”

GCP2018-002100 - “Diseño y desarrollo de un sistema para medir el engrasamiento de los corderos en la manga de un cebadero”

GCP2019-003400 - “Diseño y desarrollo de una nueva tecnología automática para el corte del costillar del cordero a través de visión artificial”

10. Referencias

- Achour, B., Belkadi, M., Aoudjit, R., & Laghrouche, M. (2019). Unsupervised automated monitoring of dairy cows' behavior based on Inertial Measurement Unit attached to their back. *Computers and Electronics in Agriculture*, 167(October), 105068. <https://doi.org/10.1016/j.compag.2019.105068>
- Achour, B., Belkadi, M., Filali, I., Laghrouche, M., & Lahdir, M. (2020). Image analysis for individual identification and feeding behaviour monitoring of dairy cows based on Convolutional Neural Networks (CNN). *Biosystems Engineering*, 198, 31-49. <https://doi.org/10.1016/j.biosystemseng.2020.07.019>
- Adeyemi, O., Grove, I., Peets, S., Domun, Y., & Norton, T. (2018). Dynamic neural network modelling of soil moisture content for predictive irrigation scheduling. *Sensors (Switzerland)*, 18(10). <https://doi.org/10.3390/s18103408>
- Adzitey, F. (2011). Effect of pre-slaughter animal handling on carcass and meat quality. *International Food Research Journal*, 18(2), 485-491.
- Afolayan, R. A., Adeyinka, I. A., & Lakpini, C. A. M. (2006). The estimation of live weight from body measurements in Yankasa sheep. *Czech Journal of Animal Science*, 51(8), 343-348.
- Agarap, A. F. (2018). Deep Learning using Rectified Linear Units (ReLU). March 2018. <http://arxiv.org/abs/1803.08375>

- Aguayo-Ulloa, L. A., Miranda-de la Lama, G. C., Pascual-Alonso, M., Fuchs, K., Olleta, J. L., Campo, M. M., Alierta, S., Villarroel, M., & María, G. A. (2013). Effect of feeding regime during finishing on lamb welfare, production performance and meat quality. *Small Ruminant Research*, 111(1-3), 147-156. <https://doi.org/10.1016/j.smallrumres.2012.09.011>
- Ahmad, M., Bhatti, J. A., Abdullah, M., Ullah, R., ul Ain, Q., Hasni, M. S., Mahboob Ali, Rashid, A., Qaisar, I., Rashid, G., & Uddin, R. (2019). Different ambient management intervention techniques and their effect on milk production and physiological parameters of lactating NiliRavi buffaloes during hot dry summer of subtropical region. *Tropical Animal Health and Production*, 51(4), 911-918. <https://doi.org/10.1007/s11250-018-1774-5>
- Ali, M. M., Paul, B. K., Ahmed, K., Bui, F. M., Quinn, J. M. W., & Moni, M. A. (2021). Heart disease prediction using supervised machine learning algorithms: Performance analysis and comparison. *Computers in Biology and Medicine*, 136(May), 104672. <https://doi.org/10.1016/j.compbiomed.2021.104672>
- Alitavoli, M., & McGeough, J. A. (1998). An expert process planning system for meat cutting by high pressure water-jet. *Journal of Materials Processing Technology*, 76(1-3), 146-152. [https://doi.org/10.1016/S0924-0136\(97\)00337-3](https://doi.org/10.1016/S0924-0136(97)00337-3)
- Alomar, M. A. (2022). Performance Optimization of Industrial Supply Chain Using Artificial Intelligence. *Computational Intelligence and Neuroscience*, 2022. <https://doi.org/10.1155/2022/9306265>
- Álvarez-Aparicio, C., Guerrero-Higueras, Á. M., Calderita, L. V., Rodríguez-Lera, F. J., Matellán, V., & Fernández-Llamas, C. (2021). Convolutional neural networks refitting by bootstrapping for tracking people in a mobile robot. *Applied Sciences (Switzerland)*, 11(21). <https://doi.org/10.3390/app112110043>
- Arai, K., Shigetomi, O., & Miura, Y. (2018). Artificial intelligence based fertilizer control for improvement of rice quality and harvest amount. *International Journal of Advanced Computer Science*

and Applications, 9(10), 61-67. <https://doi.org/10.14569/IJAC-SA.2018.091008>

- Atta, M., & El Khidir, O. A. (2004). Use of heart girth, wither height and scapuloischial length for prediction of liveweight of Nilotic sheep. *Small Ruminant Research*, 55(1-3), 233-237. <https://doi.org/10.1016/j.smallrumres.2004.01.005>
- Avril, D. H., Lallo, C., Mlambo, V., & Bourne, G. (2013). The application of bioelectrical impedance analysis in live tropical hair sheep as a predictor of body composition upon slaughter. *Tropical Animal Health and Production*, 45(8), 1803-1808. <https://doi.org/10.1007/s11250-013-0438-8>
- Berckmans, D. (2014). Precision livestock farming technologies for welfare management in intensive livestock systems. *Revue Scientifique et Technique de l'OIE*, 33(1), 189-196. <https://doi.org/10.20506/rst.33.1.2273>
- Betancourt, A., Morerio, P., Regazzoni, C. S., & Rauterberg, M. (2014). An Overview of First Person Vision and Egocentric Video Analysis for Personal Mobile Wearable Devices. *Circuits and Systems for Video Technology*, (Under Review((Under Review))), 744-760.
- Bewley, J. M., & Russell, R. a. (2010). Reasons for Slow Adoption Rates of Precision Dairy Farming Technologies : Evidence from a Producer Survey. *The First North American Conference on Precision Dairy Management*, 1, 2-3.
- Bradski, G. (2000). The OpenCV Library. *Dr. Dobb's Journal*, 25(11), 120.
- Brown, D. J., Savage, D. B., Hinch, G. N., & Hatcher, S. (2015). Monitoring liveweight in sheep is a valuable management strategy: A review of available technologies. *Animal Production Science*, 55(4), 427-436. <https://doi.org/10.1071/AN13274>
- Brown, T. B., Mann, B., Ryder, N., Subbiah, M., Kaplan, J., Dhariwal, P., Neelakantan, A., Shyam, P., Sastry, G., Askell, A., Agarwal, S.,

- Herbert-Voss, A., Krueger, G., Henighan, T., Child, R., Ramesh, A., Ziegler, D. M., Wu, J., Winter, C., ... Amodei, D. (2020). Language models are few-shot learners -- special version. Conference on Neural Information Processing Systems (NeurIPS 2020), NeurIPS, 1-25.
- Brynjolfsson, E., & McAfee, A. (2017). The Business of Artificial Intelligence Harvard Business Review. Harvard Business Review.
- Caldarini, G., Jaf, S., & McGarry, K. (2022). A Literature Survey of Recent Advances in Chatbots. Information (Switzerland), 13(1). <https://doi.org/10.3390/info13010041>
- Campo, M. M., Muela, E., Resconi, V. C., Barahona, M., & Sañudo, C. (2016). Influence of commercial cut on proximate composition and fatty acid profile of Rasa Aragonesa light lamb. Journal of Food Composition and Analysis, 53, 7-12. <https://doi.org/10.1016/j.jfca.2016.08.001>
- Cang, Y., He, H., & Qiao, Y. (2019). An Intelligent Pig Weights Estimate Method Based on Deep Learning in Sow Stall Environments. IEEE Access, 7, 164867-164875. <https://doi.org/10.1109/ACCESS.2019.2953099>
- Canny, J. (1986). A Computational Approach to Edge Detection. IEEE Transactions on Pattern Analysis and Machine Intelligence, PAMI-8(6), 679-698. <https://doi.org/10.1109/TPAMI.1986.4767851>
- Carabús, A., Gispert, M., & Font-i-Furnols, M. (2016). Imaging technologies to study the composition of live pigs: A review. Spanish Journal of Agricultural Research, 14(3), 1-16. <https://doi.org/10.5424/sjar/2016143-8439>
- Carmela Annosi, M., Brunetta, F., Capo, F., & Heideveld, L. (2020). Digitalization in the agri-food industry: the relationship between technology and sustainable development. Management Decision, 58(8), 1737-1757. <https://doi.org/10.1108/MD-09-2019-1328>

- Chawla, N. V., Bowyer, K. W., Hall, L. O., & Kegelmeyer, W. P. (2002). SMOTE: Synthetic Minority Over-sampling Technique. *Journal of Artificial Intelligence Research*, 16(Sept. 28), 321-357. <https://doi.org/10.1613/jair.953>
- Chen, I. C., Hwang, R. C., & Huang, H. C. (2023). PCB Defect Detection Based on Deep Learning Algorithm. *Processes*, 11(3), 1-13. <https://doi.org/10.3390/pr11030775>
- Chi-Hsien, K., & Nagasawa, S. (2019). Applying machine learning to market analysis: Knowing your luxury consumer. *Journal of Management Analytics*, 6(4), 404-419. <https://doi.org/10.1080/23270012.2019.1692254>
- Ciruela-Lorenzo, A. M., Del-Aguila-Obra, A. R., Padilla-Meléndez, A., & Plaza-Angulo, J. J. (2020). Digitalization of agri-cooperatives in the smart agriculture context. Proposal of a digital diagnosis tool. *Sustainability (Switzerland)*, 12(4). <https://doi.org/10.3390/su12041325>
- Coleman, G. B., & Andrews, H. C. (1979). Image segmentation by clustering. *Proceedings of the IEEE*, 67(5), 773-785. <https://doi.org/10.1109/PROC.1979.11327>
- Collett, D. (2015). *Modelling Survival Data in Medical Research*. Chapman and Hall/CRC. <https://doi.org/10.1201/b18041>
- Collier, R. J., Dahl, G. E., & Vanbaale, M. J. (2006). Major advances associated with environmental effects on dairy cattle. *Journal of Dairy Science*, 89(4), 1244-1253. [https://doi.org/10.3168/jds.S0022-0302\(06\)72193-2](https://doi.org/10.3168/jds.S0022-0302(06)72193-2)
- Comisión Europea. (2020). Comunicación de la Comisión al Parlamento Europeo, al Consejo, al Comité Económico y Social Europeo y al Comité de las Regiones. “Estrategia «de la granja a la mesa» para un sistema alimentario justo, saludable y respetuoso con el medio ambiente”. 23.

- Cong, M., Zhang, J., Du, Y., Wang, Y., Yu, X., & Liu, D. (2021). A Porcine Abdomen Cutting Robot System Using Binocular Vision Techniques Based on Kernel Principal Component Analysis. *Journal of Intelligent and Robotic Systems: Theory and Applications*, 101(1). <https://doi.org/10.1007/s10846-020-01280-3>
- Cox, S. (2003). *Precision livestock farming*. Wageningen Academic. <https://doi.org/10.3920/978-90-8686-515-4>
- Daley, W., Britton, D., Usher, C., Diao, M., & Ruffin, K. (2005). 3D sensing for machine guidance in meat cutting applications. *Optical Sensors and Sensing Systems for Natural Resources and Food Safety and Quality*, 5996, 59960D. <https://doi.org/10.1117/12.632239>
- Daponte, J. S., & Fox, M. D. (1988). Enhancement of Chest Radiographs with Gradient Operators. *IEEE Transactions on Medical Imaging*, 7(2), 109–117. <https://doi.org/10.1109/42.3937>
- De-Pablos-Heredero, C., Montes-Botella, J. L., & García, A. (2020). Impact of dynamic capabilities on performance in dairy sheep farms in Spain. *Journal of Agricultural Science and Technology*, 2(3), 597–610. <https://doi.org/10.3390/SU12083368>
- De La Iglesia, D. H., González, G. V., García, M. V., Rivero, A. J. L., & De Paz, J. F. (2020). Non-invasive automatic beef carcass classification based on sensor network and image analysis. *Future Generation Computer Systems*, 113(1208), 318–328. <https://doi.org/10.1016/j.future.2020.06.055>
- Dechter, R. (1986). Learning While Searching in Constraint-Satisfaction-Problems. *Proceedings of the National Conference on Artificial Intelligence*, 1, 178–183.
- Delfa, R., Teixeira, A., Blasco, I., & Rocher-Colomber, F. (1991). Ultrasonic estimates of fat thickness, C measurement and longissimus dorsi depth in rasa aragonesa ewes with same body condition score. *Options Méditerranéennes - Série Séminaires*, 13, 25–30.

- Delfa, R., Teixeira, A., & Colomer-Rocher, F. (1989). A note on the use of a lumbar joint as a predictor of body fat depots in Aragonese ewes with different body condition scores. *Animal Production*, 49(2), 327–329. <https://doi.org/10.1017/S0003356100032487>
- Delfa, R., Teixeira, A., Gonzalez, C., & Blasco, I. (1995). Ultrasonic estimates of fat thickness and Longissimus dorsi muscle depth for predicting carcass composition of live Aragon lambs. *Small Ruminant Research*, 16(2), 159–164. [https://doi.org/10.1016/0921-4488\(95\)00632-U](https://doi.org/10.1016/0921-4488(95)00632-U)
- Devlin, J., Chang, M.-W., Lee, K., Google, K. T., & Language, A. I. (2018). BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding. *Naacl-Hlt 2019, Mlm*, 4171–4186.
- Di Vaio, A., Boccia, F., Landriani, L., & Palladino, R. (2020). Artificial intelligence in the agri-food system: Rethinking sustainable business models in the COVID-19 scenario. *Sustainability (Switzerland)*, 12(12). <https://doi.org/10.3390/SU12124851>
- Dias, L. G., Silva, S. R., & Teixeira, A. (2020). Simultaneously prediction of sheep and goat carcass composition and body fat depots using in vivo ultrasound measurements and live weight. *Research in Veterinary Science*, 133(March), 180–187. <https://doi.org/10.1016/j.rvsc.2020.09.024>
- Duan, L., & Xu, L. Da. (2012). Business intelligence for enterprise systems: A survey. *IEEE Transactions on Industrial Informatics*, 8(3), 679–687. <https://doi.org/10.1109/TII.2012.2188804>
- Duan, L., Xu, L., Liu, Y., & Lee, J. (2009). Cluster-based outlier detection. *Annals of Operations Research*, 168(1), 151–168. <https://doi.org/10.1007/s10479-008-0371-9>
- Duan, N., Liu, L. Z., Yu, X. J., Li, Q., & Yeh, S. C. (2019). Classification of multichannel surface-electromyography signals based on convolutional neural networks. *Journal of Industrial Information Integration*, 15, 201–206. <https://doi.org/10.1016/j.jii.2018.09.001>

- Duff, G. C., & Galyean, M. L. (2007). Board-invited review: Recent advances in management of highly stressed, newly received feedlot cattle. *Journal of Animal Science*, 85(3), 823-840. <https://doi.org/10.2527/jas.2006-501>
- Dwivedi, Y. K., Hughes, L., Ismagilova, E., Aarts, G., Coombs, C., Crick, T., Duan, Y., Dwivedi, R., Edwards, J., Eirug, A., Galanos, V., Ilavarasan, P. V., Janssen, M., Jones, P., Kar, A. K., Kizgin, H., Kronemann, B., Lal, B., Lucini, B., ... Williams, M. D. (2021). Artificial Intelligence (AI): Multidisciplinary perspectives on emerging challenges, opportunities, and agenda for research, practice and policy. *International Journal of Information Management*, 57(July), 0-1. <https://doi.org/10.1016/j.ijinfomgt.2019.08.002>
- Elango, V., & Karunamoorthy, L. (2008). Effect of lighting conditions in the study of surface roughness by machine vision - An experimental design approach. *International Journal of Advanced Manufacturing Technology*, 37(1-2), 92-103. <https://doi.org/10.1007/s00170-007-0942-y>
- Elbasi, E., Mostafa, N., Alarnaout, Z., Zreikat, A. I., Cina, E., Varghese, G., Shdefat, A., Topcu, A. E., Abdelbaki, W., Mathew, S., & Zaki, C. (2023). Artificial Intelligence Technology in the Agricultural Sector: A Systematic Literature Review. *IEEE Access*, 11(December 2022), 171-202. <https://doi.org/10.1109/ACCESS.2022.3232485>
- Estévez-Moreno, L. X., María, G. A., Sepúlveda, W. S., Villarroel, M., & Miranda-de la Lama, G. C. (2021). Attitudes of meat consumers in Mexico and Spain about farm animal welfare: A cross-cultural study. *Meat Science*, 173(November 2020). <https://doi.org/10.1016/j.meatsci.2020.108377>
- Estevez, I. (2007). Density allowances for broilers: Where to set the limits? *Poultry Science*, 86(6), 1265-1272. <https://doi.org/10.1093/ps/86.6.1265>
- Europeo, P. (2017). REGLAMENTO DELEGADO (UE) 2017/1182 DE LA COMISIÓN de 20 de abril de 2017 por el que se completa el Reglamento (UE) n.o 1308/2013 del Parlamento Europeo y del Consejo

en lo que atañe a los modelos de la Unión de clasificación de las canales de vacuno, porc. 2017, 74-99.

- Ferguson, D. M., & Warner, R. D. (2008). Have we underestimated the impact of pre-slaughter stress on meat quality in ruminants? *Meat Science*, 80(1), 12-19. <https://doi.org/10.1016/j.meatsci.2008.05.004>
- Fernandes, H. J., Tedeschi, L. O., Paulino, M. F., & Paiva, L. M. (2010). Determination of carcass and body fat compositions of grazing crossbred bulls using body measurements. *Journal of Animal Science*, 88(4), 1442-1453. <https://doi.org/10.2527/jas.2009-1919>
- Fernández-López, D., Cabido, R., Sierra-Alonso, A., Montemayor, A. S., & Pantrigo, J. J. (2014). A knowledge-based component library for high-level computer vision tasks. *Knowledge-Based Systems*, 70, 407-419. <https://doi.org/10.1016/j.knsys.2014.07.017>
- Fitzgerald, R. F., Stalder, K. J., Matthews, J. O., Schultz Kaster, C. M., & Johnson, A. K. (2009). Factors associated with fatigued, injured, and dead pig frequency during transport and lairage at a commercial abattoir. *Journal of Animal Science*, 87(3), 1156-1166. <https://doi.org/10.2527/jas.2008-1270>
- Fuentes, S., Gonzalez Viejo, C., Tongson, E., & Dunshea, F. R. (2022). The livestock farming digital transformation: implementation of new and emerging technologies using artificial intelligence. *Animal Health Research Reviews*, 23(1), 59-71. <https://doi.org/10.1017/S1466252321000177>
- Girshick, R. (2015). Fast R-CNN. *Proceedings of the IEEE International Conference on Computer Vision*, 2015 Inter, 1440-1448. <https://doi.org/10.1109/ICCV.2015.169>
- Girshick, R., Donahue, J., Darrell, T., & Malik, J. (2014). Rich feature hierarchies for accurate object detection and semantic segmentation. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 580-587. <https://doi.org/10.1109/CVPR.2014.81>

- González-Yebra, Aguilar, M. A., & Aguilar, F. J. (2019). Is the design a vector to be considered in the agri-food industry? An interprofessional analysis in andalusia (Spain). *Lecture Notes in Mechanical Engineering*, 610–621. https://doi.org/10.1007/978-3-030-12346-8_59
- Grandin, T., & Shivley, C. (2015). How farm animals react and perceive stressful situations such as handling, restraint, and transport. *Animals*, 5(4), 1233–1251. <https://doi.org/10.3390/ani5040409>
- Greenwood, P. L., Hunt, a S., Hermanson, J. W., & Bell, a W. (1998). Effects of birth weight and postnatal nutrition on neonatal sheep : I . Body growth and composition , and some aspects of energetic efficiency The online version of this article , along with updated information and services , is located on the World Wide. *Journal of Animal Science*, February 2016, 2354–2367. <https://doi.org/doi:/2000.78150x>
- Greiner, S. P., Rouse, G. H., Wilson, D. E., Cundiff, L. V., & Wheeler, T. L. (2003). The relationship between ultrasound measurements and carcass fat thickness and longissimus muscle area in beef cattle. *Journal of Animal Science*, 81(3), 676–682. <https://doi.org/10.2527/2003.813676x>
- Griffin, A. (2017). Facebook’s artificial intelligence robots shut down after they start talking to each other in their own language. Independent.Co.Uk.
- Gu, Z., Zhu, T., Jiao, X., Xu, J., & Qi, Z. (2021). Neural network soil moisture model for irrigation scheduling. *Computers and Electronics in Agriculture*, 180(1), 105801. <https://doi.org/10.1016/j.compag.2020.105801>
- Guo, L., Lei, Y., Xing, S., Yan, T., & Li, N. (2018). Deep Convolutional Transfer Learning Network: A New Method for Intelligent Fault Diagnosis of Machines with Unlabeled Data. *IEEE Transactions on Industrial Electronics*, 66(9), 7316–7325. <https://doi.org/10.1109/TIE.2018.2877090>

- Gupta, P., Kumar, S., Suman, R. R., & Kumar, V. (2021). Sentiment Analysis of Lockdown in India during COVID-19: A Case Study on Twitter. *IEEE Transactions on Computational Social Systems*, 8(4), 939–949. <https://doi.org/10.1109/TCSS.2020.3042446>
- Hatcher, S., Eppleston, J., Graham, R. P., McDonald, J., Schlunke, S., Watt, B., & Thornberry, K. J. (2008). Higher weaning weight improves postweaning growth and survival in young Merino sheep. *Australian Journal of Experimental Agriculture*, 48(7), 966–973. <https://doi.org/10.1071/EA07407>
- He, K., Sun, J., & Tang, X. (2013). Guided image filtering. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35(6), 1397–1409. <https://doi.org/10.1109/TPAMI.2012.213>
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2016–Decem, 770–778. <https://doi.org/10.1109/CVPR.2016.90>
- Hemamalini, V., Rajarajeswari, S., Nachiyappan, S., Sambath, M., Devi, T., Singh, B. K., & Raghuvanshi, A. (2022). Food Quality Inspection and Grading Using Efficient Image Segmentation and Machine Learning-Based System. *Journal of Food Quality*, 2022. <https://doi.org/10.1155/2022/5262294>
- Hennessey, E., DiFazio, M., Hennessey, R., & Cassel, N. (2022). Artificial intelligence in veterinary diagnostic imaging: A literature review. *Veterinary Radiology and Ultrasound*, 63(S1), 851–870. <https://doi.org/10.1111/vru.13163>
- Hernández, J. E., Kacprzyk, J., Lyons, A., Ortiz, A., & Panetto, H. (2018). Review on operational research advances in agri-food supply chains and societal challenges. 29th European Conference on Operational Research.
- Hernandez, J. E., Kacprzyk, J., Panetto, H., Fernandez, A., Liu, S., Ortiz, A., & De-Angelis, M. (2017). Challenges and solutions for enhan-

- cing agriculture value chain decision-making. A short review. *IFIP Advances in Information and Communication Technology*, 506, 761–774. https://doi.org/10.1007/978-3-319-65151-4_68
- Hostiou, N., Turlot, A., Fagon, J., Chauvat, S., Kling-Eveillard, F., Boivin, X., & Allain, C. (2017). Impact of precision livestock farming on work and human-animal interactions on dairy farms. A review. *Biotechnol. Agron. Soc. Environ.* 2017, 21(1), 22–35. <https://doi.org/10.25518/1780-4507.13706>
- Houghton, P. L., & Turlington, L. M. (1992). Application of ultrasound for feeding and finishing animals: a review. *Journal of Animal Science*, 70(3), 930–941. <https://doi.org/10.2527/1992.703930x>
- Hu, S., Liang, Y. C., Xiong, Z., & Niyato, D. (2021). Blockchain and Artificial Intelligence for Dynamic Resource Sharing in 6G and beyond. *IEEE Wireless Communications*, 28(4), 145–151. <https://doi.org/10.1109/MWC.001.2000409>
- Huang, B., Huan, Y., Xu, L. Da, Zheng, L., & Zou, Z. (2019). Automated trading systems statistical and machine learning methods and hardware implementation: a survey. *Enterprise Information Systems*, 13(1), 132–144. <https://doi.org/10.1080/17517575.2018.1493145>
- Huang, C., Cai, H., Xu, L., Xu, B., Gu, Y., & Jiang, L. (2019). Data-driven ontology generation and evolution towards intelligent service in manufacturing systems. *Future Generation Computer Systems*, 101, 197–207. <https://doi.org/10.1016/j.future.2019.05.075>
- Hughes, B. O., Gilbert, A. B., & Brown, M. F. (1986). Categorisation and causes of abnormal egg shells: Relationship with stress. *British Poultry Science*, 27(2), 325–337. <https://doi.org/10.1080/00071668608416885>
- Irizarry, J., & Costa, D. B. (2016). Exploratory Study of Potential Applications of Unmanned Aerial Systems for Construction Management Tasks. *Journal of Management in Engineering*, 32(3), 1–10. [https://doi.org/10.1061/\(asce\)me.1943-5479.0000422](https://doi.org/10.1061/(asce)me.1943-5479.0000422)

- Jaboyedoff, M., Oppikofer, T., Abellán, A., Derron, M. H., Loye, A., Metzger, R., & Pedrazzini, A. (2012). Use of LIDAR in landslide investigations: A review. *Natural Hazards*, 61(1), 5–28. <https://doi.org/10.1007/s11069-010-9634-2>
- Jeelani, I., Han, K., & Albert, A. (2018). Automating and scaling personalized safety training using eye-tracking data. *Automation in Construction*, 93(October 2017), 63–77. <https://doi.org/10.1016/j.autcon.2018.05.006>
- Johnson, C. M., Johnston, D., Crowley, P. K., Culbertson, H., Rippen, H. E., Damico, D. J., & Plaisant, C. (2011). EHR Usability Toolkit: A Background Report on Usability and Electronic Health Records. AHRQ Publication, 11, 1–63.
- Jones, A., Van Burgel, A. J., Behrendt, R., Curnow, M., Gordon, D. J., Oldham, C. M., Rose, I. J., & Thompson, A. N. (2011). Evaluation of the impact of Lifetimewool on sheep producers. *Animal Production Science*, 51(9), 857–865. <https://doi.org/10.1071/EA08303>
- Kim, H., & Kim, H. (2018). 3D reconstruction of a concrete mixer truck for training object detectors. *Automation in Construction*, 88(November 2017), 23–30. <https://doi.org/10.1016/j.autcon.2017.12.034>
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet Classification with Deep Convolutional Neural Networks. In F. Pereira, C. J. Burges, L. Bottou, & K. Q. Weinberger (Eds.), *Advances in Neural Information Processing Systems* (Vol. 25). Curran Associates, Inc. https://proceedings.neurips.cc/paper_files/paper/2012/file/c399862d3b9d6b76c8436e924a68c45b-Paper.pdf
- Kurek, J., Swiderski, B., Jegorowa, A., Kruk, M., & Osowski, S. (2017). Deep learning in assessment of drill condition on the basis of images of drilled holes. In Y. Wang, T. D. Pham, V. Vozenilek, D. Zhang, & Y. Xie (Eds.), *Eighth International Conference on Graphic and Image Processing (ICGIP 2016)* (Vol. 10225, p. 102251V). SPIE. <https://doi.org/10.1117/12.2266254>

- Kuzuhara, Y., Kawamura, K., Yoshitoshi, R., Tamaki, T., Sugai, S., Ikegami, M., Kurokawa, Y., Obitsu, T., Okita, M., Sugino, T., & Yasuda, T. (2015). A preliminarily study for predicting body weight and milk properties in lactating Holstein cows using a three-dimensional camera system. *Computers and Electronics in Agriculture*, 111, 186–193. <https://doi.org/10.1016/j.compag.2014.12.020>
- Lachat, E., Macher, H., Landes, T., & Grussenmeyer, P. (2015). Assessment and calibration of a RGB-D camera (Kinect v2 Sensor) towards a potential use for close-range 3D modeling. *Remote Sensing*, 7(10), 13070–13097. <https://doi.org/10.3390/rs71013070>
- Latino, M. E., Corallo, A., Menegoli, M., & Nuzzo, B. (2023). Agriculture 4.0 as Enabler of Sustainable Agri-Food: A Proposed Taxonomy. *IEEE Transactions on Engineering Management*, 70(10), 3678–3696. <https://doi.org/10.1109/TEM.2021.3101548>
- Lauriola, I., Lavelli, A., & Aiolfi, F. (2022). An introduction to Deep Learning in Natural Language Processing: Models, techniques, and tools. *Neurocomputing*, 470(xxxx), 443–456. <https://doi.org/10.1016/j.neucom.2021.05.103>
- Lecun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278–2324. <https://doi.org/10.1109/5.726791>
- Lefaucheur, L. (2010). A second look into fibre typing - Relation to meat quality. In *Meat Science* (Vol. 84, Issue 2, pp. 257–270). Elsevier Ltd. <https://doi.org/10.1016/j.meatsci.2009.05.004>
- Lin, T. Y., Goyal, P., Girshick, R., He, K., & Dollar, P. (2017). Focal Loss for Dense Object Detection. *Proceedings of the IEEE International Conference on Computer Vision*, 2017–October, 2999–3007. <https://doi.org/10.1109/ICCV.2017.324>
- Linaza, M. T., Posada, J., Bund, J., Eisert, P., Quartulli, M., Döllner, J., Pagani, A., Olaizola, I. G., Barriguinha, A., Moysiadis, T., & Lucat, L. (2021). Data-driven artificial intelligence applications for

- sustainable precision agriculture. *Agronomy*, 11(6). <https://doi.org/10.3390/agronomy11061227>
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., van der Laak, J. A. W. M., van Ginneken, B., & Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60–88. <https://doi.org/10.1016/j.media.2017.07.005>
- Liu, J., Kong, X., Xia, F., Bai, X., Wang, L., Qing, Q., & Lee, I. (2018). Artificial Intelligence in the 21st Century. *IEEE Access*, 6(February 2020), 34403–34421. <https://doi.org/10.1109/ACCESS.2018.2819688>
- Liu, J., Yan, S., Lu, N., Yang, D., Lv, H., Wang, S., Zhu, X., Zhao, Y., Wang, Y., Ma, Z., & Yu, Y. (2022). Automated retinal boundary segmentation of optical coherence tomography images using an improved Canny operator. *Scientific Reports*, 12(1), 1–16. <https://doi.org/10.1038/s41598-022-05550-y>
- Liu, L., Lu, S., Zhong, R., Wu, B., Yao, Y., Zhang, Q., & Shi, W. (2021). Computing Systems for Autonomous Driving: State of the Art and Challenges. *IEEE Internet of Things Journal*, 8(8), 6469–6486. <https://doi.org/10.1109/JIOT.2020.3043716>
- Liu, L., Ouyang, W., Wang, X., Fieguth, P., Chen, J., Liu, X., & Pietikäinen, M. (2020). Deep Learning for Generic Object Detection: A Survey. *International Journal of Computer Vision*, 128(2), 261–318. <https://doi.org/10.1007/s11263-019-01247-4>
- Liu, R., Wang, Z., Sparks, T., Liou, F., & Nedic, C. (2017). Stereo vision-based repair of metallic components. *Rapid Prototyping Journal*, 23(1), 65–73. <https://doi.org/10.1108/RPJ-09-2015-0118>
- Liu, S., Wang, Y., Yang, X., Lei, B., Liu, L., Li, S. X., Ni, D., & Wang, T. (2019). Deep Learning in Medical Ultrasound Analysis: A Review. *Engineering*, 5(2), 261–275. <https://doi.org/10.1016/j.eng.2018.11.020>

- Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C.-Y., & Berg, A. C. (2016). SSD: Single Shot MultiBox Detector. In B. Leibe, J. Matas, N. Sebe, & M. Welling (Eds.), *Eccv* (Vol. 9905, pp. 21-37). Springer International Publishing. https://doi.org/10.1007/978-3-319-46448-0_2
- Liu, Z., Luo, P., Wang, X., & Tang, X. (2015). Deep learning face attributes in the wild. *Proceedings of the IEEE International Conference on Computer Vision, 2015 Inter*, 3730-3738. <https://doi.org/10.1109/ICCV.2015.425>
- 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*, 262, 121409. <https://doi.org/10.1016/j.jclepro.2020.121409>
- Lu, L., Xu, L., Xu, B., Li, G., & Cai, H. (2018). Fog Computing Approach for Music Cognition System Based on Machine Learning Algorithm. *IEEE Transactions on Computational Social Systems*, 5(4), 1142-1151. <https://doi.org/10.1109/TCSS.2018.2871694>
- Lu, Y., & Xu, L. Da. (2019). Internet of things (IoT) cybersecurity research: A review of current research topics. *IEEE Internet of Things Journal*, 6(2), 2103-2115. <https://doi.org/10.1109/JIOT.2018.2869847>
- Lucas, D., Brun, A., Gispert, M., Carabús, A., Soler, J., Tibau, J., & Font-i-Furnols, M. (2017). Relationship between pig carcass characteristics measured in live pigs or carcasses with Piglog, Fat-o-Meat'er and computed tomography. *Livestock Science*, 197(January), 88-95. <https://doi.org/10.1016/j.livsci.2017.01.010>
- Maedche, A., Legner, C., Benlian, A., Berger, B., Gimpel, H., Hess, T., Hinz, O., Morana, S., & Söllner, M. (2019). AI-Based Digital Assistants: Opportunities, Threats, and Research Perspectives. *Business and Information Systems Engineering*, 61(4), 535-544. <https://doi.org/10.1007/s12599-019-00600-8>

- Mahmood, K., Mahmood, R., & van Dijk, M. (2021). On the Robustness of Vision Transformers to Adversarial Examples. *Proceedings of the IEEE International Conference on Computer Vision*, 7818–7827. <https://doi.org/10.1109/ICCV48922.2021.00774>
- Malorgio, G., & Marangon, F. (2021). Agricultural business economics: the challenge of sustainability. *Agricultural and Food Economics*, 9(1), 4–7. <https://doi.org/10.1186/s40100-021-00179-3>
- María, G. A. (2006). Public perception of farm animal welfare in Spain. *Livestock Science*, 103(3), 250–256. <https://doi.org/10.1016/j.livsci.2006.05.011>
- MARM, O. de los precios de los alimentos. (2009). Estudio de la cadena de valor y formación de precios del sector ovino. Ministerio de Agricultura Pesca y Alimentación, 60. http://www.magrama.gob.es/es/alimentacion/servicios/observatorio-de-precios-de-los-alimentos/ESTUDIO_ZANAHORIA_14112010_tcm7-182799.pdf
- Matthews, S. G., Miller, A. L., Plötz, T., & Kyriazakis, I. (2017). Automated tracking to measure behavioural changes in pigs for health and welfare monitoring. *Scientific Reports*, 7(1), 1–12. <https://doi.org/10.1038/s41598-017-17451-6>
- McCarthy, J., Minsky, M. L., Rochester, N., & Shannon, C. E. (2006). A proposal for the Dartmouth summer research project on artificial intelligence. *AI Magazine*, 27(4), 12–14.
- McGeough, J. A. (2016). Cutting of Food Products by Ice-particles in a Water-jet. *Procedia CIRP*, 42(Isem Xviii), 863–865. <https://doi.org/10.1016/j.procir.2016.03.009>
- Miotto, R., Wang, F., Wang, S., Jiang, X., & Dudley, J. T. (2017). Deep learning for healthcare: Review, opportunities and challenges. *Briefings in Bioinformatics*, 19(6), 1236–1246. <https://doi.org/10.1093/bib/bbx044>

- Miranda, J., Ponce, P., Molina, A., & Wright, P. (2019). Sensing, smart and sustainable technologies for Agri-Food 4.0. *Computers in Industry*, 108, 21–36. <https://doi.org/10.1016/j.compind.2019.02.002>
- Mitlöhner, F. M., Morrow, J. L., Dailey, J. W., Wilson, S. C., Galyean, M. L., Miller, M. F., & McGlone, J. J. (2001). Shade and water misting effects on behavior, physiology, performance, and carcass traits of heat-stressed feedlot cattle. *Journal of Animal Science*, 79(9), 2327–2335. <https://doi.org/10.2527/2001.7992327x>
- Mittal, H., Pandey, A. C., Saraswat, M., Kumar, S., Pal, R., & Modwel, G. (2022). A comprehensive survey of image segmentation: clustering methods, performance parameters, and benchmark datasets. *Multimedia Tools and Applications*, 81(24), 35001–35026. <https://doi.org/10.1007/s11042-021-10594-9>
- Nambu, T. (2016). Legal regulations and public policies for next-generation robots in Japan. *AI and Society*, 31(4), 483–500. <https://doi.org/10.1007/s00146-015-0628-1>
- Nasirahmadi, A., Edwards, S. A., & Sturm, B. (2017). Implementation of machine vision for detecting behaviour of cattle and pigs. *Livestock Science*, 202(May), 25–38. <https://doi.org/10.1016/j.livsci.2017.05.014>
- Neethirajan, S. (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>
- Niemann, H., Kuhla, B., & Flachowsky, G. (2011). Perspectives for feed-efficient animal production. *Journal of Animal Science*, 89(12), 4344–4363. <https://doi.org/10.2527/jas.2011-4235>
- Nir, O., Parmet, Y., Werner, D., Adin, G., & Halachmi, I. (2018). 3D Computer-vision system for automatically estimating heifer height and body mass. *Biosystems Engineering*, 173, 4–10. <https://doi.org/10.1016/j.biosystemseng.2017.11.014>

- Norman, D. A. (1986). Cognitive Engineering. User Centered System Design, January 1986, 31–62. <https://doi.org/10.1201/b15703-3>
- Oliveira, B. R., Ribas, M. N., Machado, F. S., Lima, J. A. M., Cavalcanti, L. F. L., Chizzotti, M. L., & Coelho, S. G. (2018). Validation of a system for monitoring individual feeding and drinking behaviour and intake in young cattle. *Animal*, 12(3), 634–639. <https://doi.org/10.1017/S1751731117002002>
- Onyango, S. O., Owiredu, S. A., Kim, K. Il, & Yoo, S. L. (2022). A Quasi-Intelligent Maritime Route Extraction from AIS Data. *Sensors*, 22(22), 1–18. <https://doi.org/10.3390/s22228639>
- Otsu, N. (1979). A Threshold Selection Method from Gray-Level Histograms. *IEEE Transactions on Systems, Man, and Cybernetics*, C(1), 62–66.
- Panetto, H., Lezoche, M., Hernandez Hormazabal, J. E., del Mar Eva Alemany Diaz, M., & Kacprzyk, J. (2020). Special issue on Agri-Food 4.0 and digitalization in agriculture supply chains - New directions, challenges and applications. *Computers in Industry*, 116, 4–6. <https://doi.org/10.1016/j.compind.2020.103188>
- Parés, R., Llonch, P., Manteca, X., & Such, X. (2023). Sheep welfare assessment of meat farms from Spain in different breeds and production systems. *Frontiers in Animal Science*, 4(August), 1–12. <https://doi.org/10.3389/fanim.2023.1218495>
- Peyrou, B., Vignaux, J.-J., & André, A. (2019). Artificial Intelligence and Health Care. In *Radiology* (Vol. 301, Issue 3, pp. 29–40). https://doi.org/10.1007/978-3-319-98216-8_3
- Pfeiffer, J., Gabriel, A., & Gandorfer, M. (2021). Understanding the public attitudinal acceptance of digital farming technologies: a nationwide survey in Germany. *Agriculture and Human Values*, 38(1), 107–128. <https://doi.org/10.1007/s10460-020-10145-2>

- Pizer, S. M., Johnston, R. E., Ericksen, J. P., Yankaskas, B. C., & Muller, K. E. (1990). Contrast-Limited Adaptive Histogram Equalization: Speed and Effectiveness Stephen M. Pizer, R. Eugene Johnston, James. Access.
- Pouyanfar, S., Sadiq, S., Yan, Y., Tian, H., Tao, Y., Reyes, M. P., Shyu, M., Chen, S., & Iyengar, S. S. (2019). A Survey on Deep Learning. *ACM Computing Surveys*, 51(5), 1–36. <https://doi.org/10.1145/3234150>
- Pugalethi, R., Prabhu Chakkaravarthy, A., Ramya, J., Babu, S., & Rasika Krishnan, R. (2021). Artificial learning companion using machine learning and natural language processing. *International Journal of Speech Technology*, 24(3), 553–560. <https://doi.org/10.1007/s10772-020-09773-0>
- Quaresma, M., Payan-Carreira, R., & Silva, S. R. (2013). Relationship between ultrasound measurements of body fat reserves and body condition score in female donkeys. *Veterinary Journal*, 197(2), 329–334. <https://doi.org/10.1016/j.tvjl.2012.12.031>
- Rafiei, M., Raitoharju, J., & Iosifidis, A. (2023). Computer Vision on X-Ray Data in Industrial Production and Security Applications: A Comprehensive Survey. *IEEE Access*, 11(January), 2445–2477. <https://doi.org/10.1109/ACCESS.2023.3234187>
- Rajkomar, A., Oren, E., Chen, K., Dai, A. M., Hajaj, N., Hardt, M., Liu, P. J., Liu, X., Marcus, J., Sun, M., Sundberg, P., Yee, H., Zhang, K., Zhang, Y., Flores, G., Duggan, G. E., Irvine, J., Le, Q., Litsch, K., ... Dean, J. (2018). Scalable and accurate deep learning with electronic health records. *Npj Digital Medicine*, 1(1), 18. <https://doi.org/10.1038/s41746-018-0029-1>
- Realini, C. E., Pavan, E., Johnson, P. L., Font-i-Furnols, M., Jacob, N., Agnew, M., Craigie, C. R., & Moon, C. D. (2021). Consumer liking of *M. longissimus lumborum* from New Zealand pasture-finished lamb is influenced by intramuscular fat. *Meat Science*, 173(September 2020), 108380. <https://doi.org/10.1016/j.meatsci.2020.108380>

- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2016-Decem, 779-788. <https://doi.org/10.1109/CVPR.2016.91>
- Ren, S., He, K., Girshick, R., & Sun, J. (2017). Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. IEEE Transactions on Pattern Analysis and Machine Intelligence, 39(6), 1137-1149. <https://doi.org/10.1109/TPAMI.2016.2577031>
- Riego, V., Castejón-Limas, M., Sánchez-González, L., Fernández-Robles, L., Perez, H., Díez-Gonzalez, J., & Guerrero-Higueras, Á. M. (2021). Strong classification system for wear identification on milling processes using computer vision and ensemble learning. Neurocomputing, 456, 678-684. <https://doi.org/10.1016/j.neucom.2020.07.131>
- Ripoll-Bosch, R., Díez-Unquera, B., Ruiz, R., Villalba, D., Molina, E., Joy, M., Olaizola, A., & Bernués, A. (2012). An integrated sustainability assessment of mediterranean sheep farms with different degrees of intensification. Agricultural Systems, 105(1), 46-56. <https://doi.org/10.1016/j.agsy.2011.10.003>
- Ripoll, G., Joy, M., Alvarez-Rodriguez, J., Sanz, A., & Teixeira, A. (2009). Estimation of light lamb carcass composition by in vivo real-time ultrasonography at four anatomical locations. Journal of Animal Science, 87(4), 1455-1463. <https://doi.org/10.2527/jas.2008-1285>
- Ritzler, C. P., Lukas, K. E., Bernstein-Kurtycz, L. M., & Koester, D. C. (2021). The Effects of Choice-Based Design and Management on the Behavior and Space Use of Zoo-Housed Amur Tigers (*Panthera tigris altaica*). Journal of Applied Animal Welfare Science, 26(2), 256-269. <https://doi.org/10.1080/10888705.2021.1958684>
- Rivas, J., Perea, J. M., De-Pablos-Heredero, C., Angon, E., Barba, C., & García, A. (2019). Canonical correlation of technological innovation and performance in sheep's dairy farms: Selection of a set of

- indicators. *Agricultural Systems*, 176(July 2018), 102665. <https://doi.org/10.1016/j.agsy.2019.102665>
- Rohit Madan, & Mona, A. (2022). *Handbook of Research on Artificial Intelligence in Government Practices and Processes* (J. R. Saura & F. Debasia (eds.)). IGI Global. <https://doi.org/10.4018/978-1-7998-9609-8>
- Ruan, J., Wang, Y., Chan, F. T. S., Hu, X., Zhao, M., Zhu, F., Shi, B., Shi, Y., & Lin, F. (2019). A Life Cycle Framework of Green IoT-Based Agriculture and Its Finance, Operation, and Management Issues. *IEEE Communications Magazine*, 57(3), 90–96. <https://doi.org/10.1109/MCOM.2019.1800332>
- Samoil, S., Lopez Cobo, M., Gomez Gutierrez, E., De Prato, G., Martinez-Plumed, F., & Delipetrev, B. (2020). AI Watch – Defining Artificial Intelligence. In JRC Publications Repository. <https://doi.org/10.2760/382730>
- Samuel, A. L. (1959). Some Studies in Machine Learning. *IBM Journal of Research and Development*, 3(3), 210–229. <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=5392560>
- Scozzafava, G., Corsi, A. M., Casini, L., Contini, C., & Loose, S. M. (2016). Using the animal to the last bit: Consumer preferences for different beef cuts. *Appetite*, 96, 70–79. <https://doi.org/10.1016/j.appet.2015.09.004>
- Segerkvist, K. A., Höglund, J., Österlund, H., Wik, C., Högberg, N., & Hesse, A. (2020). Automatic weighing as an animal health monitoring tool on pasture. *Livestock Science*, 240(October 2019), 104157. <https://doi.org/10.1016/j.livsci.2020.104157>
- SG de Producciones Ganaderas y Cinegéticas. (2020). EL SECTOR DE LA CARNE DE CERDO EN CIFRAS: Principales indicadores económicos. Ministerio de Agricultura, Pesca y Alimentación, 1–75. https://www.mapa.gob.es/es/ganaderia/temas/produccion-y-mercados-ganaderos/indicadoreseconomicossectorporcino2020_tcm30-379728.pdf

- SG de Producciones Ganaderas y Cinegéticas. (2023). Caracterización del sector ovino y caprino de leche en España. Ministerio de Agricultura Pesca y Alimentación, 1-14. <https://cpage.mpr.gob.es/NIPO:003211284>
- Shadrin, D., Menshchikov, A., Somov, A., Bornemann, G., Hauslage, J., & Fedorov, M. (2020). Enabling Precision Agriculture through Embedded Sensing with Artificial Intelligence. *IEEE Transactions on Instrumentation and Measurement*, 69(7), 4103-4113. <https://doi.org/10.1109/TIM.2019.2947125>
- Shaikh, F. K., Memon, M. A., Mahoto, N. A., Zeadally, S., & Nebhen, J. (2022). Artificial Intelligence Best Practices in Smart Agriculture. *IEEE Micro*, 42(1), 17-24. <https://doi.org/10.1109/MM.2021.3121279>
- Sheu, J. S., & Tsai, W. H. (2017). Implementation of a following wheel robot featuring stereoscopic vision. *Multimedia Tools and Applications*, 76(23), 25161-25177. <https://doi.org/10.1007/s11042-016-4297-y>
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, 6(1). <https://doi.org/10.1186/s40537-019-0197-0>
- Siena, F. L., Byrom, B., Watts, P., & Breedon, P. (2018). Utilising the Intel RealSense Camera for Measuring Health Outcomes in Clinical Research. *Journal of Medical Systems*, 42(3), 1-10. <https://doi.org/10.1007/s10916-018-0905-x>
- Simonyan, K., & Zisserman, A. (2015). Very deep convolutional networks for large-scale image recognition. 3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings, 1-14.
- Sodhro, A. H., Pirbhulal, S., & de Albuquerque, V. H. C. (2019). Artificial Intelligence-Driven Mechanism for Edge Computing-Based Industrial Applications. *IEEE Transactions on Industrial Informatics*, 15(7), 4235-4243. <https://doi.org/10.1109/TII.2019.2902878>

- Song, X., Schutte, J., van der Tol, P., van Halsema, F., & Groot Koerkamp, P. (2014). Body measurements of dairy calf using a 3-D camera in an automatic feeding system. *International Conference of Agricultural Engineering - AgEng 2014 - Zurich*, 8.
- Sowande, O. S., & Sobola, O. S. (2008). Body measurements of west African dwarf sheep as parameters for estimation of live weight. *Tropical Animal Health and Production*, 40(6), 433-439. <https://doi.org/10.1007/s11250-007-9116-z>
- Spoliansky, R., Edan, Y., Parmet, Y., & Halachmi, I. (2016). Development of automatic body condition scoring using a low-cost 3-dimensional Kinect camera. *Journal of Dairy Science*, 99(9), 7714-7725. <https://doi.org/10.3168/jds.2015-10607>
- Sünderhauf, N., Brock, O., Scheirer, W., Hadsell, R., Fox, D., Leitner, J., Upcroft, B., Abbeel, P., Burgard, W., Milford, M., & Corke, P. (2018). The limits and potentials of deep learning for robotics. *International Journal of Robotics Research*, 37(4-5), 405-420. <https://doi.org/10.1177/0278364918770733>
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., & Rabinovich, A. (2015). Going deeper with convolutions. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 07-12-June, 1-9. <https://doi.org/10.1109/CVPR.2015.7298594>
- Szeliski, R. (2011). *Computer Vision*. Springer London. <https://doi.org/10.1007/978-1-84882-935-0>
- Tadic, V., Toth, A., Vizvari, Z., Klincsik, M., Sari, Z., Sarcevic, P., Sarosi, J., & Biro, I. (2022). Perspectives of RealSense and ZED Depth Sensors for Robotic Vision Applications. *Machines*, 10(3), 1-26. <https://doi.org/10.3390/machines10030183>
- Tambe, P., Cappelli, P., & Yakubovich, V. (2019). Artificial intelligence in human resources management: Challenges and A path forward. *California Management Review*, 61(4), 15-42. <https://doi.org/10.1177/0008125619867910>

- Tan, L. T., Hu, R. Q., & Hanzo, L. (2019). Twin-Timescale Artificial Intelligence Aided Mobility-Aware Edge Caching and Computing in Vehicular Networks. *IEEE Transactions on Vehicular Technology*, 68(4), 3086–3099. <https://doi.org/10.1109/TVT.2019.2893898>
- Tan, M., & Le, Q. V. (2019). EfficientNet: Rethinking model scaling for convolutional neural networks. 36th International Conference on Machine Learning, ICML 2019, 2019–June, 10691–10700.
- Tang, P. C., & Patel, V. L. (1994). Major issues in user interface design for health professional workstations: summary and recommendations. *International Journal of Bio-Medical Computing*, 34(1–4), 139–148. [https://doi.org/10.1016/0020-7101\(94\)90017-5](https://doi.org/10.1016/0020-7101(94)90017-5)
- Tasdemir, S., Urkmez, A., & Inal, S. (2011). Determination of body measurements on the Holstein cows using digital image analysis and estimation of live weight with regression analysis. *Computers and Electronics in Agriculture*, 76(2), 189–197. <https://doi.org/10.1016/j.compag.2011.02.001>
- Topal, M., & Macit, M. (2004). Prediction of body weight from body measurements in morkaraman sheep. *Journal of Applied Animal Research*, 25(2), 97–100. <https://doi.org/10.1080/09712119.2004.9706484>
- Tresoldi, G., Schütz, K. E., & Tucker, C. B. (2019). Cooling cows with sprinklers: Effects of soaker flow rate and timing on behavioral and physiological responses to heat load and production. *Journal of Dairy Science*, 102(1), 528–538. <https://doi.org/10.3168/jds.2018-14962>
- Trieb, F. H. (2005). Waterjet Cutting: State of the Art and Future Trends. Volume 5: High Pressure Technology, Nondestructive Evaluation, Pipeline Systems, Student Paper Competition, 91–95. <https://doi.org/10.1115/PVP2005-71684>
- 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*, 650, 2751–2760. <https://doi.org/10.1016/j.scitotenv.2018.10.018>
- Tung, K. (2019). AI, the internet of legal things, and lawyers. *Journal of Management Analytics*, 6(4), 390–403. <https://doi.org/10.1080/23270012.2019.1671242>
- Turing, A. M. (1950). I.—COMPUTING MACHINERY AND INTELLIGENCE. *Mind*, LIX(236), 433–460. <https://doi.org/10.1093/mind/LIX.236.433>
- Van Der Walt, S., Schönberger, J. L., Nunez-Iglesias, J., Boulogne, F., Warner, J. D., Yager, N., Gouillart, E., & Yu, T. (2014). Scikit-image: Image processing in python. *PeerJ*, 2014(1), 1–18. <https://doi.org/10.7717/peerj.453>
- van Rossum, G. (1995a). Python tutorial, May 1995. CWI Report CS-R9526, CS-R9526, 1–65. <http://oai.cwi.nl/oai/asset/5007/05007D.pdf>
- van Rossum, G. (1995b). Python tutorial. CWI Report CS-R9526, CS-R9526, 1–65. <http://oai.cwi.nl/oai/asset/5007/05007D.pdf>
- Vanderelst, D., & Winfield, A. (2018). An architecture for ethical robots inspired by the simulation theory of cognition. *Cognitive Systems Research*, 48, 56–66. <https://doi.org/10.1016/j.cogsys.2017.04.002>
- Varoquaux, G., Buitinck, L., Louppe, G., Grisel, O., Pedregosa, F., & Mueller, A. (2015). Scikit-learn: Machine Learning in Python. *GetMobile: Mobile Computing and Communications*, 19(1), 29–33. <https://doi.org/10.1145/2786984.2786995>
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention is All you Need. In I. Guyon, U. Von Luxburg, S. Bengio, H. Wallach, R. Fergus, S. Vishwanathan, & R. Garnett (Eds.), *Advances in Neural Information Processing Systems* (Vol. 30). Curran Associates, Inc.

https://proceedings.neurips.cc/paper_files/paper/2017/file/3f5ee243547dee91fbd053c1c4a845aa-Paper.pdf

- Vecerek, V., Grbalova, S., Voslarova, E., Janackova, B., & Malena, M. (2006). Effects of travel distance and the season of the year on death rates of broilers transported to poultry processing plants. *Poultry Science*, 85(11), 1881–1884. <https://doi.org/10.1093/ps/85.11.1881>
- Vieira, A., Brandão, S., Monteiro, A., Ajuda, I., & Stilwell, G. (2015). Development and validation of a visual body condition scoring system for dairy goats with picture-based training. *Journal of Dairy Science*, 98(9), 6597–6608. <https://doi.org/10.3168/jds.2015-9428>
- Villa, E., Arteaga-Marrero, N., & Ruiz-Alzola, J. (2020). Performance assessment of low-cost thermal cameras for medical applications. *Sensors (Switzerland)*, 20(5), 1–17. <https://doi.org/10.3390/s20051321>
- Vranken, E., & Berckmans, D. (2017). Precision livestock farming for pigs. *Animal Frontiers*, 7(1), 32–37. <https://doi.org/10.2527/af.2017.0106>
- Walden, A., Garvin, L., Smerek, M., & Johnson, C. (2020). User-centered design principles in the development of clinical research tools. *Clinical Trials*, 17(6), 703–711. <https://doi.org/10.1177/1740774520946314>
- Wang, H., Li, B., Zhong, H., Xu, A., Huang, Y., Zou, J., Chen, Y., Wu, P., Chen, Y., Leung, C., & Miao, C. (2022). Smart Decision-Support System for Pig Farming. *Drones*, 6(12), 1–13. <https://doi.org/10.3390/drones6120389>
- Wang, J., & Shanmugam, D. K. (2009). Cutting meat with bone using an ultrahigh pressure abrasive waterjet. *Meat Science*, 81(4), 671–677. <https://doi.org/10.1016/j.meatsci.2008.11.010>

- Wang, R., Pan, W., Jin, L., Li, Y., Geng, Y., Gao, C., Chen, G., Wang, H., Ma, D., & Liao, S. (2019). Artificial intelligence in reproductive medicine. *Reproduction*, 158(4), R139–R154. <https://doi.org/10.1530/REP-18-0523>
- Wang, Y., Yang, W., Winter, P., & Walker, L. (2008). Walk-through weighing of pigs using machine vision and an artificial neural network. *Biosystems Engineering*, 100(1), 117–125. <https://doi.org/10.1016/j.biosystemseng.2007.08.008>
- Wang, Y., Yang, W., Winter, P., & Walker, L. T. (2006). Non-contact sensing of hog weights by machine vision. In *Applied Engineering in Agriculture* (Vol. 22, Issue 4, pp. 577–582).
- Wang, Z., Wang, K., Yang, F., Pan, S., & Han, Y. (2018). Image segmentation of overlapping leaves based on Chan–Vese model and Sobel operator. *Information Processing in Agriculture*, 5(1), 1–10. <https://doi.org/10.1016/j.inpa.2017.09.005>
- Weather, N., & Chain, P. V. (2020). Realizing the benefits of AI across the numerical weather prediction value chain. *Bulletin of the American Meteorological Society*, 101(1), 29–33. <https://doi.org/10.1175/BAMS-D-18-0324.A>
- Webb, E. C., & O’Neill, H. A. (2008). The animal fat paradox and meat quality. *Meat Science*, 80(1), 28–36. <https://doi.org/10.1016/j.meatsci.2008.05.029>
- Weber, A., Salau, J., Haas, J. H., Junge, W., Bauer, U., Harms, J., Suhr, O., Schönrock, K., Rothfuß, H., Bieletzki, S., & Thaller, G. (2014). Estimation of backfat thickness using extracted traits from an automatic 3D optical system in lactating Holstein–Friesian cows. *Livestock Science*, 165(1), 129–137. <https://doi.org/10.1016/j.livsci.2014.03.022>
- Xing Li, H., & Li, L. . (1999). Representing diverse mathematical problems using neural networks in hybrid intelligent systems. *Expert Systems*, 16(4), 262–272. <https://doi.org/10.1111/1468-0394.00118>

- Xu, L. Da. (2013). Introduction: Systems Science in Industrial Sectors. *Systems Research and Behavioral Science*, 30(3), 211–213. <https://doi.org/10.1002/sres.2186>
- Xu, L. Da, Lu, Y., & Li, L. (2021). Embedding Blockchain Technology into IoT for Security: A Survey. *IEEE Internet of Things Journal*, 8(13), 10452–10473. <https://doi.org/10.1109/JIOT.2021.3060508>
- Xu, J., Zhang, J., Zhang, K., Liu, T., & Wang, D. (2020). An APF-ACO algorithm for automatic defect detection on vehicle paint Content courtesy of Springer Nature , terms of use apply . Rights reserved . Content courtesy of Springer Nature , terms of use apply . Rights reserved . 25315–25333.
- Xu, L., Tan, W., Zhen, H., & Shen, W. (2008). An approach to enterprise process dynamic modeling supporting enterprise process evolution. *Information Systems Frontiers*, 10(5), 611–624. <https://doi.org/10.1007/s10796-008-9114-3>
- Xu, Y., Seward, P., Gaye, C., Lin, L., & Olago, D. O. (2019). Preface: Groundwater in Sub-Saharan Africa. *Hydrogeology Journal*, 27(3), 815–822. <https://doi.org/10.1007/s10040-019-01977-2>
- Yang, G., Xie, L., Mäntysalo, M., Zhou, X., Pang, Z., Xu, L. Da, Kao-Walter, S., Chen, Q., & Zheng, L. R. (2014). A Health-IoT platform based on the integration of intelligent packaging, unobtrusive bio-sensor, and intelligent medicine box. *IEEE Transactions on Industrial Informatics*, 10(4), 2180–2191. <https://doi.org/10.1109/TII.2014.2307795>
- Yilmaz, O., Cemal, I., & Karaca, O. (2012). Estimation of mature live weight using some body measurements in Karya sheep. *Tropical Animal Health and Production*, 45(1), 397–403. <https://doi.org/10.1007/s11250-012-0229-7>
- Young, T., Hazarika, D., Poria, S., & Cambria, E. (2018). Recent trends in deep learning based natural language processing [Review Article]. *IEEE Computational Intelligence Magazine*, 13(3), 55–75. <https://doi.org/10.1109/MCI.2018.2840738>

- Zappone, A., Di Renzo, M., & Debbah, M. (2019). Wireless Networks Design in the Era of Deep Learning: Model-Based, AI-Based, or Both? *IEEE Transactions on Communications*, 67(10), 7331–7376. <https://doi.org/10.1109/TCOMM.2019.2924010>
- Zhang, C. (2020). Research on the economical influence of the difference of regional logistics developing level in China. *Journal of Industrial Integration and Management*, 5(2), 205–223. <https://doi.org/10.1142/S2424862220500049>
- Zhang, C., & Lu, Y. (2021). Study on artificial intelligence: The state of the art and future prospects. *Journal of Industrial Information Integration*, 23(April), 100224. <https://doi.org/10.1016/j.jii.2021.100224>
- Zhang, W., Xiang, Y., Liu, X., & Zhang, P. (2019). Domain ontology development of knowledge base in cardiovascular personalized health management. *Journal of Management Analytics*, 6(4), 420–455. <https://doi.org/10.1080/23270012.2019.1694454>
- Zhao, M., Ju, R., Wang, X., & Hong, G. (2008). Setup of X-Ray imaging system in foreign objects inspection of shielded packaged food. *American Society of Agricultural and Biological Engineers Annual International Meeting 2008, ASABE 2008*, 1, 497–507. <https://doi.org/10.13031/2013.24586>

