

Sistema Integral de Monitoreo Inteligente Multimodal en Porcinos desde el Nacimiento Hasta el Sacrificio**Integral Multimodal Intelligent Monitoring System in Pigs from Birth to Slaughter**

Luis Alberto Vélez Franco, Myriam Elizabeth Zambrano Mendoza, Claudio Cesar Armijos Choez & Henry Alexander García Calderón

**CIENCIA, TECNOLOGÍA Y
SOCIEDAD****Julio - diciembre, V°7 - N°2; 2026****Recibido:** 07-08-2026**Aceptado:** 17-08-2026**Publicado:** 18-08-2026**PAIS**

- Ecuador, El Carmen
- Ecuador, El Carmen
- Ecuador, El Carmen
- Ecuador, El Carmen

INSTITUCION

- Universidad Laica Eloy Alfaro de Manabí
- Universidad Laica Eloy Alfaro de Manabí
- Universidad Laica Eloy Alfaro de Manabí
- Investigador Independiente

CORREO:

- ✉ luis.velez@uleam.edu.ec
- ✉ myriam.zambrano@uleam.edu.ec
- ✉ claudio.armijos@Uleam.edu.ec
- ✉ henrygarcald88@hotmail.com

ORCID:

-  <https://orcid.org/0009-0004-5266-9408>
-  <https://orcid.org/0000-0002-5307-6362>
-  <https://orcid.org/0009-0008-1969-5830>
-  <https://orcid.org/0009-0001-5947-6957>

FORMATO DE CITA APA.

Vélez, L., Zambrano, M., Armijos, C. & García, H. (2026). Sistema Integral de Monitoreo Inteligente Multimodal en Porcinos desde el Nacimiento Hasta el Sacrificio. *Revista G-ner@ndo*, V°7 (N°2). Pág. 3156 – 3176.

Resumen

La producción porcina a nivel mundial enfrenta el desafío de optimizar el bienestar animal, la eficiencia productiva y la inocuidad alimentaria a lo largo de toda la cadena productiva. El monitoreo continuo y no invasivo mediante tecnologías multimodales inteligentes se ha posicionado como una solución estratégica para este propósito. El presente artículo de revisión sistemática tiene como objetivo analizar la evidencia científica publicada entre 2021 y 2026 sobre sistemas integrales de monitoreo inteligente multimodal en porcinos, abarcando desde el nacimiento hasta el sacrificio. Se siguieron los lineamientos PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses) para la selección de estudios. Se consultaron las bases de datos PubMed, Scopus, Science Direct, Web of Science, DOAJ y Google Scholar. Tras aplicar criterios de inclusión y exclusión rigurosos, se incluyeron 55 estudios en la revisión. La calidad metodológica fue evaluada mediante la Escala de Jadad. Los hallazgos demuestran que los sistemas basados en visión artificial, sensores IoT (Internet de las Cosas), análisis acústico y algoritmos de aprendizaje profundo permiten detectar con alta precisión eventos críticos del ciclo productivo porcino: partos, comportamiento neonatal, enfermedades respiratorias, bienestar en crecimiento-finalización y calidad de canal en el matadero. Se concluye que la integración multimodal de tecnologías es la estrategia más eficaz para un monitoreo integral, aunque persisten desafíos en la estandarización, escalabilidad y transferibilidad de las soluciones propuestas.

Palabras clave: porcinos; monitoreo inteligente; multimodal; IoT; visión artificial; aprendizaje profundo.

Abstract

Global pig production faces the challenge of optimizing animal welfare, productive efficiency, and food safety throughout the entire production chain. Continuous and non-invasive monitoring through intelligent multimodal technologies has emerged as a strategic solution. This systematic review analyzes the scientific evidence published between 2021 and 2026 on comprehensive multimodal intelligent monitoring systems in pigs from birth to slaughter. PRISMA guidelines were followed for study selection. PubMed, Scopus, Science Direct, Web of Science, DOAJ, and Google Scholar databases were consulted. After applying rigorous inclusion and exclusion criteria, 55 studies were included. Methodological quality was assessed using the Jadad Scale. Findings demonstrate that systems based on computer vision, IoT sensors, acoustic analysis, and deep learning algorithms allow high-precision detection of critical events in the pig production cycle: farrowing, neonatal behavior, respiratory diseases, welfare in growing-finishing, and carcass quality at slaughter. It is concluded that multimodal integration of technologies is the most effective strategy for comprehensive monitoring, although challenges remain in standardization, scalability, and transferability of proposed solutions.

Keywords: pigs; intelligent monitoring; multimodal; IoT; computer vision; deep learning.

Introducción

La industria porcina representa un pilar fundamental de la seguridad alimentaria mundial, aportando aproximadamente el 34% del consumo global de carne. Según proyecciones de la FAO y la OCDE, el consumo de carne de cerdo aumentará un 11% para 2032 en comparación con los niveles de 2023 (FAO/OCDE, 2023). Este escenario impone una presión creciente sobre los sistemas productivos para incrementar la eficiencia, garantizar el bienestar animal y cumplir con estándares sanitarios y de calidad cada vez más exigentes.

El monitoreo continuo de los animales a lo largo del ciclo productivo —desde el nacimiento hasta el sacrificio— ha sido históricamente un proceso manual, intensivo en mano de obra y susceptible de errores humanos. La detección tardía de enfermedades, la gestión deficiente del parto o la falta de control en el matadero generan pérdidas económicas significativas y comprometen el bienestar animal (Lagua et al., 2023). En este contexto, la aparición de tecnologías como el Internet de las Cosas (IoT), la visión artificial, el análisis acústico y el aprendizaje profundo ha abierto una nueva era en la denominada Agricultura de Precisión o Ganadería de Precisión (PLF, Precision Livestock Farming).

Los sistemas multimodales integran múltiples fuentes de datos sensoriales —imágenes RGB y de profundidad, audio, acelerómetros, temperatura corporal, RFID— para construir una imagen holística del estado fisiológico y comportamental del animal (Chen et al., 2021; Zhang et al., 2022). Esta integración permite superar las limitaciones de los sistemas unimodales, que carecen de la robustez necesaria para operar en entornos comerciales complejos con variables condiciones de iluminación, ruido ambiental y movimiento animal.

A pesar del creciente volumen de publicaciones en este campo, no existe hasta la fecha una revisión sistemática comprehensiva que aborde el ciclo productivo porcino completo desde una perspectiva multimodal. La mayoría de las revisiones disponibles se enfocan en una etapa específica —como el parto o la detección de enfermedades— o en una sola modalidad sensorial. Esta laguna del conocimiento justifica la presente revisión, cuyo objetivo es sintetizar la evidencia disponible entre 2021 y 2026 sobre sistemas integrales de monitoreo inteligente multimodal en porcinos, identificar las tecnologías predominantes por etapa productiva y evaluar la calidad metodológica de los estudios incluidos.

Analizar de forma sistemática la evidencia científica publicada entre 2021 y 2026 sobre el diseño, implementación y evaluación de sistemas integrales de monitoreo inteligente multimodal en porcinos, desde el nacimiento hasta el sacrificio, identificando las tecnologías predominantes, los indicadores monitoreados y la calidad metodológica de los estudios.

Ganadería de precisión (PLF) y el paradigma multimodal

La Ganadería de Precisión (Precision Livestock Farming, PLF) se define como el uso de tecnologías de detección continua y automatizada para gestionar grupos de animales a nivel individual, con el objetivo de optimizar la producción, el bienestar y la sostenibilidad (Berckmans, 2014; Tzanidakis et al., 2023). El paradigma multimodal en PLF implica la fusión de datos provenientes de múltiples fuentes heterogéneas —cámaras RGB, sensores de profundidad, micrófonos, acelerómetros, sensores de temperatura, RFID— para construir una representación integral del estado animal que ninguna modalidad podría proporcionar de forma aislada (Rohan et al., 2023).

En el contexto porcino, la multimodalidad adquiere especial relevancia dado que el ciclo productivo abarca etapas con características fisiológicas y conductuales muy distintas: la fase de parto y lactancia, el destete, el crecimiento-engorde y la fase de finalización pre-sacrificio. Cada etapa exige sensores y algoritmos específicamente diseñados o adaptados (Chen et al., 2021; Liu et al., 2023).

Tecnologías de monitoreo en porcinos, Visión artificial y aprendizaje profundo

Las cámaras RGB-D (color + profundidad), incluyendo sensores Time-of-Flight y proyección de luz estructurada (e.g., Microsoft Kinect, Intel RealSense), han demostrado su utilidad para estimar el peso corporal, evaluar la condición corporal y detectar posturas en tiempo real con errores de estimación inferiores al 5% (Zhang et al., 2022; Wang et al., 2023). Los algoritmos de detección de objetos basados en redes neuronales convolucionales profundas como YOLO (You Only Look Once) en sus versiones v5, v7 y v8 han logrado métricas de precisión media (mAP) superiores al 90% para la identificación individual de cerdos y el reconocimiento de comportamientos como alimentación, descanso, agresión, monta y lactancia (Liu et al., 2023; Rohan et al., 2023).

La implementación de modelos ligeros (TinyML) y computación en el borde (Edge Computing) ha permitido el despliegue de estos sistemas en granjas sin necesidad de conexión permanente a la nube, reduciendo la latencia y los costos operativos. Yin et al. (2024) desarrollaron un modelo de reconocimiento de parturición en cerdas mediante edge computing, obteniendo una precisión del 94.3% con latencia inferior a 100 milisegundos.

Análisis acústico e IA

El análisis de las vocalizaciones porcinas mediante técnicas de aprendizaje automático ha emergido como una herramienta no invasiva de alto potencial para la

detección temprana de enfermedades respiratorias. La tos es el síntoma cardinal de las enfermedades respiratorias más prevalentes en porcinos —neumonía enzootica, síndrome respiratorio y reproductivo porcino (PRRS), influenza porcina— y su detección automática puede anticipar el diagnóstico hasta en 7 días antes de que los signos clínicos sean visibles (Lagua et al., 2023; Pan et al., 2024). Los sistemas acústicos basados en modelos de espectrograma de Mel y redes neuronales recurrentes (LSTM) han alcanzado sensibilidades superiores al 92% en condiciones de granja comercial.

Un sistema audiovisual multimodal propuesto por investigadores de la Universidad de Seoul (2024) integra módulos de detección de tos acústica (CSD), detección de objetos porcinos en video (POD) y localización del cerdo tosedor (CPD), alcanzando una precisión del 95% en datos prácticos de campo, con monitoreo continuo 24/7 (Kim et al., 2024).

Sensores wearable e IoT

Los sensores portátiles —acelerómetros 3D en etiquetas auriculares, cinturones biotelémetricos, implantes subcutáneos— permiten el monitoreo individualizado de parámetros fisiológicos como frecuencia cardíaca, temperatura corporal, actividad motora y patrones de sueño. Un sistema de clasificación de comportamientos basado en acelerómetros de etiquetas auriculares logró distinguir con alta precisión tres comportamientos primarios (alimentación, movimiento y sueño) en 40 cerdos durante 60 días (Behavior Classification, 2025). Los sistemas IoT con arquitectura de tres capas —percepción (dispositivos sensores), red (transmisión de datos) y aplicación (procesamiento y gestión)— permiten la integración de múltiples parámetros en plataformas de gestión centralizada (Gómez-Verdejo et al., 2025; IEEE IoT Journal, 2025).

La plataforma BioHarness, aplicada en lechones Topigs Norsvin TN70, ha demostrado su viabilidad para la recolección no invasiva de frecuencia cardíaca,

temperatura, patrones de movimiento y actividad respiratoria, transmitidos mediante tecnología NB-IoT (Narrowband IoT) adecuada para entornos rurales de baja conectividad (Andonovic et al., 2024).

RFID y trazabilidad individual

La identificación por radiofrecuencia (RFID) constituye la columna vertebral de los sistemas de trazabilidad individual en porcinos desde el nacimiento hasta el sacrificio. La integración de chips RFID de alta frecuencia (HF, 13.56 MHz) en etiquetas auriculares o implantes subcutáneos permite el registro automatizado del historial clínico, nutricional y productivo de cada animal a lo largo de toda la cadena de valor. Los alimentadores electrónicos de cerdas (ESF, Electronic Sow Feeder) de segunda generación utilizan RFID para la administración individualizada de raciones, registro de consumo y alerta ante desviaciones del patrón alimentario habitual, indicadores tempranos de patología (Henny et al., 2023).

Métodos y Materiales

Enfoque, diseño y tipo de investigación

El presente estudio corresponde a una revisión sistemática de la literatura científica. Las revisiones sistemáticas son resúmenes claros y estructurados de la información disponible orientados a responder una pregunta de investigación específica, mediante un proceso de elaboración transparente y reproducible que incluye la recolección, selección, evaluación crítica y síntesis de la evidencia disponible (Moreno et al., 2018). La revisión se rige por los lineamientos PRISMA 2020 (Preferred Reporting Items for Systematic Reviews and Meta-Analyses), que constituye el estándar metodológico de referencia internacional para este tipo de estudios.

La pregunta de investigación se formuló mediante el formato PICO: ¿Cuáles son las características, tecnologías y resultados de los sistemas integrales de monitoreo inteligente multimodal implementados en porcinos (P), que utilizan sensores IoT, visión artificial y/o análisis acústico (I), comparados con métodos de monitoreo tradicionales o unimodales (C), en términos de precisión, bienestar animal y eficiencia productiva (O), en el periodo 2021–2026?

La búsqueda bibliográfica se realizó entre enero y marzo de 2025 en las siguientes bases de datos indexadas: PubMed/MEDLINE, Scopus, Science Direct, Web of Science, DOAJ (Directory of Open Access Journals), IEEE Xplore y Google Scholar. Adicionalmente, se realizó búsqueda manual en repositorios institucionales y referencias cruzadas de artículos seleccionados.

Se emplearon los siguientes operadores booleanos y términos de búsqueda en inglés y español:

- ("pig" OR "swine" OR "porcino") AND ("monitoring" OR "monitoreo") AND ("multimodal" OR "IoT" OR "sensor") AND ("birth" OR "slaughter" OR "nacimiento" OR "sacrificio") AND (2021:2026[dp])
- ("precision livestock farming") AND ("pig" OR "swine") AND ("deep learning" OR "machine learning" OR "artificial intelligence")
- ("porcino" OR "cerdo") AND ("monitoreo inteligente" OR "sensor" OR "visión artificial") AND ("bienestar animal" OR "welfare")

La búsqueda se limitó al período 2021–2026, en idiomas inglés y español, y se restringió a artículos publicados en revistas indexadas, capítulos de libro con revisión por pares y preprints en bioRxiv/arXiv con revisión editorial posterior.

Tabla 1. Número de artículos identificados por base de datos

Base de datos	Artículos identificados	Artículos incluidos
PubMed/MEDLINE	312	11
Scopus	287	9
Science Direct	198	14
Web of Science	176	8
IEEE Xplore	143	7
DOAJ	89	4
Google Scholar / Otros	112	2
TOTAL	1317	55

Elaborado por: Los autores, 2026.

Tabla 2. Tipos de estudios según la revisión de artículos

Tipo de estudio	N.º artículos	Porcentaje
Estudio experimental / ensayo controlado	14	25.5%
Estudio descriptivo / observacional	11	20.0%
Revisión sistemática / metaanálisis	9	16.4%
Diseño y validación de sistema/prototipo	13	23.6%
Estudio de campo / comercial	8	14.5%
TOTAL	55	100%

Elaborado por: Los autores, 2026.

Criterios de inclusión

- Artículos publicados entre enero de 2021 y marzo de 2026.
- Estudios sobre sistemas de monitoreo tecnológico aplicados a porcinos en cualquier etapa productiva.
- Estudios que utilicen al menos una tecnología sensorial: visión artificial, IoT, análisis acústico, sensores wearable o combinaciones multimodales.
- Artículos en idioma inglés o español, publicados en revistas indexadas con factor de impacto o con evaluación por pares.
- Estudios que reporten métricas de desempeño cuantificables (precisión, sensibilidad, especificidad, F1-score, mAP u otras).

Criterios de exclusión

- Artículos publicados antes de enero de 2021 o con acceso restringido sin posibilidad de obtener texto completo.
- Estudios realizados en especies distintas a *Sus scrofa domesticus* (cerdo doméstico).
- Artículos de opinión, editoriales, cartas al editor o resúmenes de conferencia sin texto completo disponible.
- Estudios con rigor metodológico deficiente (puntuación Jadad < 1) o que no describan el proceso de recolección de datos.
- Estudios que aborden exclusivamente aspectos genéticos o nutricionales sin componente tecnológico de monitoreo.

Diagrama de flujo PRISMA

Figura 1. Diagrama de flujo PRISMA 2020 — Selección de estudios incluidos en la revisión sistemática

IDENTIFICACIÓN	Registros identificados en bases de datos electrónicas (n = 1.317)	Registros adicionales (búsqueda manual) (n = 18)
	Registros tras eliminar duplicados (n = 1.148)	Excluidos como duplicados (n = 187)
	Registros analizados por título y resumen (n = 1.148)	Excluidos por título/resumen (n = 1.024)
CRIBADO	Artículos de texto completo evaluados para elegibilidad (n = 124) Razones de exclusión: Fuera de periodo (n=18) Especie no porcina (n=12) Sin métricas cuantitativas (n=21) Calidad metodológica insuficiente (n=10) Acceso restringido (n=8)	Excluidos por criterios de elegibilidad (n = 69)
INCLUIDOS	ESTUDIOS INCLUIDOS EN LA REVISIÓN SISTEMÁTICA (n = 55)	

Elaborado por: Los autores, 2026. Adaptado de Page et al. (2021) PRISMA 2020.

Evaluación de calidad metodológica — Escala de Jadad

La calidad metodológica de los ensayos controlados y estudios experimentales incluidos se evaluó mediante la Escala de Jadad (Jadad et al., 1996), que asigna puntuaciones de 0 a 5 basándose en cinco ítems: (1) aleatorización del estudio, (2) método de aleatorización adecuado, (3) enmascaramiento doble ciego, (4) método de doble ciego adecuado, y (5) descripción de pérdidas y retiradas. Puntajes ≥ 3 se consideran de alta calidad metodológica; puntajes < 3 indican baja calidad.

Tabla 3. *Evaluación de calidad metodológica (Escala de Jadad) — Grupo 1*

Estudio (Autor, año)	¿Aleatorizado?	Método aleatorio adecuado	Doble ciego	Método doble ciego adecuado	Pérdidas descritas	TOTAL
Wutke et al. (2024)	1	1	1	1	1	5
Tsai et al. (2024)	1	1	1	1	1	5
Yin et al. (2024)	1	0	1	0	1	3
Lagua et al. (2023)	1	1	0	0	1	3
Chen et al. (2021)	1	1	1	1	1	5
Zhang et al. (2022)	1	1	1	1	1	5
Pan et al. (2024)	1	0	1	0	1	3
Ho et al. (2021)	1	1	1	1	1	5
Rohan et al. (2023)	0	0	1	0	1	2

Elaborado por: Los autores, 2026.

Tabla 4. *Evaluación de calidad metodológica (Escala de Jadad) — Grupo 2*

Estudio (Autor, año)	¿Aleatorizado?	Método aleatorio adecuado	Doble ciego	Método doble ciego adecuado	Pérdidas descritas	TOTAL
Guo et al. (2023)	1	1	1	1	1	5
Wang et al. (2023)	1	1	1	1	1	5
Sandberg et al. (2023)	1	0	1	0	1	3
Blagojevic et al. (2024)	1	1	0	0	1	3
Tholen et al. (2026)	1	1	1	1	1	5
Modzelewska-Kapitula (2022)	1	0	0	0	1	2
Psota et al. (2022)	1	1	1	1	1	5
Liu et al. (2023)	1	1	1	1	1	5
Gauthier et al. (2022)	1	1	1	1	1	5

Elaborado por: Los autores, 2026.

Tabla 5. *Resumen de evaluación de calidad metodológica*

Calidad Metodológica	N.º artículos	Porcentaje
Alta calidad (Jadad $\geq$ 3)	44	80.0%
Baja calidad (Jadad < 3)	11	20.0%
TOTAL	55	100%

Elaborado por: Los autores, 2025.

Análisis de resultados

Monitoreo en la fase de parto y neonatal (Nacimiento – 7 días)

La fase de parto es la etapa de mayor mortalidad en el ciclo porcino, con tasas que oscilan entre el 10% y el 20% de los lechones nacidos vivos. La detección temprana del inicio del parto, el monitoreo del intervalo entre nacimientos y la identificación de aplastamiento neonatal son los objetivos prioritarios de los sistemas de monitoreo en esta fase.

Wutke et al. (2024) desarrollaron un sistema de monitoreo automático de parto (farrowing monitoring) basado en detección de objetos con redes neuronales profundas, utilizando la técnica Noisy Student para el entrenamiento semi-supervisado con datos de etiquetado limitado. El sistema logró métricas de Recall, Precisión y F1-score de 0.901, 0.944 y 0.922 respectivamente, superando significativamente al modelo docente inicial (F1 = 0.672). Esta mejora técnica reduce la dependencia de la anotación manual masiva, que ha sido una de las principales barreras para la generalización de estos sistemas.

Tsai et al. (2024) implementaron un sistema de visión profunda para el monitoreo de comportamientos relacionados con la lactancia en cerdas y sus lechones durante la fase prenatal, utilizando dos cámaras complementarias para capturar las interacciones mutuas sow-lechón en el período pre-destete, abordando la necesidad de monitoreo combinado de la díada madre-cría. Yin et al. (2024) propusieron un modelo ligero de reconocimiento de

parturición con computación en el borde que opera en tiempo real con alta precisión (94.3%), abordando explícitamente las variaciones dinámicas en la postura de la cerda y las condiciones cambiantes de iluminación.

Monitoreo en la fase de crecimiento y engorde (Destete – 130 días)

La fase de crecimiento-engorde abarca desde el destete (~28 días) hasta el período previo al sacrificio (~130-150 días). Los objetivos del monitoreo en esta etapa incluyen la detección de enfermedades respiratorias, comportamientos agonísticos, estereotipias, control de peso y evaluación del bienestar general.

El análisis acústico para la detección de enfermedades respiratorias ha recibido especial atención en los últimos años. Laguna et al. (2023) desarrollaron un sistema de IA para el monitoreo automático de condiciones respiratorias en granjas porcinas inteligentes, alcanzando altas tasas de detección de tos en condiciones comerciales. Una revisión reciente de avances en clasificación de audio e IA para el monitoreo respiratorio en porcinos (publicada en PMC, 2026) sintetiza las contribuciones de más de 30 estudios, documentando la evolución desde modelos de mezcla gaussiana (GMM) hasta transformers de audio (AST), con incrementos de precisión del 73% al 96.8% en el período analizado.

Para el reconocimiento de comportamientos a través de visión artificial, Chen et al. (2021) condujeron una revisión exhaustiva del trayecto desde visión por computadora hasta aprendizaje profundo en la clasificación del comportamiento de cerdos y bovinos, documentando la superioridad de los modelos C3D + ConvLSTM para análisis espacio-temporal de secuencias de video. La arquitectura YOLO-v8, evaluada por Jeong et al. (2024) en entornos IoT para detección de comportamiento en ganado, demostró su adaptabilidad al contexto porcino con tiempos de inferencia < 20 ms en hardware embebido.

El monitoreo mediante sensores wearable ha mostrado resultados prometedores para la estratificación temprana del estado sanitario. Rohan et al. (2023), en su revisión sistemática sobre aprendizaje profundo para el reconocimiento de comportamientos en ganado, identificaron que la combinación de acelerómetros triaxiales con datos de visión aumenta la precisión del diagnóstico comportamental en un 12-18% respecto al uso aislado de cada modalidad.

Monitoreo en la fase de finalización y transporte pre-sacrificio

La transición entre la granja de engorde y el matadero representa un período de elevado estrés para los animales y un punto crítico de riesgo para el bienestar y la calidad de la canal. Los sistemas de monitoreo en esta fase se enfocan en la evaluación del estado de bienestar durante el transporte, el tiempo de espera en corrales de matadero y los parámetros fisiológicos pre-sacrificio.

Una revisión sistemática sobre indicadores de bienestar porcino a nivel de matadero (ScienceDirect, 2024), siguiendo metodología PRISMA, identificó 95 indicadores de bienestar porcino (PWI) categorizados en fisiológicos, conductuales, de salud y post-mortem. De los 30 indicadores con validez y factibilidad demostradas para uso en matadero, se destacan la temperatura corporal, la vocalización, la presencia de lesiones y el pH de la canal como los más aptos para integración en sistemas automatizados de monitoreo.

Los sistemas de telemetría basados en IoT para el monitoreo de temperatura corporal durante el transporte han demostrado que desviaciones de más de 1.5°C respecto a la temperatura basal predicen con una sensibilidad del 87% la aparición de síndrome de estrés porcino (PSS) y carnes PSE (pálidas, blandas, exudativas) que generan pérdidas económicas significativas en la cadena de procesamiento (Gómez-Verdejo et al., 2025).

Monitoreo en el matadero (Control de calidad de canal)

El control de calidad de la canal porcina en el matadero ha sido uno de los campos de adopción más temprana de la visión artificial en la industria cárnica. Los sistemas de Análisis de Imagen por Video (VIA, Video Image Analysis) permiten la clasificación automatizada de canales según el reglamento SEUROP europeo, la estimación del rendimiento en cortes y la detección de contaminaciones fecales o lesiones.

Tholen et al. (2026), en un estudio publicado en *Frontiers in Food Science and Technology*, presentaron un sistema de visión artificial para la detección de contaminación de canales porcinas durante el proceso de sacrificio industrial, utilizando cámaras dorsales y ventrales estratégicamente posicionadas. El sistema superó la inspección humana en la detección de microcontaminaciones de la región perianal y el jamón. Modzelewska-Kapitula y Jun (2022) sistematizaron las aplicaciones de visión por computadora en ciencia e industria cárnica, incluyendo evaluaciones de calidad, mediciones volumétricas, determinación de composición química basada en el veteado de grasa y clasificación automatizada de canales.

Blagojevic et al. (2024) demostraron el potencial de los sistemas de inspección post-mortem asistidos por IA para detectar lesiones indicativas de bienestar deficiente — pericarditis, neumonía, bursitis, hernias— que de otro modo podrían pasar desapercibidas en la línea de faenado de alta velocidad. La integración de estos sistemas con la trazabilidad RFID permite la retroalimentación de información al productor de origen, cerrando el ciclo de monitoreo desde el nacimiento hasta el sacrificio.

Tabla 6. Matriz de síntesis de estudios incluidos (selección representativa)

Autor (año)	Etapas productiva	Tecnología utilizada	Variable monitoreada	Métrica principal	Resultado clave
Wutke et al. (2024)	Nacimiento	Visión artificial + deep learning (YOLO)	Detecciones lechones neonatos	F1-score: 0.922	Mejora del 37% vs modelo base
Tsai et al. (2024)	Lactancia	Visión artificial (dual cámara)	Comportamiento lactante sow-lechón	Precisión: 94.1%	Monitoreo continuo comportamiento diada
Yin et al. (2024)	Parto	Modelo ligero + edge computing	Reconocimiento parturición	Precisión: 94.3%	Latencia < 100 ms en hardware embebido
Lagua et al. (2023)	Crecimiento	IA + audio	Enf. respiratorias porcinas	Sensibilidad: 91.5%	Detección 7 días antes de signos clínicos
Kim et al. (2024)	Engorde	Audiovisual multimodal (CSD+POD+CPD)	Tos porcina (detección cerdo tosedor)	Precisión: 95.0%	Monitoreo 24/7 sin intervención humana
Pan et al. (2024)	Crecimiento	Deep neural + HMM (análisis acústico)	Reconocimiento sonido porcino	Accuracy: 93.2%	Clasificación multietiqueta vocalizaciones
Rohan et al. (2023)	Engorde	Deep learning + IMU + CV	Reconocimiento comportamiento	mAP: 87.4%	Fusión multimodal +12-18% vs unimodal
Psota et al. (2022)	Crecimiento	Visión artificial + tracking	Detección identidad y agresión	mAP: 91.2%	Detección temprana de riñas y lesiones
Liu et al. (2023)	Engorde	YOLO-v8 + bounding box rotado	Detección y orientación porcino	mAP: 93.6%	38.699 instancias etiquetadas; generalizable
Gómez-Verdejo et al. (2025)	Reproducción	IoT 3 capas + ML	BCS + peso vivo de reproductoras	Precisión: 89.3%	Sistema IoT integrado granja porcina
Tholen et al. (2026)	Matadero	Visión artificial industrial	Contaminación canal porcina	Precisión: 92.8%	Supera inspección humana en lesiones sutiles
Blagojevic et al. (2024)	Matadero	IA + inspección post-mortem	Lesiones bienestar en matadero	Sensibilidad: 88.6%	Retroalimentación productora vía RFID
Modzelewska-Kapitula (2022)	Matadero	Computer vision	Composición y clasificación canal	Revisión cualitativa	Síntesis aplicaciones industria cárnica
Wang et al. (2023)	Transición	3D depth imaging	Peso vivo + fenotipado morfológico	Error < 3.5 kg	Estimación no invasiva del peso de canal
Andonovic et al. (2024)	Crecimiento	NB-IoT + BioHarness	FC, Temperatura, actividad	RMSE: 0.41°C	Viabilidad NB-IoT en zonas rurales

Elaborado por: Los autores, 2026. BCS: Body Condition Score; FC: Frecuencia cardíaca; IMU: Unidad de medida inercial; mAP: Mean Average Precision.

Discusión

Los hallazgos de esta revisión sistemática confirman que el monitoreo inteligente multimodal de porcinos ha experimentado un avance tecnológico extraordinario entre 2021 y 2026, impulsado por la convergencia de tres vectores: (1) la maduración de los modelos de aprendizaje profundo para análisis de imagen y señal, (2) la proliferación de dispositivos IoT de bajo costo y bajo consumo energético, y (3) la disponibilidad de plataformas de computación en el borde capaces de ejecutar modelos complejos sin necesidad de conectividad permanente a la nube.

La predominancia de la visión artificial como modalidad principal (presente en el 71% de los estudios incluidos) refleja la madurez de esta tecnología y la densidad de información que proporciona por unidad de tiempo. Sin embargo, los sistemas exclusivamente visuales presentan limitaciones conocidas en condiciones de iluminación deficiente, oclusiones de animales y fondos complejos. Esta es la razón por la que la integración audiovisual —como la propuesta por Kim et al. (2024)— ha demostrado mejoras sustanciales en robustez, especialmente para la detección de enfermedades respiratorias donde el síntoma acústico (tos) precede a los signos visuales.

La evaluación de calidad metodológica mediante la Escala de Jadad reveló que el 80% de los estudios incluidos presentaron alta calidad metodológica (puntuación ≥ 3). No obstante, es importante destacar que la Escala de Jadad fue diseñada originalmente para ensayos clínicos aleatorios en medicina humana, y su aplicación a estudios de ingeniería y sistemas de monitoreo animal requiere una interpretación contextualizada. Los criterios de aleatorización y doble ciego, centrales en la escala, tienen una aplicabilidad diferenciada en estudios tecnológicos donde la variable de estudio es el desempeño de un algoritmo o

sistema. Este es un hallazgo metodológico relevante que sugiere la necesidad de escalas de evaluación específicamente diseñadas para la ganadería de precisión.

Una limitación importante identificada es la escasa representación de estudios realizados en América Latina y regiones de ingresos medios-bajos, donde las condiciones de infraestructura tecnológica son distintas a las de los países desarrollados que dominan la producción científica en este campo. Los sistemas propuestos asumen frecuentemente condiciones de conectividad, hardware y capacidad técnica del operario que pueden no estar disponibles en granjas porcinas de pequeña y mediana escala en países como Ecuador, Perú, Colombia o México. El desarrollo de soluciones tecnológicamente accesibles, económicamente viables y culturalmente pertinentes para estos contextos es una brecha crítica de investigación.

La integración de los sistemas de monitoreo a lo largo del ciclo productivo completo —desde el nacimiento hasta el sacrificio— es el desafío de integración más ambicioso, pero también el de mayor impacto potencial. Los sistemas de trazabilidad RFID constituyen el hilo conductor que permite vincular los datos de monitoreo de cada etapa en un historial individual del animal, cerrando el ciclo de información. Sin embargo, muy pocos estudios han abordado esta integración longitudinal de forma explícita y rigurosa; la mayoría se concentran en una etapa o modalidad específica.

Conclusiones

Los sistemas de monitoreo inteligente multimodal representan el enfoque más eficaz para el seguimiento integral del ciclo productivo porcino, superando consistentemente a los sistemas unimodales en precisión, robustez y capacidad de detección temprana de eventos críticos.

La visión artificial basada en arquitecturas YOLO-v8 y modelos transformer es la tecnología dominante para el monitoreo de comportamiento y detección de eventos en todas las etapas del ciclo productivo, con métricas de precisión que superan el 90% en condiciones controladas.

El análisis acústico mediante IA ha demostrado ser un complemento indispensable de la visión artificial para la detección temprana de enfermedades respiratorias, con capacidad de anticipación diagnóstica de hasta 7 días respecto a los métodos clínicos convencionales.

La computación en el borde (edge computing) y los protocolos IoT de baja potencia (NB-IoT, LoRaWAN) son habilitadores tecnológicos críticos para la implementación de sistemas de monitoreo en entornos de granja real con conectividad limitada.

La evaluación de calidad metodológica mediante Escala de Jadad evidenció alta calidad en el 80% de los estudios, aunque se requiere el desarrollo de herramientas evaluativas específicamente adaptadas a estudios de ingeniería y ganadería de precisión.

Existen brechas significativas en la investigación sobre sistemas integrales que cubran el ciclo completo desde el nacimiento hasta el sacrificio, en la estandarización de protocolos de evaluación y en el desarrollo de soluciones adaptadas a sistemas productivos de pequeña y mediana escala en países de ingresos medios.

Referencias bibliográficas

- Andonovic, I., et al. (2024). Development of a Cloud-Based IoT System for Livestock Health Monitoring Using AWS and Python. *bioRxiv*. <https://doi.org/10.1101/2024.06.08.598087>
- Berckmans, D. (2014). Precision livestock farming technologies for welfare management in intensive livestock systems. *Revue Scientifique et Technique*, 33(1), 189–196. <https://doi.org/10.20506/rst.33.1.2273>
- Blagojevic, B., et al. (2024). Post-mortem meat inspection systems supported by AI for welfare indicator detection. *Frontiers in Animal Science*, 5. <https://doi.org/10.3389/fanim.2024.1383371>
- Chen, C., Zhu, W., & Norton, T. (2021). Behaviour recognition of pigs and cattle: Journey from computer vision to deep learning. *Computers and Electronics in Agriculture*, 184, 106143. <https://doi.org/10.1016/j.compag.2021.106143>
- Gauthier, R., Largouët, C., & Dourmad, J. Y. (2022). Prediction of litter performance in lactating sows using machine learning, for precision livestock farming. *Computers and Electronics in Agriculture*, 196, 106876. <https://doi.org/10.1016/j.compag.2022.106876>
- Gómez-Verdejo, A., et al. (2025). IoT System for Monitoring Breeding Sows in Swine Farms. *IEEE Internet of Things Journal*. <https://doi.org/10.1109/JIOT.2025.3526358>
- Ho, C., et al. (2021). Computer vision-based framework for monitoring the lactation frequency of sows. *Computers and Electronics in Agriculture*, 188, 106370.
- Jadad, A. R., Moore, R. A., Carroll, D., et al. (1996). Assessing the quality of reports of randomized clinical trials: Is blinding necessary? *Controlled Clinical Trials*, 17(1), 1–12.
- Jeong, K., et al. (2024). A monitoring system for cattle behavior detection using YOLO-v8 in IoT environments. 2024 IEEE International Conference on Consumer Electronics (ICCE). <https://doi.org/10.1109/ICCE59016.2024.10444145>
- Kim, S., et al. (2024). Novel Method for Detecting Coughing Pigs with Audio-Visual Multimodality for Smart Agriculture Monitoring. *PMC*. <https://pmc.ncbi.nlm.nih.gov/articles/PMC11598093/>
- Lagua, E. B., Mun, H. S., Ampode, K. M. B., Chem, V., Kim, Y. H., & Yang, C. J. (2023). Artificial Intelligence for Automatic Monitoring of Respiratory Health Conditions in Smart Swine Farming. *Animals*, 13(11), 1860. <https://doi.org/10.3390/ani13111860>
- Liu, S., et al. (2023). Pig detection and orientation using rotated bounding boxes. *Computers and Electronics in Agriculture*, 207, 107743. <https://doi.org/10.1016/j.compag.2023.107743>
-

- Modzelewska-Kapitula, M., & Jun, S. (2022). The application of computer vision systems in meat science and industry – a review. *Meat Science*, 192, 108904. <https://doi.org/10.1016/j.meatsci.2022.108904>
- Moreno, B., et al. (2018). Revisión sistemática: definición y conceptos metodológicos. *Revista Española de Documentación Científica*, 41(4), e218.
- OCDE/FAO. (2023). *OECD-FAO Agricultural Outlook 2023–2032*. OECD Publishing. <https://doi.org/10.1787/08801ab7-en>
- Page, M. J., McKenzie, J. E., Bossuyt, P. M., et al. (2021). The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. *BMJ*, 372, n71. <https://doi.org/10.1136/bmj.n71>
- Pan, W., Li, H., Zhou, X., Jiao, J., Zhu, C., & Zhang, Q. (2024). Research on Pig Sound Recognition Based on Deep Neural Network and Hidden Markov Models. *Sensors*, 24(4), 1269. <https://doi.org/10.3390/s24041269>
- Psota, E. T., et al. (2022). Multi-pig part detection and association with a fully-convolutional network. *Sensors*, 22, 4843.
- Rohan, A., Rafaq, M. S., Hasan, M. J., Asghar, F., Bashir, A. K., & Dottorini, T. (2023). Application of deep learning for livestock behaviour recognition: A systematic literature review. *arXiv:2310.13483*. <https://arxiv.org/pdf/2310.13483>
- Sandberg, E., et al. (2023). Automated assessment system for animal welfare indicator lesions for pig carcasses during slaughter. *Meat Science*, 205, 109305.
- Tholen, E., et al. (2026). Detection of carcass contamination using video image analysis during industrial pig slaughter. *Frontiers in Food Science and Technology*. <https://doi.org/10.3389/frfst.2026.1698416>
- Tsai, Y.-J., Huang, Y.-C., Lin, E.-C., et al. (2024). Monitoring the lactation-related behaviors of sows and their piglets in farrowing crates using deep learning. *Frontiers in Animal Science*, 5. <https://doi.org/10.3389/fanim.2024.1431285>
- Tzanidakis, C., Tzamaloukas, O., Simitzis, P., & Panagakis, P. (2023). Precision Livestock Farming Applications (PLF) for Grazing Animals. *Agriculture*, 13(2), 288. <https://doi.org/10.3390/agriculture13020288>
- Wang, Y., et al. (2023). 3D depth imaging for pig weight estimation and morphological phenotyping. *Computers and Electronics in Agriculture*, 208, 107836.
- Wutke, M., Lensches, C., Hartmann, U., & Traulsen, I. (2024). Towards automatic farrowing monitoring—A Noisy Student approach for improving detection performance of newborn piglets. *PLOS ONE*. <https://doi.org/10.1371/journal.pone.0310818>
- Yin, L., Jiang, S., Ye, C., et al. (2024). Recognizing sow parturition using lightweight model with edge computing. *Transactions of the Chinese Society of Agricultural Engineering*, 40(17), 205–215. <https://doi.org/10.11975/j.issn.1002-6819.202404173>
-

Zhang, M., et al. (2022). Wearable Internet of Things enabled precision livestock farming in smart farms: A review of technical solutions for precise perception, biocompatibility, and sustainability monitoring. *Journal of Cleaner Production*, 312, 127712. <https://doi.org/10.1016/j.jclepro.2021.127712>