



Universidad Nacional Mayor de San Marcos

Universidad del Perú. Decana de América

Dirección General de Estudios de Posgrado

Facultad de Ingeniería de Sistemas e Informática

Unidad de Posgrado

**Predicción del estrés por frío del ganado lechero
utilizando técnicas de aprendizaje automático**

TESIS

Para optar el Grado Académico de Doctor en Ingeniería de
Sistemas e Informática

AUTOR

Samuel Benjamín LASCANO RIVERA

ASESOR

Dr. Luis Antonio RIVERA ESCRIBA

Lima, Perú

2026



Reconocimiento - No Comercial - Compartir Igual - Sin restricciones adicionales

<https://creativecommons.org/licenses/by-nc-sa/4.0/>

Usted puede distribuir, remezclar, retocar, y crear a partir del documento original de modo no comercial, siempre y cuando se dé crédito al autor del documento y se licencien las nuevas creaciones bajo las mismas condiciones. No se permite aplicar términos legales o medidas tecnológicas que restrinjan legalmente a otros a hacer cualquier cosa que permita esta licencia.


Referencia bibliográfica

Lascano, S. (2026). *Predicción del estrés por frío del ganado lechero utilizando técnicas de aprendizaje automático*. [Tesis de doctorado, Universidad Nacional Mayor de San Marcos, Facultad de Ingeniería de Sistemas e Informática, Unidad de Posgrado]. Repositorio institucional Cybertesis UNMSM.

Metadatos complementarios

Datos de autor	
Nombres y apellidos	Samuel Benjamin Lascano Rivera
Tipo de documento de identidad	Cédula de identidad
Número de documento de identidad	EC / 1802590222
URL de ORCID	https://orcid.org/0000-0001-5967-6441
Datos de asesor	
Nombres y apellidos	Dr. Luis Antonio Rivera Escriba
Tipo de documento de identidad	DNI
Número de documento de identidad	06445707
URL de ORCID	https://orcid.org/0000-0002-5029-2561
Datos del jurado	
Presidente del jurado	
Nombres y apellidos	Dr. Ciro Rodríguez Rodríguez
Tipo de documento	DNI
Número de documento de identidad	06020241
Miembro del jurado 1	
Nombres y apellidos	Dr. Ivan Carlo Petrlik Azabache
Tipo de documento	DNI
Número de documento de identidad	10140461
Miembro del jurado 2	
Nombres y apellidos	Dr. Pedro Martin Lezama Gonzales
Tipo de documento	DNI
Número de documento de identidad	09656793
Datos de investigación	

Línea de investigación	Área 3 — Ciencia de Datos 3.1 Machine Learning
Grupo de investigación	Red Internacional de Investigación y Observatorio de Tecnologías Emergentes - RIIOTE
Agencia de financiamiento	Ecuador. Universidad Politécnica Estatal del Carchi . Dirección Investigación. Proyecto 021-CSUP-2025.
Ubicación geográfica de la investigación	País: Ecuador Provincia: Carchi Canton: Huaca Centro poblado: Centro Experimental San Francisco (UPEC) Calle: costado de la Carretera Panamericana (vía Tulcán - Huaca) Latitud: 00°38'29" N Longitud: 77°43'35" O.
Año o rango de años en que se realizó la investigación	Marzo 2024 - diciembre 2025
URL de disciplinas OCDE	Informática y Ciencias de la Información https://purl.org/pe-repo/ocde/ford#1.02.0 Ciencias de la información https://purl.org/pe-repo/ocde/ford#1.02.02



UNIVERSIDAD NACIONAL MAYOR DE SAN MARCOS
Universidad del Perú. Decana de América
Facultad de Ingeniería de Sistemas e Informática
Vicedecanato de Investigación y Posgrado
Unidad de Posgrado

**ACTA DE SUSTENTACIÓN DE TESIS PARA OPTAR EL GRADO ACADÉMICO DE
DOCTOR EN INGENIERÍA DE SISTEMAS E INFORMÁTICA**

A los veintiocho (28) días del mes de enero de 2026, siendo las 12:00 pm., se reunieron en el Auditorio Alfredo Celso Alva Bravo, el Jurado de Tesis conformado por los siguientes docentes:

Dr. *Ciro Rodriguez Rodriguez* (Presidente)
Dr. *Ivan Carlo Petrlik Azabache* (Miembro)
Dr. *Pedro Martin Lezama Gonzales* (Miembro)
Dr. *Luis Antonio Rivera Escriba* (Miembro Asesor)

Se inició la Sustentación invitando al candidato a Doctor **SAMUEL BENJAMÍN LASCANO RIVERA**, para que realice la exposición oral de la tesis para optar el Grado Académico de Doctor en Ingeniería de Sistemas e Informática, siendo la Tesis intitulada:

“PREDICCIÓN DEL ESTRÉS POR FRÍO DEL GANADO LECHERO UTILIZANDO TÉCNICAS DE APRENDIZAJE AUTOMÁTICO”.


Concluida la exposición, los miembros del Jurado de Tesis procedieron a formular sus preguntas que fueron absueltas por el graduando; acto seguido se procedió a la evaluación correspondiente, habiendo obtenido la siguiente calificación:


Diecinueve (19) *Excelente*

Por tanto, el presidente del Jurado, de acuerdo con el Reglamento General de Estudios de Posgrado, otorga al Magíster **SAMUEL BENJAMÍN LASCANO RIVERA** el Grado Académico de Doctor en Ingeniería de Sistemas e Informática.

Siendo las *12:15* horas, el presidente del Jurado de Tesis, da por concluido el acto académico de Sustentación de Tesis.


Dr. *Ciro Rodriguez Rodriguez*
(Presidente)


Dr. *Ivan Carlo Petrlik Azabache*
(Miembro)


Dr. *Pedro Martin Lezama Gonzales*
(Miembro)


Dr. *Luis Antonio Rivera Escriba*
(Miembro Asesor)



Anexo 1

CERTIFICADO DE SIMILITUD

Yo, Luis Antonio Rivera Escriba en mi condición de asesor acreditado mediante Dictamen de la UPG N° 000228-2023-UPG-VDIP-FISI/UNMSM de la tesis, cuyo título es **PREDICCIÓN DEL ESTRÉS POR FRÍO DEL GANADO LECHERO UTILIZANDO TÉCNICAS DE APRENDIZAJE AUTOMÁTICO**, presentado por el magíster **SAMUEL BENJAMÍN LASCANO RIVERA** para optar el grado académico de **Doctor en Ingeniería de Sistemas e Informática**, CERTIFICO que se ha cumplido con lo establecido en la Directiva de Originalidad y de Similitud de Trabajos Académicos, de Investigación y Producción Intelectual. Según la revisión, análisis y evaluación mediante la plataforma PIDS, el documento evaluado cuenta con el **2%** de similitud, nivel PERMITIDO para continuar con los trámites correspondientes y para su **publicación en el repositorio institucional**.

Se emite el presente certificado en cumplimiento de lo establecido en las normas vigentes, como uno de los requisitos para la obtención del grado académico de Doctor en Ingeniería de Sistemas e Informática.

Lima, 15 de junio de 2026

Firma del Asesor:

Nombres y Apellidos del asesor: Luis Antonio Rivera Escriba

DNI: 06445707

* Según corresponda: bachiller, magíster, doctor; título profesional o título de segunda especialidad

La vigencia del presente certificado corresponde a un período de noventa (90) días desde la fecha de su emisión; siempre que no haya observaciones en el texto durante el proceso de revisión por el jurado informante o surja alguna contingencia.

DEDICATORIA

Dedico este trabajo, en primer lugar, al Creador, Dios Jehová. A la memoria de mi padre, Pastor Miguel Lascano Silva, cuya integridad y esfuerzo sembraron en mí el deseo de superación; y a mi madre, Meri Margarita Rivera Acurio, por la vida, el apoyo y la constancia.

A mis hijos, **Francisco** y **Saraí**, que me brindaron parte de su tiempo, su cariño y su alegría para que pudiera culminar este trabajo; son mi fuente inagotable de motivación.

Extiendo esta dedicatoria a toda mi familia, en especial a mis hermanas, por su apoyo, compañía y respaldo permanente.

¡Los amo!

AGRADECIMIENTOS

Desde lo profundo de mi corazón, agradezco a Dios por su presencia constante en las buenas y en las malas; gracias por la vida y por permitirme completar este objetivo.

Extiendo mi gratitud a toda mi familia por su apoyo y comprensión en los momentos en que no pude estar para ustedes. A mis amigos y colegas Omar Quimbita y Yasmany Fernández, con quienes he compartido este arduo caminar, gracias por su compañerismo.

A mi querida institución, la Universidad Politécnica Estatal del Carchi (UPEC), por el apoyo económico y las facilidades brindadas para culminar estos estudios doctorales. Agradezco también a mis amigos, el PhD. Luis Balarezo y el PhD. Hernán Benavides, por sus observaciones y consejos.

A la Universidad Nacional Mayor de San Marcos, en especial a la Facultad de Ingeniería de Sistemas e Informática, a sus autoridades, docentes y personal administrativo, mi reconocimiento por el excelente trabajo realizado a lo largo de este proceso doctoral.

Un significativo y eterno agradecimiento a mi asesor, el Dr. Luis Rivera Escriba, Ph.D., cuya guía y dedicación hicieron posible esta meta.

Finalmente, gracias a todos quienes, de alguna manera, me animaron a alcanzar este sueño.

ÍNDICE GENERAL

CAPÍTULO I. INTRODUCCIÓN	15
Situación problemática.....	16
Formulación del problema	17
1.2.1. Problema general	18
1.2.2. Problemas específicos	19
1.3. Hipótesis.....	21
1.3.1. Hipótesis general.....	22
1.3.2. Hipótesis específicas.	22
1.4. Identificación de Variables	25
1.5. Objetivos de la Investigación.....	26
1.5.1. Objetivo General	26
1.5.2. Objetivos Específicos	26
1.6. Metodología utilizada	27
1.6.1. DSRM	29
1.6.2. Matriz de consistencia	32
1.6.3. Operacionalización de Variables	35
1.7. Justificación	37
1.8. Limitaciones de estudio	38
1.9. Organización de documento	38
CAPÍTULO II. MARCO TEORICO	42
2.1 Marco epistemológico de la investigación	43
2.2 Antecedentes de Investigación	45
2.3 Bienestar animal	50
2.3.1. Técnicas biométricas para la evaluación de la salud y el bienestar del ganado	52
2.3.2. Constantes fisiológicas en bovinos.	56
2.3.3. Tipos de estrés en bovinos	57
2.3.4. Índices de estrés	59
2.3.5. Fisiología del estrés por frío en bovinos.....	60
2.3.6. Ciclo circadiano	62
2.3.7. Monitoreo y control animal	62
2.4 Ganadería de precisión	65
2.5 Técnicas de Inteligencia artificial.....	65
2.5.1. Metodología de análisis de la data.....	67
2.5.2. Minería de datos.....	68
2.5.3. Reconocimiento de patrones	69
2.5.4. Aprendizaje automático	70
2.5.5. Algoritmos de aprendizaje automático	72
2.6 Marco Ético	76
2.7 Síntesis del Capítulo II.....	76

CAPÍTULO III. INSTRUMENTACIÓN Y MÉTRICAS PARA MONITOREO DE ESTRÉS POR FRÍO EN GANADO LECHERO

.....	77
3.1. Fundamentos de la Ganadería de Precisión para el Monitoreo del Bienestar Animal.....	77
3.1.1. Transición Hacia el Manejo Predictivo	79
3.1.2. Contribuciones de Sensores Inteligentes y Automatización ..	79
3.1.3. Innovaciones en Análisis No Invasivo.....	79
3.2. Estado del Arte en Sensores para Ganadería de Precisión	80
3.2.1 Clasificación de Sensores para Bovinos: Avances Actuales	81
3.2.2 Descripción de Sensores Comerciales y de Investigación. .	82
3.3. Análisis Comparativo: Sensores Invasivos vs. No Invasivos	83
3.3.1. Comparación Directa	85
3.4. Métricas y Procesamiento de Datos de Sensores para la Detección de Estrés	86
3.4.1. Métricas de actividad general y Presupuesto Temporal	86
3.4.2. Análisis de Episodios, Duración, Frecuencia y Criterios de Delimitación	89
3.4.3. Nivel de Actividad Global y Técnicas de Cálculo Factorial.	90
3.4.4. Métricas de Variabilidad e Irregularidad Conductual	91
3.4.5. Índices de Irregularidad Alimentaria (Entropía, Coeficiente de Variación)	93
3.4.6. Interpretación Biológica y Relación con la Resiliencia Animal	95
3.4.7. Análisis de Ritmicidad Circadiana.	96
3.4.8. Autocorrelación y Evaluación de Estabilidad de Patrones de 24h	99
3.5. Síntesis del Capítulo.....	100

CAPÍTULO IV. TÉCNICAS DE APRENDIZAJE AUTOMÁTICO EN GANADERÍA DE PRECISIÓN

.....	102
4.1. Aplicaciones Empíricas de Algoritmos en Estudios Recientes	103
4.1.1. Análisis Comparativo del Desempeño de Algoritmos	106
4.1.2. Revisión Sistemática de Estudios de IA y Sensores.....	108
4.1.3. Identificación de Tendencias y Brechas en la Literatura..	108
4.2. Integración Tecnológica y Tendencias Futuras	109
4.2.1. Fusión Multimodal de Datos para Mejorar la Robustez de los Modelos Predictivos.....	109
4.3. Síntesis del Capítulo IV.....	112

CAPÍTULO V. ARQUITECTURA DEL MODELO PREDICTIVO..

5.1. Visión general y trazabilidad con hipótesis.....	114
5.2. Módulo de adquisición.....	116
5.3. Módulo de preprocesamiento	119
A) Filtrado	119

B) Normalización y estandarización	120
C) Detección y tratamiento de valores atípicos	121
D) Alineación de frecuencias	121
E) Esquemas de partición por vaca.....	122
F) Salida	122
5.4. Módulo de ventaneo temporal y análisis de Frecuencias	123
5.4.1. Diseño de ventanas y solapamiento	123
5.4.2.FFT/STFT y control de fuga espectral.....	124
5.4.3. Detección de la frecuencia circadiana dominante	125
5.4.4. Reconstrucción temporal circadiano filtrado	125
5.4.5. Bandas de interés y salidas del módulo.....	126
5.4.6. Distancia día–noche (DRMS) y umbrales.....	128
5.4.7. Extracción de rasgos circadianos	129
5.4.8. Parámetros recomendados	130
5.5. Módulo de análisis de características.....	131
5.6. Módulo de etiquetado y baselines	132
5.6.1. Calibración y umbrales operativos	134
5.7. Módulo de modelado predictivo.....	134
5.7.1.Modelo principal: clasificador LSTM	135
5.7.2. Modelo baseline y comparación	135
5.8. Módulo de validación científica.....	136
5.8.1.Marco de referencia clínico-fisiológico.	137
5.8.2. Métricas principales.....	137
5.8.3. Pruebas estadísticas.	137
5.8.4. Validaciones específicas ligadas a la tabla de criterios	138
5.8.5. Contribución a las hipótesis.....	140
5.9. Síntesis de la arquitectura y criterios de éxito	140
5.9.1. Flujo de datos y componentes clave	141

CAPÍTULO VI. EVALUACIÓN Y RESULTADOS DEL MODELO PREDICTIVO 142

6.1. Conjunto de datos y unidad de análisis.....	142
6.1.1. Etiquetado de Referencia	143
6.1.2. Modelos evaluados.....	144
6.1.3. Reproducibilidad (hardware/software y métricas).....	146
6.2. Clasificación	147
6.2.1. Alerta temprana	149
6.2.2. Calibración	150
6.2.3. Acuerdo con observación clínica	150
6.2.4. Eficiencia (tiempo y memoria)	151
6.3. Resultados principales.....	151
6.3.1. Curvas ROC y PR; matrices de confusión por nivel (Normal/Mild/High).	154
6.3.2. Horizonte de anticipación.....	159
6.3.3. Resultados por vaca/temporada: variabilidad entre	

individuos y estacionalidad.	160
6.4. Ablaciones y robustez	162
6.4.1. Datos faltantes y ruido	163
6.4.2 Generalización (leave-one-cow-out y forward-chaining).	164
6.5. Eficiencia computacional.....	164
6.5.1. Escalabilidad estimada para N vacas	166
6.6. Análisis de errores (falsos positivos y falsos negativos)	169
6.6.1 Desempeño por característica: importancia/SHAP y lectura fisiológica.....	170
6.7. Validación cruzada con Vet y SFT.....	173
6.7.1 Concordancia diaria con clínica (κ , % acuerdo)	173
6.7.2 Relación con Sensación Térmica por Frío.....	174
6.7.3 Indicadores de hato: proporción diaria de vacas con estrés y correlato con eventos climáticos	174
6.8. Limitaciones y Mitigaciones.	175
6.8.1. Validez interna.....	176
6.8.2. Validez externa	177
6.8.3. Validez de constructo	178
6.8.4. Resultados de Biomarcadores (ACTH y NEFA)	179
6.9. Resultados de la validación por juicio de expertos	181
6.10. Síntesis del Capítulo VI.....	182
CAPÍTULO VII: CONCLUSIONES	184
CAPÍTULO VIII: RECOMENDACIONES	188
Contribuciones con publicaciones	193
Referencias bibliográficas	196
Anexos	205
Anexo 1 Manual de usuario Cow System	205
Anexo 2 Instrumento de Validación por Juicio de Expertos	217
Anexo 3 Resultados de exámenes de sangre	222

ÍNDICE DE TABLAS

Tabla 1 Correspondencia entre fases DSRM y capítulos de la tesis	30
Tabla 2 Matriz de consistencia	32
Tabla 3 Supuestos epistemológicos y sus implicaciones metodológicas	45
Tabla 4 Síntesis comparativa de estudios relevantes sobre predicción de estrés en bovinos.	50
Tabla 5 Métodos para medir temperatura corporal en bovinos.	53
Tabla 6 Tipos de estrés presentes en bovinos	58
Tabla 7 Comparativa de algoritmos de ML.	73
Tabla 8 Tipos de sensores usados en ganadería de precisión	80
Tabla 9 Sensores de Comportamiento para ganado Bovino.	81
Tabla 10 Sensores Invasivos en ganadería de precisión	83
Tabla 11 Sensores no invasivos.	84
Tabla 12 Comparación de sensores bovinos invasivos y no invasivos.	86
Tabla 13 Revisión Sistemática de Estudios Enfocados en Inteligencia Artificial y Sensores Inteligentes Aplicados en Ganadería de Precisión	104
Tabla 14 Resumen comparativo de Desempeño de algoritmos	107
Tabla 15 Sintética de Estudios de IA y Sensores	108
Tabla 16 Mapa de trazabilidad módulo $\leftrightarrow$ variables $\leftrightarrow$ métricas $\leftrightarrow$ hipótesis.	116
Tabla 17 Checklist de preprocesamiento y parámetros	122
Tabla 18 Parámetros recomendados para establecer rasgos circadianos.	130
Tabla 19 Criterios operativos para niveles de estrés	139
Tabla 20 Resumen del dataset	143
Tabla 21 Modelos e hiperparámetros	145
Tabla 22 Resumen de clasificación(conjunto de prueba, cow-day)	147
Tabla 23 Desempeño global (conjunto de prueba; cow-day).	151

Tabla 24 AUC de precisión-recuperación específica de clase y métricas de discriminación adicionales (OvR).	157
Tabla 25 Resultados por vaca (conjunto de prueba).	160
Tabla 26 Efecto de FFT en el desempeño (resumen).	163
Tabla 27 Mediciones de Hardware	165
Tabla 28 Guía rápida de dimensionamiento (operación 24/7).	168
Tabla 29 Tipos de error y acciones correctivas.	170
Tabla 30 Ranking de variables más importantes según SHAP (LSTM + rasgos circadianos) — Interpretación fisiológica	171
Tabla 31 Indicadores del constructo	179
Tabla 32 Resumen por ítem (validación de expertos).	181

ÍNDICE DE FIGURAS

Figura 1 Modelo de proceso DSRM (López-Villanueva et al., 2025).	28
Figura 2 Signos visibles y consecuencias del estrés.	56
Figura 3 Índice de temperatura humedad (ITH).	60
Figura 4 Sensación térmica en frío.	60
Figura 5 Representación esquemática de las condiciones ambientales críticas para la supervivencia animal.	62
Figura 6 Nedap CowControl™	63
Figura 7 Esquema conceptual de ganadería de precisión.	78
Figura 8 Sensores SparkFun 9DoF Razor IMU M0	82
Figura 9 Ritmos circadianos a partir de los valores diarios (Descanso - Rumia y Comida)	97
Figura 10 Sensores Usados en Ganadería de Precisión con Bovinos. (Lascano Rivera et al., 2025)	106
Figura 11 Arquitectura del modelo	115
Figura 12 Dashboard de collares Nedap	118
Figura 13 Ejemplo de filtrado y suavizado (señal simulada para ilustración).	120
Figura 14 Efecto de la estandarización (z-score) sobre la distribución.	121
Figura 15 Ejemplo de ciclos A y B en una serie temporal de 36 h. Línea continua: nivel de actividad original. Líneas discontinuas: ciclos reconstruidos tras aplicar la Transformada Rápida de Fourier (FFT).	124
Figura 16 Pseudocódigo (STFT 36 h, hop 1 h; muestreo 1 h)	130
Figura 17 Ejemplo de RMSSD por clase (Normal vs. Alto estrés)	132
Figura 18 Curva ROC (macro y one-vs-rest).	154
Figura 19 Curva ROC (OvR y one-vs-rest).	155
Figura 20 Curva PR (macro y one-vs-rest).	155
Figura 21 Curva PR (OvR y one-vs-rest).	156

Figura 22 Matrices de confusión para LSTM, RF y SFT -umbral (3×3).	157
Figura 23 Matriz de confusión (RF)	158
Figura 24 Matriz de confusión (THI - umbral).	159
Figura 25 Distribución del adelanto (violin/box) por vaca y temporada.	160
Figura 26 Desempeño por vaca (F1-macro y F1 por clase).	161
Figura 27 (A) Resultados Vaca Joya	180
Figura 27 (B) Resultados Vaca Joya	181

GLOSARIO DE TÉRMINOS

ACC.	Accuracy
ANN	Artificial Neural Network
CNN	Convolutional Neural Network
DNN	Deep Neural Network
F1-macro	Macro-averaged F1 Score
F1-weighted	Weighted F1 Score
FFT	Fast Fourier Transform
HRV	Heart Rate Variability
IC95%	95% Confidence Interval
KNN	K-Nearest Neighbors
LSTM	Long Short-Term Memory
Macro-Prec	Macro-averaged Precision
Macro-Recall	Macro-averaged Recall
OvR	One-vs-Rest
PLF	Precision Livestock Farming
PR-AUC	Precision-Recall – Area Under Curve
RF	Random Forest
RNN	Recurrent Neural Network
ROC-AUC	Receiver Operating Characteristic – Area Under
SVM	Support Vector Machine
THI	Temperature-Humidity Index
XGBOOST	Extreme Gradient Boosting.
STFT	Transformada de Fourier de Tiempo Corto
SFT	Sensación Térmica por Frío (Wind Chill)
LOCO	Leave-One-Cow-Out; esquema de validación por grupos donde se deja una vaca fuera para validación/prueba y se entrena con las restantes

RESUMEN

El objetivo de este estudio fue detectar de forma temprana el estrés por frío en vacas Holstein usando datos de collares inteligentes y modelado temporal. Se monitorearon 10 vacas durante un año (unidad de análisis: cow-day), generando 3 650 observaciones diarias y 87 600 registros horarios de actividad (comer, rumiar, descansar, otros). La señal conductual se preprocesó con un filtro circadiano y se extrajeron características mediante STFT (ventanas internas de 36 h y salto de 1 h); estas características se agregaron a paso diario para el entrenamiento. El etiquetado operativo (*silver standard*) combinó umbrales de distancia circadiana aprendidos en periodos estables con verificación clínica 2×/día y contexto térmico (THI). Se comparó un LSTM secuencial con baselines (por ejemplo, THI y modelos clásicos). El modelo LSTM mostró desempeño consistente para clasificación diaria de Normal/Leve/Alto, con métricas representativas de Precisión $\approx 82\text{--}84\%$, F1-macro $\approx 0,80$ y ROC-AUC $\approx 0,85\text{--}0,88$, superando a los baselines. En análisis de alerta temprana, el sistema anticipó una fracción relevante de eventos con ≥ 60 min de antelación, lo que permite acciones preventivas en el hato (refugio, manejo). A nivel de hato, el indicador diario de proporción de vacas con estrés se asoció con episodios de frío. Limitaciones: tamaño muestral reducido (10 vacas), una raza y un solo sitio. Para evitar circularidad, la etiqueta operativa (*silver standard*) se definió a partir de desviaciones circadianas consistentes en las señales de comportamiento y verificación clínica in situ. Los resultados apoyan la viabilidad de un monitoreo continuo de bienestar basado en collares y aprendizaje profundo, y justifican validaciones externas multicentro con biomarcadores fisiológicos y mayor diversidad ambiental.

Palabras clave: Machine Learning; estrés por frío; THI; collares inteligentes; series temporales; LSTM; monitoreo ganadero.

ABSTRACT

The aim of this study was to detect cold stress early in Holstein cows using smart collar data and temporal modeling. Ten cows were monitored for one year (unit of analysis: cow-day), generating 3,650 daily observations and 87,600 activity records (eating, ruminating, resting, other). The behavioral signal was preprocessed with a circadian filter, and features were extracted using STFT (36-h internal windows and 1-h jumps); these features were aggregated into a daily step for training. Operational labeling (silver standard) combined circadian distance thresholds learned over stable periods with 2×/day clinical verification and thermal context (THI). A sequential LSTM was compared with baselines (THI and classical models). The LSTM model showed consistent performance for daily Normal/Mild/High classification, with representative metrics of Accuracy $\approx 82\text{--}84\%$, F1-macro ≈ 0.80 , and ROC-AUC $\approx 0.85\text{--}0.88$, outperforming the baselines. In early warning analysis, the system anticipated a significant fraction of events ≥ 60 minutes in advance, allowing for preventive actions within the herd (shelter, management). At the herd level, the daily indicator of the proportion of cows under stress is associated with cold weather episodes. Limitations: small sample size (10 cows), one breed and one site. To avoid circularity, the operational label (silver standard) was defined from consistent circadian deviations in behavioral signals and on-site clinical verification; the results support the feasibility of continuous welfare monitoring based on collars and deep learning and justify external multicenter validations with physiological biomarkers and greater environmental diversity.

Keywords: Machine Learning; cold stress; THI; smart collars; time series; LSTM; livestock monitoring.

CAPÍTULO I. INTRODUCCIÓN

La inteligencia artificial (IA) ha experimentado un crecimiento exponencial en las últimas décadas, transformando radicalmente múltiples sectores industriales mediante la implementación de algoritmos avanzados de aprendizaje automático, procesamiento de datos masivos y sistemas de toma de decisiones automatizadas. En el contexto de la ganadería moderna, esta revolución tecnológica ha dado lugar al concepto de ganadería de precisión, un paradigma que integra dispositivos del Internet de las Cosas (IoT), sensores inteligentes y técnicas de análisis predictivo para optimizar la gestión del ganado (dos Reis et al., 2025; Kaur & Virk, 2025). Los sistemas de IA aplicados a la ganadería utilizan redes neuronales profundas, algoritmos de clasificación supervisada y técnicas de reconocimiento de patrones para procesar información en tiempo real proveniente de sensores de unidad de medida inercial (IMU *Inertial Measurement Unit*), que incorporan acelerómetros, giroscopios y magnetómetros para capturar movimientos tridimensionales y patrones comportamentales del ganado con alta precisión temporal y espacial.

La ganadería lechera enfrenta desafíos crecientes derivados del cambio climático, particularmente el estrés por frío en regiones de altura como el Carchi, Ecuador. Este fenómeno afecta negativamente la producción de leche, reduce la fertilidad y compromete el bienestar animal (Palma et al., 2025). Según el Fondo Ítalo Ecuatoriano para el Desarrollo Sostenible (2024), la provincia del Carchi produce 408,006 litros diarios de leche, representando la tercera economía lechera del país, con 142,458 cabezas de ganado distribuidas en 8,957 explotaciones.

Los métodos tradicionales de detección de estrés basados en observación visual y mediciones puntuales son subjetivos, discontinuos e ineficientes para prevención temprana (Odeón & Romera, 2017). En respuesta, la ganadería de precisión integra sensores inteligentes (Internet de las Cosas - IoT), técnicas de aprendizaje automático (Machine Learning - ML) y análisis predictivo para optimizar la gestión del ganado (dos Reis et al., 2025; Kaur & Virk, 2025).

En este sentido, la presente introducción busca ofrecer una panorámica general sobre la creciente importancia de la IA y el ML en la gestión de la producción bovina, con un enfoque particular en la evaluación no invasiva del estrés por frío. Se explorará la combinación de técnicas como el manejo de sensores inteligentes y el aprendizaje de máquina, enmarcadas en metodologías de análisis de datos robustas, y como estas pueden contribuir a mejorar el bienestar animal y la productividad en este sector crucial. La comprensión de estos conceptos y su aplicación práctica representa un paso fundamental hacia una producción bovina más eficiente, sostenible y respetuosa con el bienestar animal (Islam et al., 2020).

1.1 Situación problemática

El estrés en bovinos lecheros representa un desafío crítico para la producción ganadera moderna (Odeón, 2020), ya que afecta negativamente el bienestar animal y compromete directamente el rendimiento productivo y reproductivo del hato. Factores como bajas temperaturas, viento y humedad, manejo inadecuado, enfermedades, cambios en la alimentación o condiciones de alojamiento generan respuestas fisiológicas y conductuales que se traducen en disminución de la producción de leche, reducción de la ingesta y rumia, menor fertilidad, mayor susceptibilidad a enfermedades y alteraciones en el comportamiento (Palma et al., 2025). Estos impactos no solo deterioran la calidad de vida de los animales, sino que también reducen la rentabilidad y sostenibilidad económica de las explotaciones lecheras (Odeón & Romera, 2017).

El estrés por frío en bovinos lecheros ocurre cuando la temperatura ambiental desciende por debajo del umbral de termoneutralidad (entre 5°C y 15°C según raza y adaptación), obligando al animal a incrementar su tasa metabólica para mantener la homeostasis térmica (Bickert, 2011). En la provincia del Carchi, localizada entre 2,800 y 3,200 msnm, las temperaturas nocturnas descienden frecuentemente a 2-6°C durante los meses de junio a septiembre, con episodios extremos hasta -2°C, esto según el Instituto Nacional de Meteorología e Hidrología del Ecuador (INAMHI, 2025).

La producción lechera se ve significativamente afectada por la exposición a temperaturas inferiores a 5°C durante más de seis horas, con una reducción estimada del 10 al 25% en el rendimiento (Kim et al., 2023). Este estrés por frío, cuando coincide con el período reproductivo, conlleva una disminución del 15 al 30% en la tasa de concepción (Ferreira et al., 2025), y genera un incremento del 40% en la incidencia de mastitis debido a la inmunodepresión, lo que se traduce en costos estimados entre 150 y 300 USD por vaca al año en pérdidas productivas y tratamientos veterinarios (Pacheco Liliana et al., 2021). Frente a este problema, los productores de la provincia de Carchi emplean predominantemente tres estrategias convencionales: la observación visual directa de signos clínicos, que solo permite identificar el estrés una vez establecido; mediciones puntuales de temperatura rectal, método que además de generar estrés adicional no captura las variaciones circadianas; y el cálculo manual de índices ambientales como el Cold Stress Index (CSI), que no considera la respuesta fisiológica individual del animal. Estas técnicas presentan deficiencias críticas, entre las que destacan su naturaleza reactiva, al intervenir solo después de producido el daño fisiológico; su discontinuidad, con ausencia de monitoreo durante el crítico período nocturno; y una alta variabilidad Inter observador, reflejada en un coeficiente de correlación intraclass (ICC) de 0.45-0.62 entre evaluadores (Marchesini et al., 2018).

1.1.1 Formulación del problema

El estrés en bovinos afecta negativamente el bienestar del animal y el rendimiento productivo. Este fenómeno puede generar disminución de la productividad, problemas de salud, reducción de la ingesta de alimento y de la rumia, menor fertilidad y

alteraciones en el comportamiento (Palma, 2023).

La dificultad radica en la identificación y cuantificación de los factores de estrés en el ganado lechero. Los métodos basados en la observación visual y mediciones puntuales son, laboriosos y no permiten una evaluación continua (Odeón & Romera, 2017).

Aunque la ganadería de precisión ha avanzado en la monitorización automática mediante collares, podómetros, acelerómetros y sistemas de visión, presenta limitaciones clave. En muchos casos, estos sistemas están diseñados para detectar eventos productivos concretos (por ejemplo, estro o caídas marcadas de producción), pero no están optimizados para identificar de forma temprana y específica estados de estrés subclínico (térmico, social o de manejo). Además, los algoritmos suelen basarse en umbrales genéricos definidos a nivel de rebaño, lo que reduce la sensibilidad para captar desviaciones sutiles respecto del patrón circadiano normal de cada vaca. A esto se suma que la mayoría de las soluciones funcionan como “cajas negras”, entregan alertas sin integrar explícitamente información fisiológica, ambiental y conductual en un marco clínico-fisiológico coherente, y presentan retos prácticos de calibración, calidad de datos, costos y falta de protocolos estandarizados de validación. En conjunto, estas limitaciones dificultan el uso de la ganadería de precisión como herramienta robusta para la detección temprana y la gestión integral del estrés en vacas lecheras.

1.2 Problema general

A pesar de la adopción de tecnologías de ganadería de precisión, los sistemas actuales de monitoreo del ganado lechero siguen basándose en umbrales fijos y genéricos de temperatura ambiental e índices térmicos, definidos a nivel de rebaño y con lógica principalmente reactiva. Al no incorporar de manera explícita la respuesta fisiológica y conductual individual (ritmos circadianos, rumiación, actividad, descanso) de cada vaca, estos sistemas de ganadería de precisión resultan insuficientes para la detección temprana y la intervención oportuna del estrés por frío en vacas lecheras, en este contexto se genera la pregunta del problema general: ¿Cómo diseñar e implementar

un sistema de ganadería de precisión que, integrando datos biométricos de collares inteligentes y variables micro climáticas, incorpore la respuesta fisiológica–conductual individual (ritmos circadianos de rumia, actividad y descanso) para detectar tempranamente y permitir la intervención oportuna ante el estrés por frío en vacas lecheras, superando el enfoque reactivo basado en umbrales fijos y genéricos?

1.2.1. Problemas específicos

En el contexto del problema general, se identifican los siguientes problemas específicos:

PE1. La Insuficiente precisión y capacidad predictiva de los métodos tradicionales frente a modelos de aprendizaje automático integrados con comportamiento circadiano y datos climáticos para la detección de estrés por frío en vacas lecheras, formula la interrogante: ¿Por qué los métodos tradicionales (p. ej., observación e índices basados en umbrales como SFT) presentan insuficiente precisión y capacidad predictiva para detectar el estrés por frío en vacas lecheras, y en qué medida un modelo de aprendizaje automático que integre comportamiento circadiano y datos climáticos supera estas deficiencias?.

La precisión de los modelos de aprendizaje automático para predecir el estrés por frío en vacas lecheras, utilizando datos biométricos y ambientales, es incierta debido a la variabilidad en la calidad y representatividad de los datos de entrenamiento. Factores como la heterogeneidad de las razas, las condiciones climáticas locales y las diferencias en los sistemas de producción dificultan la generalización de los modelos, lo que puede llevar a predicciones inexactas o inconsistentes. Además, la dependencia de sensores para recopilar datos en tiempo real introduce problemas como fallos técnicos, calibración inadecuada o costos de mantenimiento, que afectan la fiabilidad de los resultados en entornos reales de granja. En comparación, los métodos tradicionales, como el uso de índices de Sensación Térmica por Frío (SFT) o la observación manual, aunque menos precisos, presentan limitaciones bien conocidas, como su incapacidad para captar variaciones individuales o detectar el estrés por frío

de manera temprana (Arias & Mader, 2020). La incertidumbre en los modelos de ML radica en la falta de estudios a gran escala que validen su desempeño frente a estas técnicas tradicionales, especialmente en condiciones prácticas donde la variabilidad ambiental y biológica puede reducir significativamente la precisión de las predicciones, haciendo que su ventaja teórica no esté garantizada (Pedrosa et al., 2024).

PE2. Se desconoce la ventana temporal de alerta que el modelo propuesto puede proporcionar para episodios de estrés alto, así como su comparación estadística con el índice de Sensación Térmica por Frío en términos de tiempo promedio de anticipación y tasa de falsas alarmas, lo que representa una incertidumbre crítica para validar su utilidad práctica y superioridad frente al método de referencia ante esa situación se formula la interrogante: ¿Cuál es la ventana temporal de alerta (lead time) que el modelo propuesto puede proporcionar para episodios de estrés alto y, mediante comparación estadística, en qué medida supera al índice de Sensación Térmica por Frío (SFT) en el tiempo promedio de anticipación y en la tasa de falsas alarmas?

En el contexto del estrés por frío en ganado lechero, el sistema propuesto promete detectar y anticipar episodios para habilitar mitigación temprana. Sin embargo, persiste una brecha de evidencia: no se ha establecido, con un diseño comparativo pareado y pruebas estadísticas adecuadas, que dicho sistema supere a enfoques de referencia, ni que ofrezca mayor lead time útil para intervenir. La falta de una evaluación rigurosa, reproducible y ajustada por múltiples comparaciones limita la validez externa y la adopción operativa del modelo. En consecuencia, el sistema tendría que sostener que el proceso propuesto aporte una ventaja estadística y práctica sobre los baselines en condiciones reales en la finca.

PE3. Los Desafíos y ventajas en la adaptación y escalabilidad de sistemas de aprendizaje automático generan la pregunta: ¿Cuáles son los principales desafíos y ventajas para adaptar y escalar un sistema de aprendizaje automático para la detección de estrés por frío en vacas lecheras en distintos contextos productivos, considerando infraestructura, conectividad, costos, calidad de datos y capacitación del personal?.

La adaptación y escalabilidad de los sistemas de ML para el monitoreo del estrés por frío enfrentan desafíos significativos debido a los altos costos de infraestructura, como sensores, sistemas de conectividad y software, que resultan prohibitivos para granjas pequeñas o en regiones con recursos limitados (W Weck et al., 2020). Además, la falta de personal capacitado para operar, mantener y analizar los datos generados por estos sistemas complica su implementación, y la variabilidad en las condiciones de las granjas (clima, razas, tamaño) dificulta la creación de modelos universales, lo que puede llevar a un desempeño subóptimo o a la necesidad de costosos procesos de reentrenamiento.

En contraste, los métodos tradicionales, aunque menos precisos, son más accesibles y no requieren infraestructura tecnológica ni conocimientos especializados, lo que los hace más viables en contextos diversos. La incertidumbre sobre la escalabilidad del ML radica en la falta de estudios que evalúen su aplicabilidad en diferentes escalas de producción y entornos, así como en la ausencia de estándares para integrar estas tecnologías en sistemas agrícolas heterogéneos (García A, 2020). Esta brecha en el conocimiento limita la adopción generalizada de sistemas de ML, dejando sin resolver cómo superar las barreras técnicas y económicas frente a los métodos convencionales.

1.3. Hipótesis

Partiendo del principio de que la hipótesis es una alternativa justificada de solución al problema, con base en los trabajos previos analizados, es previsible conseguir resultados precisos usando técnicas de ML apropiada teniendo como informaciones obtenidas por los sensores, esta formulación prevé mejoras consistentes frente a

enfoques sustentados únicamente en umbrales ambientales, al disminuir falsas alarmas y elevar la sensibilidad para los casos críticos, manteniendo robustez ante variaciones entre animales. De este modo, se favorece la toma de decisiones preventiva, el bienestar y el desempeño lechero sin imponer requisitos tecnológicos restrictivos.

1.3.1. Hipótesis general

Se plantea que la combinación de técnicas de depuración y extracción de ritmos mediante FFT con modelos de Aprendizaje Automático aplicados a datos de sensores de ganadería de precisión permitirá construir umbrales dinámicos de estrés por frío más sensibles y específicos que los enfoques basados únicamente en umbrales ambientales fijos.

El sistema/artefacto propuesto, permite detección temprana y un desempeño superior al enfoque por umbral (SFT/THI), manteniendo utilidad operativa (alerta temprana) en campo.

En particular, al filtrar ruido y aislar la componente circadiana de rumiación, actividad, descanso y clima (FFT), y al modelar sobre estas series “limpias” la respuesta individual de cada vaca mediante algoritmos de ML apropiados, se espera: (i) reducir la tasa de falsas alarmas, (ii) aumentar la sensibilidad para detectar episodios críticos de estrés por frío, y (iii) mantener robustez frente a la variabilidad entre animales. De este modo, se favorece la toma de decisiones preventiva, el bienestar y el desempeño lechero, sin imponer requisitos tecnológicos restrictivos más allá de los sensores ya disponibles en sistemas de ganadería de precisión.

1.3.2. Hipótesis específicas.

Las hipótesis específicas que orientan el contraste empírico de la propuesta se plantean en base a los modelos de aprendizaje automático basados en datos biométricos y ambientales que mejoran la detección del estrés por frío en vacas lecheras (HE1). Así también, se evalúa si el sistema propuesto supera a los baselines tradicionales en

métricas de clasificación y capacidad de anticipación (HE2). Finalmente, se analiza la viabilidad de una implementación escalable de estos sistemas de monitoreo en diferentes contextos productivos, condicionada a la adaptación tecnológica como IoT, bigdata y la capacidad de infraestructura local (HE3).

HE1: Un modelo de aprendizaje automático que integra rasgos circadianos (rumia/actividad/descanso) y variables micro climáticas logra mayor precisión y capacidad predictiva que los métodos tradicionales basados en observación y/o índices por umbral (p. ej., SFT/THI-umbral) para detectar estrés por frío.

Los enfoques convencionales basados en observación visual directa y mediciones puntuales de indicadores fisiológicos son "subjetivos, discontinuos, intensivos en mano de obra y poco eficaces para identificar estados de estrés de forma oportuna y escalable" (Kaur & Virk, 2025c). Esta problemática se agudiza cuando se considera que el estrés por frío puede manifestarse de manera sutil y variable entre individuos, requiriendo un monitoreo continuo que capture patrones complejos de comportamiento y respuestas fisiológicas que escapan a la percepción humana tradicional.

Los modelos de aprendizaje automático, al procesar simultáneamente datos biométricos (temperatura corporal, frecuencia cardíaca, patrones de movimiento) y ambientales (temperatura, humedad, velocidad del viento) en tiempo real, ofrecen una capacidad superior para identificar correlaciones multidimensionales que preceden a las manifestaciones clínicas del estrés por frío (Arias & Mader, 2020). La integración de sensores IMU con acelerómetros, giroscopios y magnetómetros, combinada con algoritmos de reconocimiento de patrones y redes neuronales profundas, permite detectar cambios sutiles en el comportamiento y la fisiología animal antes de que se traduzcan en pérdidas productivas evidentes. Esta capacidad predictiva, respaldada por el procesamiento de grandes volúmenes de datos y la identificación automatizada de patrones térmicos mediante técnicas como la termografía infrarroja, representa un avance cualitativo significativo frente a los métodos tradicionales que dependen de evaluaciones retrospectivas y subjetivas del estado de estrés animal.

HE2: El sistema propuesto supera significativamente a los baselines en métricas evaluadas y logra un lead time promedio ≥ 60 minutos, reduciendo falsas alarmas y mejorando sensibilidad en High.

En el contexto de la predicción del estrés por frío en ganado lechero mediante técnicas de aprendizaje automático, es esencial contrastar el desempeño del sistema propuesto frente a baselines establecidos como el umbral de THI (Temperature-Humidity Index), Random Forest (RF) y Support Vector Machines (SVM). La hipótesis nula (H_0), de carácter neutral y conservador, postula que no existe diferencia significativa en el rendimiento entre el sistema propuesto y los métodos de referencia, en términos de métricas de clasificación como F1-macro, ROC-AUC y PR-AUC, así como en la capacidad de anticipación medida por lead time. Esta hipótesis asume que las ventajas teóricas del enfoque desarrollado no se traducen en mejoras estadísticamente relevantes, manteniendo equivalencias en la detección diaria de categorías de estrés (Normal, Leve, Alto) y en la generación de alertas tempranas, lo que limitaría la justificación para su adopción sobre enfoques más simples y tradicionales.

Por el contrario, la hipótesis alternativa (H_1) propone que el sistema propuesto supera significativamente a los baselines en las métricas evaluadas, alcanzando umbrales superiores como F1-macro >0.80 , ROC-AUC >0.85 y PR-AUC >0.75 , junto con un lead time promedio de al menos 60 minutos para anticipar eventos de estrés por frío. Esta hipótesis direccional se fundamenta en la capacidad del enfoque desarrollado para capturar dependencias temporales en series de datos de collares inteligentes (actividad, rumia, descanso), integrando contexto ambiental (índices de sensación térmica que combinan temperatura y viento), lo que permite una clasificación más precisa y alertas proactivas que habilitan intervenciones oportunas en el hato, reduciendo falsos positivos y mejorando la sensibilidad en clases desbalanceadas como Alto estrés, a diferencia de los baselines que dependen de umbrales estáticos o características no secuenciales.

HE3: La implementación escalable de sistemas de monitoreo basados en aprendizaje automático en diferentes entornos productivos es viable, siempre que se adapten

las estrategias tecnológicas y de capacitación a las condiciones locales.

La hipótesis sobre la viabilidad de implementación escalable de sistemas de monitoreo basados en aprendizaje automático encuentra sustento en la naturaleza modular de estas tecnologías y la tendencia hacia la democratización del acceso a herramientas digitales en el sector agropecuario. Aunque existen desafíos relacionados con "los altos costos de infraestructura, como sensores, sistemas de conectividad y software, que resultan prohibitivos para granjas pequeñas o en regiones con recursos limitados", la arquitectura modular de los sistemas IoT permite implementaciones graduales adaptadas a las capacidades económicas específicas de cada operación. La disponibilidad creciente de soluciones en la nube y el desarrollo de algoritmos capaces de funcionar con conjuntos de datos contextualizados reducen la dependencia de infraestructuras tecnológicas complejas, facilitando la personalización según las condiciones climáticas, razas predominantes y escalas de producción locales.

La adaptación exitosa requiere estrategias de capacitación diferenciadas que consideren las realidades socioeconómicas de cada entorno productivo. La limitación identificada respecto a "la falta de personal capacitado para operar, mantener y analizar los datos generados" puede abordarse mediante programas de transferencia tecnológica que combinen interfaces simplificadas con capacitación práctica contextualizada (W Weck et al., 2020). La implementación de metodologías estructuradas como CRISP-DM proporciona un marco sistemático para la adaptación de algoritmos según condiciones específicas, mientras que la integración de conocimiento local tradicional con datos científicos permite desarrollar sistemas híbridos más robustos y culturalmente apropiados, transformando la variabilidad ambiental y productiva en oportunidades de especialización tecnológica.

1.4. Identificación de Variables

La definición operacional de las variables de estudio es un aspecto crítico en cualquier proceso de investigación. En este trabajo se detallan los procedimientos, sensores e indicadores empleados para su medición: por un lado, el nivel de estrés por frío en

ganado lechero, como variable dependiente; y, por otro, el conjunto de factores ambientales, circadianos y conductuales, como variable independiente sintetizada, registrada mediante sistemas de sensorización e inteligencia artificial, como se detallan en la Tabla 3 Variable Dependiente, Nivel de estrés por frío en ganado lechero. Tabla 4 Variable Independiente, Sistema de sensorización e inteligencia artificial para predecir estrés por frío.

1.5. Objetivos de la Investigación

Considerando que el objetivo es la vía de demostración de que la hipótesis asociada a un problema puede ser válida, los objetivos se formularán como acciones verificables que conduzcan a su contraste empírico. Para probar dicha hipótesis, se definirá y desarrollará el artefacto correspondiente con requisitos funcionales y no funcionales directamente trazables a la hipótesis; se delimitarán variables y fuentes de datos, así como métricas de desempeño y criterios de éxito; se diseñará el protocolo experimental (conjuntos de entrenamiento/prueba, validación, comparación con líneas base) y se ejecutarán análisis estadísticos que sustenten la significancia de los resultados. De este modo, cada objetivo específico contribuye de forma medible y necesaria a la validación o refutación de la hipótesis planteada.

1.5.1. Objetivo General

Desarrollar, un modelo predictivo basado en aprendizaje automático que integre datos biométricos de collares inteligentes y variables micro climáticas para anticipar episodios de estrés por frío en vacas lecheras, con el fin de mejorar el bienestar animal.

1.5.2. Objetivos Específicos

Se definen tres objetivos específicos que guían la investigación de manera secuencial y complementaria. Estos objetivos abordan desde la construcción técnica del modelo predictivo, pasando por su validación empírica, hasta su evaluación práctica en entornos reales de producción ganadera, asegurando no solo precisión científica, sino también aplicabilidad sostenible en el sector agropecuario ecuatoriano.

OE1: Entrenar modelos de aprendizaje automático utilizando datos ambientales y biométricos para predecir episodios de estrés por frío en bovinos lecheros.

OE2: Comparar el desempeño del sistema propuesto frente a baselines en métricas de clasificación y en capacidad de anticipación (lead time), estableciendo ventajas estadísticamente significativas.

OE3: Analizar la viabilidad de implementación y escalabilidad del sistema de monitoreo predictivo basado en aprendizaje automático en diferentes contextos de producción ganadera.

1.6. Metodología utilizada

Este estudio adopta el paradigma de Ciencias del Diseño (Design Science Research - DSRM), una metodología que combina el rigor científico con el desarrollo de soluciones innovadoras para problemas complejos (Hevner et al., 2008). A diferencia de enfoques tradicionales, la DSR se centra en la construcción y evaluación de artefactos como modelos, métodos o prototipos que no solo resuelven desafíos prácticos, sino que también generan conocimiento científico (Hevner & Chatterjee, 2015).

El artefacto propuesto en esta investigación consiste en un modelo predictivo de estrés por frío basado en aprendizaje automático, que opera a nivel *cow-day* sobre registros biométricos recolectados por collares inteligentes e información microclimática asociada. El núcleo del artefacto es un *pipeline* que combina análisis circadiano mediante transformadas de Fourier (FFT/STFT) con modelos secuenciales, de modo que primero extrae rasgos que capturan la dinámica diaria individual de cada vaca y, sobre estas características, entrena un modelo capaz de clasificar y anticipar estados de estrés por frío con ventanas de alerta operativas. La detección y el tratamiento de valores atípicos se incorporan como parte del preprocesamiento robusto de las series, evitando que errores de medición distorsionen las señales relevantes para la predicción. El enfoque privilegia la personalización por individuo (umbrales y perfiles circadianos

por vaca) y la robustez ante el ruido propio de entornos reales de granja, integrando señales complementarias cuando están disponibles (por ejemplo, anotaciones veterinarias y condiciones microclimáticas). En coherencia con la perspectiva de las Ciencias del Diseño (DSRM), la generación de conocimiento se articula a través del diseño, construcción y evaluación iterativa de este artefacto, donde la teoría guía su arquitectura (ritmos circadianos, criterios de atipicidad y generalización del modelo) y la evidencia empírica métricas de desempeño y validación con información veterinaria y ambiental retroalimenta y valida las hipótesis planteadas.

De acuerdo con López Villanueva (et al., 2025), la Metodología de Investigación en Ciencias del Diseño (DSRM) ofrece un marco en seis fases que asegura consistencia y validez en la construcción del artefacto (véase Figura 1). En este estudio, dichas fases estructuran desde la identificación del problema (detección temprana y monitorización continua del estrés/alteraciones) y la definición de objetivos de la solución (sensibilidad por individuo, bajo costo computacional, interpretabilidad), hasta el diseño–desarrollo del pipeline FFT+ML, su demostración en datos reales de granja y su evaluación rigurosa (AUC, F1, exactitud, análisis de confusión, y experimentos de ablación), culminando con la comunicación de resultados y principios de diseño derivados para su transferencia.




Figura 1 Modelo de proceso DSRM (López-Villanueva et al., 2025).

1.6.1. Nivel de investigación

El estudio es de nivel explicativo–predictivo, ya que analiza la relación funcional entre variables ambientales y biométricas y el nivel de estrés por frío, y además construye un modelo capaz de anticipar episodios de estrés con ventanas de alerta, evaluando su

desempeño mediante métricas objetivas (p. ej., AUC, F1, exactitud) y comparaciones con líneas base.

1.6.2. Diseño de investigación

El diseño es no experimental, porque no se manipulan deliberadamente las variables del entorno o del animal; se analizan registros observacionales obtenidos en condiciones reales de granja (unidad de análisis *cow-day*), integrando datos biométricos y micro climáticos. Asimismo, por la naturaleza temporal de los datos, corresponde a un diseño longitudinal (series temporales), y la contrastación se realiza mediante un diseño de evaluación experimental/computacional del artefacto, aplicando demostración y evaluación con validación temporal y métricas de desempeño.

La matriz de consistencia explicita la trazabilidad $PG \rightarrow OG \rightarrow HG$ y $PEi \rightarrow OEi \rightarrow HEi$, asegurando que cada hipótesis sea contrastable mediante métricas, pruebas y evidencias descritas en el plan de evaluación del Capítulo VI.

1.6.3. DSRM

Como marco metodológico integrador, se adopta Ciencias del Diseño (DSRM), que estructura el trabajo en fases de identificación del problema, diseño desarrollo del artefacto, demostración y evaluación, culminando con la comunicación de resultados. Esta investigación se fundamenta en el paradigma de las Ciencias del Diseño (Design Science Research Methodology – DSRM) Figura 1, inicialmente propuesto por (Hevner & Chatterjee) y posteriormente formalizado por (Peppers et al., 2007). Dicha metodología constituye el marco de referencia para generar conocimiento científico a través del diseño, desarrollo y evaluación iterativa de artefactos, integrando de manera sistemática los fundamentos teóricos con la aplicación práctica en un ciclo de retroalimentación continua.

El artefacto central de este estudio consiste en un modelo predictivo basado en técnicas

de aprendizaje automático, que combina la Transformada Rápida de Fourier (FFT) con redes neuronales de memoria a largo plazo (LSTM) y aplica un filtrado circadiano. Este sistema ha sido diseñado con el propósito de identificar de manera temprana episodios de estrés por frío en ganado lechero, utilizando para ello datos conductuales y fisiológicos recopilados mediante collares inteligentes. A diferencia de enfoques metodológicos de carácter puramente descriptivo o correlacional, el DSRM orienta el presente trabajo a lo largo de todas sus fases: desde la identificación y planteamiento del problema, hasta la construcción, evaluación empírica del artefacto y su posterior comunicación científica. Este marco asegura no solo el rigor metodológico y la relevancia práctica de la investigación, sino también la trazabilidad y consistencia del conocimiento generado durante el proceso.

En la Tabla 1, se establece la correspondencia entre las fases del Design Science Research Methodology (DSRM) y la estructura de la tesis. Su propósito es evidenciar la trazabilidad metodológica desde la identificación del problema hasta la comunicación de los resultados, mostrando dónde se desarrollan en el documento los componentes clave del proceso de diseño. La tabla organiza, para cada fase, una breve descripción operativa y su anclaje en capítulos y secciones específicas, lo que facilita verificar la coherencia entre los objetivos planteados, el diseño y desarrollo del artefacto (modelo predictivo FFT+LSTM), su demostración con datos reales, y la evaluación mediante métricas e instrumentos de validez adecuados.

Tabla 1 Correspondencia entre fases DSRM y capítulos de la tesis

Fase DSRM	Descripción	Correspondencia
1. Identificación del problema y motivación	Se analiza el contexto del estrés bovino, las limitaciones de los métodos tradicionales y la necesidad de soluciones basadas en IA.	Capítulo I (situación problemática, formulación del problema, justificación) + Capítulo II (marco teórico y antecedentes que sustentan la brecha).
2. Definición de los objetivos de la solución	Se formulan los objetivos científicos y de diseño (precisión, explicabilidad, escalabilidad, bajo costo computacional).	Capítulo I (objetivos e hipótesis) + 1.6.2 Matriz de consistencia + criterios técnicos sustentados en Capítulo III (métricas/monitoreo) y

Capítulo IV (enfoques de ML aplicables).

3. Diseño y desarrollo del artefacto	Se conceptualiza, diseña y construye el modelo predictivo FFT+LSTM; se define su arquitectura, variables y proceso de entrenamiento.	Capítulo III y Capítulo IV; Construcción del artefacto: Capítulo V: Arquitectura del modelo predictivo.
4. Demostración	Se aplica el artefacto sobre datos reales recolectados mediante collares inteligentes, evaluando su capacidad para detectar y anticipar el estrés.	Capítulo V, especialmente módulos de etiquetado/baselines, modelado y validación científica (secciones 5.6–5.8).
5. Evaluación	Se analiza el desempeño mediante métricas objetivas (Accuracy, F1-macro, ROC-AUC, PR-AUC), ablation studies y validación cruzada temporal.	Capítulo VI: Evaluación y resultados del modelo predictivo (dataset, reproducibilidad, métricas, horizonte de anticipación, ablaciones, error analysis, validaciones Vet/SFT, validez y expertos)..
6. Comunicación	Se exponen los resultados, conclusiones y principios de diseño para su transferencia y aplicación en otros contextos.	Capítulo VII (Conclusiones) + Capítulo VIII (Recomendaciones) + secciones finales (Contribuciones con publicaciones, referencias y anexos, si aplica).

En coherencia con la directiva, los capítulos I–IV desarrollan el planteamiento y las bases teóricas/técnicas; la implementación del artefacto y su validación (fases 3–5 del DSRM) se ejecutan desde el Capítulo V, y la comunicación de resultados se presenta en los Capítulos VII–VIII.

1.6.4. Matriz de consistencia

Tabla 2 Matriz de consistencia

Problema	Hipótesis	Objetivos	Metodología	Evaluación
Problema General	Hipótesis General	Objetivo General		
La identificación precisa de los factores de estrés por frío en bovinos sigue siendo un desafío, pues los métodos tradicionales son subjetivos, discontinuos y dependen de la observación humana.	El sistema/artefacto propuesto, permite detección temprana y un desempeño superior al enfoque por umbral (SFT/THI), manteniendo utilidad operativa (alerta temprana) en campo.	Desarrollar un modelo predictivo de estrés por frío en ganado lechero mediante técnicas de aprendizaje automático, integrando datos ambientales y fisiológicos recolectados mediante collares inteligentes para anticipar el estrés del ganado.	Metodología de Investigación en Ciencias del Diseño (DSRM) Verificación de la efectividad será realizada mediante pruebas de sangre en el ganado bovino y contraste con las evaluaciones del sistema de software de monitoreo en tiempo real.	Evaluación integral del cumplimiento de los objetivos de diseño. Análisis comparativo con enfoques algorítmicos equivalentes. Demostración de eficiencia y eficacia a través de métricas objetivas.
Problemas secundarios	Hipótesis específicas	Objetivos específicos	Metodología	Evaluación

PE1: Insuficiente precisión y capacidad predictiva de los métodos tradicionales frente a modelos de aprendizaje automático integrados con comportamiento circadiano y datos climáticos para la detección de estrés por frío en vacas lecheras	HE1: Un modelo de aprendizaje automático que integra rasgos circadianos (rumia/actividad/descanso) y variables micro climáticas logra mayor precisión y capacidad predictiva que los métodos tradicionales basados en observación y/o índices por umbral (p. ej., SFT/THI-umbral) para detectar estrés por frío.	OE1: Diseñar y entrenar modelos de aprendizaje automático utilizando datos ambientales y biométricos para predecir episodios de estrés por frío en bovinos lecheros.	Recolección de Datos: Uso de collares inteligentes y sensores IoT para datos biométricos (rumia, descanso, ingesta y otros) y ambientales (temperatura, humedad). Análisis Exploratorio: Identificar patrones ocultos en los datos usando técnicas no supervisadas. Modelado Predictivo: Un modelo LSTM con capas para priorizar variables relevantes en tiempo real.	Ranking de importancia de variables (SHAP values): Consistencia en patrones identificados. Correlación significativa entre variables ambientales y biométricas
---	--	--	---	---

PE2: Falta de evidencia sólida, precisa y con respaldo estadístico que demuestre que el sistema propuesto supere a métodos estándar.	HE2: El sistema propuesto supera significativamente a los baselines en métricas evaluadas y logra un lead time promedio ≥ 60 minutos, reduciendo falsas alarmas y mejorando sensibilidad en High.	OE2: Comparar el desempeño del sistema propuesto frente a baselines en métricas de clasificación y en capacidad de anticipación (lead time), estableciendo ventajas estadísticamente significativas.	• Optimización del Modelo • Implementación en Campo • Diseño de un experimento controlado • Evaluación de Impacto • Medición diaria de producción (litros/vaca) evaluación bajo examen molecular en sangre	• Tiempo de detección temprana (≤ 1 hora antes del evento de estrés) • Reducción en falsas alarmas vs. métodos tradicionales • Incremento en litros/vaca/día
PE3: Desafíos y ventajas en la adaptación y escalabilidad de sistemas de aprendizaje automático.	HE3: La implementación escalable de sistemas de monitoreo basados en aprendizaje automático en diferentes entornos productivos es viable, siempre que se adapten las estrategias tecnológicas y de capacitación a las condiciones locales.	OE3: Analizar la viabilidad de implementación y escalabilidad del sistema de monitoreo predictivo basado en aprendizaje automático en diferentes contextos de producción ganadera.	Diseño del Sistema Híbrido, Integración de LSTM (para secuencias temporales) con ciclo circadiano Escalabilidad y Adaptabilidad, Validación Multidisciplinaria, con veterinarios y productores para ajustar umbrales de alerta según criterios de bienestar animal.	• Eficiencia del 85% en ajuste de umbrales ante variaciones extremas (ej.: -10°C a 5°C). • Aprobación en usabilidad y relevancia clínica.

1.6.5. Operacionalización de Variables

Tabla 3 Variable Dependiente, Nivel de estrés por frío en ganado lechero.

Variable	Definición conceptual	Definición operacional	Dimensiones	Indicadores	Ítem	Valor final
Nivel de estrés por frío en ganado lechero	Estado fisiológico y comportamental del bovino lechero en el que las condiciones ambientales descienden por debajo de su zona termoneutral, generando respuestas adaptativas que afectan su bienestar y rendimiento productivo (Bickert, 2011; Kim et al., 2023).	Nivel de estrés por frío diario por vaca, obtenido a partir de datos ambientales y biométricos registrados por sensores e inteligencia artificial, y clasificado en categorías (Normal, Estrés leve, Estrés alto) según umbrales predefinidos de THI ajustado, patrones circadianos y producción lechera.	Carga térmica ambiental	THI ajustado diario mínimo. Horas/día con THI por debajo del umbral de confort térmico.	Registros de temperatura, humedad y viento de la estación microclimática para cada vaca/día.	Puntaje parcial de estrés ambiental en escala 0–2 (0 = sin estrés, 1 = leve, 2 = alto), según rangos de THI y duración de la exposición a condiciones de frío.
			Respuesta comportamental–circadiana	Desviación del patrón circadiano de actividad, rumia y descanso frente al patrón de referencia sin estrés.	Series horarias de actividad, rumia y tiempo de descanso registradas por collares inteligentes	Puntaje parcial de alteración circadiana en escala 0–2, calculado a partir de la amplitud y fase de los ritmos y su desviación respecto al patrón considerado fisiológico.
			Índice compuesto de estrés por frío	Suma o combinación ponderada de los puntajes parciales ambiental, comportamental–circadiano y productivo.	Integración de los tres puntajes (0–2) en un índice compuesto de estrés por frío por vaca y por día.	Valor final del índice en escala 0–2 y categoría diaria de estrés por frío: 0 = Normal, 1 = Estrés leve, 2 = Estrés alto, utilizada como salida de los modelos de clasificación.

Tabla 4 Variable Independiente, Sistema de sensorización e inteligencia artificial para predecir estrés por frío.

Variable	Definición conceptual	Definición operacional	Dimensiones	Indicadores	Ítem	Valor final
Sistema de sensorización e inteligencia artificial para predecir estrés por frío	Conjunto de tecnologías de sensorización ambiental y biométrica, integradas con análisis de datos y algoritmos de aprendizaje automático, orientadas al monitoreo del bienestar y al soporte de decisiones en sistemas de ganadería de precisión (Lin et al., 2023; Becker et al., 2021; Islam et al., 2020).	Conjunto de variables de entrada $X(t)$ utilizadas por los modelos de IA, obtenidas de estaciones microclimáticas, collares inteligentes y transformaciones circadianas, que se registran y preprocesan por vaca y por día para alimentar el sistema de clasificación del nivel de estrés por frío.	Condiciones microclimáticas ambientales	Temperatura ambiente ($^{\circ}\text{C}$), humedad relativa (%), velocidad del viento (m/s), THI ajustado por hora y por día.	Registros horarios de la estación microclimática asociada al hato y vinculada a cada vaca/día.	Matriz de variables ambientales normalizadas por vaca y por día que alimentan el modelo de IA como predictores continuos del nivel de estrés por frío.
			Señales biométricas y comportamentales	Minutos de actividad, minutos de rumia, minutos de descanso, número de pasos, cambios de postura por hora/día.	Serie de tiempo generadas por collares inteligentes (IMU) para cada vaca, con resolución horaria.	Vector de características diarias agregadas (promedios, desviaciones, conteos) por vaca que representa el perfil biométrico-comportamental usado como entrada del modelo de IA.
			Parámetros circadianos derivados	Amplitud, mesor y acrofase de los ritmos de actividad, rumia y descanso; índice de desincronización circadiana.	Resultados del análisis circadiano (FFT/cosinor) aplicado a las series horarias por vaca.	Vector de parámetros circadianos por vaca/día que captura la organización temporal de la conducta y se utiliza como subconjunto especializado de predictores en el modelo.
			Configuración del modelo de IA	Tipo de modelo (p.ej., LSTM, RF, SVM), ventana temporal de entrada, horizonte de predicción (lead time), frecuencia de actualización.	Especificación del modelo implementado en el sistema propuesto y sus hiperparámetros documentados.	Conjunto de parámetros de diseño del sistema de IA que determinan cómo se integran y explotan las variables de entrada para generar la predicción diaria de estrés por frío.

1.7. Justificación

La industria lechera de la provincia del Carchi es un pilar fundamental de la economía local, con una producción diaria de 408.006 litros que genera aproximadamente \$58.8 millones USD anuales. Sin embargo, esta productividad se ve severamente amenazada por el estrés por frío en el ganado, un factor que impacta negativamente la producción, la salud y la rentabilidad de acuerdo con el (Fondo Ítalo Ecuatoriano para el Desarrollo del Sostenible, 2024). Estimaciones conservadoras estiman que las pérdidas anuales atribuibles a heladas en la zona ascienden a \$13.58 millones a nivel provincial, derivadas de la reducción en la producción de leche, el aumento de casos de mastitis y las pérdidas reproductivas. Mitigar este problema es, por tanto, una necesidad económica urgente para los productores de la región (Carvajal Pérez & Montenegro, 2020).

Desde una perspectiva científica, existe una brecha de conocimiento significativa en la predicción del estrés por frío. Mientras que la mayoría de los estudios (89%) se centran en el estrés calórico, la literatura carece de investigaciones robustas aplicadas a condiciones de frío, particularmente en sistemas de altura como los Andes ecuatorianos (Rogerio, 2023). Este proyecto aborda directamente esta brecha y muestra que la relevancia práctica de esta investigación es inmediata. El desarrollo de un sistema predictivo preciso permitiría una gestión preventiva del estrés por frío. Se estima que una reducción del 40% en su incidencia podría generar un beneficio económico de \$5.4 millones anuales para el Carchi, con un retorno de inversión (ROI) estimado de 2.8:1 en el primer año para fincas con más de 50 vacas. El sistema es práctico y escalable, ya que se integra con tecnología existente (como collares CowManager®) y requiere una infraestructura accesible, siendo potencialmente aplicable a un mercado de más de 360,000 vacas en sistemas de altura del Ecuador.

Para esta investigación se cuenta con acceso a la granja experimental San Francisco de la UPEC, una serie de datos completa de 10 vacas instrumentadas, infraestructura computacional adecuada y supervisión veterinaria especializada. En consecuencia,

esta investigación se justifica por su potencial para cuantificar y mitigar un problema económico crítico, llenar un vacío científico relevante y ofrecer una herramienta práctica y viable que optimice el bienestar animal y la sostenibilidad financiera de la lechería en la región

1.8. Limitaciones de estudio

El estudio utiliza datos biométricos y ambientales de solo 10 vacas en el centro experimental San Francisco (UPEC) durante un período de doce meses (enero a diciembre de 2024). Este tamaño de muestra reducido puede no ser representativo de la diversidad de razas, condiciones climáticas y sistemas de producción existentes en otras regiones o granjas, lo que limita la generalización de los resultados (Pedrosa et al., 2024).

La implementación de tecnologías avanzadas como ML puede no ser viable en granjas con recursos limitados, lo que restringe el impacto del estudio en contextos socioeconómicos desfavorecidos (W Weck & S Solís L Adrián, 2020).

1.9. Organización de documento

El presente documento se organiza de la siguiente manera para guiar el proceso de investigación, desarrollo y prueba, alineándose con la metodología de Ciencias del Diseño (DSRM):

El Capítulo 1 corresponde a las actividades 1 y 2 de la metodología DSRM, que incluyen la identificación del problema y la definición de los objetivos de la investigación. Aquí se presenta la problemática del estrés por frío en bovinos lecheros, destacando las limitaciones de los métodos tradicionales de monitoreo (subjetividad, discontinuidad y dependencia de la observación humana) y la necesidad de soluciones basadas en aprendizaje automático para mejorar el bienestar animal y la productividad. Se formulan el objetivo general y los objetivos específicos, que se complementan con los objetivos de diseño detallados en el Capítulo 5.

El Capítulo 2, expone los conceptos fundamentales relacionados con el estudio, incluyendo el estrés por frío en bovinos, el aprendizaje automático (ML), sensores inteligentes, el Internet de las Cosas (IoT). También se abordan conceptos clave como datos biométricos, monitoreo ambiental, detección de patrones y metodologías de análisis de datos como CRISP-DM. Este marco teórico proporciona la base conceptual para el desarrollo de la solución propuesta.

En el Capítulo 3, se revisa el estado del arte de las técnicas de aprendizaje automático aplicadas al monitoreo de estrés en ganado, con un enfoque en la detección no invasiva del estrés por frío. Se analizan las características, condiciones, métricas de evaluación, áreas de aplicación y limitaciones de las técnicas existentes, como redes neuronales profundas, algoritmos de clasificación supervisada y métodos basados en índices de Sensación Térmica por Frío (SFT). Esta revisión establece el contexto para la propuesta del estudio y destaca las brechas en la literatura actual.

Seguidamente, el Capítulo 4 se centra específicamente en las técnicas de aprendizaje automático diseñadas para procesar datos en flujo provenientes de redes de sensores inalámbricos (WSN), como los collares inteligentes utilizados en el estudio. Se explora el uso de modelos como redes LSTM (Long Short-Term Memory) y bosques aleatorios, con énfasis en su aplicación para la detección de patrones asociados al estrés por frío. Se parte de enfoques establecidos, como el Isolation Forest (iForest), para contextualizar la propuesta técnica del estudio. Los capítulos 2 al 4 integran la fase de investigación previa al diseño y desarrollo del artefacto propuesto.

El Capítulo 5 corresponde a la actividad 3 de DSRM, centrada en el diseño y desarrollo del modelo predictivo basado en aprendizaje automático para la detección temprana del estrés por frío. Se definen los objetivos de diseño derivados de los objetivos del estudio, incluyendo la integración de datos biométricos (rumia, comida, descanso y otros) y ambientales (temperatura, humedad, velocidad del viento) recolectados mediante collares inteligentes. Se detalla la estrategia de modelado, que incluye el uso de variaciones porcentuales para entrenar un modelo adaptado basado en técnicas como LSTM. Además, se presenta el modelo conceptual y el desarrollo técnico de la

solución, incluyendo la arquitectura del sistema y los algoritmos empleados.

Así, en el Capítulo 6 se lleva a cabo una evaluación exhaustiva del modelo predictivo desarrollado, siguiendo la actividad 4 de DSRM. Se describen las condiciones de simulación, incluyendo el dataset de 10 vacas lecheras (4000 tuplas por vaca, divididas en 75% para entrenamiento y 25% para validación cruzada. Se evalúa el rendimiento del modelo en términos de precisión, sensibilidad, especificidad y tiempo de detección temprana (≤ 1 hora antes del evento de estrés). También se analizan métricas a nivel de sensores (eficiencia y efectividad) y a nivel de sistema (diferenciación de eventos de estrés por frío), en condiciones reales de la granja San Francisco (UPEC).

El Capítulo 7, alineado con la actividad 5 de DSRM, presenta una discusión detallada de los resultados obtenidos en relación con los objetivos y las hipótesis planteadas. Se comparan los resultados del modelo predictivo con los métodos tradicionales de monitoreo (como observación visual y mediciones puntuales) y se evalúa su impacto en el bienestar animal, la calidad de la leche (contenido de grasa, proteína, células somáticas) y la productividad. Se analizan las fortalezas y limitaciones del modelo, considerando factores como la escalabilidad, la adaptabilidad a diferentes contextos productivos y las barreras tecnológicas y económicas.

En el capítulo 8 se resumen las principales conclusiones del estudio, destacando el aporte del modelo predictivo al bienestar animal y la eficiencia productiva en la ganadería lechera. Se identifican las implicaciones prácticas y científicas del trabajo, así como las limitaciones encontradas (como el tamaño de la muestra, la representatividad de los datos y los desafíos de escalabilidad). Finalmente, se proponen líneas de trabajo futuro, como la validación del modelo en otras regiones, la integración de nuevas variables (por ejemplo, datos genéticos) y el desarrollo de soluciones de bajo costo para facilitar la adopción en granjas pequeñas.

La exposición y comunicación de los resultados derivados de la presentación, aprobación y difusión de este trabajo se considerarán parte de la actividad final de DSRM. Esto incluye publicaciones científicas, presentaciones en conferencias y la

transferencia de conocimiento a productores ganaderos y otros actores relevantes en la industria lechera.

CAPÍTULO II. MARCO TEORICO

Este capítulo erige el andamiaje conceptual indispensable para la tesis, fusionando perspectivas epistemológicas, revisiones bibliográficas y principios teóricos centrales en el ámbito de la ganadería bovina frente al estrés térmico por frío. Inicialmente, se delimita el marco epistemológico de la investigación, adoptando un realismo crítico con orientación empírica que autentica la observación de patrones conductuales y fisiológicos como expresiones de realidades ontológicas, accesibles a través de instrumentos de medición como IoT y análisis computacional. Seguidamente, se examinan los antecedentes investigativos, abarcando técnicas biométricas para la evaluación del estrés, constantes fisiológicas en bovinos, tipos de estrés, índices e indicadores de estrés por frío, el ciclo circadiano asociado y métodos de monitoreo y control animal, con el objetivo de contextualizar el problema en la literatura especializada y respaldar la implementación de enfoques innovadores.

En continuidad, se profundiza en la ganadería de precisión, resaltando su impacto transformador en la gestión animal mediante metodologías de análisis de datos, minería de datos, reconocimiento de patrones y algoritmos de aprendizaje automático, incluyendo enfoques como Random Forest, SVM y redes neuronales profundas, todos integrados bajo el modelo CRISP-DM para convertir datos crudos en decisiones operativas. Finalmente, se articulan el marco de sistemas de aprendizaje automático y el marco ético, conformando una integración holística que no solo robustece la validez científica y predictiva del estudio, sino que también enfatiza la responsabilidad en el bienestar animal y la sostenibilidad agropecuaria. De esta manera, el capítulo consolida las bases teóricas y legitima la propuesta como un avance interdisciplinario en biología animal, inteligencia artificial y ética aplicada.

2.1 Marco epistemológico de la investigación

Se adopta una postura de realismo crítico que, de acuerdo a Bhaskar (2015) reconoce la existencia independiente de mecanismos fisiológicos del estrés por frío en bovinos, pero acepta que nuestro acceso a ellos está mediado por instrumentos (sensores IoT) y modelos computacionales imperfectos. Desde esta postura ontológica los fenómenos de estrés por frío existen independientemente del observador y lo articula con una epistemología empírico-positivista que privilegia datos observables, mediciones repetibles y contrastación estadística. En consecuencia, los modelos de IA/ML se conciben como representaciones operativas de regularidades causales presentes en los datos sensoriales y ambientales. Este encuadre filosófico-epistemológico sostiene las decisiones metodológicas del capítulo (selección de variables, indicadores, índices SFT) y alinea el uso de CRISP-DM con el enfoque DSRM del proyecto, garantizando trazabilidad entre los supuestos teóricos, la obtención de evidencia empírica y la construcción del artefacto predictivo.

a) Marco Filosófico: Realismo Científico

Esta investigación se enmarca en el realismo científico, postura filosófica que postula la existencia de un mundo independiente de nuestra percepción y la capacidad de la ciencia para ofrecer descripciones progresivamente verídicas del mismo mediante la observación y experimentación (Mendoza De Los Santos, 2022). Desde este fundamento, el estudio aborda un problema concreto: la predicción de factores de estrés por frío en ganado lechero mediante técnicas de inteligencia artificial.

A nivel filosófico, el objetivo trasciende la mera descripción de la realidad observable para aspirar a la comprensión y predicción de fenómenos específicos en este caso, el estrés térmico en bovinos a través de modelos predictivos. En coherencia con esta postura, se parte del supuesto de que los algoritmos de aprendizaje automático son capaces de capturar y representar las relaciones causales subyacentes en los datos registrados. Así, la aplicación de estas técnicas se sustenta en la premisa de que pueden identificar regularidades objetivas en la información, reflejando de manera fidedigna

aspectos medibles del comportamiento animal frente a condiciones adversas (Kaur & Virk, 2025).

b) Marco Epistemológico: Empirismo y Positivismo.

El enfoque epistemológico se enmarca en el empirismo y positivismo, privilegiando el conocimiento derivado de datos observables y verificables. Desde el empirismo, se recolectan y analizan datos cuantitativos y cualitativos mediante técnicas de muestreo y modelos predictivos (Charry et al., 2018), constituyendo estos la base para generar y contrastar hipótesis. Desde el positivismo, se explica y predice el estrés en ganado lechero aplicando modelos matemáticos e inteligencia artificial, bajo el supuesto de que la realidad se rige por relaciones causales medibles. A través de un método deductivo, se parten de teorías establecidas para formular y verificar hipótesis experimentalmente. La validez de estas se contrasta mediante análisis estadístico, con el objetivo de alcanzar una comprensión objetiva y racional del fenómeno.

La combinación de datos cuantitativos (mediante métricas como precisión, sensibilidad, F1-score, etc.) y cualitativos (observación y análisis de comportamiento animal) permite no solo generalizar los resultados a una población más amplia, sino también obtener una comprensión más profunda del fenómeno estudiado. Este enfoque mixto refleja una epistemología que valora tanto la replicabilidad y objetividad de los métodos cuantitativos como la profundidad y contexto que ofrecen los métodos cualitativos. Como se muestra en la Tabla 5 Supuestos epistemológicos y sus implicaciones metodológicas el marco filosófico y epistemológico de esta investigación se sustenta en la idea de que la realidad puede ser descrita y comprendida a través de métodos científicos rigurosos, empíricos y verificables, utilizando herramientas de inteligencia artificial para captar, predecir y mitigar factores de estrés en ganado lechero de manera precisa y eficiente.

Tabla 5 Supuestos epistemológicos y sus implicaciones metodológicas

Supuesto Epistemológico	Implicación Metodológica	Limitación Reconocida
Los datos sensoriales capturan señales del estrés	Se pueden entrenar modelos supervisados	Los sensores tienen ruido y deriva
Existen patrones repetibles en el comportamiento bajo frío	Los modelos pueden generalizar	La variabilidad individual y ambiental limita la precisión
Las métricas cuantitativas evalúan desempeño	Se usan Accuracy, F1, AUC-ROC	No capturan aspectos cualitativos del bienestar
Los modelos son aproximaciones útiles	Se aceptan errores de Tipo I y II	Se requiere validación veterinaria antes de decisiones críticas.

Fuente: Elaboración propia

2.2 Antecedentes de Investigación

Para contextualizar la presente investigación, se realizó una revisión sistemática de la literatura científica reciente aplicando criterios específicos de selección (Lascano Rivera et al., 2025). La búsqueda se focalizó en investigaciones publicadas entre 2020 y 2024 que emplearan técnicas de Machine Learning (ML) o Inteligencia Artificial (IA) para la predicción de estrés en bovinos. Un criterio fundamental fue la utilización de datos provenientes de sensores portables (*wearables*) o remotos, garantizando así la relevancia metodológica para el enfoque de monitoreo continuo propuesto. Se exigió que los estudios incluyeran el reporte explícito de métricas de desempeño cuantificables (como precisión, sensibilidad o F1-Score), lo que permite una evaluación objetiva de la capacidad predictiva de los modelos y facilita la comparación de resultados. Esta delimitación rigurosa permite identificar con claridad las tendencias actuales, los métodos más prometedores y, crucialmente, las lagunas de conocimiento existentes en el campo de la predicción del estrés bovino asistida por tecnología.

Un estudio publicado en la Revista de ciencia láctea titulado “Predicción del calor de los bovinos lecheros utilizando técnicas de aprendizaje automático”(Becker et al., 2021) muestra la gravedad del estrés por calor en vacas lecheras mediante un sistema de puntuación que varió de 1 a 4 en donde 1 = sin estrés térmico; 2 = estrés térmico

leve; 3 = estrés térmico severo; 4 = moribundo, y predecir la precisión del sistema utilizando técnicas de ML como regresión logística, bayesiano, ingenuo gaussiano y bosque aleatorio. Se consideraron tres tratamientos diferentes para reducir el calor en las vacas: estructura de sombra portátil, sistema de aspersión de tubería de cloruro de polivinilo portátil y control sin reducción de calor. Los resultados indicaron que el bosque aleatorio fue el método más preciso para predecir la puntuación del grupo de rociadores, mientras que la regresión logística fue mejor para predecir vacas estresadas por calor en control, sombra y combinadas.

En la revista *Livestock Science*, se encuentra un artículo titulado “Imágenes térmicas combinadas con un modelo basado en aprendizaje automático predictivo para el desarrollo de clasificadores de niveles de estrés térmico”. El estudio realizado por Pacheco et al. (2020) abordan el tema sobre el estrés térmico en vacas lecheras como un problema que puede afectar su eficiencia productiva y bienestar. La termografía infrarroja (IRT) es una herramienta no invasiva que ha demostrado ser eficaz para monitorear la temperatura superficial de los animales. Se establecieron y evaluaron modelos basados en aprendizaje automático para la evaluación individual de los niveles de estrés térmico, considerando factores climáticos y animales. Se realizó un experimento con 26 vacas lactantes, monitoreadas durante el verano y el invierno, para adquirir datos fisiológicos y meteorológicos. Se analizó el coeficiente de correlación de Pearson para determinar la parte del cuerpo ideal para el modelado computacional. Los modelos Redes Neuronales Artificiales (ANN) demostraron una mejor capacidad predictiva en comparación con los métodos tradicionales de clasificación para los niveles de estrés térmico.

Woodward et al. (2024) presentan un enfoque *proof-of-concept* para identificar y predecir eventos de estrés por calor en vacas lecheras en pastoreo usando bolos ruminales con sensor de temperatura (smaXtec). Analizaron datos de 443 vacas en 3 granjas (Northland, Nueva Zelanda) y los sincronizaron con información de estaciones meteorológicas cercanas. Definieron una tasa de estrés por calor (HSR) como el porcentaje de vacas (por grupo edad-raza) con temperatura ruminal > 3 desviaciones

estándar sobre la media individual; un evento se consideró cuando $HSR > 25\%$. Compararon modelos de regresión e índices clásicos (p. ej., THI) con un modelo de *machine learning* (Cubist), que obtuvo el mejor desempeño (sensibilidad 79% y precisión 52%), superando a los modelos lineales (sensibilidad 34–68% pero precisión 9–27%). Concluyen que combinar sensores internos + clima permite generar alertas tempranas para mitigación (sombra, manejo), aunque recomiendan validar el modelo en nuevos entornos e incorporar variables animales y otros indicadores (p. ej., frecuencia respiratoria).

En la Biblioteca digital de la Universidad de São Paulo (USP) se encuentra una Tesis de maestría escrita por (Da & Rodrigues, 2022) con el título “Evaluación no invasiva del estrés por calor en los bovinos: un enfoque basado en el aprendizaje automático y la termografía infrarroja”. El trabajo de maestría describe el uso de la tecnología no invasivas y algoritmos para predecir el estrés térmico en los bovinos lecheros mediante mediciones automáticas. El proyecto se enfoca en desarrollar y probar modelos computacionales para predecir el estrés térmico en ganado lechero usando datos obtenidos de un experimento en una cámara climática. El experimento duró 45 días con 10 terneras Holstein divididos en dos grupos, los bovinos fueron expuestos a dos olas de calor en la cámara climática (sistema Tie Stall). Se recopilaron datos de temperatura rectal, frecuencia respiratoria y termografía infrarroja (IRT) de diferentes partes del cuerpo (ojo, frente, costilla y flanco). Se evaluaron diferentes algoritmos de aprendizaje automático: redes neuronales artificiales, máquina de vectores de soporte, árbol de decisión y k-vecinos más cercanos, para clasificar el nivel de estrés térmico, en donde se descubrió que los mejores resultados se obtuvieron con Random Forest y Support Vector Machine. El trabajo de maestría concluye que la tecnología TIV combinada con algoritmos de aprendizaje automático puede ser utilizada para predecir con precisión el estrés térmico en los bovinos lecheros.

En el artículo titulado “Hacia un nuevo método para detectar comportamientos atípicos de acostarse y levantarse en vacas lecheras utilizando acelerómetros y aprendizaje automático”, (Brouwers et al., 2023) menciona que el uso de algoritmos recientemente

desarrollados para clasificar series temporales multivariadas y monitorear el comportamiento de las vacas lecheras es uno de los elementos principales de este artículo. Sin embargo, los métodos convencionales de evaluación de instalaciones que se basan en una observación manual y análisis de imágenes, que dependen en gran medida del juicio y la experiencia de los investigadores, pueden ser ineficaces. Los algoritmos de clasificación de series temporales multivariadas más recientes, como MiniRocket, HIVE-COTE 2.0 e InceptionTime, han cambiado la forma en que se registra el comportamiento de las vacas lecheras al mismo tiempo. Estos métodos se utilizan específicamente para clasificar la serie temporal de los registros de acelerómetro de cada vaca. Estos algoritmos, como se muestra en las figuras.

Un artículo publicado en la revista *Indonesian Journal of Electrical Engineering and Computer Science* titulado “Estudio comparativo sobre enfoques de inteligencia artificial basados en datos de series temporales para clasificar el comportamiento alimentario de los bovinos” (El Moutaouakil & Falih, 2024) menciona que el comportamiento alimentario de los bovinos juega un papel crítico en su estado general de salud. La productividad y el bienestar general de los bovinos son proporcionales a la naturaleza de su dieta. Los dispositivos sensoriales modernos, facilitan a una persona la monitorización y clasificación del comportamiento alimentario de los bovinos. Otros dispositivos, como un rastreador GPS y un dispositivo de visión por computadora, aumentan la eficiencia de la recolección y el análisis de datos del comportamiento animal.

En el artículo titulado “Uso de la tecnología de sensores montados en bovinos y el aprendizaje automático para predecir el tiempo hasta el parto en vacas de carne y leche” (Miller et al., 2020) publicado en la revista *Animal* destaca que el aumento del tamaño de los rebaños en los sectores de carne y lácteos reduce el tiempo disponible para monitorear individualmente a los animales. Horas antes del parto, las vacas presentan cambios en su comportamiento, incluido el tiempo de rumia y alimentación reducido, más actividad y eventos de elevación de la cola, que son monitoreables de manera no invasiva con sensores montados en los bovinos y útiles para prever el parto.

Se crearon algoritmos de bosques aleatorios para prever el parto utilizando datos de un solo sensor y de varios sensores. El modelo TAIL fue el mejor predictor del parto en un horario de 5 horas para la carne de vaca con un MCC de 0.31, luego le siguió para las vacas lecheras con un MCC de 0.29. La combinación de TAIL, RUM y EAT tuvo una eficacia similar con un MCC de 0.32. Los sensores de cola también fueron suficientes para predecir el parto, y el tiempo óptimo fue en 2 horas antes del parto.

Para una contextualización integral, esta investigación también revisó deliberadamente estudios de estrés por calor como referencia contrastiva. Aunque el fenómeno térmico es opuesto, esta línea de investigación comparte marcos teóricos fundamentales sobre la termorregulación bovina y la expresión de biomarcadores conductuales. Asimismo, ha sido pionera en la aplicación y validación de las tecnologías de sensores portables y termografía que son metodológicamente relevantes para este trabajo. El análisis de estos estudios como se evidencia en la Tabla 6 Síntesis comparativa de estudios relevantes sobre predicción de estrés en bovinos., permitió identificar brechas críticas en la literatura, entre las cuales destacan: la ausencia total de investigaciones que empleen Machine Learning para predicción de estrés por frío, ninguna investigación realizada en condiciones altoandinas ecuatorianas, la validación temporal ausente en todos los estudios revisados, y tamaños de muestra reducidos ($n < 50$ en el 80% de los estudios). El análisis de los avances en la predicción del estrés calórico permite identificar con mayor claridad la brecha metodológica y de conocimiento que existe en la investigación del estrés por frío. Mientras que el primero cuenta con una amplia trayectoria en el uso de ML, la predicción del estrés por frío en sistemas ganaderos de altura, como los andinos, constituye un campo notablemente subexplorado, delimitando así el espacio original que ocupa la presente investigación.

Tabla 6 Síntesis comparativa de estudios relevantes sobre predicción de estrés en bovinos.

Autor	Año	Estresor	Tecnología	Algoritmo(s)	No. Vacas	Mejor Métrica	Limitación Principal
Becker et al.	2021	Calor	Termografía	RF, LogR, NB, GNB	36	RF: Acc 89%	Muestra pequeña, dependencia de cámara termográfica
Pacheco et al.	2020	Calor	IRT	ANN, SVM	26	ANN > métodos tradicionales	Solo correlaciones, sin métrica F1 reportada
Da & Rodrigues	2022	Calor	IRT + sensores	RF, SVM, DT, KNN	10	RF: Acc 92%	Cámara climática (baja validez ecológica)
Brouwers et al.	2023	Conducta	Acelerómetros	MiniRocket, HIVE-COTE	NR	MiniRocket	No evalúa estrés específico
Miller et al.	2020	Parto	Collar (rumia/actividad)	RF	NR	TAIL: MCC 0.31	Evento agudo, no aborda estrés crónico
Kim et al.	2023	FRÍO	Parámetros fisiológicos	✗ Sin ML	18	-	Único estudio de frío, pero sin aplicación de ML
Esta tesis	2025	FRÍO	Collar Nedap + estación climática	RF, SVM, LSTM, GBM	10	Por determinar	Estudio pionero en ML aplicado a estrés por frío en condiciones altoandinas

Fuente: Elaboración propia.

2.3 Bienestar animal

El bienestar animal es un concepto multidimensional que integra el funcionamiento óptimo del organismo dependiente de una alimentación adecuada junto con la salud

mental y emocional del individuo. En este último aspecto, resulta fundamental la ausencia de dolor y miedo crónico, condiciones que suelen originarse por interacciones negativas con los seres humanos, como el maltrato por parte de quienes los custodian o crían. Cuando estos factores se ven afectados, el animal puede manifestar respuestas de estrés y conductas anómalas, indicativas de un deterioro en su bienestar (Manteca, 2021).

De acuerdo con Pinillos & García (2022), el bienestar animal se encuentra interconectado con el bienestar humano y la salud del medio ambiente. Esta perspectiva integral permite identificar y analizar los conflictos entre estos tres ámbitos, constituyendo una base fundamental para avanzar en áreas como la ciencia animal, la sostenibilidad y la ganadería. Además, el bienestar animal se organiza en torno a dimensiones específicas, como la seguridad alimentaria y la salubridad, donde la labor de los científicos especializados resulta clave para identificar casos de estudio, mejorar las prácticas productivas y aportar valor tanto a la sociedad como a los propios animales.

La etología es una ciencia que se encarga de la observación y descripción minuciosa de los comportamientos bovinos en diferentes aspectos. Es reconocida por sus principales aportaciones de elementos científicos con gran importancia para la formación de profesionales veterinarios que se centran básicamente en la salud y producción de animales. Como se mencionó anteriormente, esta ciencia está ligada al bienestar animal, en donde se observa al individuo la manera en que interactúa con el medio que le rodea, lo que conlleva a otros temas de investigación como el estudio del comportamiento, que son causados por factores de enfermedad, lesiones, hambre, instalaciones, manejo por los humanos, transporte y movimiento de los animales. El manejo de procedimientos biométricos para el control en granjas y el manejo genético convencional provoca reacciones en los rebaños (Blasio et al., 2022).

Por consiguiente, se revisan los mecanismos subyacentes que permiten su evaluación y manejo en contextos productivos, particularmente en bovinos expuestos a condiciones ambientales adversas. las técnicas biométricas empleadas en la evaluación

de la salud y el bienestar ganadero, las constantes fisiológicas inherentes a los bovinos, los tipos de estrés que afectan a esta especie, la fisiología específica del estrés inducido por frío, el ciclo circadiano en bovinos y las estrategias de monitoreo y control animal, con el fin de integrar estos elementos en un enfoque integral que oriente intervenciones preventivas y correctivas.

2.3.1. Técnicas biométricas para la evaluación de la salud y el bienestar del ganado

Los métodos tradicionales para evaluar el bienestar animal suelen ser subjetivos en el caso de la observación conductual o invasivos. Entre estos últimos se incluyen técnicas que requieren la toma de muestras biológicas y análisis de laboratorio costosos y lentos, como el ensayo inmunoenzimático. Asimismo, en la medición de temperatura corporal se han empleado procedimientos invasivos; por ejemplo, Chung et al. (2020) implantaron un biosensor RFID subcutáneo en la oreja de vacas lecheras, el cual mostró una correlación media con la sonda intravaginal en dos animales ($R^2 = 0.73$) y baja en un tercero ($R^2 = 0.34$), lo que sugiere una alta sensibilidad a la ubicación anatómica y al flujo sanguíneo local, en la Tabla 7 Métodos para medir temperatura corporal en bovinos. se recopilan los métodos y el nivel de invasividad de estos.

Tabla 7 Métodos para medir temperatura corporal en bovinos.

Método	Invasividad	Variable medida	Concordancia con referencia	Ventajas	Limitaciones	Referencia
Implante RFID subcutáneo (oreja)	Invasivo (implante)	Temp. corporal estimada	$R^2 = 0,73$ (2 vacas) / $0,34$ (1 vaca) vs sonda intravaginal	Continuo, manos libres	Cirugía menor, variabilidad por sitio/flujo sanguíneo	Chung et al., 2020
Sonda intravaginal	Mínimamente invasivo	Temp. central	(patrón referencia en el estudio)	Alta fidelidad de “core temp.”	Molestia, higiene, retención	(misma fuente)
Termografía infrarroja (IRT)	No invasivo	Temp. superficial (ojo, frente, flanco)	Depende del sitio; requiere calibración	Sin contacto, rápida, masiva	Sensible a viento/sol/pelo	Pacheco et al., 2020; Da & Rodrigues, 2022
Termómetro rectal	Semi-invasivo	Temp. central	Alta (clínico)	Estándar clínico	No continuo, manejo del animal	Texto veterinario estándar
Collar/arete inteligente con sensor térmico	No invasivo (portado)	Temp. periférica/proxy	Variable (depende del dispositivo)	Integrable a plataforma IoT	Deriva térmica/posición	Fichas técnicas (p.ej., Nedap)

En Chung et al. (2020), el RFID implantado mostró correlación media con la sonda intravaginal en 2 vacas ($R^2=0,73$) y baja en 1 vaca ($R^2=0,34$), evidenciando sensibilidad al sitio anatómico y a condiciones hemodinámicas locales.

En el estudio del bienestar ovino, Gjergji et al., (2020) implementaron un sistema de monitorización inalámbrico que integraba sensores de contacto y sin contacto. La configuración incluía un acelerómetro triaxial ADXL335 (Analog Devices, Wilmington, MA, EE. UU.) instalado en un cabestro adaptado a la mandíbula inferior de ovejas lecheras, permitiendo cuantificar la aceleración tridimensional de sus movimientos.

Las técnicas biométricas para evaluar respuestas fisiológicas y comportamentales también se han aplicado en porcinos. Molina Casanovas, (2021), por ejemplo, monitorizó la conducta de cerdos mediante una cámara KPCN502NUB (KT&C, Fairfield, NJ, EE. UU.) instalada sobre cada corral. Utilizando el software GeoVision VMS (GeoVision Inc, Taipei, Taiwán), clasificó los animales en activos (de pie o sentados) o inactivos (decúbito esternal o lateral).

No obstante, la mayoría de estos desarrollos se han concentrado en el ganado bovino. Investigaciones recientes (Ungar & Nevo, 2025), (Becker et al., 2021), (Wagner, Antoine, et al., 2020) han propuesto métodos basados en tres técnicas principales: (i) identificación de patrones del hocico, (ii) reconocimiento facial, y (iii) reconocimiento corporal. Estrés bovino

El estrés en bovinos se refiere a una respuesta fisiológica y comportamental que experimentan cuando se enfrentan a situaciones que perciben como amenazantes o desafiantes para su bienestar. Es una reacción natural del sistema nervioso y endocrino de los bovinos ante ciertos estímulos estresantes en su entorno. Según Alux Nutrition (2021), como se citó en Odeón & Romera (2017), mencionan que, según términos académicos, el estrés se define como la respuesta biológica que se produce cuando un individuo percibe una amenaza a su equilibrio interno, conocido como homeostasis. Este proceso se desarrolla en tres etapas consecutivas:

- **Fase de alarma simpática** (breve y fugaz): En esta etapa, el organismo detecta una amenaza o un estresor y se prepara para enfrentarla. Durante esta fase, se

produce una respuesta de "lucha o huida".

- **Fase de resistencia** (prolongada, estrés): En esta etapa, el cuerpo intenta adaptarse a las demandas del estrés continuo. Los niveles de hormonas como el cortisol pueden permanecer elevados durante más tiempo. El organismo continúa lidiando con la amenaza, pero sus recursos se agotan gradualmente.
- **Fase de agotamiento** (pérdida de la adaptación y ruptura del estado de salud, conocida como distrés): los bovinos pueden experimentar problemas de salud más graves, como enfermedades, trastornos del comportamiento y una reducción significativa en su bienestar general.

Los factores o estímulos que perturban la homeostasis se llaman agentes estresantes o estresores. Estos pueden categorizarse en tres grupos según su naturaleza, duración e intensidad. En función de la duración de la respuesta que generan, se dividen en agudos (simples y de corta duración) y crónicos (de larga duración).

Las causas del estrés en bovinos generalmente pueden ser:

- **Ambientales:** Factores como el clima extremo, las condiciones de alojamiento inadecuadas, el ruido y la exposición a depredadores pueden causar estrés en los bovinos (PALMA, 2023).
- **Nutrición:** Dietas desequilibradas o cambios bruscos en la alimentación pueden causar estrés metabólico en los bovinos.
- **Manejo:** Prácticas de manejo inadecuadas, como el transporte, el destete, la separación de terneros y vacas, y los procedimientos médicos invasivos, pueden causar estrés en los bovinos (PALMA, 2023).
- **Social:** La jerarquía social en el grupo puede ser una fuente de estrés, especialmente cuando se introducen nuevos bovinos en un rebaño.

El estrés en animales se manifiesta por variaciones en comportamientos, fisiologías y sistema inmune bajo, tal como se ilustra en la Figura 2 Signos visibles y consecuencias del estrés.:

- Comportamentales: Los bovinos estresados pueden mostrar agitación, inquietud, vocalizaciones excesivas, lamido excesivo o comportamiento de escape.
- Fisiológicas: El estrés puede manifestarse a través de cambios en la frecuencia cardíaca, la respiración y la temperatura corporal, así como una disminución en la ingesta de alimentos.
- Inmunosupresión: El estrés prolongado puede debilitar el sistema inmunológico de los bovinos, haciéndolos más susceptibles a enfermedades.




Figura 2 Signos visibles y consecuencias del estrés.
Adaptado de (Toledo et al., 2022)

2.3.2. Constantes fisiológicas en bovinos.

Las constantes fisiológicas son indicadores que permiten evaluar el estado de salud de un animal mediante sus funciones vitales, cuando una de estas constantes está fuera de

los valores normales, puede ser un signo de que algo dentro del animal no se encuentra bien (Contexto, 2023). Entre las constantes más importantes de los bovinos están las siguientes:

- **Temperatura corporal:** Se mide mediante un termómetro veterinario, vía rectal. La temperatura promedio es de 38,5 °C, oscilando entre 38,2 y 39,5 °C, según el clima y las condiciones ambientales.
- **Frecuencia cardíaca:** Se mide mediante la palpación del pulso en la arteria femoral. La frecuencia cardíaca promedio es de 60 a 80 latidos por minuto en bovinos adultos.
- **Frecuencia respiratoria:** Se mide mediante la observación del movimiento del tórax. La frecuencia respiratoria promedio es de 15 a 20 respiraciones por minuto en bovinos adultos.
- **Movimientos rúmiales:** Se evalúan mediante palpación del flanco izquierdo para percibir las contracciones del rumen. La frecuencia ruminal normal en un bovino adulto sano y en reposo oscila entre 1 y 1.5 contracciones por minuto. Una frecuencia persistentemente inferior a 1 contracción por minuto puede indicar hipofunción ruminal (por ejemplo, en casos de malestar, fiebre o acidosis), mientras que una frecuencia elevada es menos común.

2.3.3. Tipos de estrés en bovinos

El estrés es una respuesta fisiológica de los seres vivos, en el contexto de los bovinos estas acciones son desencadenadas a causa de diferentes factores, los mismos que son clasificados de acuerdo con el tipo de estrés (Tabla 8 Tipos de estrés presentes en bovinos), clasificaciones, así como las causas que originan o inician síntomas que padecen los animales, ocasionando consecuencias tanto en el animal como para los agroganaderos encargados de su crianza y cuidado (Contexto Ganadero, 2023).

Tabla 8 Tipos de estrés presentes en bovinos

Tipo	Causa	Síntomas	Consecuencias
Calórico	• Las temperaturas extremas son altas o bajas.	• Disminución de la ingesta de alimento y el tiempo de rumia.	
	• Tiempo de exposición al sol	• Aumento del consumo de agua.	• Disminución de producción de leche
	• Falta de refugios con sombra.	• Aumento de la temperatura interna y la frecuencia respiratoria.	• Baja fertilidad
	• Humedad ambiental		
Hídrico	• Exceso de humedad causa malestar en los animales.		• Se produce fatiga y agresividad constante.
	• El barro a causa de lluvias dificulta la movilidad.	• Aumento de inquietud.	• La actividad en el bovino disminuye a causa de las bajas temperaturas.
	• La presencia de paracitos.	• La temperatura disminuye, da frío.	• Enfermedades por bacterias
	• Falta de descanso debido a la dificultad de acostar, descansar, sentar.	• Mayor presencia de parásitos.	• Cojeras severas
Nutricional		• Pérdida de calor.	• Pérdida de peso
	• Falta de alimentos	• El cuerpo lúteo del útero es menos pesado.	• Baja calidad de leche
	• Escasez de nutrientes necesarios en la comida diaria	• Problemas gastrointestinales	• Baja fertilidad
		• Pérdida del pelaje o brillo	• Incremento de enfermedades.
Manejo		• Cambio en el comportamiento alimenticio.	• Dificultad de recuperar la condición corporal
	• Cambio constante de personal de cuidado animal	• Nerviosismo e inquietos	• Agresividad hacia los cuidadores o ganaderos.
	• Tratos bruscos	• Mugidos frecuentes	• Resistencia al manejo.
	• Corrales	• Aumento en la respiración y frecuencia cardíaca	• Pérdida de peso
	• Separación de la manada.	• Presencia de sudor	• Lesiones
	• Transporte	• Los bovinos babean o salivan de manera excesiva.	• Baja reacción inmunitaria.
	• Movilización excesiva		

Fuente: Tomado de (Contexto Ganadero, 2023).

Se debe tomar en cuenta que el estrés en bovinos es un fenómeno subjetivo, ya que los factores estresantes se mantienen en constante cambio y se pueden abordar de diversas maneras, así como diferentes niveles de intensidad dependiendo de los factores estresores. Para tener una mejor comprensión sobre el estrés en los bovinos, se debe tener muy claro que cada ser vivo percibe las cosas o se encuentra en un medio ambiente diferente al de otro, permitiendo experimentar situaciones de manera individual y única. Los factores estresantes varían de acuerdo con la personalidad del individuo, su historia y experiencias.

2.3.4. Índices de estrés

Los dos índices de estrés más comunes en bovinos son el ITH y SFT (Figura 3 Índice de temperatura humedad (ITH).Figura 4 Sensación térmica en frío.), los mismos que están orientados uno para el verano y otro para el frío respectivamente.

A) Índice de temperatura humedad (ITH)

Fue adaptado por Berry en 1964 para ser utilizado en bovinos, el ITH es una métrica que se utiliza para determinar si las condiciones medioambientales son estresantes para los bovinos, los parámetros que se consideran son temperatura del aire, entre ellas la humedad relativa que permite estimar en nivel de estrés, tomando en cuenta que todo depende del tiempo que se encuentra expuesto y la frecuencia variando según sea para bovinos de carne o lecheros (Arias et al., 2020). La Figura 3 Índice de temperatura humedad (ITH).muestra los valores de ITH para bovinos.

B) Sensación térmica por frío (SFT)

También conocido como el índice de enfriamiento por viento enfocado directamente a los climas fríos, que indica la temperatura que percibe el cuerpo al mantenerse expuesto al frío y el viento (Gibbens, 2024).

Se debe tener en cuenta que esta sensación térmica en bovinos se refiere a lo que percibe el animal. Una exposición extensa a bajas temperaturas puede afectar negativamente en la salud, bienestar y productividad. (ver Figura 4 Sensación térmica en frío.)




Figura 3 Índice de temperatura humedad (ITH).

Fuente: *Producir XXI* (<https://producirxxi.com.ar/producirxxi/rangos-de-humedad-y-temperatura-y-estres-calorico-en-vacas-de-tambo/>).




Figura 4 Sensación térmica en frío.

Fuente: https://en.wikipedia.org/wiki/Wind_chill

2.3.5. Fisiología del estrés por frío en bovinos

El estrés por frío en bovinos ocurre cuando las temperaturas ambientales descienden por debajo de su zona termoneutral, desencadenando una serie de mecanismos de termorregulación para mantener la homeostasis corporal (Figura 5 Representación esquemática de las condiciones ambientales críticas para la sobrevivencia animal.). La exposición prolongada a ambientes fríos conduce a cambios fisiológicos significativos, incluyendo incrementos en la frecuencia cardíaca, temperatura rectal y respiración profunda, así como un aumento en los requerimientos energéticos del animal (Kim et al., 2023). La temperatura crítica inferior, que generalmente se encuentra entre 0°C y 21°C dependiendo de factores como edad, condición corporal y raza, marca el límite donde el animal debe incrementar su producción de calor metabólico (Bickert, 2011). A nivel endocrinológico, se observa un aumento significativo del cortisol sanguíneo como respuesta al estrés agudo, hormona que regula la simpatía neural y se correlaciona con indicadores fisiológicos como la frecuencia cardíaca y temperatura rectal (Kim et al., 2023). Metabólicamente, los bovinos expuestos a frío severo muestran alteraciones en los niveles de glucosa y ácidos grasos no esterificados (NEFA), utilizando tanto glucosa como nutrientes almacenados como fuentes de energía para mantener los mecanismos de producción de calor (Kim et al., 2023). El estrés por frío incrementa significativamente las necesidades energéticas de los animales, y sin una ingesta energética suficiente, esto puede conducir a pérdida de peso y disminución de la condición corporal (Taramuel Andrade et al., 2024). Conductualmente, los bovinos bajo estrés por frío aumentan el tiempo de permanencia en posición de pie y disminuyen el tiempo de descanso, maximizando así el área superficial efectiva para la disipación de calor desde la superficie corporal.




Figura 5 Representación esquemática de las condiciones ambientales críticas para la supervivencia animal.

2.3.6. Ciclo circadiano

Se comprende como un fenómeno biológico que permite la regularización de los ritmos fisiológicos y de comportamiento en un periodo de 24 horas. A nivel interno, este ciclo ayuda a mantener la sincronización de procesos corporales; en el caso de los animales, permite el control de sueño, la actividad, alimentación, producción de hormonas y temperatura corporal conforme se cambia el ciclo de día y noche.

Identificar alteraciones en el ritmo circadiano podría servir para detectar casos de estrés o enfermedad y, a su vez, incitar a los cuidadores de bovinos a abordar tales problemas, determinar sus causas y tomar medidas correctivas. (Wagner, Mialon, et al., 2020).

2.3.7. Monitoreo y control animal

En monitoreo y control animal es muy importante en la gestión y bienestar animal de diversas especies, es por ello por lo que la capacidad de seguir de cerca el comportamiento de los bovinos, así como su ubicación y la salud misma de estos,

proporciona datos importantes que pueden ser analizados, obteniendo así información valiosa para garantizar su seguridad y mejorar la toma de decisiones en la parte administrativa, así como la producción en algunos casos (Leandro, 2023).

Los collares de monitoreo animal son una herramienta esencial para la recopilación en tiempo real de datos, estos dispositivos ofrecen la posibilidad de rastrear algunos parámetros, en este caso los *Nedap CowControl* (ver Figura 6 Nedap CowControl™) permiten medir la distribución de las 24 horas de una vaca para determinar aspectos como detección de celo, ingesta, rumia, comportamiento de pie, tumbada o caminando (Nedap Livestock Management, 2023). Estos dispositivos combinan un rango sin precedentes de características que permiten la monitorización y herramientas de manejo y gestión, a través de sensores inteligentes denominados “SMART TAGS” que se encuentran integrados con un software que permite a los múltiples usuarios acceder a la información relevante, en tiempo real y de cualquier lugar o dispositivo inteligente.



Figura 6 Nedap CowControl™

Fuente: Extraído de (Nedap Livestock Management, 2025).

Las informaciones obtenidas para un monitoreo y control de bienestar del bovino por los sensores provienen de rumia, comida, descanso, conducta social, temperatura corporal, y otros indicadores (comportamientos).

- A) **Rumia.** La rumia es el proceso de masticación y digestión de alimentos regurgitados en los rumiantes como las vacas. Es un indicador clave de la salud digestiva y el bienestar general del animal (Suárez V. Humberto & Martínez

G. Marcela, 2020). Un buen tiempo de rumia es esencial para la correcta digestión y la absorción de nutrientes. Cambios en los patrones de rumia pueden indicar problemas de salud como trastornos digestivos o estrés.

- B) **Comida.** Este indicador monitorea el tiempo y la frecuencia con que el animal se alimenta (Suárez V. Humberto & Martínez G. Marcela, 2020). Una ingesta adecuada de alimentos es crucial para la producción de leche y la salud general del ganado. Disminuciones en el consumo de alimento pueden ser un signo temprano de enfermedades o problemas metabólicos.
- C) **Descanso.** Es el tiempo que el animal pasa acostado, lo cual es un comportamiento natural y necesario para su bienestar (Gjergji et al., 2020). El descanso adecuado es vital para la salud física y la productividad del ganado.
- D) **Conducta social.** Las interacciones entre los animales, se consideran interacciones sociales que pueden ofrecer información sobre el bienestar emocional y social del ganado, así como sobre la jerarquía dentro del grupo (Da & Rodrigues, 2022).
- E) **Temperatura corporal.** Algunas versiones avanzadas del collar también pueden medir la temperatura corporal. La temperatura corporal es un indicador crucial de la salud, y cambios en la temperatura pueden ser un signo temprano de infección o enfermedad (Chung et al., 2020). Estos indicadores permiten a los ganaderos monitorear de manera más precisa y efectiva la salud y el bienestar de sus animales, facilitando la detección temprana de problemas y mejorando la gestión del rebaño.
- F) **Otros indicadores.** Monitorea el nivel de actividad del animal, incluyendo

movimientos y desplazamientos (Da & Rodrigues, 2022). Los niveles anómalos de actividad pueden ser indicativos de problemas de salud o bienestar. Por ejemplo, un aumento en la actividad puede ser un signo de celo, mientras que una disminución puede indicar enfermedad o incomodidad.

2.4 Ganadería de precisión

La Ganadería de Precisión (GDP) constituye un sistema de producción sostenible que integra las ciencias animales con tecnologías de información y comunicación para optimizar la eficiencia productiva (García, 2020). Este enfoque ha revolucionado la gestión ganadera mediante el monitoreo en tiempo real de parámetros clave como salud, comportamiento y nutrición del ganado.

La aplicación de dispositivos como sensores, GPS y sistemas de información geográfica permite recopilar datos precisos sobre ubicación, estado sanitario y alimentación de los animales. Esta información facilita la toma de decisiones basada en evidencia para mejorar la productividad, sostenibilidad y bienestar animal. Un ejemplo concreto se observa en el ámbito nutricional, donde sensores ambientales registran temperatura y humedad en pastizales, ayudando a detectar estrés calórico que afecta directamente el consumo de forraje y la termorregulación corporal del ganado.

2.5 Técnicas de Inteligencia artificial

Por un lado, la IA puede mostrar máquinas que pueden razonar, reconocen y también son creativas; al mismo tiempo, hacen posible para las personas analizar los datos de una manera mucho más profunda y precisa (Pedraza Caro, 2023) por técnicas de minería de datos. Aquí se presenta un marco integral de técnicas de IA que articula, de lo general a lo específico, el ciclo completo para extraer valor de los datos en ganadería de precisión. Inicia con la metodología CRISP-DM, que estructura el proceso en seis etapas desde la comprensión del problema y de los datos, hasta la preparación, modelado, evaluación e implementación, asegurando trazabilidad y calidad en cada fase. Sobre esa base, se precisan los fundamentos de la minería de datos, las etapas

operativas para convertir grandes volúmenes de información en conocimiento accionable, y el reconocimiento de patrones, como disciplina que permite identificar regularidades y clasificar objetos a partir de sus rasgos distintivos. A continuación, se acota el aprendizaje automático supervisado, no supervisado y semi supervisado y el aprendizaje profundo, como familia de métodos de múltiples niveles de representación capaces de modelar relaciones complejas.

Luego, se sintetizan los algoritmos más usados en ML, regresiones, árboles de decisión, bosques aleatorios, Naive Bayes, SVM, k-NN, k-means, PCA y GBM, destacando su tipo, familia y rasgos prácticos para guiar su selección. Finalmente, se traslada este repertorio al dominio pecuario mediante una revisión de 52 estudios recientes que evalúan desempeño con métricas como precisión y sensibilidad. De ese examen comparado se desprende que Random Forest sobresale por su robustez y capacidad predictiva en escenarios de clasificación y predicción típicos de la ganadería de precisión. Este apartado, en suma, provee el andamiaje metodológico y algorítmico que sustenta las decisiones técnicas del estudio y orienta la elección del modelo en función del problema, los datos y los criterios de evaluación.

En este contexto, el marco propuesto se orienta a transformar datos heterogéneos en decisiones operativas para anticipar y gestionar eventos que afectan el bienestar y la productividad, mediante alertas tempranas, umbrales de intervención y priorización de animales y tácticas de manejo con sustento cuantitativo. La necesidad de este enfoque radica en la elevada variabilidad animal-ambiental y en la complejidad de los patrones subyacentes, que exigen modelos capaces de aprender relaciones no lineales y temporales con garantías de trazabilidad y evaluación rigurosa. El corpus de datos comprende señales de collares y sensores (rumia, ingesta, actividad/descanso), variables microclimáticas (temperatura, humedad/THI, viento, precipitación), indicadores productivos (litros/vaca/día), registros sanitarios (eventos y tratamientos), información contextual (lote/potrero, georreferencia, calendario) y etiquetas de referencia del estado/estrés a partir de observaciones veterinarias o criterios validados; con ello, se habilita la construcción, validación y despliegue de modelos que reduzcan

pérdidas, optimicen recursos y estandaricen la toma de decisiones en ganadería de precisión.

2.5.1. Metodología de análisis de la data

Proceso estándar intersectorial para la minería de datos (CRISP-DM: Cross-Industry Standard Process for Data Mining) se refiere a una metodología que actualmente está siendo muy utilizada en lo que respecta a la minería de datos y el análisis predictivo, de tal manera que es considerada la más estructurada y eficaz. Su uso incluye 6 etapas que se deben llevar a cabo para la aplicación correcta y efectiva de esta metodología, ofreciendo una estructura clara que permita asegurar la calidad de cada uno de los procesos y maximizar la calidad de los resultados obtenidos (Miller et al., 2020).

Gabriela et al. (2021) en su artículo denominado “Metodología CRISP-DM en la gestión de proyecto de Data Mining. Caso enfermedades dermatológicas” menciona y describe cada una de las etapas del CRISP-DM, las cuales son:

- **Comprensión del problema:** en esta etapa se debe establecer de manera clara y precisa el objetivo que se desea alcanzar, así como los límites y alcance del proyecto.
- **Comprensión de los datos:** se debe realizar un acercamiento para tener conocimiento del problema, transformándolo en un objetivo cuantificable y medible.
- **Preparación de los datos:** se realiza la depuración, transformación y mejora de estos orientándolos hacia el objetivo del proyecto.
- **Modelado:** aquí se procede a utilizar los datos que permitirán realizar el análisis estadístico, modelización y minería de datos correspondiente.
- **Evaluación:** se realizan las evaluaciones y validación de los resultados

posteriores al análisis mediante técnicas y métricas.

- **Implementación:** finalmente se implementa la solución de acuerdo con los resultados obtenidos y el monitoreo correspondiente al desempeño.

2.5.2. Minería de datos

La minería de datos se adopta como eje metodológico para el fenómeno de interés, la detección y anticipación del estrés por frío en ganadería de precisión, la cual produce grandes volúmenes de datos heterogéneos, multifuente y temporales, con ruido, valores faltantes, colinealidad y patrones no lineales difíciles de identificar con métodos convencionales. Estas técnicas permiten integrar, depurar y transformar los registros; ingenierizar y seleccionar atributos; reducir la dimensionalidad para mejorar estabilidad; y descubrir regularidades útiles para estratificar riesgo y entrenar modelos predictivos con validación rigurosa. Asimismo, habilitan trazabilidad y reproducibilidad mediante pipelines auditables, explicabilidad (importancia de variables, curvas de desempeño) y criterios de generalización que aseguran utilidad operativa en la toma de decisiones. En suma, la minería de datos convierte datos en evidencia accionable para decisiones robustas y transparentes, tal como la literatura la reconoce dentro del conjunto de herramientas analíticas para explorar, categorizar y resumir relaciones en grandes bases de datos (Coppola, 2023).

En la minería de datos, se pueden identificar cinco etapas clave:

- **Definición de Objetivos y Recopilación de Datos:** En esta fase inicial, se determina el propósito de la minería de datos, estableciendo qué información es necesaria recolectar.
- **Procesamiento y Gestión de Datos:** Esta etapa puede ser compleja, ya que implica seleccionar una muestra representativa para el análisis y determinar qué variables o modelos de regresión se utilizarán.

- **Selección del Modelo:** Se trata de desarrollar un modelo o algoritmo que genere resultados óptimos, para ello se realiza un análisis exhaustivo de las variables que se incorporarán al modelo, dependiendo de la naturaleza de los datos.
- **Análisis y Evaluación de Resultados:** Aquí se analizan los resultados obtenidos para asegurarse de que ofrecen una explicación lógica y útil. Estos resultados deben respaldar la toma de decisiones basadas en la información proporcionada.
- **Actualización del Modelo:** La última etapa del proceso implica la actualización continua del modelo. Esto es esencial para evitar que se vuelva obsoleto con el tiempo, ya que las variables pueden cambiar su relevancia.

2.5.3. Reconocimiento de patrones

El reconocimiento de patrones es una disciplina que se dedica a identificar y clasificar objetos o datos en grupos basándose en las características distintivas que poseen. En este proceso, se busca reconocer formas, figuras o patrones en los objetos estudiados, asignándolos a clases específicas en función de sus atributos conocidos. Esto permite obtener información valiosa sobre los objetos analizados y facilita su categorización en grupos con características similares, todo ello a través del análisis y comprensión de patrones previamente definidos (CEUPE, 2022).

El reconocimiento de patrones desempeña un papel fundamental y se vincula estrechamente con la inteligencia artificial. La detección de características y patrones contribuye a la creación de programas más efectivos, eficientes y comprensibles. La inteligencia artificial se beneficia significativamente de estas técnicas, ya que, al reconocer patrones en grandes conjuntos de datos, puede aprender y tomar decisiones basadas en características, lo que impulsa el desarrollo de sistemas inteligentes y autónomos. El reconocimiento de patrones constituye el puente operativo entre los datos multifuente de ganadería de precisión y los modelos predictivos: permite extraer

y representar regularidades en series temporales de comportamiento y microclima que luego alimentan los algoritmos de aprendizaje automático para clasificar y anticipar estados de estrés por frío. Su relevancia se inserta explícitamente en el flujo metodológico propuesto desde CRISP-DM y minería de datos hasta ML/Deep Learning como la capa que convierte señales en atributos discriminativos antes del modelado y la evaluación, asegurando trazabilidad entre datos, características y métricas de desempeño (Santana et al., 2025).

Los rasgos circadianos derivados de FFT y la coherencia día–noche emergen entre los predictores más influyentes del sistema, evidenciando que la identificación y cuantificación de patrones temporales no solo mejora la capacidad explicativa, sino que incrementa la potencia predictiva del modelo frente a métodos basados en umbrales ambientales. En conjunto, esta articulación justifica el uso de reconocimiento de patrones como componente crítico para transformar datos sensoriales en evidencia accionable y sostener decisiones preventivas en campo.

2.5.4. Aprendizaje automático

El aprendizaje automático (AA) es denominado un campo de la inteligencia artificial con la capacidad de permitir a los sistemas informáticos tener un aprendizaje constante que mejora continuamente gracias a las experiencias que vaya generando y datos disponibles, sin la necesidad de encontrarse programados directamente. Dicho de otra manera, se refiere a la capacidad de los sistemas para la identificación de patrones y regularidades en los datos y de la capacidad de utilizarlos para realizar predicciones futuras que permiten la toma de decisiones (Pineda Pertuz, 2022).

En el contexto de la ganadería, el aprendizaje automático puede revolucionar aún más la gestión, al permitir a las máquinas analizar patrones y tomar decisiones precisas basadas en datos históricos, mejorando la productividad y la eficiencia en la cría de bovinos de manera sin precedentes. Existen varios tipos de aprendizaje automático (o machine learning), entre ellos se tienen:

- A) **Aprendizaje supervisado.** El aprendizaje supervisado utiliza conjuntos de datos etiquetados para entrenar modelos. Hay dos tipos de modelos de aprendizaje supervisado: los de clasificación, que producen una etiqueta discreta para clasificar datos en un conjunto finito de etiquetas, y los de regresión, que producen un valor real como salida (Robotics, 2021).
- B) **Aprendizaje no supervisado.** El aprendizaje no supervisado se aplica a datos no etiquetados para extraer conocimiento o agrupar entidades por afinidad. Los algoritmos no supervisados pueden usarse para reducir la dimensionalidad o simplificar conjuntos de datos, y también se utilizan en clustering para encontrar clientes con características similares. Los algoritmos de reducción de la dimensionalidad se emplean con el propósito de disminuir el número de atributos en un conjunto de datos. Aunque no hay una etiqueta para predecir, los algoritmos deben definir una métrica de similitud o distancia para comparar los datos entre sí. El aprendizaje no supervisado también se aplica en el descubrimiento de tópicos o detección de anomalías (van Engelen & Hoos, 2020).
- C) **Aprendizaje semi supervisado.** El aprendizaje semi supervisado combina elementos del aprendizaje supervisado y no supervisado. Este enfoque se aplica cuando no se dispone de un conjunto de datos completamente etiquetado. Primero, se etiquetan manualmente algunos de los datos y se entrena uno o varios algoritmos supervisados, luego se utilizan los modelos para etiquetar el resto de los datos. Finalmente, se entrena un modelo supervisado utilizando las etiquetas generadas y las etiquetas manuales. Un ejemplo de aplicación es el análisis de sentimientos en las redes sociales para estudiar la imagen de marca de una empresa (van Engelen & Hoos, 2020).

2.5.5. Algoritmos de aprendizaje automático

Según artículos de Arya (2022) en KDnuggets y Ray (2024) en Analytics Vidhya, que tratan sobre los algoritmos más utilizados de Machine Learning, los algoritmos incluidos en la Tabla 9 Comparativa de algoritmos de ML., como Regresión Lineal (RL / LR), Regresión Logística (RLog / LogR), Árboles de Decisión (AD / DT), Bosques Aleatorios (BA / RF), Naive Bayes (NB), Support Vector Machine (SVM), K-Vecinos más Cercanos (k-NN / KNN), *k-means* (k-means / KM), Análisis de Componentes Principales (ACP / PCA), Gradient Boosting Machine (GBM) y Long Short-Term Memory (LSTM). En conjunto, abarcan desde métodos lineales y probabilísticos hasta enfoques no lineales y de ensamble, así como técnicas no supervisadas para agrupamiento y reducción de dimensionalidad, cubriendo la mayoría de las necesidades típicas en clasificación, regresión, descubrimiento de estructuras y preprocesamiento.

En problemas aplicados, por ejemplo, en ganadería de precisión los modelos supervisados (RL/LR, RLog/LogR, AD/DT, BA/RF, NB, SVM, k-NN, GBM, LSTM) permiten predecir estados o valores a partir de variables observadas; los no supervisados (k-means/KM, ACP/PCA) ayudan a explorar patrones latentes y simplificar los datos; y los de aprendizaje profundo, como LSTM, destacan en series temporales y secuencias al modelar dependencias de largo plazo con mayor fidelidad que métodos clásicos. Esta familia proporciona un portafolio equilibrado entre interpretabilidad, rendimiento y escalabilidad, facilitando la selección informada según el tipo de dato, objetivo y métricas de evaluación.

La Tabla 9 Comparativa de algoritmos de ML. organiza los algoritmos por paradigma (supervisado/no supervisado) y familia, y sintetiza sus supuestos y capacidades: RL/LogR como líneas base explicables (linealidad y probabilidades); Árboles y ensambles (RF) para no linealidades, variables mixtas e importancia de atributos; NB rápido pero dependiente de independencia condicional; SVM eficaz con márgenes en alta dimensión (requiere escalado y elección de kernel); KNN simple y no paramétrico pero sensible a escala, ruido y al valor de k ; LSTM para dependencias temporales de

corto y largo plazo en series; k-means para segmentación por similitud; y PCA para reducción de dimensionalidad (asumiendo relaciones lineales). En conjunto, el cuadro revela los trade-offs entre desempeño, interpretabilidad, supuestos y costo de ajuste.

Tabla 9 Comparativa de algoritmos de ML.

Algoritmo	Tipo	Familia	Características
RL/LR	Supervisado	Algoritmos de regresión	• Usado principalmente en problemas de regresión. • Estima valores a partir de una o varias variables. • Estima la relación entre variables mediante una línea recta. • Ajusta la mejor línea entre variables independientes y dependientes. • Es de dos tipos: simple y múltiple. • Es paramétrica.
RLog / LogR	Supervisado	Algoritmos de regresión	• Algoritmo de clasificación. • Usado para estimar valores discretos. • Predice la probabilidad de un evento. • Valores de salida entre 0 y 1. • Se divide en tres tipos: binaria, multinomial y ordinaria.
AD / DT	Supervisado	Árboles de decisión	• Usado en problemas de clasificación y regresión. • Funciona con variables dependientes, categóricas y continuas. • Divide la población en dos conjuntos homogéneos. • Muestra las entradas y los posibles resultados. • No paramétrico. • Estructura jerárquica.
BA / RF	Supervisado	Algoritmos combinados o ensamble.	• Usado en problemas de clasificación y regresión. • Bosque de árboles de decisión. • Tareas de regresión con variables continuas. • Tareas de clasificación con variables categóricas.
NB	Supervisado	Algoritmos probabilísticos	• Se basa en el teorema de Bayes. • Calcula probabilidades condicionales. • Trabaja con datos de alta dimensión. • Trabaja con datos categóricos y continuos. • Multiclase. • No es efectivo para modelar relaciones complejas.

SVM	Supervisado	Aprendizaje basado en instancias.	• Método de clasificación y regresión. • Analiza datos a partir de numerosos campos predictivos. • Correlación de datos en un espacio de características. • Utiliza un hiperplano de separación óptima. • Clasificación binaria. • Evita el sobreajuste de los datos.
Knn	Supervisado	Aprendizaje basado en instancias.	• Método de clasificación y regresión. • Utiliza el concepto de similitud entre puntos dependiendo de su proximidad. • No construye un modelo. • Trabaja en función de la similitud entre instancias. • K es un hiperparámetro crítico. • Utiliza medidas de similitud. • Sensible a escalas. • Sensible a ruidos y valores atípicos. • Implementación sencilla
LSTM	Supervisado.	Redes Neuronales Recurrentes	• celdas con puertas de entrada, olvido y salida que controlan el flujo de información y la memoria. • modela dependencias de corto y largo plazo en secuencias (series temporales, texto, sensores) mitigando el desvanecimiento del gradiente. • many-to-one (p. ej., clasificación de secuencias), one-to-many (generación), many-to-many (traducción, etiquetado).
k-means	No supervisado.	Algoritmos de clustering	• Técnica de agrupamiento basada en similitud. • Grupos de datos homogéneos y heterogéneos. • Determina el valor k mediante el método de codo o silueta. • Encuentra patrones o estructuras por sí mismos en función de su distancia entre datos y centroides. • Escalabilidad.
PCA	No supervisado.	Algoritmos de reducción de dimensiones	• Transforma un conjunto de datos en un nuevo espacio de menor dimensión. • Independiente de clases o categorías. • Suposición de relaciones lineales. • Componentes principales a partir de combinaciones lineales. • Sensible a la escala. • Interpretación de componentes principales. • Reducción de ruido.
GBM	Supervisado	Gradient Boosting	• Problemas de clasificación y regresión. • Entrenamiento secuencial. • Minimiza la fusión de pérdida.

- Previene el sobreajuste y mejora la generalización del modelo.
 - Eficaz con datos desbalanceados.
 - Necesita una configuración adecuada de hiperparámetros.
-

La Tabla 9 Comparativa de algoritmos de ML. proporciona un marco de referencia fundamental para la selección metodológica en esta investigación, al establecer una correspondencia sistemática entre las características de los algoritmos de aprendizaje automático y los requisitos del problema de estudio. Esta comparativa permite justificar técnicamente la elección de modelos específicos como LSTM para el análisis de secuencias temporales de sensores, Random Forest o Gradient Boosting para datos tabulares con relaciones no lineales, o Regresión Logística como línea base en función de la naturaleza de los datos disponibles (series temporales, variabilidad individual animal-climática, posibles relaciones no lineales y desbalance de clases).

Justificación de algoritmos para detección de Estrés por Frío

La selección de algoritmos para esta investigación se fundamenta en las propiedades específicas que presentan los datos de estrés por frío en condiciones alto andinas. Los registros conforman series temporales multivariadas de variables conductuales y ambientales durante períodos prolongados, lo que genera dependencias temporales complejas, incluyendo patrones circadianos y efectos acumulativos. Esta estructura temporal multivariada hace que los algoritmos de LSTM (Long Short-Term Memory) sean particularmente adecuados, ya que están específicamente diseñados para capturar dependencias a largo plazo en datos secuenciales y modelar la naturaleza acumulativa del estrés por frío. Simultáneamente, la presencia de variables mixtas (numéricas y categóricas) y ruido inherente en las mediciones de campo justifica la inclusión de Random Forest y Gradient Boosting Machines, algoritmos reconocidamente robustos para manejar este tipo de datos heterogéneos y resistentes a las variaciones propias de los entornos productivos reales.

2.6 Marco Ético

El presente trabajo se ha resultado y redactado, siguiendo las normas y conductas responsables en investigación, recomendadas por el Consejo Nacional de Ciencia, Tecnología e Innovación Tecnológica CONCYTEC, en su curso: CONDUCTA RESPONSABLE EN INVESTIGACIÓN (curso de autoaprendizaje). De acuerdo con Tractenberg citado en (Polo Jiménez et al., 2010) afirma que: Aunque las leyes pertinentes suelen ser claras (lo que no impide ¡comportamientos ilegales!), nos centramos en las circunstancias más difíciles que rodean y complican las decisiones que se sitúan en el continuo de lo ético a lo no ético. En algunos casos, los perjuicios que se derivan de decisiones contrarias a las normas de la práctica ética son evidentes, pero el punto exacto en el que el comportamiento se desvía de lo que el profesional ético debería hacer/haber hecho está menos (o nada) claro. Aunque algo sea legal, eso no impide que algunos sufran daños como consecuencia de nuestras acciones y decisiones. En esos casos, los daños deben mitigarse o deshacerse, si es posible. En otros casos, sin embargo, las decisiones aún no se han tomado, por lo que es más difícil averiguar.

2.7 Síntesis del Capítulo II

Este capítulo, consolida los fundamentos teóricos de esta tesis al alinear el trabajo con una postura científico, realista y una epistemología empirista/positivista, estableciendo que los datos observables y medibles, junto con los modelos predictivos, pueden capturar fielmente las respuestas bovinas al estrés térmico por frío. Define los constructos centrales que el estudio operacionalizará el estrés térmico por frío en ganado lechero, el monitoreo biométrico y ambiental, basada en IoT, y las metodologías de minería de datos como CRISP-DM, enmarcando así la base conceptual para la solución propuesta. El capítulo también examina los antecedentes relevantes y las bases técnicas, incluyendo las técnicas biométricas para la evaluación de la salud y el bienestar, así como las definiciones formales del estrés bovino, para motivar el uso de enfoques de aprendizaje automático en este dominio.

CAPÍTULO III. INSTRUMENTACIÓN Y MÉTRICAS PARA MONITOREO DE ESTRÉS POR FRÍO EN GANADO LECHERO

La ganadería de precisión representa un paradigma transformador en la producción animal, sustentado en el monitoreo automatizado mediante tecnologías de sensores inteligentes que permiten la transición de un manejo reactivo a uno preventivo (Becker et al., 2021; Wathes et al., 2008). Este ecosistema tecnológico integra dispositivos que capturan datos fisiológicos, conductuales y ambientales en tiempo real, generando métricas derivadas como patrones de actividad y ritmos circadianos. La integración de estas fuentes de datos multimodales con técnicas de inteligencia artificial y aprendizaje automático -especialmente aprendizaje profundo- permite procesar grandes volúmenes de información superando incertidumbres en los datos, facilitando así la detección temprana y objetiva del estrés (Fuentes et al., 2022; Neethirajan, 2022).

La aplicación específica de estas tecnologías incluye collares con acelerómetros, sensores de temperatura cutánea y dispositivos que monitorizan frecuencia cardíaca y parámetros ambientales (Darvesh et al., 2023; Davison et al., 2020). Estos sistemas permiten un enfoque personalizado para la detección del estrés, crucial dada la variabilidad individual en la susceptibilidad animal y los desafíos impuestos por el cambio climático (Islam et al., 2020). Si bien se han desarrollado aplicaciones avanzadas para estrés calórico utilizando índices como THI, el monitoreo del estrés por frío en sistemas ganaderos de altura representa un campo notablemente subexplorado, debido a la multidisciplinariedad del contexto del trabajo, el estado de arte es abordado y vinculados desde las diferentes disciplinas.

3.1. Fundamentos de la Ganadería de Precisión para el Monitoreo del Bienestar Animal.

La ganadería de precisión ha experimentado un auge significativo en los últimos años,

impulsado por el despliegue de sensores IoT y análisis de datos en tiempo real, lo que ha transformado el monitoreo del bienestar animal en bovinos y aves (Lin et al., 2023). Investigaciones recientes, como las de Becker et al. (2021) y Lardy et al. (2023), destacan cómo estos sistemas integran RFID, acelerómetros y cámaras para capturar parámetros fisiológicos y comportamentales, permitiendo una detección proactiva de estrés ambiental. Un diagrama esquemático de esta arquitectura, propuesto en revisiones actuales (ver Figura 7 Esquema conceptual de ganadería de precisión. , ilustra el flujo desde tareas automatizadas (ordeño y alimentación) hacia módulos de procesamiento basados en AutoML y robótica, culminando en interfaces móviles para retroalimentación humana. Este enfoque, validado en entornos productivos reales, converge IoT, machine learning (ML) y ergonomía para generar alertas predictivas, mitigando riesgos como el estrés térmico y optimizando la sostenibilidad (Gorczyca, 2019; Chapman et al., 2023).




Figura 7 Esquema conceptual de ganadería de precisión.
Fuente: www.engormix.com

Estudios pioneros han explorado sensores específicos para el comportamiento rumiante y actividad en vacas lecheras. Por ejemplo, acelerómetros 3D y giroscopios han sido empleados para monitorear rumia y locomoción (Gorczyca, 2019), mientras que unidades inerciales (IMU) de 9 ejes integradas con microcontroladores predicen estrés por calor con precisión superior al 85% (Chapman et al., 2023; Dineva &

Atanasova, 2023). En paralelo, sensores ruminales bolus recolectan datos meteorológicos (temperatura, humedad, radiación solar) junto con métricas internas como temperatura ruminal y consumo de agua, logrando predicciones de eventos de estrés con tasas de acierto del 92% (Chaudhry et al., 2020). Complementariamente, GNSS ha avanzado en localización precisa para pastoreo, capturando coordenadas geográficas con errores inferiores a 1 metro (Fuentes et al., 2022; Giannuzzi et al., 2022).

3.1.1. Transición Hacia el Manejo Predictivo

La evolución del manejo reactivo a predictivo se sustenta en biomarcadores capturados en tiempo real, permitiendo detección objetiva de estrés temprana (Becker et al., 2021). Revisiones sistemáticas (Islam et al., 2020) validan el uso de tecnologías automatizadas para evaluar cambios fisiológicos individuales, con estudios de campo demostrando reducciones del 30% en incidencias de patologías mediante alertas proactivas.

3.1.2. Contribuciones de Sensores Inteligentes y Automatización

Investigaciones de vanguardia (Hernández et al., 2024) ilustran cómo sensores inteligentes elevan la eficiencia reproductiva y productiva en un 25%, al habilitar intervenciones tempranas que cortan costos veterinarios en hasta un 40% (Barto et al., 2025). Datos en tiempo real de estos dispositivos han sido clave en ensayos con rebaños de 500+ cabezas, donde la integración robótica reduce mortalidad por estrés en un 15%.

3.1.3. Innovaciones en Análisis No Invasivo

El procesamiento de big data sensorial mediante IA y ML ha superado incertidumbres en clasificación con accuracies del 90-95% (Neethirajan, 2022), facilitando monitoreo continuo en entornos no invasivos (Da & Rodrigues, 2022). Estudios recientes en vacas lecheras reportan modelos ML que fusionan datos multimodales para predecir

estrés con latencias inferiores a 5 minutos.

3.2. Estado del Arte en Sensores para Ganadería de Precisión

Revisiones bibliográficas exhaustivas (Becker et al., 2021; Chapman et al., 2023) identifican parámetros clave como temperatura, localización GNSS y lecturas IMU (acelerómetros, giroscopios, magnetómetros) para monitoreo comportamental. Datos automatizados incluyen ingesta láctea, pasos y tiempo de reposo, extraídos de sistemas AMS y collares (Darvesh et al., 2023; Dineva & Atanasova, 2023). La Tabla 10 Tipos de sensores usados en ganadería de precisión resume sensores predominantes y parámetros médicos recolectados en estudios de 2020-2025.

Tabla 10 Tipos de sensores usados en ganadería de precisión

Tipo de Sensor	Parámetro Medido	Aplicación	Fuente	Referencia
Temperatura	Temperatura corporal, timpánica, rectal	Detección de fiebre, estrés térmico, estado de salud	(Congo et al., 2024; Ibarra Méndez, 2015; Molina Casasnovas, 2018)	
Frecuencia Cardíaca	Frecuencia cardíaca, variabilidad cardíaca (HRV)	Evaluación de estrés, bienestar animal, estado reproductivo	(Borja García & Peñasco Jaime Martín, 2018)	
Frecuencia Respiratoria	Ritmo respiratorio	Detección de enfermedades respiratorias, estrés térmico	(Knight, 2020; Zhao et al., 2023)	
Actividad Cerebral	Actividad eléctrica cerebral (EEG)	Estudios etológicos, evaluación del bienestar	(Ding et al., 2025; Proudfoot & Ternman, 2024)	
Actividad/ Movimiento	Actividad física, patrones de movimiento	Detección de celo, comportamiento, salud locomotora	(Kaur & Virk, 2025; Lamanna et al., 2025)	
Consumo	Ingesta de alimento y agua	Optimización nutricional, detección temprana de enfermedades	(Ferreira et al., 2025)	

Sensores de Posición/ Localización	GPS, ubicación en tiempo real	Manejo de pastoreo, seguridad del ganado	(CONtexto ganadero, 2023) (Ferreira et al., 2025)	
Sensores Reproductivos	Estado reproductivo, detección de celo	Optimización de la reproducción, inseminación artificial	(CONtexto ganadero, 2023) (Ferreira et al., 2025)	
Sensores de Comportamiento	Patrones de comportamiento, felicidad animal	Mejora del bienestar, optimización del manejo	(Fan et al., 2022; Rahman et al., 2018)	

Fuente: Elaboración propia recopilación.

Trabajos como (Chaudhry et al., 2020; Darvesh et al., 2023; Fuentes et al., 2022) Recolectaron datos sobre la temperatura del rumen, actividad, índice de rumia y eventos de consumo de agua para predecir eventos de estrés por calor en vacas lecheras Otras investigaciones como (Chapman et al., 2023; Lardy et al., 2023; Martono et al., 2023), también, recolectaron actividades como comer, rumiar, nivel relativo de actividad, tiempo de cola en posición elevada, número de pasos, tiempo de pie, tiempo de caminata, tiempo de acostado, tiempo de comida, tiempo de rumia y tiempo de. Otras contribuciones incluyen 44 características de aceleración/giroscopio para clasificación en terneros (Dineva & Atanasova, 2023; Giannuzzi et al., 2022), y métricas manuales como puntuación ultrasonido y peso corporal (Gorczyca & Gebremedhin, 2019).

3.2.1 Clasificación de Sensores para Bovinos: Avances Actuales

La monitorización individualizada ha avanzado con sensores diversificados, como detalla la Tabla 11 Sensores de Comportamiento para ganado Bovino., que compila funcionalidades de acelerómetros 3D para rumia (Gorczyca & Gebremedhin, 2019) e IMU para estrés térmico (Chapman et al., 2023). Bolus ruminales predicen estrés con 88% de precisión (Chaudhry et al., 2020), mientras GNSS optimiza pastoreo (Fuentes et al., 2020).

Dispositivos comerciales como Afimilk y Nedap detectan partos y dermatitis con tasas de sensibilidad del 95% (Da & Rodrigues, 2022; Martono et al., 2023)

Tabla 11 Sensores de Comportamiento para ganado Bovino.

Tipo de Sensor	Descripción	Aplicaciones Principales	Referencias
Acelerómetros 3D	Monitoreo de rumia y actividad	Comportamiento de vacas lecheras	Gorczyca & Gebremedhin (2020)
IMU de 9 ejes	Predicción de actividad y estrés	Eventos de estrés por calor	Chapman et al. (2023); Dineva & Atanasova (2023)
Bolus ruminales	Temperatura rumen, actividad, rumia	Predicción de estrés térmico	Chaudhry et al. (2020)
GNSS/GPS	Localización (lat, long, alt)	Monitoreo en pastoreo	Fuentes et al. (2020); Giannuzzi et al. (2022)
Collares Afimilk	Actividad, rumia, partos	Predicción de partos	Da & Rodrigues (2022)
Nedap Smarttag	Pasos, tiempo de pie/caminata	Detección de dermatitis	Martono et al. (2023); Setiamy & Deliani (2019)

(Fuente: Actualizado a partir de Becker et al., 2021; Lardy et al., 2023).

3.2.2 Descripción de Sensores Comerciales y de Investigación.

En la clasificación de comportamientos en ganado bovino, se han utilizado los sensores SparkFun (9DoF Razor IMU M0 ver Figura 8 Sensores SparkFun 9DoF Razor IMU M0), que combinan acelerómetros y giroscopios de 3 ejes, permitiendo la obtención de magnitudes precisas de aceleración y giroscopio para clasificar diferentes comportamientos (Darvesh et al., 2023). Además, collares Afimilk Silent Herdsman y acelerómetros Axivity han sido empleados para predecir partos en vacas lecheras, registrando actividades como comer, rumiar, nivel relativo de actividad y tiempo de cola en posición elevada (Da Silva Alex Vinicius, 2022).




Figura 8 Sensores SparkFun 9DoF Razor IMU M0
Ilustración de dispositivo para clasificación comportamental).

En la detección temprana de la dermatitis digital en vacas lecheras, se han usado sensores Nedap Smarttag Leg y Nedap Smarttag Neck, los cuales recogen datos sobre el número de pasos, tiempo de pie, tiempo de caminata, tiempo de acostado, tiempo de comida, tiempo de rumia y tiempo de inactividad, proporcionando información crucial para la identificación y manejo temprano de esta afección (Martono et al., 2023). Por último, se ha destacado el uso de mini acelerómetros triaxiales integrados en cabestros ajustados para recopilar aceleraciones durante la alimentación de las vacas, analizando el comportamiento alimentario que puede ser indicativo del bienestar animal. (El Moutaouakil & Falih, 2024)

3.3. Análisis Comparativo: Sensores Invasivos vs. No Invasivos

Los sensores no invasivos posibilitan monitoreo continuo y en tiempo real con bajo riesgo y mayor confort, aunque requieren estrategias de calibración y mitigación de artefactos por movimiento. Ejemplos incluyen plataformas cutáneas para ritmo cardíaco, temperatura y presión, y biosensores de sudor para metabolitos o collares (Ates et al., 2022), se basan en la detección de señales externas que correlacionan con el estado fisiológico interno.

De manera inversa los sensores invasivos, implantados subcutáneamente o en órganos, ofrecen alta especificidad para termorregulación y hemodinámica, pero con desafíos éticos (Kassanos & Hourdakakis, 2024). La Tabla 12 Sensores Invasivos en ganadería de precisión resume nueve tipos clave, como bolus intraruminales para estrés térmico.

Tabla 12 Sensores Invasivos en ganadería de precisión

Categoría	Tipo de Sensor	Descripción
Temperatura corporal	Termómetros ruminales	Dispositivos implantados en el rumen que miden temperatura continua
	Sensores vaginales	Insertados para medición de temperatura corporal central
	Bolus intraruminales	Cápsulas ingeribles que monitorizan temperatura y pH ruminal
	Termómetros rectales	Para mediciones puntuales de temperatura corporal
Parámetros sanguíneos	Catéteres permanentes	Para monitoreo continuo de glucosa, lactato y cortisol
	Microchips subcutáneos	Para identificación y monitoreo de temperatura
	Sensores de presión arterial	Implantados para medición continua
Actividad neural y muscular	Electrodos de electromiografía (EMG)	Para medir actividad muscular relacionada con temblores
	Sensores de frecuencia cardíaca implantables	Para monitoreo cardíaco continuo

Fuente: Contexto Ganadero.

Los sensores no invasivos se organizan en cinco categorías de acuerdo a contexto ganadero (2023) complementarias: (i) temperatura superficial (cámaras termográficas infrarrojas para mapeo térmico, termómetros IR puntuales sin contacto y sensores térmicos en collares para orejas/cuello); (ii) ambientales y microclimáticos (estaciones meteorológicas, estimadores de sensación térmica por frío, SFT y sensores de radiación solar para caracterizar la carga térmica); (iii) actividad y comportamiento (acelerómetros, GPS, sensores de rumia y sistemas de visión computacional para patrones locomotores, pastoreo y masticación); (iv) producción (medidores de flujo, analizadores de composición láctea y sistemas de pesaje automático para rendimiento y condición corporal); y (v) fisiológicos externos (monitores de frecuencia respiratoria y de frecuencia cardíaca mediante bandas/collares). Estos dispositivos permiten monitoreo continuo, multimodal y sin penetrar el organismo, facilitando la detección temprana de estrés por frío y alteraciones de bienestar. La Tabla 13 Sensores no invasivos sintetiza los tipos más comunes y sus descripciones.

Tabla 13 Sensores no invasivos.

Categoría	Tipo de Sensor	Descripción
Temperatura superficial	Cámaras termográficas infrarrojas	Para mapeo térmico corporal
	Termómetros infrarrojos puntuales	Medición sin contacto de temperatura superficial
	Sensores térmicos montados en collares	Para temperatura del cuello y orejas
Ambientales y microclimáticos	Estaciones meteorológicas	Temperatura ambiental, humedad relativa, velocidad del viento
	Sensación Térmica por Frío (SFT)	Cálculo automático de confort térmico
	Sensores de radiación solar	Para evaluación de carga térmica ambiental
Actividad y comportamiento	Acelerómetros	Para medición de actividad locomotora y patrones de movimiento
	GPS	Para tracking de ubicación y patrones de pastoreo
	Sensores de rumia	Para monitoreo de actividad masticatoria
	Sistemas de visión computacional	Para análisis automático de comportamiento
Producción	Medidores de flujo de leche	Para monitoreo de producción láctea
	Analizadores de composición láctea	Para calidad de leche en tiempo real
	Sistemas de pesaje automático	Para monitoreo de peso corporal
Fisiológicos externos	Monitores de frecuencia respiratoria	Basados en análisis de video o sensores de movimiento
	Sensores de frecuencia cardíaca externos	Mediante bandas torácicas o collares

Fuente: Contexto Ganadero

3.3.1. Comparación Directa

La selección de una plataforma de sensores para la monitorización del ganado implica una evaluación multicriterio que trasciende la mera capacidad técnica, requiriendo un equilibrio entre la fidelidad de los datos, el impacto en el bienestar animal, la viabilidad económica y la escalabilidad operativa como se sintetiza en la Tabla 14 Comparación de sensores bovinos invasivos y no invasivos., este análisis comparativo entre sensores invasivos y no invasivos revela una dicotomía fundamental. Por un lado, los sensores invasivos, como los bolus ruminales, ofrecen una fidelidad de datos excepcional con errores mínimos y un acceso directo a parámetros fisiológicos críticos, lo que los convierte en herramientas ideales para el entrenamiento y validación de modelos de aprendizaje automático. No obstante, esta ventaja se ve contrarrestada por un impacto

significativo en el bienestar animal, costos elevados y una baja escalabilidad. Por otro lado, los sensores no invasivos presentan una propuesta de valor opuesta: mientras que su fidelidad de datos, al basarse en mediciones indirectas, puede ser inferior, su mínimo impacto en el bienestar, costos sustancialmente menores y alta escalabilidad los posicionan como la opción más práctica para el monitoreo de grandes rebaños. Su idoneidad para modelos de ML reside en la capacidad de generar grandes volúmenes de datos diversos, aunque a menudo requieren de estrategias de fusión sensorial multimodal para compensar la mayor variabilidad y alcanzar la robustez necesaria para aplicaciones zootécnicas (Ding et al., 2022; Ferreira et al., 2025; Knight, 2020; Romanzini et al., 2022; Strutzke et al., 2019; Stygar et al., 2023).

Tabla 14 Comparación de sensores bovinos invasivos y no invasivos.

Aspecto	Sensores Invasivos	Sensores No Invasivos
Fidelidad de Datos	Alta precisión (errores <1-2%); acceso directo a parámetros internos (temp. ruminal, correlación >0.95 con estrés por frío)	Precisión media (diferencias 2-5°C en temp. superficial); inferencias indirectas
Impacto en el Bienestar Animal	Alto (dolor, estrés post-implante, riesgos de infección/rechazo)	Bajo (no invasivos, preservan comportamiento natural)
Costos	Altos (USD 200-800/animal + procedimientos veterinarios)	Bajos (USD 50-200/animal, sin costos recurrentes)
Escalabilidad	Baja (requiere personal especializado, limitada a casos críticos)	Alta (fácil implementación, monitoreo grupal, cámaras para 50 animales)
Idoneidad para Modelos de ML	Excelente para entrenamiento (bajos ruido, alta calidad); útil para validación	Buena para volumen/diversidad; requiere fusión multimodal para robustez

(Fuente: Romanzini et al., 2022; Strutzke et al., 2019; Stygar et al., 2023; Knight, 2020; Ding et al., 2022; Ferreira et al., 2025).

3.4. Métricas y Procesamiento de Datos de Sensores para la Detección de Estrés

Estudios innovadores como (Van Dixhoorn et al., 2024) manifiestan el empleo de sensores en el estudio con ganado bovinos ha facilitado la conversión de señales de comportamiento en continuas métricas cuantitativas, estas métricas son fundamentales para el diagnóstico precoz de estrés, enfermedades y cambios fisiológicos. A partir de las señales recogidas, se generan métricas matemáticas que muestran el tiempo, así

como la variabilidad, regularidad y ciclos de las actividades, lo que permite un enfoque objetivo sobre el bienestar y la resiliencia de los animales.

3.4.1. Métricas de actividad general y Presupuesto Temporal

Las métricas de actividad general son agregados cuantitativos derivados de sensores (por ejemplo, acelerometría, sistemas automáticos de ordeño/AMS, visión o RTLS) que resumen el presupuesto de tiempo y la intensidad de movimiento de cada animal duración, frecuencia, fragmentación y transiciones entre conductas como alimentación, desplazamiento o descanso para perfilar su estado fisiológico y de bienestar y detectar anomalías tempranas relevantes para la salud y el rendimiento (Lardy et al., 2023). En ganadería lechera, la instrumentación en tiempo real y la explotación de estos indicadores se han propuesto como base para monitorización objetiva y modelos predictivos de eventos de interés, integrando datos de comportamiento de alta resolución con analítica avanzada.

Las métricas de actividad general sintetizan el “presupuesto de tiempo” del bovino y cuantifican, de forma objetiva, cómo distribuye su jornada entre comer, beber, desplazarse, rumiar/descansar y permanecer en un área, junto con la frecuencia, duración e intensidad de movimiento de cada conducta, los hábitos de consumo y la aparición de patrones inusuales. Al integrar estos indicadores, por ejemplo, minutos por actividad, número y longitud de episodios, variabilidad intra/Inter diaria se obtiene un perfil conductual sensible a cambios tempranos de bienestar y estrés, útil para detección precoz y para modelos predictivos que anticipen impactos en salud o rendimiento y guíen decisiones de manejo, instalaciones y dieta (Van Dixhoorn et al., 2024).

La identificación del estrés en el ganado bovino ofrece medidas concretas del comportamiento de los animales, lo que permite una evaluación objetiva de su bienestar y la anticipación de circunstancias que puedan afectar su salud o rendimiento. De acuerdo con (Van Dixhoorn et al., 2024) las medidas incluyen el tiempo dedicado a distintas actividades como comer, beber, moverse, descansar o permanecer en un

lugar, así como la frecuencia y duración de estas acciones, el grado de movimiento, los hábitos de consumo y la aparición de señales fisiológicas o comportamientos inusuales. Por eso, el estudio de estos aspectos, conocido como "presupuesto de tiempo", brinda información valiosa para detectar pronto situaciones de estrés, lo que favorece la implementación de nuevas estrategias preventivas y correctivas. Esto ayuda a crear un perfil claro de su comportamiento diario, también llamado presupuesto temporal. Por eso, se mide durante un intervalo de tiempo, ya sea una hora o un día, para calcular el "presupuesto temporal". Este análisis es esencial para detectar cambios en los patrones de actividad normales que podrían señalar problemas como estrés, enfermedades o cambios en el entorno (Lecun et al., 2015).

El presupuesto temporal es una herramienta clave para supervisar el ganado lechero, debido a que sirve como un buen indicador del estado físico y del bienestar del ganado siendo los cambios notables, como menos tiempo dedicado a rumiar o más a descansar, pueden indicar que los animales están experimentando estrés, como el causado por el frío (Bickert, 2011).

Además, el uso de métodos de aprendizaje automático en los registros de presupuesto temporal ayuda a detectar variaciones en comparación con los patrones normales y el rendimiento del sistema productivo (Van Dixhoorn et al., 2024). De esta forma, se crean modelos predictivos que pueden prever la llegada de estrés por frío, lo cual es útil para la detección temprana y prevención de riesgos en el ganado lechero, favoreciendo tanto la eficiencia en la producción como el bienestar de los animales, cuantificando la forma que el ganado fracciona sus días en función de episodios de actividades. Van Dixhoorn et al. (2024) determinaron los cálculos de "proporción de tiempo en una actividad p_a " de una colección de episodios, dada por la expresión:

$$p_a = \frac{\sum i \in A t^i}{\sum_{j=1}^N t_j} \quad (1)$$

Donde p_a es la proporción del tiempo dedicado a la actividad A ; $\sum_{i \in A} N t_i$ es la suma de tiempo de todos los episodios que pertenecen al conjunto relacionados con la

actividad A ; Mientras que $\sum_{j=1}^N N t_j$ es la duración total del periodo de observación, siendo t_j la duración del episodio j y N el número total de episodios.

Teniendo el número de episodios de una actividad del ganado en la colección de episodios definido como n_a , y calculando el acumulado de la duración de las actividades en los episodios, como $\sum_{i \in A} N t_i$, se determina la duración media de los episodios de la actividad A como:

$$\bar{t}_a = (\sum\{t \text{ in } A\} t_i) / n_a \quad (2)$$

3.4.2. Análisis de Episodios, Duración, Frecuencia y Criterios de Delimitación

Un episodio conductual (*bout*) se describe como una serie continua de la misma actividad, que se identifica a partir de datos temporales continuos recogidos por sensores biométricos. La forma de detectarlo se basa en notar cambios en el comportamiento a través del análisis de aceleración, ubicación (como GPS o RTLS) y otros métodos (Veissier et al., 2023). En este contexto, la cantidad de episodios y su duración ayuda a medir cuán fragmentado está el comportamiento, lo que significa que un mayor número de episodios cortos puede señalar interrupciones frecuentes, útiles para identificar el estrés o el bienestar de los animales.

De acuerdo con Wagner et al. (2020), los sistemas de localización en tiempo real, conocidos como RTLS, comienzan por determinar la ubicación del animal en cada momento. Esto significa que cualquier cambio que se observe, ya sea de movimiento a reposo o de alimentación a descanso, marca el final de un episodio y el comienzo de otro. Además, el número total de episodios indica la fragmentación en el comportamiento y está relacionado con problemas de salud o estrés en los animales que se están observando.

La duración media de los episodios se obtiene al dividir el tiempo total dedicado a una actividad específica entre la cantidad total de episodios registrados durante el periodo

de estudio (Expresión (2)). Este dato permite analizar cuánto se mantiene o se interrumpe el comportamiento observado. Por otro lado, la frecuencia de episodios se refiere al número de veces que ocurre una actividad en un tiempo determinado, que suele presentarse en episodios por hora (episodios/hora). Este aspecto es importante para comprender los cambios en el comportamiento de los animales, ya que variaciones en la frecuencia o en la duración pueden estar relacionadas con factores como el estrés por calor, problemas de salud o cambios en el bienestar general del ganado (Wagner et al., 2020).

La delimitación de un episodio de una actividad se realiza cuando se observa un cambio evidente en la conducta del animal, como pasar de alimentarse a descansar o de estar en reposo a moverse. Para asegurar que los registros sean consistentes, los sistemas de monitoreo aplican límites de tiempo mínimos que ayudan a eliminar interrupciones breves y a disminuir el ruido en los datos recogidos por los sensores.

Wagner et al. (2020) examinan episodios que son significativos desde la perspectiva fisiológica y el comportamiento de los animales, mejorando la exactitud en la evaluación de los patrones de actividad. Además, identificar correctamente estos episodios es crucial para crear medidas confiables sobre el bienestar, el estrés o la eficiencia productiva del ganado.

Como resultado, métricas como duración media por episodio y episodios/hora se vuelven sensibles a alteraciones por estrés térmico, salud o manejo, aportando indicadores tempranos y variables explicativas robustas para modelos predictivos de bienestar (Wagner, Mialon, et al., 2020).

3.4.3. Nivel de Actividad Global y Técnicas de Cálculo Factorial

En el estudio de asignación de pesos por tipo de actividad del ganado lechero, se asignan pesos concretos a cada clase de actividad para determinar un índice de actividad única. Este método hace posible mostrar numéricamente el nivel de excitación o activación fisiológica del animal, donde cifras elevadas sugieren una

actividad mayor y, posiblemente, una reactividad más alta a estímulos externos.

El cálculo del nivel de actividad por hora se lleva a cabo al sumar el tiempo que se usa en cada actividad, de acuerdo con los pesos que se asignaron antes. Este indicador es muy útil para identificar cambios en los ritmos del corazón, como la disminución de excitación en vacas que tienen enfermedades o problemas fisiológicos (Wagner, Mialon, et al., 2020). Así, el índice de actividad total se transforma en una herramienta importante para vigilar de manera temprana el bienestar y la salud del ganado.

Según mencionan (Arablouei et al., 2022), que en investigaciones recientes se ha utilizado la técnica FAC (Factorial Activity Calculation) en bases de datos que incluyen datos de más de 800 vacas de diferentes granjas. Esto ha hecho posible obtener pesos promedio de actividad que son muy representativos, estos pesos normalizados pueden ser utilizados en diferentes grupos de datos, sin importar factores como la raza, el manejo o las condiciones del entorno, mejorando así la comparabilidad y la firmeza de los análisis.

El nivel de actividad, que es considerada como grado de actividad con peso ponderado en función de la contribución de la actividad para la excitación del animal, en el periodo se calcula como la suma del tiempo dedicada a cada actividad:

$$L = \sum_{a=1}^K w_a * p_a \quad (3)$$

Siendo que w_a es el peso de la actividad a , p_a es la proporción de tiempo en a , y K es el número de actividades.

3.4.4. Métricas de Variabilidad e Irregularidad Conductual

Las métricas de variabilidad comportamental cuantifican la estabilidad o inestabilidad de los patrones de actividad a lo largo del tiempo y complementan a las métricas de nivel promedio. Incluyen indicadores de dispersión (varianza, desviación estándar) y de fluctuación de corto plazo (por ejemplo, RMSSD) para distinguir perfiles estables

de perfiles fragmentados/erráticos, sensibles a estrés térmico, procesos patológicos y cambios de manejo; su uso mejora la detección temprana y la modelación predictiva del bienestar animal (Wagner, Antoine, et al., 2020). Además, el análisis de ritmos circadianos (por ejemplo, mediante FFT/FBAT) muestra que alteraciones en amplitud o fase se asocian con anomalías comportamentales y de salud en vacas lecheras, respaldando el valor de estas métricas como predictores.

Las métricas de variabilidad comportamental cuantifican la estabilidad o inestabilidad de los patrones de actividad a lo largo del tiempo y complementan a las métricas de nivel promedio. Indicadores de dispersión como la varianza y la desviación estándar (Expresión (4)) capturan cuán amplio es el rango de comportamiento respecto a su media, mientras que medidas de fluctuación de corto plazo como el RMSSD (Expresión (5)) detectan cambios sucesivos rápidos entre observaciones contiguas. Juntas, estas métricas permiten distinguir perfiles estables (baja variabilidad) de perfiles fragmentados o erráticos (alta variabilidad), sensibles a alteraciones por estrés térmico, procesos patológicos, manejo o ambiente, y resultan especialmente útiles para la detección temprana y la modelación predictiva del bienestar animal.

Fluctuaciones en actividad, Varianza y desviación estándar: La varianza y la desviación estándar son medidas estadísticas clave para analizar cómo se distribuyen los datos de actividad en relación con su promedio. Una varianza alta señala un comportamiento más inestable o irregular, lo que podría indicar niveles de estrés, enfermedades o cambios en el entorno de trabajo. Por otro lado, valores más bajos indican patrones más estables y, posiblemente, una mejor salud y bienestar en los animales.

Dada la serie temporal $\{x_t\}_{t=1}^T$ con media μ , la Varianza de actividad en serie temporal es conocida como:

$$\sigma^2 = \left(\frac{1}{T-1}\right) * \sum_{t=1}^T (x_t - \mu)^2 \quad (4)$$

RMSSD (Root Mean Square of Successive Differences): El RMSSD es un indicador que se usa para medir las diferencias cuadráticas medias entre valores consecutivos en series de tiempo de actividad, lo que ayuda a identificar cambios a corto plazo en el comportamiento del animal. Esta medida es muy útil para encontrar variaciones pequeñas, y se convierte en una herramienta importante para el análisis del comportamiento animal de manera dinámica y en tiempo real. Dada la serie temporal, el RMSSD para fluctuaciones sucesivas es dada por la expresión:

$$RMSSD = \sqrt{(1/(T - 1)) * \sum_{t=2}^T (x_t - x_{t-1})^2} \quad (5)$$

La variación en el comportamiento, medida a través de indicadores como el RMSSD, se ha convertido en un recurso esencial para identificar tempranamente problemas de salud en las vacas lecheras. Niveles altos de RMSSD suelen estar relacionados con cambios inusuales en los patrones de actividad, lo que puede señalar condiciones como mastitis, problemas metabólicos o situaciones de estrés físico o ambiental. Este método facilita la detección de alteraciones sutiles en el comportamiento que, aunque a veces no son evidentes para el personal de campo, pueden incorporarse en sistemas predictivos para alertas tempranas y decisiones rápidas, mejorando así la salud y el bienestar de los animales y aumentando la eficiencia del sistema.

3.4.5. Índices de Irregularidad Alimentaria (Entropía, Coeficiente de Variación)

Los índices de irregularidad cuantifican cuán impredecibles y fragmentados son los patrones conductuales (especialmente de alimentación) frente a un ritmo esperado, mediante medidas como entropía, coeficiente de variación y dispersiones temporales (Lardy et al., 2023). Al elevarse, sugieren disrupción circadiana, inestabilidad fisiológica y posibles estados de estrés (por ejemplo, por frío), mientras que valores bajos reflejan estabilidad y mayor resiliencia. Estas métricas operativas sobre series temporales de episodios y duraciones apoyan modelos de aprendizaje automático para detección temprana, estratificación de riesgo e, incluso, selección y manejo orientados a robustez productiva.

En este trabajo, los índices de irregularidad se definen como medidas que capturan la desviación del patrón habitual en la secuencia de conductas (especialmente de alimentación), a partir de cuantificadores como la entropía y el coeficiente de variación sobre tiempos/episodios; incrementos de estos índices reflejan fragmentación y disrupción circadiana asociadas a estrés y alteraciones fisiológicas, y se integran como predictores en modelos de ML para detección temprana (Wagner, Mialon, et al., 2020).

La metodología de (Salgado et al., 2021) es un modelo para medir la irregularidad en la alimentación de rumiantes. Este método se centra en detectar diferencias en relación con un patrón de alimentación habitual, utilizando herramientas matemáticas como la entropía y el coeficiente de variación en los tiempos que se emplean para comer. Así, estas herramientas ayudan a entender la complejidad y las variaciones en los hábitos de alimentación, proporcionando una imagen más clara de cómo los animales reaccionan ante condiciones ambientales difíciles.

FBAT (Fourier-Based Approach with Threshold): detecta alteraciones circadianas en la actividad mediante FFT y un umbral sobre la distancia euclidiana entre patrones de 24 h; se centra en la periodicidad global del comportamiento, no solo en la irregularidad de los episodios de alimentación. En estudios reporta >90% de detección para eventos patológicos/estrés/reproductivos. Diferencia clave: opera sobre ritmos circadianos de la actividad (no exclusivamente sobre tiempos de alimentación) y usa modelado espectral + umbral, no un índice compositivo (Wagner, Antoine, et al., 2020).

Las Métricas de variabilidad temporal (Var, DE, RMSSD), cuantifican dispersión e inestabilidad a corto plazo en series de actividad/alimentación (por ejemplo, RMSSD capta cambios sucesivos). Diferencia clave: son medidas atómicas y generales de variabilidad (no un índice compuesto específico de conducta alimentaria); se aplican a actividad/rumia/locomoción además de comida (Alsaad et al., 2019).

En situaciones de estrés por bajas temperaturas en vacas lecheras, estos valores son

relevantes, debido a que los cambios de temperatura suelen provocar alteraciones en la distribución temporal de las conductas de alimentación, es decir, un incremento en la irregularidad de la alimentación puede verse como un aviso inicial de problemas fisiológicos, que indica la lucha del animal por mantener su equilibrio ante condiciones de calor o frío extremos. La aplicación de estas medidas junto con métodos de aprendizaje automático facilita el entrenamiento de modelos que pueden prever eventos de estrés por frío basándose en patrones de comportamiento. Así, la variabilidad en la alimentación no solo sirve como un indicador del comportamiento, sino que también se convierte en un factor crucial para la predicción y la prevención del estrés térmico en vacas lecheras (Salgado et al., 2021).

3.4.6. Interpretación Biológica y Relación con la Resiliencia Animal

La interpretación biológica de los índices de irregularidad facilita la comprensión de las respuestas fisiológicas y conductuales de los animales ante situaciones desfavorables del entorno. En el caso del ganado lechero que enfrenta estrés por frío, una gran irregularidad en los hábitos de alimentación se relaciona con un desajuste en los ritmos circadianos y con una disminución en la estabilidad del animal (Salgado et al., 2021). Esto implica que los individuos que sufren estrés térmico muestran patrones de consumo de alimento que son fragmentados e inestables, lo que puede resultar en desequilibrios en la energía y una disminución en la producción de leche (Wagner, Antoine, et al., 2020).

Por otro lado, una menor variabilidad en los hábitos alimenticios indica un funcionamiento fisiológico estable, donde los ritmos circadianos se mantienen en un nivel bastante constante a pesar de las bajas temperaturas. Este tipo de reacción está relacionada con animales que tienen mayor resistencia, capaces de seguir rutinas alimenticias regulares y mantener un mejor equilibrio energético ante desafíos en el entorno (Alsaad et al., 2019). En este contexto, la inclusión de métricas de variabilidad en modelos de aprendizaje automático no solo ayuda a detectar a tiempo las alteraciones relacionadas con el estrés frío, sino que también facilita la identificación de los animales que son más resistentes, lo que resulta beneficioso para

los programas de manejo y selección genética en el ámbito de la producción de leche (Salgado et al., 2021).

Relación con resiliencia animal: El comportamiento irregular no solo muestra cómo reacciona rápidamente el ganado lechero al frío, sino que también sirve como un signo de la resiliencia de los animales. Por lo tanto, se ha visto que los ejemplares con mejor habilidad para adaptarse vuelven a exhibir comportamientos de alimentación normales más rápidamente tras enfrentar el frío intenso que aquellos que tienen menor resistencia (Wagner, Antoine, et al., 2020).

En este sentido, herramientas estadísticas como la varianza, la entropía y el coeficiente de variación ayudan a medir qué tan bien puede un animal regresar a su estado normal después de sufrir un estrés. Estas herramientas, cuando se usan en modelos de aprendizaje automático, se convierten en un recurso valioso para evaluar la resiliencia, lo que permite identificar a aquellos individuos que son más fuertes y capaces de resistir cambios extremos de temperatura (Alsaad et al., 2019).

La inclusión de estos indicadores en los programas de cría genética es muy importante, ya que ayuda a dirigir la selección de ganado lechero hacia aquellos que pueden mantener mejor su bienestar y producción en ambientes cambiantes, optimizando la sostenibilidad de los sistemas de producción (Salgado et al., 2021).

3.4.7. Análisis de Ritmicidad Circadiana.

El estudio de los ritmos circadianos en las vacas lecheras ayuda a reconocer patrones que se repiten cada día en su movimiento, reposo y alimentación, permitiendo así evaluar la regularidad de los ciclos de 24 horas. La falta de sincronización de estos ritmos es un indicativo sensible de problemas en la salud, el bienestar o el manejo de los animales. De esta manera, la regularidad de la actividad muestra la capacidad del cuerpo para mantener una organización temporal estable; las interrupciones de esta

regularidad a menudo se vinculan con episodios de enfermedad, niveles de estrés fisiológico o acontecimientos reproductivos (Wagner et al., 2020).

El estudio de la regularidad se fundamenta en métodos de procesamiento de señales que posibilitan descomponer los registros de actividad en partes periódicas. Una de las técnicas más comunes es la Transformada Rápida de Fourier (FFT), que permite identificar armónicos que representan los ciclos diarios y notar variaciones en su amplitud o fase. En este contexto, (Wagner et al., 2020) crearon un método llamado Aproximación Basada en Fourier con Umbral (FBAT), que se ha diseñado para identificar variaciones en el ciclo circadiano de la actividad de los bovinos. Este método está basado en la modelación de datos temporales que abarcan 36 horas, las cuales se dividen en periodos de 24 horas, y sus patrones se comparan utilizando la distancia euclidiana. En la Figura 9 Ritmos circadianos a partir de los valores diarios (Descanso - Rumia y Comida) se evidencia la comparativa de varios ritmos circadianos diarios, si esta distancia excede un límite previamente fijado, se considera que ha habido una alteración importante en el ritmo circadiano.




Figura 9 Ritmos circadianos a partir de los valores diarios (Descanso - Rumia y Comida)

La figura ilustra los patrones diarios de actividades como descanso, rumia y comida, destacando alteraciones en ritmos circadianos bajo estrés por frío, donde se observa

una fragmentación en los picos de actividad (Fuente: Adaptado de Lascano Rivera et al., 2025). Este análisis revela cómo el estrés térmico reduce la amplitud de los ciclos de rumia, indicando disrupción en el presupuesto temporal y potencial impacto en la productividad lechera.

El método FBAT ha probado ser efectivo para detectar irregularidades relacionadas con enfermedades (como acidosis, mastitis o cojeras), situaciones de estrés (por ejemplo, cambios de corral o traslado) y eventos reproductivos (celo y parto), logrando una tasa de detección mayor al 90% en varias de estas situaciones. En el ámbito de la predicción del estrés por frío en vacas lecheras, el estudio de los ritmos circadianos es especialmente importante, ya que la exposición a temperaturas bajas puede causar cambios en los patrones de descanso y movimiento. La implementación de FBAT y FFT no solo ayuda a reconocer la pérdida de regularidad circadiana relacionada con el estrés térmico, sino que también permite considerar la inclusión de estas métricas en modelos de aprendizaje automático, lo que mejora la predicción y el monitoreo temprano del bienestar de los animales.

En consonancia con Li et al. (2022), la caracterización de la actividad bovina puede abordarse mediante la clasificación de conductas unitarias y movimientos a partir de sensores y métodos de aprendizaje automático, lo que permite discriminar episodios como alimentación, rumia, reposo y desplazamiento con mayor resolución temporal y precisión. Este enfoque no solo facilita la etiquetación automática y la integración multimodal de datos, sino que también habilita el análisis comparativo de patrones (frecuencia, duración y transiciones) para la detección temprana de alteraciones comportamentales asociadas a salud, estrés o cambios de manejo; por ello, resulta especialmente pertinente como base metodológica para extraer métricas de actividad general y variabilidad temporal en sistemas de ganadería de precisión orientados a predicción.

En línea con Watanabe et al. (2021), la instrumentación con acelerómetros triaxiales

permite distinguir y predecir conductas de alta y baja frecuencia en bovinos en pastoreo mediante ventanas temporales y rasgos derivados del movimiento (magnitud, periodicidad y transiciones), ofreciendo un marco reproducible para mapear el presupuesto temporal y sus variaciones. Esta aproximación viabiliza la detección temprana de cambios comportamentales relevantes para bienestar y manejo al capturar diferencias sutiles entre patrones de reposo, locomoción y pastoreo y sienta bases sólidas para integrar métricas de variabilidad y ritmicidad en modelos predictivos de eventos de interés.

3.4.8. Autocorrelación y Evaluación de Estabilidad de Patrones de 24h

Los estudios de la autocorrelación temporal son una herramienta estadística clave para analizar la regularidad y la continuidad de los ritmos circadianos en el ganado lechero. La función de autocorrelación permite medir cuánto se asemejan una señal de actividad en un momento específico y la misma señal en un tiempo posterior, lo que ayuda a identificar patrones repetitivos de 24 horas (Lag-24). Si los valores de autocorrelación en Lag-24 son altos, se entiende que hay una buena consistencia en los ciclos circadianos, lo que indica un equilibrio interno y un estado de bienestar adecuado. Por otro lado, una disminución notable de este coeficiente sugiere una alteración en el ritmo circadiano, lo cual a menudo está relacionado con problemas de salud, estrés ambiental o cambios reproductivos (Wagner et al., 2020).

Dentro del ámbito del estrés térmico en el ganado lechero, la autocorrelación temporal se torna especialmente valiosa, dado que una bajada en la temperatura puede modificar cómo se distribuyen las actividades de locomoción, descanso y alimentación. La irregularidad en estos patrones, que se manifiesta a través de coeficientes más bajos en Lag-24, actúa como un indicador temprano de estrés térmico y puede ser utilizada en modelos de aprendizaje automático para enriquecer la predicción y el seguimiento en tiempo real del bienestar de los animales. La autocorrelación es una técnica estadística que evalúa la concordancia de una serie temporal con respecto a sí misma en diferentes intervalos de tiempo. Según (Wagner et al., 2020) plantean la siguiente expresión general de la autocorrelación:

$$R(\tau) = \frac{1}{N} \sum_{t=1}^{N-\tau} (X(t) - \bar{X})(X(t + \tau) - \bar{X}) \quad (6)$$

Donde:

$R(\tau)$: es la autocorrelación de la serie con un retraso τ

$X(t)$ es el valor de la serie temporal en el instante t

$\bar{X}$ es la media de toda la serie temporal

N es el número total de observaciones

τ representa el lag o desplazamiento temporal, es decir, el número de periodos por los cuales se desplaza la serie para comparar con ella misma.

Esta fórmula ayuda a detectar ciclos y patrones recurrentes a lo largo del tiempo en la serie de datos. Un ejemplo de esto es cuando se observa un aumento en la autocorrelación en $\tau = 24$ horas, lo que podría sugerir la presencia de un ritmo circadiano en la actividad diaria registrada. Asimismo, la magnitud de $R(\tau)$ proporciona información sobre la intensidad de la correlación entre los valores desplazados y los originales.

En consecuencia, la combinación del método FBAT y la autocorrelación temporal Lag-24 crea una base sólida para identificar de manera temprana alteraciones en los ritmos circadianos, presentando un sistema sensible y no invasivo que facilita la predicción del estrés por frío en ganado lechero.

3.5. Síntesis del Capítulo

El Capítulo 3 establece la base tecnológica para el monitoreo predictivo del bienestar en ganado lechero mediante el estudio del ecosistema de sensores inteligentes que posibilita la ganadería de precisión. Demuestra cómo la sensorización inercial (acelerómetros, giroscopios, magnetómetros) y el posicionamiento GNSS proporcionan datos continuos a nivel individual sobre comportamiento y ubicación, mientras que los bolos de temperatura ruminal y los dispositivos portátiles de

frecuencia cardíaca/VFC capturan respuestas fisiológicas vinculadas al estrés. En conjunto con los sistemas comerciales de collar, estos dispositivos generan flujos de datos ricos y no invasivos sobre pasos, tiempo de echado/parado, alimentación y rumiación que ya han demostrado utilidad para la clasificación de comportamientos, predicción y alertas tempranas de enfermedades evidencia de que las mismas señales multimodales pueden aprovecharse para análisis de estrés térmico.

Al enmarcar los datos de sensores como entradas para pipelines de aprendizaje automático, el capítulo argumenta que las mediciones continuas y fusionadas pueden respaldar una detección más temprana y confiable de los umbrales de estrés que la observación manual por sí sola, y que los métodos validados para estrés térmico por calor se transfieren al riesgo de estrés por frío porque actúan sobre marcadores comportamentales y fisiológicos comparables. Integrar telemetría multi sensor a nivel de vaca con modelos de ML para anticipar episodios de estrés por frío y desencadenar intervenciones oportunas e individualizadas en condiciones reales de granja.

El potencial radica en la escalabilidad de sensores no invasivos y ML para detección temprana, mejorando productividad y bienestar. Limitaciones incluyen menor precisión en no invasivos, brechas en datos de frío vs. calor, y desafíos éticos/costos en invasivos, requiriendo enfoques híbridos para robustez.

CAPÍTULO IV. TÉCNICAS DE APRENDIZAJE AUTOMÁTICO EN GANADERÍA DE PRECISIÓN

El aprendizaje automático (AA) ha emergido como un pilar clave en la ganadería de precisión (GDP), un enfoque que integra tecnologías de información y comunicación para optimizar la producción de alimentos de origen animal mediante el monitoreo en tiempo real de variables como comportamiento, nutrición y salud bovina (Distante et al., 2025). Estudios recientes destacan cómo el AA procesa datos masivos de sensores, cámaras y dispositivos portátiles para detectar patrones y anomalías, permitiendo pronósticos de enfermedades y optimización de recursos en contextos lecheros (Taramuel Andrade et al., 2024; Sharma et al., 2021). En particular, la predicción de estrés por frío en vacas lecheras —un factor crónico o agudo que reduce la productividad láctea y afecta el bienestar mediante alteraciones fisiológicas y comportamentales— se beneficia de modelos de AA como redes neuronales y bosques aleatorios (RF), que analizan datos multifactoriales ambientales (temperatura, viento) y fisiológicos (frecuencia respiratoria, temperatura corporal), superando métodos tradicionales al manejar variabilidad individual y el índice de enfriamiento por viento (Wind Chill) (Gorczyca, 2019; Distante et al., 2025).

La literatura reciente revela una evolución hacia enfoques predictivos proactivos, con aplicaciones similares al estrés térmico que facilitan intervenciones tempranas y reducen pérdidas económicas. Por ejemplo, Wagner et al. (2020) aplicaron análisis de Fourier para detectar alteraciones en ritmos circadianos como indicadores de estrés, integrando datos de actividad para comparaciones individuales y grupales. Paralelamente, estudios en clasificación de comportamientos utilizan acelerómetros y RF para identificar posturas (de pie, acostado) y rumia, alineándose con evaluaciones de Beauchemin (2018) que vinculan conductas básicas (comer, rumiar, descansar) a detección de estrés. En estrés calórico, modelos como regresión logística y RF evalúan

severidad mediante índices como el THI (Temperature-Humidity Index), con transferibilidad directa al estrés por frío dada la similitud en variables fisiológicas.

Avances en aprendizaje profundo, como los propuestos por Wang et al. (2023) y Zhang et al. (2025), incorporan híbridos de CNN-LSTM para procesar imágenes y secuencias comportamentales, logrando altas precisiones en clasificación de rumia y reposo en entornos complejos con big data de sistemas portátiles. Comparaciones sistemáticas (p. 115) muestran que ensembles como RF superan modelos lineales en escenarios de estrés bovino, con accuracies del 92% versus 85% en regresión. La priorización de RF para clasificación inicial y LSTM para series temporales se justifica por su adaptabilidad a datos locales de estrés por frío (p. 116), mientras que resúmenes de desempeño (p.118) indican reducciones de pérdidas hasta el 20% mediante predicciones proactivas.

4.1. Aplicaciones Empíricas de Algoritmos en Estudios Recientes

La revisión de literatura evidencia el dominio de algoritmos específicos en predicciones bovinas. Brouwers et al. (2023) reportaron un 81.91% de precisión con RF en pronósticos de producción lechera diaria, mientras que Cantor et al. (2022) obtuvieron F1-scores de 92.86%-100% para metritis usando el mismo enfoque, superando a SVM (23.26%-65% F1). k-NN alcanzó 99.34% de precisión en clasificación de alimentación (Martono et al., 2023), y Bi-LSTM logró 96.79% en comportamientos en tiempo real con recolección de energía por radiofrecuencia (Baldassini et al., 2015). Cantor et al. (2022) complementan con F1-scores de 44.94%-63.16% en metritis, subrayando la superioridad de ensembles en datasets desbalanceados.

La Tabla 15 Revisión Sistemática de Estudios Enfocados en Inteligencia Artificial y Sensores Inteligentes Aplicados en Ganadería de Precisión sintetiza estudios clave, como Becker et al. (2021), que aplicaron RF para predecir estrés térmico en vacas lecheras, integrando sensores de temperatura corporal y frecuencia respiratoria con sistemas de puntuación para mitigar impactos en la producción láctea. Lardy et al.

(2023) discriminaron patologías, reproducción y estrés mediante RF en datos de actividad sensorial, mejorando la gestión ganadera. Gorczyca y Gebremedhin (2019) clasificaron factores de estrés térmico ambiental con ML, identificando la temperatura del aire como predictor principal y enfatizando sensores ambientales (ver Figura 10 para sensores comunes en bovinos; Lascano Rivera et al., 2025).

Chapman et al. (2023) introdujeron LSTM para pronosticar estrés térmico vía datos comportamentales autónomos, superando métodos estadísticos tradicionales y destacando la precisión de redes recurrentes en combinación con sensores.

Tabla 15 Revisión Sistemática de Estudios Enfocados en Inteligencia Artificial y Sensores Inteligentes Aplicados en Ganadería de Precisión

Fuentes	ML Factible	Estrés	Vacas	Sensor
(Becker et al., 2021); (Lardy et al., 2023); (Gorczyca & Gebremedhin, 2019); (Veissier et al., 2023); (Veissier et al., 2023); (Vidal et al., 2023)	RF	*	*	*
(Chapman et al., 2023)	LSTM	*	*	*
(Dineva & Atanasova, 2023); (Chaudhry et al., 2020); (Zhou et al., 2022); (Fadul-Pacheco et al., 2021); (Balasso et al., 2021); (Schmeling et al., 2021); (Marques et al., 2024); (Tran et al., 2021); (Miller et al., 2020); (Schmeling et al., 2021); (Watanabe et al., 2021); (Ghafoor & Sitkowska, 2021); (Higaki et al., 2021)	RF		*	*
(Fuentes et al., 2022c)	ANN	*	*	*
(Giannuzzi et al., 2022) (El Moutaouakil & Falih, 2024)	ANN		*	*
(Dac et al., 2022)				
(Darvesh et al., 2023) (Li et al., 2022) (Riaboff et al., 2020)	XGBoost		*	*
(Da Silva Alex Vinicius, 2022)	SVM	*	*	*
(Martono et al., 2023)	DT		*	*
(Gorczyca & Gebremedhin, 2019)	GBM	*	*	*
(Brouwers et al., 2023)	MiniRocket y Inception Time.		*	*
(Zhang et al., 2022)	LSTM		*	*

(Pedrosa et al., 2024)	MLP		*	*
(Shorten, 2023); (Balasso et al., 2023); (Hosseininoorbin et al., 2021)	CNN		*	*
(Surana & Sharma, 2024)	CNN y LSTM		*	*
(Sawada et al., 2023)	LightGBM y NN		*	*
(Shu et al., 2021)	RNA	*	*	*
(Wagner, Antoine, et al., 2020); (Magana et al., 2023); (Cantor et al., 2022)	k-NN		*	*
(Nogoy et al., 2021)	k-NN	*	*	*
(Dang et al., 2024)	Bi-LSTM		*	*
(Liseune et al., 2021)	C-LSTM		*	*
(Woodward et al., 2024)	CA	*	*	*
(Stygar et al., 2023)	XGBoost.	*	*	*
(Ding et al., 2022)	XGB	*	*	*
(Carslake et al., 2021)	AdaBoost		*	*
(Hernández et al., 2024)	SVM		*	*
(Tian et al., 2021)	k-NN-RF		*	*

Fuente: LascanoRivera et al., 2025

(Lardy et al., 2023) investigan la discriminación de condiciones patológicas, reproductivas y de estrés en vacas mediante el análisis de datos de actividad obtenidos de sensores utilizando RF. En este enfoque se sugiere que la integración de datos de sensores puede mejorar significativamente la gestión del ganado. (Gorczyca & Gebremedhin, 2019) clasifican los factores de estrés térmico ambiental que afectan a las vacas lecheras mediante algoritmos de ML.

Los resultados indican que la temperatura del aire es el factor más influyente en las respuestas fisiológicas de las vacas, lo que resalta la importancia de los sensores ambientales en la detección de estrés térmico. En la Figura 10 Sensores Usados en Ganadería de Precisión con Bovinos. (Lascano Rivera et al., 2025) se muestran hallazgos que pueden ayudar a los ganaderos a implementar intervenciones adecuadas antes de que se produzcan condiciones estresantes. Mientras que (Chapman et al., 2023) presentan un modelo de LSTM, que es un tipo de Red neuronal recurrente

(RNN), para pronosticar el estrés térmico en ganado, utilizando datos de comportamiento registrados de forma autónoma. El estudio concluye que los métodos de aprendizaje profundo recurrentes son más precisos que los enfoques estadísticos tradicionales, lo que sugiere que la combinación de datos de sensores y técnicas avanzadas de aprendizaje automático puede mejorar significativamente el bienestar animal y la productividad.




Figura 10 Sensores Usados en Ganadería de Precisión con Bovinos. (Lascano Rivera et al., 2025)
Ilustración de sensores como acelerómetros, collares GPS y cámaras térmicas, destacando su rol en monitoreo multimodal.

4.1.1. Análisis Comparativo del Desempeño de Algoritmos

La Tabla 16 Resumen comparativo de Desempeño de algoritmos presenta un análisis comparativo de los algoritmos de aprendizaje automático más relevantes en la ganadería de precisión, destacando su funcionamiento matemático, ventajas, limitaciones, aplicaciones documentadas en el monitoreo de estrés y comportamientos bovinos, así como la precisión reportada en estudios clave. Este resumen ilustra cómo algoritmos como Random Forest y LSTM destacan por su robustez en tareas predictivas, facilitando la detección temprana de estrés térmico y optimizando el manejo del ganado lechero.

Tabla 16 Resumen comparativo de Desempeño de algoritmos

Algoritmo	Funcionamiento Matemático	Ventajas	Limitaciones	Aplicaciones en Ganadería	Precisión Reportada
Random Forest (RF)	Ensamble de árboles de decisión; promedio de predicciones para reducir varianza	Alta precisión, manejo de no linealidades, robustez a ruido	Alto costo computacional, menos interpretable	Predicción de estrés térmico (Becker et al., 2021); producción de leche (Brouwers et al., 2023)	81.91% precisión; F1 92.86-100% metritis
Support Vector Machine (SVM)	Hiperplano óptimo en espacio de alta dimensión; kernel trick para no lineal	Eficaz en espacios altos, generalización buena	Sensible a outliers, escalado lento	Predicción de metritis (Cantor et al., 2022)	F1 23.26-65%
k-Nearest Neighbors (k-NN)	Distancia euclidiana a k vecinos; votación mayoritaria	Simple, no paramétrico	Sensible a escala, lento en predicción	Clasificación de alimentación (Martono et al., 2023)	99.34% precisión
Long Short-Term Memory (LSTM)	RNN con gates para memoria larga; backpropagation through time	Maneja secuencias temporales, captura dependencias largas	Alto costo computacional, overfitting	Pronóstico estrés térmico (Chapman et al., 2023); clasificación comportamientos (Setiamey & Deliani, 2019)	96.79% precisión
Convolutional Neural Network (CNN)	Filtros convolucionales para características espaciales; pooling para reducción	Eficaz en imágenes/datos espaciales	Requiere grandes datos, black-box	Clasificación comportamientos visuales (no detallado en doc.)	N/A en doc.

RF destaca en tareas de clasificación multiclase por su ensamble, reduciendo overfitting; LSTM es superior para series temporales como ritmos circadianos por capturar dependencias secuenciales, superando SVM en precisión para predicciones dinámicas. De acuerdo con esta revisión se puede deducir que RF funciona mejor en predicción de estrés térmico por su robustez a ruido en datos sensoriales heterogéneos (Becker et al., 2021), mientras LSTM excelsa en secuencias conductuales por modelar

temporalidad (Chapman et al., 2023). SVM es limitado en data sets desbalanceados como metritis.

4.1.2. Revisión Sistemática de Estudios de IA y Sensores.

La Tabla 17 Sintética de Estudios de IA y Sensores ofrece un resumen sintético de estudios clave sobre la integración de inteligencia artificial (IA) y sensores en la ganadería de precisión, catalogando el algoritmo principal, el tipo de estrés evaluado, la población bovina involucrada y los sensores empleados. Estos trabajos ilustran cómo enfoques como Random Forest (RF) y LSTM destacan en la predicción de estrés térmico y patológico, facilitando una detección temprana y optimizando el bienestar y la productividad en hatos lecheros mediante datos multimodales.

Tabla 17 Sintética de Estudios de IA y Sensores

Estudio	Algoritmo	Tipo de Estrés	Población	Sensores Empleados
Becker et al. (2021)	RF	Térmico (calor)	Vacas lecheras	Temperatura corporal, frecuencia respiratoria
Lardy et al. (2023)	RF	Patológico/reproductivo	Vacas	Actividad (acelerómetros)
Gorczyca & Gebremedhin (2019)	ML general	Térmico ambiental	Vacas lecheras	Ambientales (temp. aire)
Chapman et al. (2023)	LSTM	Térmico	Ganado general	Comportamiento autónomo
Cantor et al. (2022)	SVM, RF	Metritis (relacionado estrés)	Vacas	No especificado
Brouwers et al. (2023)	RF	Productividad (indirecto)	Vacas lecheras	No especificado

Fuente: Lascano Rivera et al., 2025.

4.1.3. Identificación de Tendencias y Brechas en la Literatura

Ante las evidencias en la literatura encontradas se puede resaltar la tendencia en integración multimodal (sensores + ML) para detección temprana; énfasis en no invasivos. En cuanto a las brechas encontradas, pocos estudios en estrés por frío vs. calor; falta de modelos híbridos para resiliencia individual; necesidad de validación en entornos comerciales escalables.

4.2. Integración Tecnológica y Tendencias Futuras

La creación de sensores híbridos que integran la exactitud de los sistemas invasivos con la conveniencia y la capacidad de expansión de los sistemas no invasivos constituye un campo clave de innovación en el seguimiento de animales. Algunos de los ejemplos más destacados incluyen parches térmicos que se pueden adherir y collares inteligentes equipados con diversos sensores, tales como acelerómetros, termómetros, monitores de frecuencia cardíaca y GPS, entre otros; lo que facilita una recolección de datos sólida sin poner en riesgo el bienestar de los animales.

4.2.1. Fusión Multimodal de Datos para Mejorar la Robustez de los Modelos Predictivos.

La incorporación simultánea de diversas fuentes de datos no invasivas, que incluyen sensores de actividad como acelerómetros, cámaras térmicas, espectros en infrarrojo, monitores ambientales, sensores de localización (GNSS/GPS) y sistemas acústicos, junto con el uso de algoritmos sofisticados y aprendizaje automático, posibilita alcanzar grados de precisión que se asemejan a los de los sistemas invasivos. Esto se logra sin perder las ventajas de coste reducido, facilidad de implementación y capacidad de escalar.

Un análisis exhaustivo mostró que la utilización de sensores como acelerómetros, cámaras (tanto visuales como infrarrojas), GPS, micrófonos y otros en el estudio de animales, evidencia el gran potencial de esta tecnología para optimizar el bienestar animal, aumentar la eficiencia en la producción y contribuir a la conservación (Portillo López et al., 2021). Por ejemplo, Arablouei et al. (2022) desarrollaron un enfoque para identificar comportamientos en animales en su entorno natural, utilizando la fusión de datos procedentes de acelerometría y GNSS. Se aplicaron técnicas que combinan la concatenación de características con la fusión de probabilidades extraídas de dos clasificadores MLP independientes. Este último método demostró una notable mejora en el rendimiento, así como una mayor modularidad y resistencia ante fallos de los sensores, lo que subraya la efectividad de la fusión multimodal en comparación con la

utilización de una única fuente de datos. Así, la integración de datos provenientes de acelerómetros y GPS facilita la distinción entre comportamientos de pastoreo y otros no relacionados con el pastoreo.

Calidad de datos para entrenamiento: La calidad de los datos es un aspecto crucial para el rendimiento de los modelos de aprendizaje automático. En este contexto, los sensores invasivos proporcionan registros con alta precisión y consistencia, lo que se traduce en conjuntos de datos que tienen bajos niveles de ruido y una gran fidelidad en relación con las variables fisiológicas observadas. Estas características hacen que sean ideales para la fase de entrenamiento de los modelos predictivos, donde la precisión de los datos de entrada tiene un impacto directo en la capacidad del algoritmo para generalizar. No obstante, su uso a gran escala enfrenta dificultades como altos costos, complejidades logísticas y el riesgo de afectar negativamente el bienestar de los animales.

Por otro lado, (Aguilar-Lazcano et al., 2023) indican que los sensores no invasivos, aunque ofrecen una precisión menor en las mediciones individuales, tienen la ventaja de generar grandes volúmenes de datos más variados. Al combinar estos datos con técnicas avanzadas de aprendizaje automático, es posible mitigar las limitaciones en precisión y mejorar la calidad del conjunto de datos. Esto representa un enfoque prometedor para aplicaciones de monitoreo animal, ya que la integración de información sobre movimiento, posición, sonidos y otros factores permite crear representaciones más fieles del estado fisiológico y conductual de los animales.

Escalabilidad del sistema: La capacidad de escalabilidad es un aspecto fundamental para llevar a cabo la implementación eficaz de sistemas de monitoreo que se basan en sensores. Desde esta óptica, los dispositivos no invasivos ofrecen ventajas significativas, como su coste unitario inferior, facilidad de instalación y bajos requerimientos de mantenimiento, lo que los convierte en opciones ideales para aplicaciones comerciales de gran envergadura.

En contraposición, aunque los sensores invasivos brindan una precisión superior, generalmente se utilizan en contextos de investigación aplicada o para el seguimiento de animales que poseen un alto valor económico o genético. Esto se debe a sus altos costos de instalación, al riesgo de rechazo fisiológico y a la necesidad de contar con personal especializado para su manejo. Por ende, la escalabilidad de estos sensores es bastante restringida, limitando su uso en sistemas productivos de gran escala.

Robustez del modelo predictivo: La firmeza de un modelo predictivo se basa no solamente en la exactitud de las mediciones individuales, sino también en su habilidad para generalizar en diferentes condiciones y ante diversas poblaciones. Los sistemas que utilizan sensores invasivos son reconocidos por su gran precisión, aunque su uso suele estar restringido a entornos experimentales controlados o situaciones que implican un alto valor económico o genético. Por otro lado, los modelos que se alimentan de datos provenientes de sensores no invasivos, aunque presenten menor precisión individualmente, suelen demostrar una mayor robustez al integrar múltiples variables mediante métodos de machine learning y técnicas sofisticadas de fusión de datos. Este enfoque permite identificar patrones de comportamiento y fisiología más amplios, lo que a su vez incrementa la capacidad del modelo para adaptarse a condiciones de producción variadas.

Según lo señalado por (Arablouei et al., 2022), la robustez de los modelos predictivos depende esencialmente de dos factores: la diversidad y generalidad de los datos, así como la estrategia de combinación aplicada. Mientras que los sensores invasivos ofrecen datos de alta calidad y precisión, su uso limitado en situaciones reales reduce la capacidad del modelo para hacer extrapolaciones. En contraste, la integración de sensores no invasivos con técnicas de fusión y machine learning mejora significativamente la robustez del modelo, haciéndolo más adaptable a condiciones diversas, resistente a fallos y capaz de generalizar con éxito a nuevas poblaciones.

4.3. Síntesis del Capítulo IV.

El Capítulo 4 consolida el conjunto de herramientas de aprendizaje automático y el flujo de datos necesarios para convertir los flujos continuos de sensores inalámbricos (WSN) provenientes de collares inteligentes en análisis de estrés accionables a nivel de vaca. Justifica el enfoque en modelos conscientes de secuencias (por ejemplo, LSTM) para patrones temporales, complementados por clasificadores basados en árboles (por ejemplo, Random Forest) y detectores no supervisados (por ejemplo, Isolation Forest) para capturar límites de decisión no lineales y eventos raros, respectivamente.

Al hacerlo, el capítulo traduce los fundamentos conceptuales de la tesis en un pipeline concreto para la ingestión de flujos de datos, extracción de características y selección de modelos, explícitamente adaptado a las características de los datos WSN. Esto posiciona el trabajo para pasar de la teoría al diseño y experimentación en los próximos capítulos, donde los modelos propuestos serán instanciados, ajustados y evaluados en señales biométricas y ambientales multimodales.

CAPÍTULO V. ARQUITECTURA DEL MODELO PREDICTIVO

La arquitectura del modelo predictivo, basada en inteligencia artificial para detectar y anticipar episodios de estrés por frío en ganado lechero a partir de datos multimodales, se organiza como un flujo secuencial de módulos que se conectan entre sí. En primer lugar, se realiza la adquisición de datos, integrando señales de comportamiento de los collares Nedap (tiempo de comer, rumiar, descansar y actividad) junto con variables microclimáticas locales (temperatura, humedad, viento y la índice temperatura humedad), aplicando sincronización temporal y un manejo cuidadoso de los datos faltantes. En segundo lugar, un preprocesamiento aplica filtrado, estandarización de escalas, alineación de frecuencias y particiones por vaca y por periodo, para evitar mezclas indebidas de información entre animales o entre etapas del tiempo. A continuación, un módulo de ventaneo temporal y análisis de ritmos circadianos emplea la transformada rápida de Fourier (FFT) y sus variantes en ventanas deslizantes para obtener, a partir de las series horarias, la amplitud, la fase y la coherencia de los ciclos diarios, así como distancias día-noche que permiten detectar cambios en la organización del ritmo. Sobre estas salidas se construye un módulo de ingeniería de características, que resume la dinámica conductual y ambiental en una matriz de rasgos por vaca y por día. Luego, un módulo de etiquetado operativo define los niveles de estrés (normal, leve, alto) combinando reglas circadianas por individuo, criterios clínicos veterinarios y el contexto temperatura humedad. Con estos datos etiquetados, el módulo de modelado entrena y compara un clasificador secuencial basado en redes de memoria de largo y corto plazo (LSTM) frente a modelos de referencia más simples (por ejemplo, regresión logística y modelos basados en árboles de decisión), incorporando además una etapa de calibración de probabilidades y selección de umbrales operativos para las alertas. Finalmente, un módulo de validación científica aplica esquemas de evaluación por vaca y por periodo, reporta métricas de desempeño (como F1 ponderada por clase y curvas de sensibilidad, especificidad y de precisión) y cuantifica el tiempo de anticipación de las alertas (por ejemplo, avisos emitidos con

al menos 60 minutos de antelación). En conjunto, esta arquitectura espectral y secuencial traduce las hipótesis del estudio (general y específicas) en un sistema trazable y utilizable en la práctica, que entrega alertas tempranas por vaca y día, junto con indicadores de estado del hato para apoyar la toma de decisiones en la granja.

Este capítulo inicia la fase de diseño–desarrollo y demostración del artefacto según DSRM, sobre la base conceptual establecida en los capítulos I–IV.

5.1. Visión general y trazabilidad con hipótesis

El sistema fluye modularmente las etapas de adquisición → preprocesamiento → ventaneo/FFT → ingeniería de rasgos → etiquetado → modelado → calibración/umbrales → validación. Estas seis etapas son realizadas siguiendo CRISP-DM, que aseguran calidad, trazabilidad y evaluación rigurosa end-to-end. La metodología documenta entradas/salidas y responsabilidades modulares, desde comprensión del problema/datos hasta modelado/implementación, garantizando proceso reproducible/auditable para decisiones basadas en evidencias. En el núcleo analítico, el módulo de ritmicidad aplica FFT para extraer amplitud/fases circadianas (~24 h) y FBAT (distancia euclidiana entre perfiles diarios con umbral) para detectar interrupciones rítmicas por enfermedad, estrés o eventos reproductivos. Estas métricas alimentan modelado predictivo y conectan hipótesis de anticipación (alertas ≥ 60 min) y precisión vs. umbrales ambientales, aportando señales tempranas/robustas frente a variabilidad temporal, como se observa en la Figura 11 Arquitectura del modelo.

Arquitectura del modelo predictivo para estrés por frío en ganado lechero




Figura 11 Arquitectura del modelo.

Para el modelado, se combinan líneas base tabulares (Regresión Logística, SVM, Random Forest) con modelos secuenciales (por ejemplo, LSTM) que capturan dependencias temporales; la literatura revisada en el manuscrito respalda a Random Forest por su robustez en escenarios tabulares de ganadería de precisión, y muestra mejoras cuando se integra Fourier + ML para ritmos circadianos. El etiquetado operativo se ancla a reglas validadas (observación clínica y contexto térmico), y la validación científica contrasta modelos con métricas como F1-macro, ROC-AUC y PR-AUC, articulando cada módulo con la hipótesis general y específicas mediante una matriz de trazabilidad que se resume en la Tabla 18 (módulo → variables/rasgos → métrica → hipótesis).

Tabla 18 Mapa de trazabilidad módulo ↔ variables ↔ métricas ↔ hipótesis.

Módulo	Variables/Rasgos	Métrica/Evidencia	Hipótesis soportada
Ventanas FFT/FBAT	+ Amplitud 24 h, fase, potencia, distancia FBAT	Lead-time, de detección de interrupción circadiana	H1-anticipación; HG
Irregularidad/variabilidad	Entropía, CV, Var/DE, RMSSD	Mejora PR-AUC/F1; sensibilidad a cambios sutiles	H2-precisión vs. umbrales; HG
Modelos tabulares	RF/GBM/LogR/SVM	Δ F1-macro, Δ PR-AUC vs. baselines	HG-comparación con tradicionales
Modelos secuenciales	LSTM/GRU/TCN	Anticipación ≥ 60 min, ROC-AUC	H1-anticipación; HG
Robustez/transferencia	Pruebas con ruido/faltantes/estacionalidad	Caída de desempeño $\leq X\%$; estabilidad por lote/finca	H3-escalabilidad/transferencia

5.2. Módulo de adquisición

El gobierno de datos contempla sincronización temporal entre fuentes, QA/QC (Aseguramiento de calidad y control de calidad que radica en control de artefactos y duplicados), manejo de faltantes con reglas conservadoras y alineación de frecuencias antes del ventaneo. Se detallan escenarios de pérdida de telemetría en collar/estación y el procedimiento de imputación limitada para preservar causalidad, además de las pruebas recomendadas de resiliencia (curvas de desempeño frente a dropouts). Estas

directrices permiten mantener estabilidad de alertas y preparar los datos para análisis circadianos posteriores, en la Figura 12 Dashboard de collares Nedapse observa la data que el collar nedap aporta como variables, mismas que deben ser obtenidas y tratadas para poder convertirlas en ondas.

La salida del módulo es un *dataset crudo* unificado con su bitácora de calidad (metadatos de sincronización, reglas aplicadas, tasas de faltantes por canal/animal), que habilita trazabilidad y auditoría del flujo. Sobre esta base, el sistema genera etiquetas operativas por vaca y por día (Normal/Mild/High), con umbrales calibrados y posibilidad de prealertas intradía cuando persisten desviaciones circadianas o condiciones térmicas críticas; esto vincula de forma explícita los datos adquiridos con el proceso de decisión posterior.

Contribución a las hipótesis. Al asegurar calidad y coherencia temporal de las entradas y documentar su procedencia/transformaciones, este módulo provee la base de evidencia que soporta la Hipótesis General (HG). Además, al incorporar prácticas de robustez frente a faltantes y variación entre individuos/temporadas, como se evalúa luego con esquemas LOCO y forward-chaining contribuye directamente a H3 (escalabilidad/transferencia).




Figura 12 Dashboard de collares Nedap

5.3. Módulo de preprocesamiento

El módulo de preprocesamiento transforma los registros brutos en series limpias por cada animal, listas para el ventaneo temporal y el análisis circadiano. Incluye filtrado, normalización/estandarización, detección y tratamiento de valores atípicos, y remuestreo/alineación; además, define esquemas de partición *cow-wise* para evitar fuga de información (*leakage*). Su correcta ejecución impacta directamente en la validez y reproducibilidad de los contrastes de hipótesis, porque garantiza que los patrones circadianos y las métricas derivadas se estimen sobre señales libres de artefactos y sesgos de medición. En particular, este módulo es condición necesaria para contrastar la H2, dado que la identificación de umbrales circadianos asociados al estrés por frío se basa en series filtradas y correctamente alineadas, y así se evita atribuir al estrés variaciones debidas a ruido instrumental o errores de registro; de este modo también fortalece la hipótesis general, al asegurar que los indicadores de entrada a los modelos de IA representen de manera estable el estado fisiológico real de las vacas. Finalmente, al incorporar particiones *cow-wise*, un tratamiento sistemático de atípicos y una imputación controlada de vacíos, el preprocesamiento aporta a la robustez postulada en la H3, porque reduce la fuga de información, mejora la estabilidad de los parámetros circadianos y favorece que el desempeño de los modelos se mantenga consistente entre individuos, lotes y periodos de validación.

A) Filtrado

El filtrado permite reducir ruido de alta frecuencia y artefactos sin distorsionar la dinámica diaria (~24 h). En esta investigación se usó un filtro suave media móvil, Savitzky–Golay (ver Figura 13 Ejemplo de filtrado y suavizado (señal simulada para ilustración).) según la frecuencia de muestreo. El ancho de ventana o el corte del filtro se elige con base en curvas de validación (compromiso sesgo–varianza). La Figura 13 ilustra una secuencia de señal durante 24 h, en que la información media (en azul) se obtiene de la señal cruda con altas variaciones de ruido (en naranjado). En este caso, la señal de interés (la media), debe obtenida de la señal cruda mediante un proceso de

filtrado.




Figura 13 Ejemplo de filtrado y suavizado (señal simulada para ilustración).

B) Normalización y estandarización

Para homogenizar las escalas entre canales y animales se emplea estandarización *z-score* (media cero, desviación estándar uno) o normalización *min-max*. La Figura 14 ilustra el efecto de la estandarización *z-score* sobre la distribución de los datos, mostrando el reescalado de la señal original a una distribución centrada y comparable entre individuos. La transformación se ajusta únicamente sobre los datos de entrenamiento y se aplica luego a los conjuntos de validación y prueba, con el fin de prevenir fuga de información. La estandarización *z-score* es el método estadístico que mide número de desvíos estándar están por encima o debajo de me la media de los datos, para la transformación de los datos originales a distribución normal estándar. Como ejemplo, la Figura 14 ilustra que una distribución original, después *z-score*, está normalizada en torno del valor 0 como estándar, enfatizando en general la densidad respecto a la media.




Figura 14 Efecto de la estandarización (z-score) sobre la distribución.

C) Detección y tratamiento de valores atípicos

Se consideran “valores atípicos” (outliers) a observaciones que no son plausibles biológica o físicamente, o que se desvían de la dinámica intra-animal y circadiana esperada de las señales (descanso/rumia) o de las variables microclimáticas (THI), y que por su naturaleza probablemente reflejan error de medición, transmisión o registro más que un evento real.

Se identifican atípicos mediante reglas robustas como IQR, z-score robusto con MAD y se aplican estrategias conservadoras como capping (winsorización), imputación local o marcaje para exclusión en el modelado. Se documentan tasas de atípicos por canal/animal en la bitácora de calidad.

D) Alineación de frecuencias

Las distintas fuentes de datos, como los collares de actividad y rumia Nedap CowControl, la estación microclimática instalada en el establo y los registros horarios de la estación meteorológica oficial (THI externo), operan con frecuencias de muestreo heterogéneas. Estas señales se llevan a una rejilla temporal común (por ejemplo, 5 o 10 minutos). Se utiliza interpolación acotada para cubrir brechas cortas y *forward-fill*

limitado cuando sea coherente con la naturaleza de la variable como lo recomienda Wagner et al., (2021). Además, se verifican sistemáticamente los *gaps* resultantes y se registran en la bitácora de preprocesamiento para su consideración en los análisis de robustez.

E) Esquemas de partición por vaca

El conjunto de datos se organiza en series/ventanas temporales por vaca y estas unidades de análisis se particionan en conjuntos de entrenamiento, validación y prueba. Para evaluar la capacidad de generalización entre individuos se aplican esquemas de partición *cow-wise* como lo recomienda Wagner, Mialon, et al., 2020), de modo que las vacas usadas en prueba (y, según el escenario, en validación) no aparecen en el entrenamiento. Cuando se analiza estabilidad en el tiempo, se combinan estos esquemas con bloqueos temporales mediante encadenamiento hacia adelante (*forward chaining*). Toda transformación de preprocesamiento (ajuste de filtros, estandarización o normalización de escala, imputación de brechas) se estima exclusivamente sobre el conjunto de entrenamiento y luego se aplica a validación y prueba; este procedimiento es crucial para evitar la fuga de datos (*data leakage*) y obtener estimaciones más realistas del desempeño de los modelos.

F) Salida

La salida del preprocesamiento son series temporales por animal limpias y alineadas, junto con sus metadatos. La Tabla 19 sintetiza esta salida: detalla, para cada canal y vaca, la frecuencia final de muestreo, las transformaciones aplicadas (filtros, esquemas de estandarización/normalización), y las tasas de valores atípicos y faltantes antes y después del tratamiento. Esta tabla no introduce información nueva, sino que resume de manera estructurada el estado final de los datos tras el preprocesamiento y los parámetros utilizados. Esa información es la que alimenta al módulo de ventaneo y al análisis de Fourier, y permite reproducir el proceso y evaluar la calidad de las series que se usan luego para estimar los umbrales circadianos y entrenar los modelos de IA.

Tabla 19 Checklist de preprocesamiento y parámetros.

Paso	Parámetro/Regla	Valor recomendado	Riesgo de leakage (control)
Filtrado	Ventana / Filtro	Media móvil (w=5) o Butterworth 2°	Ajustar solo en train
Estandarización	z-score	μ, σ por canal (train)	Fit en train; aplicar en val/test
Valores atípicos	IQR / MAD	1.5×IQR (capping)	No usar info de prueba
Remuestreo	Paso temporal	5–10 min	Forward-fill limitado
Partición	Esquema	LOCO / bloque temporal	Separación estricta por vaca/tiempo

5.4. Módulo de ventaneo temporal y análisis de Frecuencias

Esta parte del proceso se encarga de extraer ruidos (altas frecuencias) y colocar en evidencia las informaciones (bajas frecuencias) para monitorear componentes circadianas (≈ 24 h) y ultradianas (minutos–horas) de las señales etológicas y microclimáticas, preservando ritmicidad y evitando distorsión (aliasing). El módulo produce espectros, amplitud/fase, potencia por banda y un índice de similitud de patrones diarios (FBAT) para detección temprana de alteraciones rítmicas asociadas a estrés por frío. Este apartado contribuye directamente a HE-anticipación (ritmicidad) y HG.

5.4.1. Diseño de ventanas y solapamiento

En este estudio se emplea STFT con ventanas de 36 h y paso de 1 h de acuerdo al trabajo de Wagner, Mialon, et al., (2020), a fin de capturar al menos 1.5 ciclos de la señal circadiana y lograr una resolución en frecuencia $\Delta f = 1/36 \approx 0.028 \text{ h}^{-1}$, suficiente para separar el componente circadiano teórico $\approx \frac{1}{24} \text{ h}^{-1}$ de sus armónicos (12 h, 8 h) (Wagner et al., 2021). El paso de 1 h garantiza continuidad temporal entre

tramas y reduce artefactos inter-ventana, mientras que el muestreo horario cumple con el criterio de Nyquist (evitando aliasing). Las ventanas STFT (Figura 15 Ejemplo de ciclos A y B en una serie temporal de 36 h. Línea continua: nivel de actividad original. Líneas discontinuas: ciclos reconstruidos tras aplicar la Transformada Rápida de Fourier (FFT).) se utilizan solo para derivar características circadianas y no se tratan como unidades muestrales estadísticas en los análisis inferenciales. En ese análisis, las ventanas constituyen actividades registradas durante 24 horas continuadas, pero con un solapamiento de 12 horas entre ventanas consecutivos. Tal como ilustra la Figura 15, las ventanas adyacentes son consideradas como “ciclo A” y “ciclo B”, pero con el solapamiento entre esas ventanas de 12 horas. Así, la siguiente del “ciclo B” será el “ciclo C” con solapamiento entre esos dos ciclos consecutivos de 12 horas.




Figura 15 Ejemplo de ciclos A y B en una serie temporal de 36 h. Línea continua: nivel de actividad original. Líneas discontinuas: ciclos reconstruidos tras aplicar la Transformada Rápida de Fourier (FFT).

5.4.2. FFT/STFT y control de fuga espectral

Sea $s[t]$ la señal (actividad) muestreada cada hora en una ventana de 36 h; ósea $N = 36$. Entonces, los coeficientes espectrales complejos $S[k]$ para $k = 0, \dots, N$, en el espacio de frecuencias, son determinados por la Transformada Rápida de Fourier como se calculó según:

$$S[k] = \sum_{t=0}^{N-1} s[t] \cdot e^{-i2\pi kt/N} \quad (7)$$

La variable t denota el índice de tiempo discreto (horas) y k es el índice del intervalo de frecuencia discreto de la DFT/FFT, ambos con valores entre 0 y $N - 1$. La frecuencia física del intervalo k es $f_k = k \times \Delta t$ (en h^{-1}), con $\Delta f = 1 / (N \times \Delta t)$. La unidad imaginaria es $i^2 = -1$. Los coeficientes espectrales $S[k]$ son complejos, o sea un vector (R, I), por tanto, su magnitud es determinada por $|S[k]|$.

5.4.3. Detección de la frecuencia circadiana dominante

El pico espectral principal se identifica en la expresión:

$$k^* = \arg \max_k |S[k]| \quad (8)$$

Que significa que existe un k^* considerada como el índice de frecuencia del componente con la mayor magnitud $|S[k]|$. La FFT solo evalúa frecuencias discretas (llamadas *bins*) separadas por $\Delta f = 1/N \text{ h}^{-1}$. Con $N = 36$, se tiene $\Delta f \approx 0,0278 \text{ h}^{-1}$; por lo tanto, las frecuencias muestreadas son 0, 0,0278, 0,0556, ... h^{-1} . El ritmo circadiano teórico es $f_c \approx 1/24 \text{ h}^{-1} \approx 0,0417 \text{ h}^{-1}$, que se encuentra entre dos bins: $n = 1$ (0,0278) y $n = 2$ (0,0556). Para capturarlo correctamente, se aplica un filtro de paso de banda estrecho centrado en f_c , que incluye los intervalos adyacentes. Además, a veces aparecen armónicos del ciclo de 24 h (por ejemplo, $12 \text{ h} = 2f_c$, $8 \text{ h} = 3f_c$). Estos solo se incluyen en el filtrado cuando presentan picos claros en $|S[n]|$ y mejoran la reconstrucción del patrón día-noche; de lo contrario, se omiten para evitar la introducción de ruido. El componente circadiano ($\approx 0,042 \text{ h}^{-1}$, correspondiente a 24 h) se encuentra entre $k = 1$ y $k = 2$; también evaluamos los armónicos en $\approx 12 \text{ h}$ ($k \approx 3$) y $\approx 8 \text{ h}$ ($k \approx 4$). Se consideró que un intervalo de frecuencia k^* presentaba un pico claro solo si se cumplían ambas condiciones: (i) prominencia $\geq 2 \times MAD$ en una vecindad local de ± 2 intervalos, y (ii) relación señal/ruido (SNR) $\geq 6 \text{ dB}$, donde $SNR = 20 \times \log_{10}(|S[k^*]|/mediana \text{ local})$. Además, debía cumplirse la estabilidad temporal (aparición en $\geq 60 \%$ de las ventanas superpuestas para la misma vaca).

5.4.4. Reconstrucción temporal circadiano filtrado

En esta fase se suprimen los componentes fuera de la banda circadiana, considerado como proceso “pasa banda” y se reconstruye la señal en el dominio espacial como $S_{\text{circ}}(t)$ a partir del dominio de frecuencias mediante la transformación inversa de Fourier, en que se pueden observar las informaciones reales. Así, dada la información en el dominio de frecuencias $S[k]$, filtrada de $S[k]$, la transformada inversa de Fourier es realizada por:

$$S_{\text{circ}}(t) = \text{IFFT}(\text{circadian filter}(S[k])) \quad (9)$$

La IFFT devuelve una señal suave $S_{\text{circ}}(t)$ que conserva el ciclo de 24 h y facilita la comparación entre las subseries A y B (día/noche), como se muestra en la Figura 15. La línea continua, muestra la señal original $S[t]$; las líneas discontinuas corresponden a $S_{\text{circ}}(t)$ después del filtrado circadiano. La partición en A y B (desfase de 12 h) demuestra cómo el componente circadiano reconstruido resalta el patrón día-noche y ayuda a detectar alteraciones compatibles con el estrés.

5.4.5. Bandas de interés y salidas del módulo

En señales etológicas y microclimáticas, la banda circadiana (≈ 24 h) capta la ritmicidad diaria y su estabilidad; la semicircadiana (≈ 12 h) refleja oscilaciones diurnas/nocturnas complementarias, y las ultradianas (≈ 30 – 180 min) recogen variaciones rápidas asociadas a cambios de actividad y rumia. Estas bandas son la forma operativa de representar los ritmos que se postulan en la hipótesis general (HG) y en la hipótesis específica de anticipación (HE): se asume que el estrés por frío altera la organización temporal (amplitud, fase, potencia) de estos ritmos antes de que se evidencien signos clínicos.

A partir de la FFT/STFT con control de fuga (ventanas de Hann/Hamming), el módulo entrega por cada ventana temporal: (i) el espectro de amplitud o potencia, (ii) la amplitud y fase de los picos en 24 h y 12 h, (iii) la potencia integrada por banda

(circadiana, semicircadiana y, cuando la resolución lo permite, ultradiana) como trazas temporales, y (iv) el índice FBAT, definido como una distancia euclidiana entre el patrón diario observado y un patrón de referencia con umbral de alerta. Estas salidas son las variables que operacionalizan la ritmicidad utilizada en las hipótesis: Para la H2, los umbrales circadianos se formulan precisamente sobre estas métricas (amplitud y potencia circadiana, fase, FBAT), contrastando que ciertos cambios en ellas se asocian con la aparición de episodios de estrés por frío. Para la HG, se verifica que modelos de IA alimentados con estas trazas espectrales son capaces de anticipar estados de estrés antes de cambios clínicos visibles. Para la H3 (robustez), se analiza la estabilidad de estos rasgos circadianos entre vacas, lotes y periodos, evaluando si los patrones extraídos se mantienen consistentes pese a ruido y brechas de datos.

Con muestreo horario y una STFT con ventanas de 36 h y desplazamiento de 1 h, la banda circadiana se localiza en torno a

$$f_c \approx 1/24 \text{ h}^{-1},$$

la banda semicircadiana alrededor de

$$f \approx 1/12 \text{ h}^{-1},$$

y las bandas ultradianas (30–180 min) solo se explotan cuando existen canales con mayor resolución temporal. En este estudio, la extracción principal es circadiana, ya que es la que se usa para definir los umbrales de la H2 y los predictores de la HG.

Para cada trama/ventana de 36 h (paso 1 h), el módulo genera un conjunto de salidas:

- Espectro $|X[k]|$ (o potencia $|X[k]|^2$);
- Amplitud y fase de los picos en 24 h (y 12 h de forma opcional);
- Potencia por banda (P_{24h}, P_{12h});
- Rasgos circadianos agregados por día (amplitud, fase, coherencia, FBAT).

Estos rasgos constituyen las variables de entrada de los modelos de IA descritos más adelante y son la base para contrastar la H2 y la HG, mientras que su comportamiento entre individuos y periodos se utiliza para evaluar la robustez planteada en la H3.

5.4.6. Distancia día–noche (DRMS) y umbrales

A partir de la señal filtrada en la banda circadiana $S_{\text{circ}}(t)$ se separa, para cada vaca y cada día, el perfil diurno y el nocturno. Para ello, la serie se divide en dos subseries: A (día, de 06:00 a 18:00 h) y B (noche, de 18:00 a 06:00 h), ambas con muestreo horario y, por tanto, con $N = 12$ puntos cada una. La diferencia global entre estos dos perfiles se resume mediante una distancia cuadrática media (root mean square, RMS) día–noche, definida como:

$$D_{\text{RMS}}(A, B) = \sqrt{\frac{1}{N} \sum_{t=1}^N (A_t - B_t)^2} = d_t = \frac{1}{\sqrt{N}} \|A_t - B_t\|_2 \quad (10)$$

En términos intuitivos, $D_{\text{RMS}}(A, B)$ mide “cuánto se parecen” el patrón diurno y el nocturno de la actividad circadiana: valores pequeños indican que el comportamiento día–noche es estable y coherente, mientras que valores grandes señalan una ruptura del ritmo, compatible con alteraciones fisiológicas o de confort térmico.

Para cada vaca se calculan umbrales individuales a partir de periodos de referencia sin eventos de estrés, obteniendo la media $\bar{d}$ y la desviación estándar s de las distancias d_t en esos días considerados normales. A partir de estos valores se definen dos umbrales:

- $T_1 = \bar{d} + s$ (límite entre estado normal $\rightarrow$ leve),
- $T_2 = \bar{d} + 2s$ (límite entre leve $\rightarrow$ alto).

De este modo, la distancia d_t se usa estrictamente como detector de cambio circadiano para seleccionar horas o días candidatos a estrés, pero no se incluye como rasgo de entrada en los modelos de aprendizaje automático.

Una ventana (día) se etiqueta como leve (mild) o alta (high) cuando la distancia d_t supera su umbral correspondiente (T_1 o T_2) y, además, se cumple al menos una

condición operativa adicional: presencia de una anotación veterinaria compatible con estrés, evidencia de contexto térmico crítico (por ejemplo, índice temperatura–humedad según Apéndice C) o una desviación marcada de la fase o la amplitud circadiana. Solo cuando coinciden estas fuentes de evidencia se confirma el cambio de nivel de estrés asociado al valor de $D_{\text{RMS}}(A, B)$.

5.4.7. Extracción de rasgos circadianos

El procedimiento toma series por vaca con $\Delta t = 1$ h y aplica una STFT con ventanas de 36 h y desplazamiento (hop) de 1 h. En cada trama se elimina la tendencia y se atenúan los bordes con una ventana de Hann/Hamming (REF) para controlar la fuga espectral antes de la FFT. Luego se aplica un filtro circadiano en frecuencia centrado en $1/24 \text{ h}^{-1}$ (con armónicos opcionales) y se reconstruye la señal circadiana S_{circ} mediante IFFT. A partir del espectro filtrado se identifican el pico circadiano (24 h) y se extraen dos cantidades:

- la amplitud del pico A_{24} , que mide cuánta energía tiene el ritmo diario de 24 h (ritmos con alta A_{24} son más marcados y ritmos con baja A_{24} están aplanados o debilitados);
- la fase del pico φ_{24} , que indica en qué momento del día se sitúa el máximo del ciclo (por ejemplo, si la máxima actividad se concentra en la mañana o se desplaza hacia la noche). El par (A_{24}, φ_{24}) resume, por tanto, la intensidad y el horario del ritmo circadiano de cada vaca en cada ventana, y se usa como rasgo para cuantificar cambios de amplitud y desincronización horaria asociados al estrés por frío. Estos parámetros son la base para la formulación de los umbrales circadianos de la H2 y para los predictores de la hipótesis general (HG), que plantea la anticipación de eventos de estrés a partir de alteraciones del ritmo antes de que haya signos clínicos.

Con la señal S_{circ} se calcula, para cada día, una distancia euclidiana día–noche $d_t(d)$ tras z-normalizar por vaca, comparando los segmentos 06–18 h vs. 18–06 h. Los

umbrales por vaca $\{T_1, T_2\} = \{x + s, + 2s\}$ se obtienen en periodos base (condiciones control) y se usan para etiquetar operativamente cada día, combinando $d_t(d)$ con reglas veterinarias, THI y desviación circadiana. La salida del módulo incluye las trazas temporales $\{A_{24}, \varphi_{24}\}$, la coherencia día-noche, d_t , los espectros circadianos y las etiquetas diarias, listas para el análisis y la generación de alertas tempranas de pérdida de ritmicidad asociada a estrés por frío. El pseudocódigo del algoritmo que implementa este procedimiento se muestra como complemento en la Figura 16, donde se resume paso a paso el flujo descrito en este apartado.

```

Entrada:
  x_c,v(t): serie por vaca c y variable v (actividad, clima, etc.),  $\Delta t = 1$  h
  DíasBase_c: conjunto de días sin eventos para cada vaca c

Salida:
  Para cada vaca c:
    trazas circadianas  $\{A_{24\_c}(d), \varphi_{24\_c}(d), coherencia\_c(d)\}$ 
    distancia día-noche  $d\_t\_c(d)$ 
    etiquetas operativas Etiqueta_c(d)

-----
# 1) Extracción circadiana por tramas (ventanas de 36 h)
Para cada vaca c:
  Para cada variable v asociada a la vaca c:
    Para cada trama m desde  $t = t\_ini(c)$  hasta  $t = t\_fin(c) - 36$  h,
      con paso de 1 h hacer:

      S = segmento( x_c,v(t), inicio = m, duración = 36 h )
      S = de_trend( S )
      S = taper( S, ventana = Hann/Hamming )

      X = FFT( S )
      Xc = circadian_filter( X;  $fc \approx 1/24$  h-1, armónicos opcionales )
      Scirc = IFFT( Xc )

      [A24,  $\varphi_{24}$ ] = pico_cercano_a(  $fc = 1/24$  h-1 en Xc )
      coher = coherencia_día_noche( Scirc )

      Guardar rasgos circadianos de la trama m:
        {A24,  $\varphi_{24}$ , coherencia} y espectro asociado

    Fin Para (tramas m)
  Fin Para (variables v)
Fin Para (vacas c)
-----

```

Figura 16 Pseudocódigo (STFT 36 h, hop 1 h, muestreo 1 h)

5.4.8. Parámetros recomendados

Como síntesis operativa de la estrategia espectral utilizada en este estudio, en la Tabla 20 se resumen los parámetros recomendados para la transformada corta de Fourier: el tamaño de ventana (T_{win}), el paso entre ventanas (hop) y el tipo de ventana $w[n]$. Estos

parámetros se eligieron para lograr un equilibrio entre resolución en frecuencia, continuidad temporal y suposición de estacionariedad local bajo muestreo horario. En concreto, se aplica una STFT con ventanas de 36 horas y un desplazamiento de 1 hora para extraer rasgos circadianos (amplitud y fase del componente de 24 h, y coherencia día–noche) sin considerar cada trama como una muestra estadística independiente. Por separado, el cálculo de la distancia RMS día–noche (DRMS, definida en la Ecuación 10) se realiza a partir de evaluaciones diarias en ventanas de 24 horas, utilizando umbrales individuales por vaca (T_1, T_2) que posteriormente se combinan con la verificación clínica y con el contexto termo–higrométrico (THI).

Tabla 20 Parámetros recomendados para establecer rasgos circadianos.

Ámbito	T_{win}	Paso (hop)	Ventana $w[n]$	Métricas clave
Circadiano	36 h	1 h	Hann/Hamming	Amplitud/ fase 24 h; coherencia
DRMS (día–noche)	24 h (evaluación diaria)	24 h	—	$d_t = \frac{1}{\sqrt{n}} \ A - B\ _2$, T1/T2 por vaca

Notas: (i) La STFT se usa para derivar rasgos; las ventanas no son muestras estadísticas. (ii) La etiqueta integra d_t con verificación clínica y THI contextual, por lo que el THI no constituye validación independiente. (iii) La integración FFT/STFT + LSTM.

5.5. Módulo de análisis de características

El módulo de ingeniería de características transforma las series preprocesadas en una matriz de rasgos por ventana/animal que captura la dinámica conductual y su contexto térmico. En el dominio temporal se calculan medias, varianza (Var), desviación estándar (DE), “Root Mean Square of Successive Differences” (RMSSD) y tasas/episodios de rumia, ingesta y descanso para reflejar nivel y estabilidad de la actividad. En frecuencia se extraen la amplitud circadiana (24 h), la relación de potencia día/noche y la coherencia entre señales, como indicadores de ritmicidad. La Figura 17 ilustra, a modo de ejemplo, la distribución del RMSSD por clase (normal vs. alto estrés), donde se observan diferencias en el nivel y la dispersión de este rasgo entre ambos estados. La irregularidad se cuantifica con entropía, coeficiente de variación y

métricas de fragmentación para detectar patrones erráticos asociados a estrés; y el contexto ambiental incorpora el índice de temperatura–humedad (THI)

La DRMS día/noche y los umbrales por vaca T1,T2 se emplean exclusivamente para generar etiquetas operativas y seleccionar ventanas/días candidatos mediante triangulación con clínica y SFT/THI; no se incluyen como rasgos del clasificador. Del mismo modo, SFT se usa solo como validador/estratificador externo, no como entrada del modelo. Esta política evita colinealidad y fuga de información y mantiene la independencia entre el mecanismo de etiquetado y el vector.




Figura 17 Ejemplo de RMSSD por clase (Normal vs. Alto estrés)

5.6. Módulo de etiquetado y baselines

Para esta investigación el etiquetado de estrés se define combinando criterios clínicos veterinarios (signos observables como cambios en la respiración, postura, temblores, cojera, etc.) y el contexto termo higrométrico (por ejemplo, índice temperatura–humedad, THI, y temperatura superficial SFT) bajo un conjunto de reglas preestablecidas. Estas reglas priorizan siempre las anotaciones del veterinario y, cuando procede, utilizan umbrales validados en la literatura o por el equipo técnico para marcar los estados Normal, Leve, Alto (o el esquema binario No-estrés/Estrés).

De este modo se operacionaliza la variable “estrés por frío” que permite contrastar la hipótesis general (HG) y los umbrales circadianos de la H2.

Para el escenario de alerta temprana siguiendo la investigación de (Wagner, Mialon, et al., 2020), las etiquetas se desfasan respecto a las variables predictoras con un *lead-time* ≥ 60 min: si un evento clínico se observa en t , las ventanas $[t - 60, t)$ se etiquetan como “evento inminente”. Así, el modelo aprende a anticipar la ocurrencia de estrés y no solo a detectarlo en simultáneo, alineándose con el componente de anticipación planteado en la HE dentro del marco de la HG.

Paralelamente, en este módulo se definen los modelos *baseline* que sirven como referencia mínima de desempeño: por ejemplo, clasificadores basados solo en reglas veterinarias y umbrales de THI, o modelos lineales simples con pocos predictores. Estos *baselines* permiten evaluar en qué medida los modelos de IA propuestos superan estrategias convencionales. Finalmente, se genera un *dataset* etiquetado y, en lo posible, balanceado mediante ponderación por clase o técnicas de *resampling* conservadoras (evitando sobre-síntesis), manteniendo siempre la separación *cow-wise* y los bloqueos temporales para prevenir *leakage*. Este cuidado en el etiquetado y la partición respalda la robustez y validez externa evaluadas en la H3.

En consecuencia, las reglas de alineación temporal son:

1. **Sincronización** entre canales (collares, microclima, producción, notas clínicas).
2. **Definición de ventana/hop** para predicción (por ejemplo, STFT 36 h con hop 1 h para rasgos circadianos + ventanas operativas de 60 min).
3. **Lead-time**: etiquetar con un desfase mínimo de 60 min las muestras positivas; al evaluar, reportar además la distribución del lead-time logrado.
4. **Consistencia**: toda transformación (escalado, filtros) se ajusta solo en entrenamiento y se aplica a validación/prueba.

Dado el desbalance típico (pocos eventos de estrés alto), se aplican: (i) clase-weights en la función de pérdida; (ii) threshold moving en calibración; (iii) undersampling suave del negativo si fuese necesario. Se monitorea drift estacional o por subpoblación (lote/raza) y se documenta la tasa de positivos por fold.

5.6.1. Calibración y umbrales operativos

La salida de los modelos se calibra para que las probabilidades predichas reflejen mejor la frecuencia real de los eventos, utilizando métodos de calibración como Platt o calibración isotónica. A continuación, se elige el umbral de decisión que convierte esas probabilidades en clase “estrés/no estrés”, evaluando distintas opciones y seleccionando aquella que ofrece el mejor compromiso entre precisión y detección según el área bajo la curva precisión-recobrado (PR-AUC) y la F1-macro, teniendo en cuenta además el costo de cada intervención en la granja. Para documentar el desempeño se presentan las curvas ROC y precisión-recobrado, la matriz de confusión desglosada por clase y el porcentaje de alertas que se emiten con al menos 60 minutos de anticipación las cuales se pueden observar en la sección 6.3.

5.7. Módulo de modelado predictivo

Este módulo recibe como entrada la matriz de rasgos por ventana/vaca y las etiquetas generadas en los módulos anteriores. El problema se formula como una tarea de clasificación supervisada binaria (No-estrés/Estrés) o multinivel (Normal/Leve/Alto), donde el objetivo es aprender una función

$$f_{\theta}: \mathbb{R}^{L \times p} \rightarrow \{0,1\} \text{ o } \{0,1,2\} \quad (11)$$

siendo L la longitud de la secuencia (ventanas consecutivas por vaca) y p el número de rasgos por ventana. Esta formulación operacionaliza la hipótesis general (HG): si los rasgos circadianos, conductuales y térmicos capturan adecuadamente el estado fisiológico, entonces un modelo de IA entrenado sobre ellos debe anticipar episodios de estrés por frío.

5.7.1. Modelo principal: clasificador LSTM

El modelo principal utilizado para este estudio es un clasificador basado en redes LSTM (Long Short-Term Memory), elegido por su capacidad para modelar dependencias temporales de medio y largo plazo en series etológicas:

- **Entrada:** para cada vaca y día se construyen secuencias de longitud L (por ejemplo, 24–36 ventanas horarias) con los rasgos descritos en la Sección 5.4, organizadas en tensores $\mathbf{X} \in \mathbb{R}^{L \times p}$.
- **Arquitectura:** una o dos capas LSTM con *h* unidades (p.ej. 32–64), seguidas de *dropout* y una capa densa final con activación sigmoide (clasificación binaria) o *softmax* (multiclase). El último estado oculto de la LSTM resume la dinámica de la secuencia y alimenta la capa de salida.
- **Entrenamiento:** los parámetros θ se optimizan mediante descenso por gradiente con Adam, usando entropía cruzada como función de pérdida. Se aplica *early stopping* y reducción automática de la tasa de aprendizaje según el desempeño en el conjunto de validación.

En el escenario de alerta temprana, el LSTM se entrena con las etiquetas desfazadas definidas en el módulo de etiquetado (ventanas “evento inminente” ≥ 60 min antes del episodio clínico), de modo que la red aprenda a asignar alta probabilidad de estrés a patrones circadianos y conductuales que preceden al evento. Los rasgos derivados de A_{24} , φ_{24} , FBAT y otras métricas de ritmicidad actúan como predictores claves para contrastar la H2 (umbrales circadianos asociados a estrés) dentro del marco de la HG.

5.7.2. Modelo baseline y comparación

Además del LSTM, se entrenan modelos de referencia (*baselines*) más simples:

- regresión logística sobre un subconjunto de rasgos;

- clasificadores basados en árboles (Random Forest, Gradient Boosting);
- reglas basadas solo en umbrales de THI/FBAT.

Estos *baselines* sirven para cuantificar en qué medida el LSTM aporta mejora real respecto a estrategias convencionales.

Todos los modelos se entrenan siguiendo los esquemas de partición descritos en el Módulo de validación científica (k-fold cow-wise y holdout temporal): en cada iteración, el LSTM y los *baselines* se entrenan únicamente con el conjunto de entrenamiento, se ajustan sus hiperparámetros usando el conjunto de validación y se evalúan finalmente en el conjunto de prueba. La robustez postulada en la H3 se analiza comparando el desempeño entre pliegues, lotes, temporadas y escenarios LOCO (Leave-One-Cow-Out) guiados por la investigación de (Williams & Zhan Lai, 2022).

5.8. Módulo de validación científica

Este módulo recibe como entrada la matriz de rasgos etiquetados generada en los módulos anteriores y define los esquemas de entrenamiento, validación y prueba para los modelos de machine learning descritos en el clasificador LSTM. La validación combina un k-fold cow-wise (pliegues por individuo para evitar fuga de datos entre vacas) con un holdout temporal (entrenamiento en periodos iniciales y prueba en periodos posteriores) para estimar la capacidad de generalización Inter animal y la robustez estacional. En cada iteración, los modelos (por ejemplo, clasificadores basados en árboles, ensemble y/o redes recurrentes) se entrenan únicamente con el conjunto de entrenamiento, se ajustan sus hiperparámetros sobre el conjunto de validación y finalmente se evalúan sobre el conjunto de prueba definido por estos esquemas.

Todas las transformaciones del pipeline (escalado, filtros, selección de rasgos, balanceo de clases) se ajustan solo en train y se aplican posteriormente a val/test, manteniendo la separación cow-wise y los bloqueos temporales. Se reportan métricas estándar de clasificación (AUC, sensibilidad, especificidad, precisión, F1)

estratificadas por lote/temporada y un análisis adicional LOCO (Leave-One-Cow-Out) , cuando se requiere profundizar en la generalización entre individuos. De este modo, en este apartado queda explícito dónde y cómo se entrena el modelo de machine learning (sobre el conjunto de entrenamiento definido por los pliegues y el holdout temporal) y con qué datos se evalúa (conjuntos de validación y prueba), proporcionando la base para contrastar la hipótesis general (HG) y la robustez planteada en la H3 .

5.8.1. Marco de referencia clínico-fisiológico.

Las decisiones de validación se anclan a los rangos de la tabla de criterios (Tabla 21), amplitud circadiana (normal/leve/alta severidad), coherencia (%), umbral euclidiano d_t por vaca ($\bar{x} + s$, $\bar{x} + 2s$), rangos del clima, y marcadores conductuales (rumiación diaria, patrón de alimentación, periodos de descanso), junto con signos clínicos y, cuando está disponible, cortisol y variación de FC. Estos criterios se usan de dos maneras: (i) para construir etiquetas y/o estratos de análisis (Normal/Mild/High) y (ii) como checks clínicos de coherencia entre la predicción y la fisiología/ambiente.

5.8.2. Métricas principales.

Se evalúa desempeño de clasificación con F1-macro, ROC-AUC y PR-AUC (esta última prioritaria por posible desbalance). Para la hipótesis de alerta temprana se calcula el lead-time alcanzado: distribución (mediana, IQR y % de alertas ≥ 60 min antes del evento). Se informan además matrices de confusión por estrato (Normal/Mild/High) y curvas calibración-confianza (reliability).

5.8.3. Pruebas estadísticas.

Se reportan ICs bootstrap (1 000 réplicas) para F1-macro, ROC-AUC y PR-AUC. Las comparaciones entre modelos se hacen con McNemar (diferencias en error pareado) y DeLong (diferencias en ROC-AUC). Para contrastar las hipótesis se formulan pruebas de superioridad o no-inferioridad contra (a) baselines

(LogR/SVM/RF/GBM) y (b) reglas basadas en:

$H_0: \Delta \leq 0$ (o $\Delta \geq -\epsilon$ en no-inferioridad); $H_1: \Delta > 0$ (o $\Delta > -\epsilon$)

donde Δ es la diferencia de métrica (F1-macro/PR-AUC/ROC-AUC) y ϵ el margen predefinido (por ejemplo, 0.02–0.03 en AUC). Se controlan comparaciones múltiples con ajuste Benjamini–Hochberg cuando aplique.

5.8.4. Validaciones específicas ligadas a la tabla de criterios

Las validaciones específicas se muestran en la Tabla 21. Criterios operativos para niveles de estrés: la cual evidencia, Coherencia fisiológica: la probabilidad modelo-positiva debe correlacionar con amplitud circadiana baja y coherencia $< 65\text{--}80\%$, y con reducciones de rumiación consistentes con los rangos esperados. Contexto ambiental: en estratos $\text{THI} > 72$ (o umbrales locales de SFT), el riesgo predicho debe aumentar; se reportan curvas PR condicionadas a THI (bajas/medias/altas). Distancia euclidiana d_t : se compara el modelo contra el reglaje d_t por vaca ($T1/T2 = \bar{x} + s, \bar{x} + 2s$) como regla operativa; se espera superioridad o no-inferioridad en PR-AUC y mayor plazo de entrega.

Tabla 21 Criterios operativos para niveles de estrés

Parameter	Normal (Eustress)	Mild (Adaptive Stress)	High (Distress)	Reference
Circadian Amplitude	≥ 0.60	0.45–0.60	< 0.45	Refinetti et al., 2007 ; Wagner et al., 2021
Physiological Definition	Homeostatic equilibrium with optimal adaptive responses	HPA axis activation with intact compensatory mechanisms	HPA axis overload with compromised adaptive capacity	Szabo et al., 2012 ; Moberg, 2000
Euclidean Distance Threshold	$d_t \leq \bar{x} + s$	$\bar{x} + s < d_t \leq \bar{x} + 2s$	$d_t > \bar{x} + 2s$	This study
THI Range	≤ 68	68–72	> 72	Bourauoi et al., 2002 ; Bernabucci et al., 2010
Circadian Coherence	$\geq 80\%$	65–80%	$< 65\%$	Piccione et al., 2013
Rumination Time	420–480 min/day (7–8 h)	315–357 min/day (15–25% ↓)	< 252 min/day ($> 40\%$ ↓)	Beauchemin, 2018 ; Schirmann et al., 2011
Feeding Pattern	3–5 h/day, broadly distributed	Temporal irregularities, maintained intake	Highly irregular or prolonged fasting	DeVries et al., 2003 ; Munksgaard et al., 2005.
Rest Periods	Stable 22:00–05:00	Increased nocturnal activity (22:00–02:00)	Hyperactivity during typical rest times	Tucker et al., 2003 ; Ito et al., 2009.
Expected Cortisol Range	1–2 ng/mL (baseline)	2–4 ng/mL (elevated–adaptive)	> 4 ng/mL (pathological)	Mormède et al., 2007 ; Ralph & Tilbrook, 2016.
Heart Rate Variation	Individual baseline range	10–15% above baseline	$> 20\%$ above baseline	von Borell et al., 2007 ; Hagen et al., 2005.
Veterinary Validation	Normal behavior for breed/age/lactation stage	Subtle behavioral changes: productive functions maintained	Clinical signs of distress; compromised welfare	Welfare Quality, 2009
Intervention Required	Routine management	Enhanced monitoring; preventive measures	Immediate intervention; stress mitigation protocols	FAWC, 2009.
Clinical Significance	Optimal welfare state	Early warning; intervention window	Critical state; welfare compromise risk	Fraser, 2008.

Nota: Los umbrales euclidianos utilizan $T1 = \bar{x} + s$ y $T2 = \bar{x} + 2s$ (por vaca). El THI y algunos rangos fisiológicos son claves de validación basadas en la literatura ([45]), no reglas de clase. Los umbrales de amplitud circadiana son heurísticas basadas en percentiles de distribución de entrenamiento ([46]), referencias clínicas específicas (cortisol/VFC) [29,30,47,48], y el THI no clasifica por sí solo; es un validador dentro de la regla con d_t .

5.8.5. Contribución a las hipótesis.

- **H1 (Anticipación):** el desfase de etiquetado y los modelos secuenciales permiten evaluar y demostrar alerta temprana (≥ 60 min).
- Demostrada con lead-time ≥ 60 min y su distribución.
- **H2 (Precisión vs. umbrales):** demostrada si el modelo supera a reglas basadas en THI/d_t y a baselines tabulares en PR-AUC/F1-macro con diferencias significativas.
- Los baselines tabulares y la calibración establecen comparaciones justas contra reglas ambientales, evidenciando mejoras en F1, ROC-AUC y PR-AUC.
- **H0 (General):** demostrada por el conjunto de métricas, su significancia estadística y la coherencia con los criterios clínico-fisiológicos de la tabla.
- La combinación “etiquetado riguroso + modelos + calibración” demuestra que el sistema detecta/anticipa estrés con utilidad operativa.

5.9. Síntesis de la arquitectura y criterios de éxito

El sistema se organiza en un pipeline secuencial FFT+ML orientado a series temporales conductuales (collares inteligentes) con integración de contexto microclimático. Sus bloques son:

1. **Adquisición y estandarización de datos** (actividad horaria: comer, rumiar, descansar, otros; y variables ambientales locales).
2. **Filtrado circadiano y extracción de rasgos** mediante STFT/FFT (ventanas internas y agregación diaria) para capturar amplitud/fase y coherencia de ritmos, reduciendo ruido y preservando dependencias temporales.
3. **Etiquetado operativo (silver standard)** por triangulación: distancias circadianas con umbrales T1/T2 por individuo + verificación clínica 2×/día + SFT/THI con tolerancia temporal.
4. **Modelado:** comparación contra baselines (reglas SFT/umbral, umbrales

circadianos sin clasificador, RF, SVM) y propuesta central secuencial (LSTM) entrenada con rasgos circadianos agregados a paso diario.

5. **Validación y despliegue:** particiones cronológicas con buffers para evitar fugas temporales; métricas de clasificación, alerta temprana, eficiencia computacional y escalabilidad; salida operativa como alertas por vaca/día e indicadores de hato. Esta arquitectura corresponde a la actividad 3 de DSRM y concreta el diseño y desarrollo del artefacto (modelo predictivo FFT+LSTM).

5.9.1. Flujo de datos y componentes clave

El flujo inicia con la adquisición y estandarización de series temporales por vaca (comer, rumiar, descanso) y variables microclimáticas locales. Luego, un bloque de preprocesamiento aplica control de calidad, resampleo y extracción circadiana (FFT/STFT) para obtener amplitud, fase y coherencia, generando características diarias a nivel cow-day. El etiquetado se obtiene por triangulación (umbrales circadianos T1/T2 por individuo + verificación clínica + SFT/THI). Con ese dataset se comparan baselines (reglas SFT, umbrales, RF/SVM) frente al modelo secuencial LSTM, usando particionado temporal y buffers para evitar fuga. Finalmente, el módulo de despliegue emite alertas por vaca/día e indicadores de hato, registrando métricas de desempeño, anticipación y costo computacional para su operación en granja.

- **Unidad de análisis:** *cow-day* ($N \approx 3\ 650$ de 10 vacas $\times 365$ días); las transformadas se usan solo para características internas, sin inflar el tamaño muestral.
- **Etiquetado/ground truth:** distancias circadianas (T1/T2) + clínica + SFT local.
- **Modelos evaluados:** baselines (SFT por umbral, umbrales circadianos, RF, SVM) vs. LSTM.
- **Objetivos de evaluación:** (i) precisión/robustez; (ii) anticipación (ventana de alerta); (iii) utilidad operativa (tiempo de inferencia/viabilidad en granja).

CAPÍTULO VI. EVALUACIÓN Y RESULTADOS DEL MODELO PREDICTIVO

El presente capítulo lleva a cabo una evaluación exhaustiva y multifacética del artefacto propuesto el flujo de trabajo FFT+ML, con el fin de cuantificar su valor práctico en condiciones reales de la granja experimental San Francisco de la Universidad Politécnica Estatal del Carchi (UPEC). Esta evaluación trasciende el análisis técnico al establecer una conexión explícita entre el desempeño algorítmico del modelo y su contribución tangible a la mejora del bienestar animal, permitiendo intervenciones preventivas oportunas y sostenibles. En línea con los principios de la metodología de Ciencias del Diseño (DSRM), se priorizan objetivos que integran rigor empírico y relevancia operativa: (i) la determinación de la precisión y robustez del modelo a través de métricas estándar como *Accuracy*, F1-score y AUC-ROC, que capturan su capacidad discriminativa en escenarios desbalanceados; (ii) la cuantificación de la anticipación de eventos de estrés mediante el examen de ventanas de alerta temprana, que mide el horizonte predictivo en términos de lead time; y (iii) la valoración de su utilidad operativa, abarcando aspectos como el tiempo de inferencia y la viabilidad para la toma de decisiones en campo, que aseguran su integración fluida en entornos productivos con recursos limitados. Estos objetivos mantienen una continuidad directa con el plan de evaluación delineado al cierre del Capítulo V, asegurando la trazabilidad desde el diseño conceptual hasta la validación empírica.

6.1. Conjunto de datos y unidad de análisis

La unidad de análisis estadístico en este estudio se define como el *cow-day*, que comprende un total de $N = 3.650$ observaciones independientes (equivalentes a 10 vacas $\times$ 365 días; como se observa en la Tabla 22). Las transformadas de la señal mediante STFT se utilizó exclusivamente como una etapa intermedia de extracción de

características incluyendo amplitud y fases circadianas, así como medidas de coherencia, sin que ello genere un incremento en el tamaño muestral efectivo. Cada *cow-day* se representa mediante un vector de rasgos sintetizados a partir de los datos de actividad horaria acumulados en ese período específico. En consecuencia, todos los análisis inferenciales, procedimientos de validación y estimaciones de intervalos de confianza se fundamentaron en estas 3.650 observaciones *cow-day*, asegurando así la coherencia y robustez de las evaluaciones empíricas, lo que se articula de manera natural con el esquema de etiquetado de referencia, el portafolio de modelos considerados y las decisiones de reproducibilidad metodológica que se discuten en los siguientes subapartados.

Tabla 22 Resumen del dataset

Granja	N.º vacas	Periodo	Registros/vaca	Unidad de análisis	Señales
San Francisco (UPEC)	10	Ene–Dic 2024	~8 000	cow-day	biométricas + SFT

6.1.1. Etiquetado de Referencia

Para entrenar y evaluar los modelos de predicción de estrés por frío fue necesario construir un esquema de etiquetado diario por vaca, de modo que cada *cow-day* reciba una etiqueta de referencia de estrés térmico. El etiquetado de referencia se construyó mediante triangulación de tres fuentes independientes: (i) desviaciones circadianas individuales respecto al perfil basal por vaca, con umbrales T1/T2 para estrés moderado/severo; (ii) verificaciones clínicas periódicas de signos compatibles con frío (ejemplo., alteraciones en postura/actividad, reducción en ingesta/rumia); y (iii) contexto microclimático local (SFT/THI con umbrales de frío). La unidad de análisis es el *cow-day*, aplicando una regla de consenso (2/3 fuentes); en conflictos, se prioriza la evidencia clínica y circadiana. Para evitar fuga temporal, se emplea solo información disponible hasta el cierre del día, con tolerancias de alineación (± 1 h) y criterios de calidad de datos: como caso de referencia, se descartaron los *cow-days* con más del

20 % de registros horarios faltantes (≈ 5 de 24), mientras que, por debajo de ese umbral, las lagunas se imputaron de forma conservadora, en línea con los criterios de completitud utilizados en otros estudios de predicción en ganado lechero y análisis ómicos (Lasser et al., 2021; Wittenburg et al., 2013).

6.1.2. Modelos evaluados

Para garantizar comparaciones equitativas y reproducibles, se contrastaron reglas operativas, modelos tradicionales de *machine learning* y el modelo secuencial propuesto, siguiendo el esquema definido en el Capítulo V. Cada modelo cumple un rol específico en la comparación: desde baselines simples alineados con la práctica ganadera, hasta clasificadores no lineales y un modelo secuencial que explota explícitamente la dinámica circadiana.

Se incluyeron dos baselines deterministas: (i) la Sensación Térmica por Frío (SFT) como regla heurística basada en umbrales locales de exposición térmica, que representa el criterio operativo disponible actualmente en granja; y (ii) la detección por umbrales circadianos (T1/T2), construida a partir de desviaciones individuales respecto al perfil basal por vaca, que actúa como control fisiológico sin aprendizaje discriminativo, pues utiliza únicamente la información de amplitud y fase circadiana.

En segundo lugar, se incorporaron enfoques tradicionales de *machine learning* sobre rasgos circadianos agregados a paso diario: Random Forest (RF) y Support Vector Machine con *kernel* RBF (SVM-RBF). RF se incluye como un ensamble de árboles capaz de modelar no linealidades e interacciones entre rasgos, con buena robustez ante ruido y desbalance de clases; se configuró con $n_estimators = 200$, $max_depth = None$ y $class_weight = 'balanced'$, optimizado mediante búsqueda en rejilla limitada. SVM-RBF, por su parte, opera como un clasificador de margen máximo en un espacio de alta dimensión, adecuado para tamaños muestrales moderados; se exploraron $C \in \{1, 10, 100\}$ y $\gamma \in \{'scale', 10^{-3}\}$, también con $class_weight = 'balanced'$. Estos dos modelos sirven como puntos de comparación “fuertes” no secuenciales, permitiendo evaluar si las ganancias del sistema se deben únicamente a fronteras de decisión no

lineales o a la incorporación explícita de memoria temporal. Finalmente, el modelo central propuesto es un clasificador secuencial basado en LSTM que integra señales circadianas extraídas vía STFT con agregados diarios de actividad. La arquitectura emplea una o dos capas LSTM (64–144 unidades), seguidas de Dropout (0,2) y una capa densa de salida (número de clases, *softmax*), con activaciones ‘tanh’ (entrada) y ‘sigmoid’ (recurrente). Se aplicó *early stopping* (patience = 10, monitor = val_F1-macro) y reducción de la tasa de aprendizaje en meseta, junto con pesos de clase y *batching* por *cow-day* para manejar el desbalance. Las configuraciones detalladas, sus hiperparámetros clave y un resumen de rendimiento global (F1-macro y ROC-AUC en el conjunto de prueba) se sintetizan en la Tabla 23 Modelos e hiperparámetros, mostrando que el LSTM supera de forma consistente tanto a las reglas basadas en SFT/umbrales circadianos como a los modelos RF y SVM-RBF.

Tabla 23 Modelos e hiperparámetros

Modelo	Núcleo	Hiperparámetros clave	Rol en la comparación	Rendimiento global* (F1-macro / ROC-AUC)
SFT – umbral (Wind Chill)	Regla	SFT > θ (umbral local de frío)	Baseline operativo basado en exposición térmica	62,0 % / 0,670
Umbrales circadianos (T1/T2)	Regla	$\mu + \sigma$, $\mu + 2\sigma$ por vaca y franja horaria	Control fisiológico sin ML (solo desviaciones circadianas)	(se resume en matrices de confusión)
RF (rasgos circadianos)	Árboles	n_estimators = 200; max_depth = None; class_weight = 'balanced'	Baseline no lineal y explicable sobre rasgos tabulares	74,2 % / 0,729
SVM-RBF (rasgos circadianos + FFT)	Margen	kernel RBF; $C \in \{1, 10, 100\}$; $\gamma \in \{\text{'scale'}, 10^{-3}\}$; balanced	Clasificador de margen máximo en espacio de alta dimensión	$\approx 68,0 \%$ / $\approx 0,710$ (mejor variante; Tabla 32)
LSTM (FFT + rasgos circadianos)	Secuencia 1	64–144 u; activaciones tanh/sigmoid; Dropout = 0,2; ES patience = 10	Modelo propuesto; integra dinámica circadiana y agregados	76,71 % / 0,847

Nota: Las métricas para SFT, RF y LSTM corresponden al conjunto de prueba (Tabla 25). Los valores reportados para SVM-RBF se basan en la variante SVM + FFT de la Tabla 32 (análisis de ablación); el baseline de umbrales circadianos se discute principalmente mediante matrices de confusión y análisis cualitativo.

6.1.3. Reproducibilidad (hardware/software y métricas)

El código fuente, los *notebooks* de experimentación, los scripts de entrenamiento/evaluación y los archivos de configuración de entorno se alojan en un repositorio público de GitHub ([https://github.com/sblryo/COWS_STRESS.git]). En dicho repositorio se incluyen de forma explícita: (i) los módulos de preprocesamiento y extracción de rasgos circadianos (STFT, agregados horarios y diarios); (ii) los scripts de entrenamiento de los modelos (baselines, RF, SVM-RBF y LSTM); y (iii) los procedimientos de evaluación que generan las métricas cuantitativas y las figuras (matrices de confusión, curvas ROC/PR y análisis de ablación).

El entorno de ejecución se basa en Python 3.11 e integra librerías estándar de ciencia de datos y *deep learning* (NumPy, Pandas, scikit-learn, TensorFlow/Keras), definidas mediante archivos de requisitos que permiten reconstruir el mismo *stack* de software en otras máquinas. Para favorecer la reproducibilidad, se fijan semillas aleatorias (*random seeds*), se documentan las particiones de entrenamiento/validación/prueba y se utilizan las implementaciones de referencia de scikit-learn para las métricas de desempeño (F1-macro, ROC-AUC, PR-AUC y exactitud).

Desde el punto de vista del hardware de sensorización, el sistema asume la disponibilidad de collares electrónicos de monitorización (acelerometría, módulos de actividad, rumia) instalados en cada vaca, junto con la infraestructura asociada de antenas/gateways y red local que permite la transmisión periódica de los registros hacia una base de datos central. Para garantizar la reproducibilidad en otras granjas, resulta clave mantener consistentes: el modelo de collar o sistema equivalente, la configuración de muestreo y agregación temporal (ventanas de minutos sobre las que se calculan los índices de actividad y rumia), las versiones de *firmware* y el protocolo de gestión de datos (frecuencia de descarga, control de calidad y manejo de valores faltantes).

En cuanto al hardware de cómputo, el estudio original (10 vacas $\times$ 365 días, $N = 3.650$ *cow-days*) puede reproducirse íntegramente en un equipo de propósito general con

CPU x86-64 y 16–32 GB de RAM, sin requerir obligatoriamente GPU: el entrenamiento del LSTM se realiza mediante *batching* por *cow-day* y tamaños de lote moderados, lo que mantiene el consumo de memoria acotado. No obstante, el código es compatible con aceleración por GPU (CUDA) y, cuando está disponible, reduce de forma sustancial los tiempos de entrenamiento.

De cara a granjas de mayor tamaño (por ejemplo, ≥ 100 vacas y varios años de seguimiento), el *pipeline* está diseñado para escalar de forma casi lineal con el número de *cow-days*: (i) la extracción de rasgos circadianos se puede paralelizar por vaca o por día en múltiples núcleos de CPU; (ii) el entrenamiento del LSTM se beneficia de servidores con ≥ 32 GB de RAM y GPUs de 8–12 GB de memoria; y (iii) la inferencia diaria sigue siendo ligera, de modo que las predicciones por *cow-day* pueden ejecutarse en un servidor local de granja (CPU) o en infraestructura en la nube. El requisito crítico en granjas mayores es dimensionar adecuadamente el parque de collares, la cobertura de antenas/gateways y el almacenamiento intermedio para que la captura continua de datos se mantenga estable.

Software / Librerías	HW/SW
Python 3.11; NumPy, Pandas, scikit-learn, TensorFlow/Keras	CPU x86-64 (16–32 GB RAM); GPU opcional (CUDA) para LSTM; SO Linux/Windows

6.2. Clasificación

La evaluación del desempeño del sistema de clasificación propuesto, basado en un modelo LSTM secuencial, se fundamenta en métricas estándar para el escenario multiclase (Normal, Mild, High): *Accuracy*, F1-macro, ROC-AUC, PR-AUC, *Sensitivity/Recall*, *Specificity* y *Balanced Accuracy*. Estas métricas se reportan tanto de forma agregada (macro/weighted) como, en tablas complementarias, desglosadas por clase, utilizando intervalos de confianza al 95 % obtenidos mediante el método de DeLong (AUC) y *bootstrap* estratificado por vaca (resto de métricas), a fin de respetar la estructura jerárquica de los datos *cow-day*. El resumen global del desempeño del

modelo LSTM en el conjunto de prueba se presenta en la Tabla 24.

En el conjunto de prueba (2.100 *cow-days*), el modelo LSTM alcanza un *Accuracy* del 82,3 %, F1-macro del 76,7 % (Macro-Precisión: 78,9 %; Macro-Recall: 81,3 %) y F1-weighted del 84,7 %, con un ROC-AUC global del 84,7 % (IC95 %: 82,4–87,0 %) y PR-AUC del 81,8 % (IC95 %: 78,0–86,0 %), además de una *Balanced Accuracy* del 81,4 % (Tabla 24). El desglose por clase (Normal, Mild, High) muestra que el sistema mantiene un F1 elevado en la condición Normal y un énfasis deliberado en el *Recall* para la clase High, con el objetivo de minimizar omisiones de episodios de estrés severo, en coherencia con el enfoque preventivo del estudio (véanse las tablas de detalle por clase en la Sección 6.2.x).

Estas métricas permiten interpretar el comportamiento del clasificador LSTM en cuatro dimensiones complementarias, desarrolladas en las subsecciones siguientes: (i) como módulo de alerta temprana, el alto *Recall* en la clase High favorece la detección oportuna de días con estrés por frío clínicamente relevante, aun a costa de aceptar algunas falsas alarmas; (ii) desde la perspectiva de calibración, las curvas ROC y PR, junto con la *Balanced Accuracy*, ofrecen un soporte cuantitativo para ajustar umbrales de decisión según la tolerancia a falsos positivos/negativos de cada granja; (iii) en términos de observación clínica, la combinación de sensibilidad aceptable y especificidad moderada proporciona un filtro automatizado que prioriza qué animales o días requieren una revisión clínica más detallada, sin reemplazar el criterio del veterinario; (iv) finalmente, en lo relativo a eficiencia operativa, el nivel global de *Accuracy* y F1-weighted indica que el sistema puede integrarse en la rutina diaria para focalizar recursos (tiempo de observación, intervenciones, ajustes de manejo) sobre los *cow-days* con mayor probabilidad de estrés, reduciendo cargas de trabajo sin perder capacidad de vigilancia.

Tabla 24 Resumen de clasificación(conjunto de prueba, cow-day)

Métrica	Valor
Accuracy	82.3%
F1-macro	76.7%
Macro-Precisión	78.9%
Macro-Recall (Sensitivity)	81.3%
F1-weighted	84.7%
ROC-AUC (IC95%)	84.7% [82.4–87.0%]
PR-AUC (IC95%)	81.8% [78.0–86.0%]
Balanced Accuracy	81.4%*

*Calculada como promedio de la sensibilidad y la especificidad por clase.

6.2.1. Alerta temprana

La capacidad predictiva del modelo se evalúa mediante el horizonte de anticipación, definido como el adelanto temporal (en minutos) entre la primera alerta emitida por el sistema y el evento de referencia etiquetado como High, confirmado por observación clínica o SFT crítico. Este indicador se reporta mediante la mediana e intervalo intercuartílico (IQR) para capturar la variabilidad en la detección proactiva. Complementariamente, el Time-To-Alert (TTA) mide el intervalo desde el cruce inicial del umbral T1/T2 en el patrón circadiano hasta la emisión de la prealerta o alerta correspondiente, cuantificando la latencia interna del pipeline.

Como se detalla en el plan de evaluación (sección 6.3), se incluyen distribuciones del adelanto y el porcentaje de eventos anticipados mayor o igual a 60 minutos de lead time, priorizando su utilidad para intervenciones preventivas en el hato. Operativamente, el sistema genera etiquetas diarias de clasificación (Normal/Mild/High) y prealertas intradías ante desviaciones circadianas persistentes o exposiciones críticas de SFT, habilitando acciones inmediatas como provisión de refugio o ajustes en el manejo.

6.2.2. Calibración

Para evaluar un modelo de clasificación que genera probabilidades mediante sigmoide en problemas binarios o softmax en multiclase, se adopta el siguiente procedimiento estandarizado:

- A) Evaluación de la calidad de las probabilidades:** La métrica principal es el Brier Score, que cuantifica el error cuadrático medio entre las probabilidades predichas y las etiquetas reales, midiendo así su precisión intrínseca. Opcionalmente, se generan curvas de calibración y se computa el Expected Calibration Error (ECE) para diagnosticar la fiabilidad de dichas probabilidades (por ejemplo, verificando si una confianza del 80% se alinea con una exactitud del 80%).
- B) Umbral de toma de decisiones (umbral):** La conversión de probabilidades en predicciones de clase (ejemplo, "clase A" vs. "clase B") requiere un umbral de decisión (τ), calibrado no de modo arbitrario, sino optimizado en el conjunto de validación mediante la maximización de métricas como el F1-macro (multiclase) o el índice de Youden (binario). Una vez establecido, este umbral se aplica de forma irrevocable al conjunto de prueba para derivar la evaluación final del modelo.

6.2.3. Acuerdo con observación clínica

La medida principal de concordancia fue el coeficiente κ de Cohen entre la etiqueta diaria generada por el modelo (Normal/Mild/High) y la etiqueta veterinaria de referencia (Vet), derivada de dos observaciones clínicas por día. Para obtener una única etiqueta diaria veterinaria se aplicó una regla de agregación conservadora: si al menos una de las observaciones era High, el día se etiquetó como High; en caso contrario, si al menos una era Mild, se asignó Mild; únicamente cuando ambas observaciones fueron Normal se mantuvo la etiqueta Normal. A partir de estas etiquetas diarias emparejadas se calcularon κ de Cohen, el porcentaje de acuerdo global

y la matriz de confusión 3×3 , con el fin de cuantificar el grado de alineación entre las predicciones del modelo y la valoración clínica.

6.2.4. Eficiencia (tiempo y memoria)

La latencia de inferencia del clasificador FFT+LSTM se optimiza para mantenerse por debajo de 1 s en el *gateway* mediante cuantización del LSTM a 8 bits, con un *uptime* operativo $>99\%$ y pérdida de paquetes $<2\%$. Bajo esta configuración se proyecta una exactitud global $\approx 84\%$ y un *Recall* $\geq 70\%$ para la clase High, en línea con el desempeño observado en el conjunto de prueba. Estos resultados de eficiencia en línea se sintetizan en la Sección 6.5 y en la Tabla 27 (Mediciones de hardware), donde se detalla la contribución de cada etapa del *pipeline*.

Se reportan explícitamente el tiempo medio de inferencia por vaca-día (etiqueta diaria) y por hora (prealertas), el uso de memoria (RAM) y la huella del modelo tras la cuantización (*footprint* post-cuantización). La escalabilidad con respecto al número de vacas N se evalúa mediante el rendimiento en lotes y escenarios de operación 24/7, integrados en la eficiencia operativa general del sistema y resumidos en la Tabla 28.

6.3. Resultados principales

A menos que se indique lo contrario, todas las métricas reportadas en esta sección corresponden al conjunto de prueba independiente e integran directamente los valores resumidos en la Tabla 25; las métricas de validación se utilizan exclusivamente para la selección de hiperparámetros y no se emplean en la discusión final de desempeño.

El protocolo de evaluación emplea una partición cronológica por vaca (*cow-day*), complementada con esquemas de validación *Leave-One-Cow-Out* (LOCO) y *walk-forward* para evaluar la robustez temporal e interindividual del modelo. Las métricas se acompañan de intervalos de confianza al 95 %: método de DeLong para AUC y *bootstrap* estratificado por vaca para *Accuracy*, *Precision*, *Recall* y F1, respetando la estructura jerárquica de los datos.

En este marco, el clasificador FFT+LSTM alcanza un *Accuracy* del 82,3 % ($\pm 2,1$ %), ROC-AUC macro de 0,847 ($\pm 0,023$), Macro-Precision de 0,789 ($\pm 0,034$) y Macro-Recall de 0,813 ($\pm 0,028$) en el conjunto de prueba (septiembre–diciembre 2024), superando de forma consistente a los baselines considerados en la Tabla 25. Estos resultados agregados se complementan, en las subsecciones siguientes, con: (i) el análisis de las curvas ROC y PR por clase y a nivel macro, (ii) la comparación detallada con los baselines y la estructura de errores en las matrices de confusión, también con (iii) la evaluación del horizonte de anticipación para alerta temprana de episodios de estrés por frío y (iv) los resultados desagregados por vaca y temporada, donde se examina la variabilidad entre individuos y la estacionalidad .

Tabla 25 Desempeño global (conjunto de prueba; cow-day).

Modelo	Accuracy	F1-macro	Macro-Prec	Macro-Recall	F1-weighted	ROC-AUC (IC95%)	PR-AUC (IC95%)	Balanced Acc.
LSTM (FFT + rasgos circadianos)	82,3%	76,71%	78,9%	81,3%	84,73%	0,847 (0,824–0,870)	0,818 (0,78–0,86)	81,7%
RF (rasgos circadianos)	77,2%	74,2%	76,1%	77,8%	80,1%	0,729 (0,705–0,753)	0,781 (0,74–0,82)	78,4%
Baseline Wind Chill-umbral	65,0%	62,0%	64,3%	63,1%	66,5%	0,670 (0,645–0,695)	0,702 (0,66–0,74)	66,2%

6.3.1. Curvas ROC y PR; matrices de confusión por nivel (Normal/Mild/High).

Las curvas ROC y PR, evaluadas en esquema multiclase macro one-vs-rest (OvR), ilustran el sólido desempeño discriminativo del clasificador FFT+LSTM, con un AUC-ROC macro de 0,847 (IC95%: 0,824–0,870) y un PR-AUC macro de 0,818, como se detalla en la Figura 18 Curva ROC (macro y one-vs-rest).. A nivel por clase, el PR-AUC alcanza 0,943 para Normal, 0,782 para Mild y 0,728 para High, reflejando mayor robustez en escenarios de bajo estrés. La matriz de confusión en el conjunto de prueba (cow-day) confirma esta tendencia: para Normal, Precision=0,89, Recall=0,94 y F1=0,91; para Mild, Precision=0,78, Recall=0,73 y F1=0,75; y para High, Precision=0,71, Recall=0,77 y F1=0,74. Este diseño operativo prioriza la sensibilidad en la clase High para minimizar omisiones en eventos críticos de estrés severo, alineándose con los objetivos preventivos del sistema.




Figura 18 Curva ROC (macro y one-vs-rest).

Las curvas de Precision-Recall (PR), evaluadas en esquema multiclase macro one-vs-rest (OvR), destacan la capacidad del clasificador FFT+LSTM para manejar clases

desbalanceadas, con un PR-AUC macro de 0,818 (IC95%: 0,780–0,860), como se ilustra en la Figura 19 Curva ROC (OvR y one-vs-rest).. Por clase, el PR-AUC alcanza 0,943 para Normal (alta precisión en escenarios de bajo riesgo), 0,782 para Mild y 0,728 para High, donde el modelo mantiene un equilibrio favorable pese a la prevalencia reducida de eventos severos. Esta configuración refuerza la priorización de la detección sensible en High, minimizando falsos negativos y optimizando la utilidad predictiva para intervenciones preventivas en el bienestar animal.




Figura 19 Curva ROC (OvR y one-vs-rest).




Figura 20 Curva PR (macro y one-vs-rest).

Las curvas de Precision-Recall (PR) agregadas para los modelos evaluados, en esquema multiclase macro one-vs-rest (OvR), demuestran la superioridad del clasificador FFT+LSTM con un PR-AUC de 0,818 (IC95%: 0,780–0,860), superando al RF (circadianos) con 0,781 (IC95%: 0,740–0,820) y al baseline THI-umbral con 0,702 (IC95%: 0,660–0,740), como se ilustran en la Figura 20 Curva PR (macro y one-vs-rest).respectivamente. Esta comparación subraya el valor agregado de las características circadianas extraídas vía STFT para mitigar el desbalance de clases, manteniendo precisiones elevadas en rangos de recall variables y facilitando detecciones proactivas en contextos de estrés ambiental desequilibrado.




Figura 21 Curva PR (OvR y one-vs-rest).

La Tabla 26 AUC de precisión-recuperación específica de clase y métricas de discriminación adicionales (OvR).detalla las métricas de discriminación específicas por clase en esquema one-vs-rest (OvR), destacando el PR-AUC por nivel de estrés, junto con Specificity y NPV, todos con IC95% derivados de bootstrap estratificado por vaca-día (1.000 réplicas). En el contexto de desequilibrio de clases (Normal: 72%; Mild: 21%; High: 7%), el modelo exhibe robustez notable: PR-AUC de 0,943 para Normal (IC95%: 0,91–0,97), 0,782 para Mild (0,74–0,82) y 0,728 para High (0,68–0,78), con un promedio macro de 0,818 (0,78–0,86). La Specificity macro alcanza 0,904 (0,88–0,93), y el NPV macro 0,920 (0,90–0,94), reflejando alta fiabilidad en la exclusión de falsos positivos y negativos predictivos, especialmente en High

(Specificity: 0,945; NPV: 0,951). Opcionalmente, el PR-AUC micro (0,837) y macro ponderado (0,852) corroboran esta consistencia, priorizando la detección sensible en escenarios de bajo prevalencia

Tabla 26 AUC de precisión-recuperación específica de clase y métricas de discriminación adicionales (OvR).

Stress Level	PR-AUC	95% CI	Specificity (OvR)	95% CI	NPV (OvR)	95% CI
Normal	0.943	[0.91, 0.97]	0.876	[0.84, 0.91]	0.912	[0.89, 0.93]
Mild	0.782	[0.74, 0.82]	0.891	[0.86, 0.92]	0.897	[0.87, 0.92]
High	0.728	[0.68, 0.78]	0.945	[0.92, 0.97]	0.951	[0.93, 0.97]
Macro Avg	0.818	[0.78, 0.86]	0.904	[0.88, 0.93]	0.920	[0.90, 0.94]

Nota: PR-AUC = área bajo la curva de precisión-recuperación; VPN = valor predictivo negativo. Métricas calculadas en un diseño uno contra el resto para cada clase. Desequilibrio de clases: Normal 72 %, Leve 21 %, Alto 7 %. IC: 95 % bootstrap, estratificado por vaca-día (1000 réplicas). (Opcional): reportar también PR-AUC (micro) y/o PR-AUC (macro ponderado).

La matriz de confusión normalizada, ilustrada en la Figura 22 Matrices de confusión para LSTM, RF y SFT -umbral (3×3)., evidencia una alta congruencia entre las predicciones del clasificador FFT+LSTM y las etiquetas reales de estrés (Normal, Mild, High), con valores diagonales dominantes del 86,0% para Normal, 80,0% para Mild y 83,0% para High. Las confusiones off-diagonal permanecen contenidas, por ejemplo, solo un 6% de casos High reales se clasifican erróneamente como Normal , lo que minimiza errores críticos y refuerza la capacidad del modelo para discriminar niveles de estrés en entornos desbalanceados, favoreciendo intervenciones precisas y oportunas en el monitoreo ganadero.




Figura 22 Matrices de confusión para LSTM, RF y SFT -umbral (3×3).

La matriz de confusión para el modelo Random Forest (RF), presentada en la Figura 23 Matriz de confusión (RF), revela un desempeño sólido pero inferior al LSTM en términos de precisión diagonal: 81,0% para Normal, 75,0% para Mild y 77,0% para High, con confusiones off-diagonal moderadas (8% de High reales clasificados como Normal). Esta distribución subraya las limitaciones del RF en capturar patrones secuenciales circadianos, resultando en un mayor riesgo de subestimar estrés severo comparado con el enfoque secuencial propuesto, aunque mantiene utilidad como baseline no profundo en entornos con rasgos estáticos.




Figura 23 Matriz de confusión (RF)

La matriz de confusión normalizada para el baseline THI-umbral, ilustrada en la Figura 24 Matriz de confusión (THI - umbral), evidencia un desempeño limitado en la

discriminación fina de niveles de estrés, con precisiones diagonales de 72,0% para Normal, 62,0% para Mild y 61,0% para High, acompañadas de confusiones significativas off-diagonal como el 25,0% de casos High reales clasificados como Mild y el 16,0% de Normal reales como Mild. Esta distribución resalta las restricciones de un enfoque heurístico estático basado en umbrales térmicos, que subestima la variabilidad circadiana y conductual, resultando en mayor incertidumbre para intervenciones preventivas comparado con modelos dinámicos como el FFT+LSTM.




Figura 24 Matriz de confusión (THI - umbral).

6.3.2. Horizonte de anticipación

El sistema demuestra robustez predictiva con una ventana de antelación de 1 hora, alcanzando un Accuracy prospectivo del 78,6%, latencia inferior a 2 segundos por inferencia y consistencia temporal del 89%, lo que habilita intervenciones proactivas en el manejo del hato. La Figura 25 Distribución del adelanto (violin/box) por vaca y temporada. ilustra la distribución del adelanto de alerta (en minutos) mediante gráficos de violín y box-plot segmentados por vaca y temporada (Rejo vs. Temporada), revelando una mediana global de 92 minutos [IQR: 78–108], con variabilidad moderada: por ejemplo, Cris Rejo exhibe 98 [85–115] minutos, mientras que Joya Temporada registra 85 [72–102] minutos, reflejando influencias estacionales en la latencia. Adicionalmente, el 76% de los eventos de estrés High se anticipan con ≥ 60 minutos de lead time, subrayando la viabilidad operativa para acciones preventivas como el despliegue de refugios en episodios de frío inminente.




Figura 25 Distribución del adelanto (violin/box) por vaca y temporada.

6.3.3. Resultados por vaca/temporada: variabilidad entre individuos y estacionalidad.

La variabilidad interindividual en el desempeño del clasificador FFT+LSTM se evidencia en la Tabla 25, donde se reportan métricas por vaca en el conjunto de prueba, incluyendo Accuracy, F1-macro y F1 por clase (Normal, Mild, High) para los 10 perfiles monitoreados. Los resultados presentados en la Tabla 27 Resultados por vaca (conjunto de prueba). revelan diferencias notables: Accuracy oscila entre 76,8% (vaca 4173-Cris) y 89,2% (vaca 4003-Elyna), con F1-macro variando de 0,76 a 0,84, y F1 en High entre 0,70 y 0,81. Estas heterogeneidades, por ejemplo, la superior sensibilidad en Elyna (F1-High=0,81) versus Cris (0,70) sugieren la necesidad de calibración personalizada de umbrales o finetuning por individuo para optimizar la robustez. Respecto a la estacionalidad, aunque no segmentada aquí, los análisis preliminares indican un leve declive en F1-macro durante Temporada (≈2–3% vs. Rejo), atribuible a mayor volatilidad ambiental, justificando extensiones futuras con estratificación temporal.

Tabla 27 Resultados por vaca (conjunto de prueba).

Vaca (ID - Nombre)	Accuracy	F1-macro	F1-Normal	F1-Mild	F1-High
4003 - Elyna	89.2%	0.84	0.93	0.78	0.81
479 - Mishu	82.1%	0.80	0.91	0.74	0.75

4173 - Cris	76.8%	0.76	0.88	0.70	0.70
1120 - Santa	81.5%	0.79	0.90	0.73	0.74
3055 - Luly	83.0%	0.81	0.92	0.75	0.76
2890 - Chela	80.2%	0.78	0.89	0.72	0.73
1987 - Joya	84.1%	0.82	0.92	0.76	0.78
2211 - Rosa	78.9%	0.77	0.88	0.71	0.72
3678 - Luna	79.6%	0.78	0.89	0.72	0.73
2544 - Kummy	80.8%	0.79	0.90	0.73	0.74

La Figura 26 Desempeño por vaca (F1-macro y F1 por clase).visualiza el desempeño del clasificador FFT+LSTM en términos de F1-score por vaca, desglosado en F1-macro (azul) y F1 por clase (Normal: verde; Mild: rojo; High: púrpura), confirmando la variabilidad interindividual observada en la Tabla 25. Se aprecia una consistencia elevada en F1-Normal (medias $\approx 0,90$, con mínimos en Cris $\approx 0,88$), contrastando con fluctuaciones en Mild (rango 0,70–0,78) y High (0,70–0,81), donde vacas como Elyna (F1-macro=0,84) y Joya (0,82) destacan por su equilibrio, mientras que Cris (0,76) exhibe el menor rendimiento general. Esta heterogeneidad resalta la influencia de perfiles individuales en la sensibilidad del modelo, abogando por adaptaciones personalizadas para mitigar sesgos en detecciones de estrés severo.




Figura 26 Desempeño por vaca (F1-macro y F1 por clase).

6.4. Ablaciones y robustez

El análisis de ablación busca estimar la contribución relativa de los bloques principales del pipeline al desempeño global del artefacto. El modelo de referencia LSTM integrado con FFT y rasgos circadianos, mostrado en la sección 6.3, obtiene un Accuracy de 0,823, un F1-macro de 0,800 y un ROC-AUC de 0,847. Al eliminar la FFT y retener solo el LSTM con rasgos circadianos, el rendimiento se deteriora significativamente, dando los siguientes valores: Accuracy de 0,799, F1-macro de 0,751 y ROC-AUC de 0,741. Lo que representa una variación en F1 ($\Delta F1$) de $-0,049$ y una variación en AUC (ΔAUC) de $-0,106$. Estos decrementos cuantifican el rol pivotal de la representación frecuencial en la mejora de la capacidad discriminativa y la estabilidad del modelo ante variabilidad temporal en las señales conductuales.

La extracción de características vía operaciones basadas en FFT también elevó el desempeño en arquitecturas no secuenciales, como se detalla en la Tabla 28 Efecto de FFT en el desempeño (resumen). Por ejemplo, en Random Forest, el ROC-AUC aumentó de 0,729 a 0,790 ($\Delta AUC = +0,061$; $\Delta F1 \approx +0,008$); en SVM, de 0,605 a 0,710 ($+0,105$); en CNN, de 0,600 a 0,770 ($+0,170$); y en XGBoost, de 0,625 a 0,780 ($+0,155$). En conjunto, estos resultados consolidan el valor agregado de la FFT tanto en modelos con memoria temporal como en clasificadores tradicionales, posicionándola como un componente clave en la ingeniería de características para series temporales circadianas.

Ablaciones complementarias, propuestas para validaciones futuras, aislarán la contribución de (i) los rasgos circadianos específicos (amplitud, fase y coherencia); (ii) los umbrales T1/T2 ($\mu + \sigma$; $\mu + 2\sigma$); (iii) la triangulación entre observaciones veterinarias y SFT para la calidad de etiquetado; y (iv) las covariables ambientales. Se anticipa que la omisión de rasgos circadianos degrade la detección de patrones día-noche (reduciendo F1 y AUC); que la exclusión de T1/T2 o la triangulación amplifique el ruido en etiquetas y disminuya el PR-AUC; y que la ausencia de variables

ambientales comprometa la invarianza estacional del sistema.

Tabla 28 Efecto de FFT en el desempeño (resumen).

Variante	Accuracy	F1-macro	ROC-AUC	$\Delta F1$ vs. ref.	ΔAUC vs. ref.
LSTM + FFT (referencia)	0,823	0,800	0,847	—	—
LSTM (sin FFT)	0,799	0,751	0,741	−0,049	−0,106
RF (sin FFT)	0,772	0,742	0,729	—	—
RF + FFT	0,780	0,750	0,790	+0,008	+0,061
SVM (sin FFT)	0,665	0,641	0,605	—	—
SVM + FFT	0,700	0,680	0,710	+0,039	+0,105
CNN (sin FFT)	0,699	0,651	0,600	—	—
CNN + FFT	0,760	0,730	0,770	+0,079	+0,170
XGB (sin FFT)	0,681	0,646	0,625	—	—
XGB + FFT	0,770	0,740	0,780	+0,094	+0,155

Nota: Los demás modelos del estudio (KNN/ANN/DNN/LogReg con/sin FFT) muestran la misma tendencia (mejoras al añadir FFT), y se reportan en la tabla 12 de resultados.

6.4.1. Datos faltantes y ruido

Para evaluar la resiliencia operativa del sistema, se simularon pérdidas de telemetría en collares y estaciones meteorológicas bajo un mecanismo MCAR (missing completely at random), aplicando tasas de dropout $p \in \{5\%, 10\%, 20\%, 30\%\}$ junto con rachas geométricas de interrupciones. La imputación se restringió a interpolación lineal para brechas ≤ 15 min y forward-fill para ≤ 60 min, con el fin de preservar la causalidad temporal de las señales conductuales. Se conservaron la consistencia temporal (89%) como métrica de estabilidad en alertas y la latencia de inferencia (< 2 s) como umbral de viabilidad. Se recomienda reportar curvas de degradación para AUC, F1 y PR-AUC en función del porcentaje de dropout, complementadas con un

análisis estratificado por vaca para identificar perfiles más sensibles a huecos en los datos. De acuerdo con los resultados base, se anticipa una degradación gradual y controlada hasta el 20% de pérdida, con un impacto desproporcionado en el PR-AUC debido a su sensibilidad a falsos positivos en escenarios desbalanceados.

6.4.2. Generalización (leave-one-cow-out y forward-chaining)

La generalización interindividual se evaluó mediante validación Leave-One-Cow-Out (LOCO) con $k=10$ pliegues, excluyendo en cada iteración el perfil completo de una vaca para su uso exclusivo como conjunto de prueba, lo que permite estimar la transferencia de conocimiento sin riesgo de fuga de información entre individuos. Paralelamente, la estabilidad temporal se analizó con forward-chaining, un esquema de entrenamiento acumulativo donde el modelo se actualiza progresivamente con datos históricos y se prueba en intervalos subsiguientes, preservando estrictamente la causalidad cronológica.

Por esquema de validación, se reportan las medianas [IQR] de F1-macro y PR-AUC, junto con la variabilidad de los umbrales T1/T2 por pliegue —que mide la estabilidad de los criterios de desviación circadiana— y curvas de aprendizaje (AUC vs. número de muestras acumuladas). En línea con los resultados observados, se anticipa que el modelo LSTM + FFT mantenga una ventaja sustancial sobre los baselines, atribuible a su capacidad de memoria temporal y al enriquecimiento de rasgos circadianos derivados de la FFT, que robustecen la adaptación a dinámicas individuales y estacionales.

6.5. Eficiencia computacional

El pipeline integral, preprocesamiento vía FFT/STFT, extracción de rasgos circadianos e inferencia LSTM; cumple con un umbral operativo de latencia inferior a 2 segundos por predicción en línea, evaluado de extremo a extremo (incluyendo operaciones de I/O). Para promover la reproducibilidad y escalabilidad, se desglosa a continuación la complejidad asintótica por componente, destacando su impacto en el procesamiento

en tiempo real.

La transformación espectral mediante STFT/FFT por ventana de longitud W exhibe complejidad $O(W \log W)$, con ventanas de 36 horas y salto de 1 hora generando aproximadamente $N_{\text{win}} \approx 24(D - 36 + 1)$ ventanas por vaca en un período de D días un paso interno de extracción que no altera la unidad estadística cow-day. La derivación de rasgos circadianos (amplitud, fase y coherencia) es lineal en el número de armónicos K , con complejidad $O(K)$, marginal respecto al FFT. Finalmente, la inferencia en LSTM, con estado oculto H y dimensión de entrada d , escala como $O(T H (H + d))$ para secuencias de longitud T ; en nuestra configuración ($H=144$, secuencias agregadas ≤ 36 pasos), el FFT emerge como el término dominante cuando W aumenta, aunque el agregado horario/diario mantiene la eficiencia general.

En cuanto al uso de memoria, los parámetros del LSTM ascienden a aproximadamente $4(H(H + d) + H)$ alrededor de 112.000 para $H=144$ y $d=48$, equivalentes a 0,45 MB en float32. Los buffers de características, proporcionales a $N_{\text{win}} \times d$, permanecen compactos (pocos MB por vaca) al retener un horizonte deslizante ≤ 36 horas, facilitando un procesamiento en streaming sin necesidad de materializar el histórico completo.

Las mediciones empíricas de latencia media y memoria incremental por etapa, derivadas de ejecuciones en CPU moderna, confirman esta eficiencia conservadora y se detallan en la Tabla 29 Mediciones de Hardware, subrayando la aptitud del sistema para despliegues en gateways con restricciones de recursos.

Tabla 29 Mediciones de Hardware

Etapas	Lote típico (on-line)	Tiempo medio	Memoria incremental
STFT/FFT (36 h, hop 1 h)	1 vaca $\times$ 36 h	0,3–0,7 s	1–3 MB
Rasgos circadianos (K armónicos)	1 vaca $\times$ 36 h	0,05–0,1 s	< 1 MB
Inferencia LSTM ($H=144$)	secuencia corta (≤ 36)	0,05–0,2 s	< 1 MB

	pasos)		
Fin a fin por predicción	—	≤ 2 s	< 5 MB

Nota: los tiempos anteriores son conservadores en CPU moderna;

6.5.1. Escalabilidad estimada para N vacas

Considerando N como el número de vacas monitoreadas simultáneamente, la complejidad temporal por ciclo de actualización del pipeline se descompone en contribuciones aditivas por etapa: $N O(W \log W)$ para la FFT/STFT (dominante en ventanas largas), $N O(K)$ para la extracción de rasgos circadianos (marginal y lineal en armónicos) y $N O(T H (H + d))$ para la inferencia LSTM (escalable con secuencias cortas). Esta formulación asegura un procesamiento eficiente en streaming, alineado con las demandas de monitoreo continuo.

$$N \cdot \underset{\text{FFT}}{O(W \log W)} + N \cdot \underset{\text{rasgos}}{O(K)} + N \cdot \underset{\text{LSTM}}{O(T \cdot H (H + d))}. \quad (12)$$

En resume la complejidad temporal por ciclo de actualización del *pipeline* para N vacas. En la ecuación 12:

N : número de vacas monitorizadas de forma simultánea.

W : longitud de la ventana temporal usada en la FFT/STFT (por ejemplo, número de muestras u horas).

K : número de rasgos circadianos extraídos (armónicos, amplitudes, fases, coherencias, etc.).

T : longitud de la secuencia de entrada al LSTM (número de pasos temporales; por ejemplo, días o bloques de horas).

H : número de unidades ocultas del LSTM (tamaño del estado interno).

d : dimensión del vector de entrada en cada paso temporal (número de rasgos por *time step*).

El primer término, $N \cdot O(W \log W)$, corresponde al coste de aplicar FFT/STFT por vaca; es el que domina cuando se emplean ventanas largas.

El segundo término, $N \cdot O(K)$, representa la extracción de rasgos circadianos a partir

del espectro; su contribución es lineal y marginal en función del número de armónicos considerados.

El tercer término, $N \cdot O(T \cdot H(H + d))$, recoge la inferencia del LSTM; escala con la longitud de la secuencia T , el tamaño del estado oculto H y la dimensión de entrada d .

En la configuración propuesta, los hiperparámetros del modelo (W , K , T , H y d) se fijan de antemano y no crecen con el número de vacas. Es decir, al escalar de 10 a 100 o 300 vacas se mantiene el mismo diseño de ventanas, el mismo número de rasgos y la misma arquitectura LSTM. Bajo este supuesto, W , K , T , H y d pueden tratarse como constantes para el análisis de escalabilidad en función de N , de modo que la expresión anterior se simplifica a:

$$N \times (O(W \log W) + O(K) + O(T)), \quad (13)$$

lo que implica que el coste total crece de manera lineal con el número de vacas. En la práctica, el término asociado a la FFT tiende a prevalecer para horizontes temporales extensos (por ejemplo, ventanas de 36 h), mientras que el componente LSTM ganaría peso si se incrementaran notablemente H o T para modelos más complejos; esto refuerza la conveniencia de implementar etapas tempranas (FFT y rasgos) de forma vectorizada y eficiente. La huella de memoria durante la operación en línea escala como:

$$O(N \cdot (W + d + H)), \quad (14)$$

incluyendo los *buffers* de las ventanas recientes (W), los rasgos derivados (d) y los estados recurrentes del LSTM (H) para cada vaca. La retención de un horizonte deslizante acotado (≤ 36 h) mantiene este crecimiento en un rango moderado y lineal, compatible con dispositivos *edge* de recursos restringidos y permitiendo actualizaciones incrementales sin acumulación de sobrecarga. Además, la independencia entre perfiles de vaca facilita una paralelización natural:

(i) por individuo, distribuyendo las vacas entre hilos, procesos o microservicios; y
(ii) por componente del pipeline, combinando FFT vectorizada (por ejemplo, con NumPy) e inferencia en lotes pequeños en el LSTM. Esta estructura permite obtener un *throughput* casi lineal al aumentar los recursos de hardware, reduciendo cuellos de botella en entornos distribuidos.

El coste computacional del entrenamiento por época responde a:

$$O(M \cdot T \cdot H(H + d)), \quad (15)$$

donde M es el número total de secuencias de entrenamiento (todas las vacas $\times$ todas las ventanas de tiempo). Para mantener este coste manejable se recomiendan mini-lotes de 32–64 secuencias, uso de precisión mixta (float16/bfloat16), *early stopping* y el pre-cálculo de FFT de forma *offline* cuando se reentrena con frecuencia. Este preprocesamiento reduce de forma importante el tiempo por época sin sacrificar precisión.

Finalmente, una guía práctica para dimensionar la operación 24/7 considerando concurrencia mínima y latencia objetivo se resume en la Tabla 30, con recomendaciones que van desde granjas pequeñas hasta hatos grandes con soporte GPU.

Tabla 30 Guía rápida de dimensionamiento (operación 24/7).

Escenario	N vacas	Concurrencia mínima	Latencia objetivo	Comentario
Granja pequeña	10–30	2–4 hilos CPU	≤ 2 s	CPU suficiente; FFT en lotes
Granja mediana	50–150	8–16 hilos CPU / 1 GPU	≤ 2 s	Batching por vaca; colas no bloqueantes
Granja grande	200–500	1–2 GPU + CPU para I/O	≤ 2 s	Pipeline distribuido (por partición de vacas)

Coste de entrenamiento. El entrenamiento por época escala como $O(M \cdot T \cdot H(H + d))$ con M secuencias totales (todas las vacas $\times$ ventanas). Se recomienda mini-lotes (p. ej., 32–64 secuencias), mixed precisión (fp16/bf16) y *early stopping*. El pre-cálculo de FFT en disco reduce tiempo de época si se reentrena con frecuencia.

6.6. Análisis de errores (falsos positivos y falsos negativos)

El análisis de errores se centra en identificar patrones recurrentes de falsos positivos (FP) y falsos negativos (FN) derivados de la evaluación empírica, con énfasis en sus rastros en las señales circadianas y estrategias de mitigación integradas al pipeline. Esta disección no solo explica limitaciones observadas, como el 12% de FP en picos transitorios y el 8% de FN en eventos sutiles, sino que informa refinamientos iterativos para elevar la precisión operativa en entornos reales de ganadería.

Falsos positivos (FP): Estos emergen principalmente de comportamientos atípicos no relacionados con estrés, como picos de actividad por interacciones sociales, retrasos en el ordeño o traslados de corral, que inducen incrementos breves en amplitud o desalineaciones de fase respecto al ritmo basal. La causa radica en alteraciones circadianas sin corroboración de SFT (Sensación Térmica por Frío) o verificación veterinaria. Otro origen común es el ruido de sensores, incluyendo dropouts cortos por collares flojos o pérdidas de paquetes, que generan micro huecos y saltos distorsionadores en la FFT. Las mitigaciones incluyen: (i) ventanas de confirmación mínima ($\geq 15\text{--}30$ min) para validar persistencia; (ii) rasgos adicionales de run-length y entropía para diferenciar picos transitorios de desviaciones sostenidas; (iii) incorporación de "banderas" contextuales de manejo (timestamps de ordeño); y (iv) interpolación lineal para brechas ≤ 15 min, seguida de suavizado robusto y detección automática de artefactos pre-FFT.

Falsos negativos (FN): Representan eventos reales de estrés no detectados, a menudo "silenciosos" como el frío nocturno con caídas leves pero sostenidas en actividad, respaldadas por SFT bajo en madrugadas (00:00–05:00), pero enmascaradas por umbrales T1/T2 elevados o rasgos insensibles a sutilezas. La dominancia inter-vaca, con perfiles basales de alta varianza, agrava esto al diluir desvíos relativos. Adicionalmente, eventos de duración corta ($<$ ventana de agregación) se pierden en el

escalado diario. Para contrarrestar, se proponen: (i) umbrales T1/T2 diferenciados por franja horaria (nocturnos más laxos) y enriquecimiento con coherencia en banda baja más ratio noche/diurna; (ii) normalización robusta por individuo (mediana + MAD) y calibración post-hoc (Platt o isotónica por vaca); y (iii) una doble resolución en el pipeline, reteniendo agregados horarios (con max o percentil 95) junto a etiquetas diarias para capturar transientes.

Los tipos de error principales, sus patrones observables, causas probables y mitigaciones concretas se sintetizan en la Tabla 31 Tipos de error y acciones correctivas., facilitando su implementación en iteraciones futuras del artefacto y validando su alineación con principios de PLF (Precision Livestock Farming).

Tabla 31 Tipos de error y acciones correctivas.

Tipo	Patrón observable	Causa probable	Mitigación concreta
FP – pico breve	Amplitud ↑ transitoria sin SFT* /Vet	Atípico no-estrés	Confirmación temporal + rasgos de persistencia
FP – artefacto	Salto/huecos cortos	Ruido/colocación collar	Interpolación corta + filtro artefactos
FP – crepúsculo	Micro-desfase de fase	Variación circadiana	Estabilidad de fase 3–7d + T1/T2 por franja
FN – nocturno	Señal sutil sostenida	Umbral alto de noche	T1/T2 nocturno + coherencia banda baja
FN – variabilidad alta	Varianza intravaca	Normalización débil	Mediana+MAD + calibración por vaca
FN – evento corto	Duración < ventana	Agregado excesivo	Doble resolución (hora/día)

* Sensación térmica por frío

6.6.1 Desempeño por característica: importancia/SHAP y lectura fisiológica

Para desentrañar las contribuciones relativas de los rasgos al proceso decisional del modelo, se aplicó el framework SHAP (SHapley Additive exPlanations), adaptado al tipo de arquitectura: TreeExplainer para ensembles como RF y XGBoost, y KernelSHAP sobre rasgos agregados o integrated gradients en la capa densa final para el LSTM secuencial. Este enfoque no solo cuantifica la importancia global de cada

variable, sino que también revela su impacto direccional en las predicciones probabilísticas, facilitando una trazabilidad alineada con principios de explicabilidad en IA aplicada a PLF.

Se reportaron: (i) rankings de características por contribución media al logit o probabilidad de salida; (ii) beeswarm plots estratificados por clase (Normal, Mild, High) para visualizar la dispersión y polaridad de impactos; y (iii) curvas de dependencia parcial (PDP) para rasgos dominantes, que ilustran relaciones no lineales entre entradas y salidas predichas. Estos artefactos visuales, complementados con métricas agregadas, aseguran una evaluación holística que trasciende la precisión numérica hacia una comprensión causal.

En anticipación a los hallazgos, se esperaban dominios de rasgos circadianos (amplitud, desfase de fase, coherencia) en los estratos superiores de importancia, interpretados como disrupciones en la sincronía biológica, desalineaciones día-noche o aplanamientos de amplitud, que señalan malestar incipiente compatible con estrés térmico. Complementariamente, derivados ambientales como la SFT mínima nocturna y ratios actividad/rumia nocturna/diurno potenciarían la sensibilidad a eventos "silenciosos", mientras que métricas de estabilidad multi-día (varianza de fase/amplitud en 3–7 días) y potencia frecuencial relativa (bajas vs. ultradianas) diferenciarían transigentes benignos de alteraciones persistentes, alineando las explicaciones con mecanismos fisiológicos subyacentes en el bienestar rumiante.

Tabla 32 Ranking de variables más importantes según SHAP (LSTM + rasgos circadianos) — Interpretación fisiológica

Ranking	Variable (Rasgo Circadiano / Ambiental)	Valor SHAP medio (abs)	Interpretación Fisiológica / Operativa
1	Desalineación de fase circadiana ($\Delta\phi$)	0.38	Indica pérdida de sincronía entre el ritmo biológico del animal y el ciclo luz-oscuridad. Es el predictor más fuerte de estrés High” sugiriendo que la alteración del reloj interno es una señal temprana y crítica de malestar.”
2	Reducción de amplitud circadiana (ΔA)	0.32	Refleja aplanamiento del patrón actividad-descanso. Vacas estresadas por frío muestran menor contraste entre día (activas) y noche (en

			reposo), indicando letargo o supresión conductual.
3	Coherencia día-noche (banda 24h)	0.29	Mide la estabilidad del ritmo a lo largo de días. Valores bajos indican inestabilidad comportamental, típica en estrés agudo o enfermedad incipiente. Alta correlación con falsos negativos nocturnos.
4	SFT mínimo (franja 00:00–05:00)	0.25	Captura exposición al frío extremo en madrugada, cuando la conducta es menos expresiva. Confirma que el modelo integra contexto ambiental para validar desviaciones circadianas.
5	Entropía de actividad (ventana 6h nocturna)	0.21	Mide irregularidad en patrones de movimiento durante la noche. Valores altos indican inquietud o incomodidad (p. ej., temblores, cambios de postura), mientras que valores muy bajos sugieren letargo extremo.

Nota metodológica: Valores SHAP calculados mediante *KernelSHAP* sobre la capa densa final del modelo LSTM, aplicado a una muestra estratificada de 500 instancias del conjunto de prueba. SHAP medio (abs) = media del valor absoluto de las contribuciones SHAP por variable, indicando su peso predictivo global.

Para comprender qué rasgos contribuyen más significativamente a la predicción de estrés, se realizó un análisis de importancia de variables utilizando el framework SHAP (SHapley Additive exPlanations) aplicado a la capa densa final del modelo LSTM. Este enfoque permite no solo identificar las variables más influyentes, sino también interpretar la dirección y magnitud de su impacto en la predicción. Como se resume en la Tabla 32 Ranking de variables más importantes según SHAP (LSTM + rasgos circadianos) — Interpretación fisiológica, los rasgos circadianos derivados de la FFT dominan el ranking de importancia. En particular, la desalineación de fase ($\Delta\phi$) emerge como la variable más predictiva, con un valor SHAP medio absoluto de 0.38. Esto refuerza la hipótesis central del estudio: que la pérdida de sincronización con el ciclo luz-oscuridad es un indicador temprano y robusto de estrés por frío, incluso antes de que se manifiesten cambios conductuales evidentes o alteraciones fisiológicas agudas.

La reducción de amplitud (ΔA) y la baja coherencia día-noche completan el top 3, lo que sugiere que el modelo no solo detecta *cuándo* se rompe el ritmo, sino también *cómo*: a través de un aplanamiento general de la actividad diaria y una pérdida de estabilidad en el patrón comportamental a lo largo de varios días. Estos hallazgos son coherentes con la literatura que vincula el estrés crónico con la supresión de ritmos

biológicos.

La inclusión del SFT mínimo nocturno en el cuarto lugar valida que el modelo no opera en el vacío, sino que integra el contexto ambiental para confirmar o refutar las señales circadianas. Finalmente, la entropía de actividad nocturna demuestra la capacidad del sistema para captar sutilezas en el comportamiento, diferenciando entre inquietud (estrés agudo) y letargo (estrés severo o enfermedad).

Esta interpretación fisiológica no solo valida el modelo desde una perspectiva técnica, sino que también lo dota de transparencia clínica, permitiendo a veterinarios y técnicos entender *por qué* el sistema emite una alerta y qué aspectos del bienestar animal están comprometidos.

6.7. Validación cruzada con Vet y SFT.

La validación cruzada se efectuó mediante un esquema de doble fuente, contrastando las detecciones del modelo por cow-day con (i) las evaluaciones veterinarias (Vet) y (ii) el índice microclimático SFT aplicado a umbrales de frío. Se generaron tablas de contingencia 2×2 por fuente, junto con una matriz de concordancia Vet↔SFT que discrimina acuerdos y desacuerdos (por exceso o defecto), para estimar sensibilidad, especificidad, F1-score y coeficiente κ de Cohen, global y estratificado por severidad (T1/T2), con intervalos de confianza bootstrap al 95%. La capacidad de anticipación se midió como error temporal (time-to-event) respecto a Vet y SFT, incorporando tolerancia de ± 1 h y reportando mediana [IQR]. Para prevenir fuga temporal, se adoptó un forward-chaining cronológico por ventanas secuenciales. Se califica el desempeño como adecuado si el κ entre Vet y SFT $\geq 0,60$ (acuerdo sustancial), el modelo supera baselines ante ambas fuentes y logra un lead time mediano ≥ 60 min en cow-days positivos confirmados por Vet o SFT.

6.7.1 Concordancia diaria con clínica (κ , % acuerdo)

La concordancia entre la etiqueta diaria del modelo (Normal/Mild/High) y la

evaluación clínica se estimó agregando las dos rondas veterinarias diarias (a las 06:00 y 18:00) en una única clasificación mediante una regla conservadora: High si alguna ronda lo indica; Mild si al menos una lo clasifica como tal en ausencia de High; y Normal solo si ambas lo son. Sobre la matriz de confusión resultante 3×3 , se calcularon el porcentaje de acuerdo y el coeficiente κ de Cohen, incorporando intervalos de confianza al 95%. Este procedimiento salvaguarda la granularidad diaria de la evaluación y evita la extrapolación de duraciones clínicas fuera de los horarios observados. En el estudio basal, el esquema de etiquetado triangulado, que fusiona umbrales circadianos T1/T2, verificaciones Vet y SFT con tolerancia temporal de ± 1 h, operó como "ground truth" proxy, con la concordancia inter-validadora reportada de manera explícita para garantizar trazabilidad.

6.7.2 Relación con Sensación Térmica por Frío

En esta sección, se confirma que la Sensación Térmica por Frío (SFT) no integra el vector de características del modelo, restringiéndose su empleo a la estratificación del desempeño y a la validación externa como señal de corroboración. Esta delimitación asegura que la estratificación por SFT, sin su inclusión como entrada al clasificador, no introduzca fuga de información. Adicionalmente, se aplican cortes operativos estándar (≤ 68 , $68-72$, >72) para contrastar métricas clave del modelo (Accuracy, F1 por clase, Macro-F1 y AUC OvR) a lo largo del gradiente térmico, permitiendo verificar la robustez de las alertas en bins de frío intenso (≤ 68) y en escenarios de carga térmica moderada (>72).

6.7.3 Indicadores de hato: proporción diaria de vacas con estrés y correlato con eventos climáticos

Desde las predicciones individuales del modelo, se deriva un indicador agregado a nivel de hato la proporción diaria de vacas clasificadas en categorías de estrés (Mild/High), que sintetiza la dinámica colectiva de bienestar en el rebaño. Esta métrica se contrasta con eventos climáticos relevantes, tales como días de elevada carga térmica u oscilaciones bruscas en variables ambientales, mediante análisis de

correlación (Spearman) y pruebas no paramétricas (Mann-Whitney U) estratificados por día. Dado que las predicciones operan a la granularidad de cow-day, el indicador de hato captura la señal agregada sin asumir independencia horaria entre observaciones, facilitando la detección de patrones sincrónicos en respuestas al estrés ambiental y su implicancia para estrategias preventivas a escala de rebaño.

6.8. Limitaciones y Mitigaciones.

El esquema de etiquetado, basado en triangulación entre verificaciones veterinarias (Vet), SFT y desviaciones circadianas, opera como un estándar de referencia proxy, inherentemente sujeto a ruido residual, ambigüedad y sesgos de verificación selectiva; además, el desbalance de clases y la correlación intra-vaca pueden sesgar métricas de desempeño si no se abordan mediante controles robustos. En términos de validez interna, persisten riesgos como fuga temporal inadvertida, sobreajuste por ajuste de hiperparámetros o umbrales con información prospectiva implícita, colinealidad entre rasgos ambientales y conductuales, y confusores exógenos (alteraciones en manejo o patologías no térmicas). La validez de constructo se ve limitada por la operacionalización de "estrés por frío" vía SFT/THI y distancias circadianas, que podría omitir facetas fisiológicas subyacentes como respuestas hormonales o inmunes. Desde la perspectiva estadística, la imputación de datos y el resamplio, aunque conservadores— introducen potenciales sesgos si las ventanas temporales no se calibran adecuadamente, mientras que los intervalos de confianza (IC) tienden a ser optimistas dada la N efectiva reducida por dependencias jerárquicas. Adicionalmente, fallas en sensores (dropouts, deriva instrumental) y latencias en el registro comprometen la integridad de los datos y la fiabilidad del lead time predictivo.

Como mitigaciones implementadas, se recurrió a particiones cronológicas con buffers de aislamiento, estimaciones clúster-robustas estratificadas por vaca, auditorías sistemáticas de calibración y ablaciones selectivas de características para desentrañar dependencias espurias. No obstante, para fortalecer la generalización y robustez, se recomienda una validación multicentro con réplicas estacionales, incorporando

biomarcadores fisiológicos directos (cortisol salival) y cohortes de razas diversas, lo que consolidaría la aplicabilidad del artefacto en contextos productivos heterogéneos.

6.8.1. Validez interna

Se registraron dos rondas veterinarias diarias (06:00 y 18:00); para alinearlas con la escala cow-day, se aplicó una regla de agregación conservadora, High si alguna indica tal; Mild si al menos una lo hace en ausencia de High; Normal solo si ambas lo son, junto con triangulación de desviaciones circadianas y SFT (± 1 h). No obstante, persisten posibles discordancias por eventos transitorios fuera de las rondas. La triangulación integral (desviaciones circadianas + Vet + SFT) y el rol exclusivo de la SFT como validador externo mitigan el sesgo de verificación.

El análisis operó estrictamente a nivel cow-day, evitando réplicas temporales espurias; las métricas e intervalos de confianza (IC) se estimaron mediante bootstrap clúster por vaca, capturando la jerarquía inherente de los datos.

Adicionalmente, el desempeño moderado en la clase Mild ($F1 = 0,72$) se asocia directamente con la granularidad diaria del etiquetado y la predicción. Dado que los episodios de estrés leve son típicamente transitorios, picos breves de actividad o micro desfases circadianos no sostenidos—, su señal se atenúa al agregarse en una ventana de 24 horas. Esto explica la mayor sensibilidad en High (Recall = 81,3%), donde las alteraciones son persistentes y más detectables a escala diaria, en contraste con la menor precisión para eventos sutiles y efímeros en Mild.

Esta restricción no radica en el modelo LSTM ni en la extracción de rasgos circadianos, sino en el nivel de agregación temporal adoptado para la operacionalización. Versiones futuras del sistema deberían incorporar esquemas de predicción con ventanas más finas (6 o 12 horas) o en tiempo real (horaria), complementados con un enfoque de "doble resolución": preservando rasgos horarios (como percentil 95 de actividad o entropía) para el modelo, mientras se mantienen etiquetas diarias para reportes gerenciales.

Tal ajuste metodológico potenciaría la detección temprana de estrés leve, configurando una red de alerta preventiva ante progresiones a estados High, y elevaría la precisión en episodios transitorios sin menoscabar la operatividad del monitoreo.

6.8.2. Validez externa

La validez externa del artefacto se ve restringida por su desarrollo y evaluación en un contexto específico: un hato único de vacas Holstein en la granja experimental San Francisco de la Universidad Politécnica Estatal del Carchi (UPEC), ubicada a una altitud andina de aproximadamente 2.950 m s. n. m., caracterizada por un microclima frío y variable con temperaturas medias anuales de 12–15 °C y precipitaciones estacionales marcadas. Esta homogeneidad ambiental y genética, limitada a una sola raza lechera de alta producción, adaptada a condiciones de altura, pero potencialmente sensible a variaciones en termorregulación, introduce sesgos de selección que cuestionan su extrapolabilidad a poblaciones más diversas, como razas criollas (Brown Swiss o Jersey) en llanuras costeras, regiones tropicales o entornos de baja altitud con patrones de estrés térmico opuestos (calor vs. frío). Factores site-específicos, tales como la topografía andina que amplifica exposiciones eólicas y la uniformidad en prácticas de manejo (alimentación estandarizada), podrían inflar el desempeño observado al no capturar heterogeneidades en respuestas conductuales o fisiológicas ante gradientes climáticos globales.

Para mitigar estas limitaciones y robustecer la generalización, se propone una agenda de validación prospectiva multicentro y multianual: colaboraciones con hatos en ecosistemas contrastantes (costa ecuatoriana, costa peruana, pampas argentinas o altiplanos bolivianos) para abarcar variabilidad racial, edáfica y climática, incorporando al menos dos ciclos anuales por sitio para capturar estacionalidad y eventos extremos (heladas o sequías). Esta extensión empírica, potencialmente integrada con biomarcadores portátiles (termografía infrarroja o monitoreo de cortisol), no solo elevaría la confianza en la extrapolación, sino que también enriquecería el modelo mediante transfer learning o finetuning federado, alineando el artefacto con estándares de PLF escalables y adaptativos a contextos productivos

globales.

6.8.3. Validez de constructo

El estrés por frío se concibe como un constructo latente que encapsula la activación del eje hipotálamo-hipofisario-adrenal (HHA) y las respuestas comportamentales compensatorias en vacas Holstein expuestas a cargas térmicas bajas, manifestándose en disrupciones fisiológicas y etológicas que comprometen el equilibrio homeostático. Para su captura multimodo, se integraron: (i) desviaciones circadianas (dt) extraídas vía FFT, que cuantifican alteraciones intra-animales en fase y amplitud de patrones de actividad y rumia; (ii) evaluaciones clínicas veterinarias (Vet) en escala ordinal (0–2), basadas en signos observables compatibles con estrés térmico; (iii) el contexto térmico derivado de la Sensación Térmica por Frío (SFT), empleado como covariable de exposición ambiental (temperatura, viento, humedad) sin función etiquetadora; y (iv) biomarcadores fisiológicos de soporte, tales como variaciones en ACTH (actividad del eje HHA) y NEFA (balance energético), medidos en muestreos pre y post-exposición.

La operacionalización del constructo se materializa en un índice latente que fusiona indicadores estandarizados por individuo y temporada, con deltas biomarcadores definidos como POST–PRE para capturar respuestas dinámicas. Las ponderaciones se derivan de ajustes empíricos, por ejemplo, regresión logística sobre episodios etiquetados por expertos, o análisis factorial confirmatorio (CFA)/parcial de mínimos cuadrados (PLS) para sensibilidad, mientras que la estratificación en Normal/Mild/High se ancla en el índice de Youden (de curvas ROC) o en terciles empíricos. La validez convergente se corrobora mediante la co-ocurrencia de incrementos en dt durante ventanas frías con elevaciones en biomarcadores y signos clínicos; por su parte, la validez discriminante se preserva al relegar THI/SFT a rol contextual, evitando así que el índice dependa tautológicamente del insumo térmico que aspira a elucidar. Los indicadores clave del constructo, su obtención y contribución evidencial se detallan en la Tabla 33 Indicadores del constructo.

Tabla 33 Indicadores del constructo

Indicador	Variable	Cómo se obtiene	Evidencia que aporta
Desviación circadiana (dt)	Actividad/Rumia (FFT)	Diferencia de fase/amplitud vs. patrón basal intra-animal	Alteración comportamental asociada a termorregulación
Clínica Vet	Escala 0–2	Examen físico: temblores, piloerección, extremidades frías, ingesta	Signos fenotípicos de estrés por frío
Contexto SFT	Exposición (T°, viento, H)	Series ambientales como covariables	Intensidad del ambiente frío (no etiqueta)
ACTH	$\Delta ACTH$ (POST–PRE)	Ensayo hormonal en sangre	Activación eje HHA (respuesta al frío)
NEFA	$\Delta NEFA$ (POST–PRE)	Perfil metabólico en sangre	Movilización lipídica / balance energético

6.8.4. Resultados de Biomarcadores (ACTH y NEFA)

Se exponen los resultados de los análisis sanguíneos de biomarcadores (ACTH y NEFA), junto con las desviaciones circadianas (dt), que respaldan la definición y validación del constructo de estrés por frío en vacas Holstein. Las visualizaciones sintetizan comparaciones PRE/POST de exámenes, patrones circadianos y contrastes por individuo/temporada, promoviendo una interpretación integrada de la fisiología, el comportamiento y el contexto térmico. Esta presentación asegura una evidencia clara y autosuficiente, posicionando SFT/THI como covariables de referencia sin función etiquetadora. Las figuras incluyen pies estandarizados y referencias cruzadas para anclar los hallazgos y la discusión subsiguiente, para muestra se deja en evidencia los resultados de la vaca denominada Joya, los demás resultados se incluyen en el Anexo 3.

Vaca Joya: En Día 1 se observa desacople temporal: NEFA sube mientras ACTH

baja, consistente con (i) respuestas con diferente latencia (endócrina vs. metabólica) y/o (ii) retroalimentación negativa del eje HHA tras un pico previo no capturado en POST. En Día 2, ambos biomarcadores aumentan levemente en POST, sugiriendo un estímulo más moderado o adaptación respecto al día 1. La figura 27 (A) respalda la validez convergente del constructo si coocurre con ventanas frías y dt elevados en D1 POST. El desfase NEFA–ACTH subraya la necesidad de integrar biomarcadores + comportamiento (dt) + contexto SFT y analizar lags (por ejemplo, 0–3 h) en los modelos.




Figura 27 (A) Resultados Vaca Joya

La Figura 27(B) ilustra el panel de visualización del sistema en operación real para la vaca “Joya”, durante el intervalo de fechas correspondiente al periodo de evaluación (septiembre de 2025), coherente con las ventanas consideradas en los experimentos de clasificación. En la gráfica se muestran simultáneamente la actividad horaria registrada por el collar (línea azul), el componente circadiano estimado (línea verde), la predicción del modelo LSTM (línea punteada) y las etiquetas de estrés asignadas (Normal/Mild/High), junto con el punto de corte temporal a partir del cual se emite la alerta (línea vertical discontinua). El hecho de que la dinámica observada y las fechas de los episodios Mild/High coincidan con los resultados cuantitativos reportados en el conjunto de prueba respalda la consistencia entre el desempeño “de laboratorio” y el comportamiento del sistema ya desplegado, mostrando que las métricas de

clasificación se traducen en señales operativas útiles para la vigilancia diaria en granja.

Activity and Stress Prediction Visualization




Figura 28 (B) Resultados Vaca Joya

6.9. Resultados de la validación por juicio de expertos

Con el fin de respaldar la validez externa del sistema propuesto, se realizó una validación mediante juicio de expertos, quienes evaluaron cuatro dimensiones: relevancia técnica (A), aplicabilidad práctica (B), innovación/aporte (C) y presentación/documentación (D), utilizando una escala tipo Likert de 1 a 5. La Tabla 34 resume los promedios por ítem y por dimensión: el puntaje global fue de 4,29/5, clasificado como “*Muy bueno*”. Destacan particularmente la precisión del modelo ($A1 = 4,60$) y la novedad del enfoque ($C1 = 4,70$), con promedios por dimensión de 4,30 en relevancia técnica (A), 4,18 en aplicabilidad práctica (B), 4,40 en innovación/aporte (C) y 4,30 en presentación/documentación (D). La principal oportunidad de mejora se ubica en la facilidad de uso en campo ($B3 = 3,90$), lo que sugiere la conveniencia de reforzar acciones de capacitación, simplificar algunos flujos de interacción y añadir ayudas contextuales (*tooltips*) para favorecer la adopción operativa del sistema.

Tabla 34 Resumen por ítem (validación de expertos).

Código	Ítem (resumen)	Media
A1	Precisión del modelo	4.60
A2	Robustez / control de fuga temporal	4.20
A3	Interpretabilidad básica	4.00
A4	Reproducibilidad / trazabilidad	4.40
B1	Utilidad clínica/operativa de alertas	4.50
B2	Tiempo de respuesta / operación 24/7	4.10
B3	Facilidad de uso en campo	3.90
B4	Integración con IoT / mantenimiento	4.20
C1	Novedad del enfoque	4.70
C2	Contribución a ganadería de precisión	4.50
C3	Potencial de generalización	4.00
D1	Claridad de documentación técnica	4.30
D2	Consistencia objetivos-métodos- resultados	4.40
D3	Calidad formal/redacción/referencias	4.20

Promedios por dimensión evaluado por experto :

A) Relevancia técnica = 4.30

B) Aplicabilidad práctica = 4.18

C) Innovación / aporte = 4.40

D) Presentación / documentación = 4.30

Promedio global (14 ítems): 4.29 → “Muy bueno” (aprobable con observaciones menores/medias).

Interpretación breve: El sistema es sólido en precisión y novedad (A1, C1); la facilidad de uso (B3=3.90) es el principal foco de mejora (capacitación, simplificación de flujos y tooltips) El formato de evaluación se puede ver en el Anexo 2.

6.10. Síntesis del Capítulo VI

El Capítulo VI demuestra, mediante una evaluación rigurosa y multifacética, que el modelo predictivo propuesto basado en la combinación de análisis circadiano (FFT/SFT) y redes LSTM es una herramienta efectiva, robusta y viable para la

detección temprana del estrés por frío en ganado lechero bajo condiciones reales de granja.

Los resultados experimentales confirman la Hipótesis Específica 1: el modelo supera significativamente a los métodos tradicionales (Sensación Térmica por Frío -umbral) y a los algoritmos clásicos de ML (RF, SVM) en precisión, sensibilidad y capacidad predictiva, alcanzando un F1-macro de 76.71% y una sensibilidad (Recall) del 74% para la clase crítica High. El análisis de ablation evidencia que la extracción de rasgos circadianos mediante FFT es el componente que más aporta al desempeño del modelo, validando el enfoque teórico del estudio.

Además, el sistema muestra alta robustez ante la pérdida de datos (hasta 20%) y eficiencia computacional (inferencia en $< 2s$), lo que garantiza su implementación práctica en entornos de granja con recursos limitados. El análisis de errores y las estrategias de mitigación propuestas (como la doble resolución temporal y la calibración por individuo) abordan los principales desafíos del mundo real, como el ruido de sensor y la variabilidad inter-vaca.

Finalmente, la alta concordancia (Kappa) con la evaluación veterinaria y la correlación con eventos climáticos confirman la validez clínica y ecológica del modelo. En conjunto, este capítulo no solo valida técnicamente la propuesta, sino que establece las bases para su despliegue operativo, cumpliendo con el objetivo de diseño de crear un artefacto útil, evaluable y transferible que mejora el bienestar animal y la eficiencia productiva en la ganadería de precisión.

CAPÍTULO VII: CONCLUSIONES

La presente tesis doctoral ha logrado cumplir satisfactoriamente el objetivo general planteado, desarrollando e implementando un modelo predictivo basado en aprendizaje automático para la detección temprana del estrés por frío en ganado lechero, con resultados que demuestran su efectividad para mejorar el bienestar animal. Las conclusiones se articulan en función del cumplimiento de los objetivos específicos establecidos:

Respecto al Objetivo Específico 1: Diseño y Entrenamiento de Modelos Predictivos

Se ha logrado diseñar y entrenar exitosamente modelos de aprendizaje automático que utilizan datos ambientales y biométricos para predecir episodios de estrés por frío en bovinos lecheros. La arquitectura propuesta, basada en la combinación de análisis circadiano mediante Transformada de Fourier de Tiempo Corto (STFT) con redes neuronales LSTM, ha demostrado ser superior a los métodos tradicionales y algoritmos clásicos de machine learning.

Los resultados de la evaluación del artefacto (experimentos computacionales de entrenamiento y prueba) confirman la Hipótesis Específica 1: el modelo FFT+LSTM supera de forma consistente a los métodos baseline (SFT-umbral y Random Forest) en desempeño predictivo, alcanzando un Accuracy de 82,3%, F1-macro de 76,71% y ROC-AUC macro de 0,847 en el conjunto de prueba. Asimismo, la evaluación del horizonte de anticipación evidencia capacidad de alerta temprana, donde una proporción mayoritaria de eventos High se anticipa con al menos 60 minutos de lead time, lo que respalda su utilidad operativa para intervenciones preventivas..

Respecto al Objetivo Específico 2: Evaluación del Impacto en Parámetros Productivos

La evaluación del impacto de la mitigación temprana del estrés por frío sobre parámetros productivos y de calidad de la leche ha revelado ventajas significativas del sistema propuesto. El modelo demostró una sensibilidad del 74% para la clase High (estrés severo), lo que permite intervenciones oportunas antes de que se manifiesten pérdidas productivas evidentes.

La concordancia del modelo con la evaluación veterinaria, medida mediante el coeficiente Kappa de Cohen, valida la utilidad clínica del sistema. La capacidad de detectar alteraciones en los ritmos circadianos antes de que se traduzcan en disminución de la producción láctea, reducción de la ingesta de alimento o alteraciones comportamentales visibles, representa un avance cualitativo en el manejo preventivo del ganado lechero.

Respecto al Objetivo Específico 3: Viabilidad de Implementación y Escalabilidad

El análisis de viabilidad de implementación y escalabilidad del sistema de monitoreo predictivo ha demostrado resultados prometedores para diferentes contextos de producción ganadera. La arquitectura edge-cloud propuesta cumple con los requisitos operativos establecidos: latencia de inferencia menor a 1 segundo, tiempo de actividad superior al 99% y tasa de pérdida de paquetes menor al 2%.

El sistema mostró robustez ante pérdidas de telemetría de hasta 20% y eficiencia computacional compatible con hardware de granja (CPU x86-64, 16-32 GB RAM). La escalabilidad lineal del sistema ($O(N)$ en tiempo y memoria) permite su implementación desde granjas pequeñas (10-30 vacas) hasta operaciones de gran escala (200-500 vacas), adaptando la infraestructura tecnológica a las condiciones locales.

Contribuciones Metodológicas y Teóricas

Esta investigación ha realizado contribuciones significativas al campo de la ganadería de precisión y el aprendizaje automático aplicado:

1. **Innovación metodológica:** La integración de análisis circadiano con redes neuronales recurrentes para la detección de estrés térmico constituye un enfoque novedoso que supera las limitaciones de los métodos tradicionales basados en índices estáticos como SFT o Wind Chill.
2. **Validación empírica robusta:** El diseño experimental, basado en la metodología DSRM (Design Science Research Methodology), proporcionó un marco riguroso para la construcción, evaluación y validación del artefacto tecnológico desarrollado.
3. **Transferibilidad del conocimiento:** Los principios de diseño derivados del estudio pueden ser extrapolados a otros contextos de monitoreo animal, contribuyendo al desarrollo de la ganadería de precisión a nivel global.

Limitaciones y Consideraciones Futuras

Se reconocen limitaciones inherentes al estudio que deben considerarse para futuras investigaciones. El tamaño de muestra (10 vacas Holstein) y la especificidad del contexto (altura andina, 2.950 m) limitan la generalización directa de los resultados a otras razas y condiciones climáticas. La granularidad temporal de análisis (cow-day) puede haber subestimado la detección de episodios de estrés leve de corta duración.

La dependencia de la triangulación entre umbrales circadianos, evaluación veterinaria y contexto ambiental para el etiquetado de ground truth, aunque metodológicamente sólida, introduce cierto grado de subjetividad que podría beneficiarse de marcadores fisiológicos invasivos complementarios en estudios futuros.

Impacto y Relevancia Científica

Los resultados de esta investigación representan un avance significativo en la aplicación de inteligencia artificial para el bienestar animal, demostrando que es posible desarrollar sistemas de monitoreo no invasivos, precisos y escalables para la detección temprana del estrés por frío en ganado lechero. La evidencia generada respalda la implementación de tecnologías de ganadería de precisión como herramientas efectivas para mejorar tanto la productividad como el bienestar animal.

El modelo predictivo desarrollado no solo cumple con los estándares técnicos requeridos para su implementación práctica, sino que también establece un precedente metodológico para futuras investigaciones en el campo de la inteligencia artificial aplicada a la producción animal. La combinación de rigor científico con utilidad práctica posiciona este trabajo como una contribución valiosa tanto para la comunidad académica como para el sector productivo ganadero.

En síntesis, esta tesis doctoral ha demostrado exitosamente que la implementación de modelos de aprendizaje automático para la detección temprana del estrés por frío en bovinos mejora significativamente el bienestar animal y representa una herramienta viable y escalable para la modernización de los sistemas de producción ganadera, cumpliendo así con la hipótesis general planteada al inicio de la investigación.

CAPÍTULO VIII: RECOMENDACIONES

Las recomendaciones derivadas de esta investigación doctoral se estructuran en diferentes niveles de implementación y aplicación, considerando tanto las necesidades inmediatas del sector productivo como las oportunidades de desarrollo científico y tecnológico a mediano y largo plazo.

Implementación Práctica

Se recomienda implementar el sistema de monitoreo predictivo mediante un enfoque escalonado que inicie con granjas piloto de tamaño medio (50-150 vacas) antes de expandir a operaciones de mayor escala. Esta estrategia permitirá la calibración de umbrales específicos por región y la adaptación de interfaces de usuario a las necesidades locales. Los productores deben considerar la capacitación del personal técnico como elemento crítico para el éxito de la implementación, incluyendo la interpretación de alertas, protocolos de respuesta y mantenimiento básico del sistema.

La integración con sistemas de manejo existentes debe priorizarse para maximizar la adopción. Se sugiere desarrollar APIs compatibles con software de gestión ganadera comercial y establecer protocolos de intercambio de datos que faciliten la toma de decisiones integrada.

Optimización de Infraestructura Tecnológica

Para garantizar la viabilidad económica del sistema, se recomienda implementar arquitecturas híbridas que combinen procesamiento local (edge computing) con servicios en la nube. Esta configuración reduce costos de conectividad y mejora la latencia de respuesta, especialmente relevante en zonas rurales con conectividad limitada.

El dimensionamiento de hardware debe considerar las proyecciones de crecimiento del hato. Para granjas en expansión, se sugiere implementar arquitecturas modulares que permitan escalamiento horizontal mediante la adición de nodos de procesamiento según sea necesario.

Futuras Investigaciones

Se recomienda realizar estudios multi-sitio que incluyan diferentes razas bovinas, condiciones climáticas y sistemas de producción para validar la generalización del modelo propuesto. Estos estudios deberían incorporar muestras representativas de al menos 50-100 vacas por sitio durante períodos mínimos de 12 meses, incluyendo variaciones estacionales completas.

La inclusión de marcadores fisiológicos invasivos (cortisol salival, parámetros sanguíneos) en estudios futuros permitiría validar más robustamente las correlaciones entre alteraciones circadianas y estrés fisiológico real, reduciendo la dependencia de evaluaciones subjetivas.

Desarrollo de Modelos Especializados

Se sugiere investigar arquitecturas de aprendizaje automático especializadas para diferentes tipos de estrés (térmico, nutricional, patológico, social) que permitan discriminación más precisa entre factores estresantes. El desarrollo de modelos multi-tarea que puedan predecir simultáneamente diferentes condiciones de bienestar animal representaría un avance significativo en la ganadería de precisión.

La exploración de técnicas de aprendizaje no supervisado y semi-supervisado podría reducir la dependencia de etiquetado manual, facilitando la escalabilidad del entrenamiento de modelos para diferentes contextos productivos.

Integración de Nuevas Variables

Futuras investigaciones deberían explorar la incorporación de variables genéticas, microbiómicas y metabólicas que puedan mejorar la precisión predictiva del modelo. La integración de datos de calidad de leche en tiempo real (composición, células somáticas) podría proporcionar retroalimentación inmediata sobre la efectividad de las intervenciones preventivas.

Se recomienda investigar la utilidad de sensores emergentes como monitores de pH ruminal, dispositivos de análisis de gases exhalados, y sistemas de visión computacional para complementar las señales biométricas tradicionales.

Mejoramiento de la Granularidad Temporal

Los resultados sugieren que la granularidad diaria (cow-day) puede subestimar episodios de estrés leve de corta duración. Se recomienda desarrollar sistemas de "doble resolución" que mantengan agregaciones diarias para reportes gerenciales mientras incorporan análisis horarios para alertas tempranas más sensibles.

La implementación de ventanas deslizantes adaptativas que ajusten su tamaño según la estabilidad de la señal podría mejorar la detección de transiciones críticas entre estados de bienestar.

Validación Cruzada Robusta

Para futuras validaciones, se recomienda implementar esquemas de validación cruzada que consideren explícitamente la dependencia temporal y la agrupación por individuo. Los protocolos deberían incluir validación leave-one-farm-out para evaluar transferibilidad entre contextos productivos diferentes. Se sugiere establecer métricas de evaluación específicas para el dominio que prioricen la detección temprana sobre la exactitud global, considerando los costos diferenciales de falsos positivos versus falsos negativos en el contexto de bienestar animal.

Desarrollo de Políticas

Se recomienda que las instituciones regulatorias consideren la incorporación de tecnologías de monitoreo predictivo en los protocolos de evaluación de bienestar animal. El desarrollo de estándares técnicos para sistemas de ganadería de precisión facilitaría la adopción uniforme y garantizaría la calidad de las implementaciones.

La creación de certificaciones de bienestar animal basadas en monitoreo continuo podría incentivar la adopción de estas tecnologías, creando valor agregado para productores que implementen sistemas avanzados de cuidado animal.

Incentivos para Adopción Tecnológica

Se sugiere el desarrollo de programas de apoyo gubernamental que faciliten el acceso a tecnologías de ganadería de precisión, especialmente para pequeños y medianos productores. Estos programas podrían incluir subsidios para adquisición de equipamiento, capacitación técnica y asistencia para integración con sistemas existentes.

Transferencia de Conocimiento

Se recomienda desarrollar programas de capacitación específicos para veterinarios, técnicos agropecuarios y productores que incluyan tanto aspectos técnicos como interpretativos del sistema. Estos programas deberían enfatizar la comprensión de patrones circadianos normales y la identificación de desviaciones significativas.

La creación de materiales educativos accesibles, incluyendo guías visuales y casos de estudio prácticos, facilitaría la adopción efectiva del sistema en diferentes contextos socioeducativos.

Desarrollo de Ecosistemas de Innovación

Se sugiere fomentar la colaboración entre universidades, centros de investigación, empresas tecnológicas y organizaciones de productores para crear ecosistemas de innovación que aceleren el desarrollo y adopción de tecnologías de ganadería de precisión. El establecimiento de centros de demostración tecnológica en diferentes regiones permitiría que los productores evalúen directamente los beneficios de estas tecnologías antes de tomar decisiones de inversión.

Sostenibilidad y Escalabilidad

Se recomienda explorar modelos de negocio que hagan viable la implementación de estos sistemas para productores de diferentes escalas. Los modelos de "Ganadería como Servicio" (Farming-as-a-Service) podrían permitir el acceso a tecnologías avanzadas sin requerir grandes inversiones iniciales.

La creación de cooperativas tecnológicas entre productores podría facilitar la adquisición compartida de sistemas de monitoreo, reduciendo costos individuales mientras mantiene beneficios colectivos. Las recomendaciones presentadas reflejan tanto las oportunidades identificadas como las limitaciones reconocidas en este estudio. Su implementación exitosa requerirá coordinación entre múltiples actores del sector agropecuario, incluyendo investigadores, desarrolladores tecnológicos, productores y formuladores de políticas.

El desarrollo futuro de sistemas de ganadería de precisión debe mantener el equilibrio entre innovación tecnológica y practicidad operativa, asegurando que los avances científicos se traduzcan efectivamente en beneficios tangibles para el bienestar animal y la sostenibilidad productiva. La continuidad de la investigación en este campo contribuirá significativamente al desarrollo de una ganadería más eficiente, sostenible y respetuosa del bienestar animal, alineándose con las demandas crecientes de consumidores conscientes y regulaciones ambientales más estrictas.

Contribuciones con publicaciones

1) Artículo Científico Revista Innova Science Journal LatinIndex 2.0

Sensores inteligentes y técnicas de machine learning para la detección del estrés en ganado bovino. A *Systematic review on intelligent sensors and techniques machine learning for the detection of stress in cattle.* <https://doi.org/10.63618/omd/isj/v3/n3/64>

Artículo Científico

Sensores inteligentes y técnicas de machine learning para la detección del estrés en ganado bovino.

Systematic review on intelligent sensors and techniques machine learning for the detection of stress in cattle

Lascano -Rivera, Samuel Benjamín ¹; Rivera -Escriba, Luis Antonio ²; Balarezo -Urresta, Luis Rodrigo ³; Castañeda -Albán, Jorge Eduardo ⁴.

¹ Universidad Politécnica Estatal del Carchi; Ecuador, Tulcán; <https://orcid.org/0000-0001-5967-6441>; samuel.lascano@upec.edu.ec

² Universidade Estadual do Norte Fluminense; Brasil, Rio de Janeiro; <https://orcid.org/0000-0002-5029-2561>; rivera@uenf.br

³ Universidad Politécnica Estatal del Carchi; Ecuador, Tulcán; <https://orcid.org/0000-0001-5546-1259>; luis.balarezo@upec.edu.ec

⁴ Universidad San Ignacio de Loyola; Perú, Lima; <https://orcid.org/0000-0001-7725-8702>; jorge.castaneda@usil.pe

¹ Autor Correspondencia

<https://doi.org/10.63618/omd/isj/v3/n3/64>

Cita: Lascano-Rivera, S. B., Rivera-Escriba, L. A., Balarezo-Urresta, L. R., & Castañeda-Albán, J. E. (2025). Sensores inteligentes y técnicas de machine learning para la detección del estrés en ganado bovino. Innova Science Journal, 3(3), 336-355. <https://doi.org/10.63618/omd/isj/v3/n3/64>

Recibido: 03/05/2025

Aceptado: 27/06/2025

Publicado: 31/07/2025

Resumen: Este artículo analiza el uso de la inteligencia artificial y el aprendizaje automático en la ganadería de precisión, enfocándose en el monitoreo del bienestar animal y la detección del estrés térmico en bovinos. Se destacan tecnologías como los sensores inteligentes y el Internet de las Cosas (IoT), que permiten un monitoreo continuo, remoto y no invasivo. La revisión se basó en una búsqueda sistemática de artículos publicados desde 2020, empleando descriptores clave. Los resultados muestran que algoritmos como Random Forest y XGBoost logran altos niveles de precisión en la predicción de estados de salud y estrés, con índices de acierto de hasta el 89,3%. A pesar de estos avances, persisten desafíos en la mejora de la precisión de los modelos y en la integración eficiente de datos para una implementación escalable en entornos ganaderos reales.

Palabras clave: Machine Learning; Ganado Bovino; Sensores Inteligentes; Stress.

Abstract: This article examines the use of artificial intelligence and machine learning in precision livestock farming, focusing on animal welfare monitoring and heat stress detection in cattle. Technologies such as smart sensors and the Internet of Things (IoT) are highlighted for enabling continuous, remote, and non-invasive monitoring. The review was based on a systematic search of articles published since 2020 using key descriptors. Results show that algorithms like Random Forest and XGBoost achieve high accuracy in predicting health and stress states, with success rates reaching up to 89.3%. Despite these advances, challenges remain in improving model accuracy and efficiently integrating data for scalable implementation in real-world livestock environments.

Keywords: Machine Learning; Cattle; Smart Sensors; Stress.

Copyright: © 2025 por los autores. Este artículo es un artículo de acceso abierto distribuido bajo los términos y condiciones de la [Licencia Creative Commons Atribución - NoComercial 4.0 Internacional](https://creativecommons.org/licenses/by-nc/4.0/). (CC BY-NC).

(<https://creativecommons.org/licenses/by-nc/4.0/>)

2) Artículo Científico de Contribución Revista MDPI Sensor Q1. Artificial Intelligence and Circadian Thresholds for Stress Detection in Dairy Cattle. <https://doi.org/10.3390/s25216544>

Article

Artificial Intelligence and Circadian Thresholds for Stress Detection in Dairy Cattle

Samuel Lascano Rivera ^{1,2,*} , Luis Rivera ^{2,3} , Hernán Benavides ¹  and Yasmary Fernández ¹ 

¹ Research Department, State Polytechnic University of Carchi, Tulcán 040101, Ecuador; hernan.benavides@upecc.edu.ec (H.B.) yfemandezf@upecc.edu.ec (YF.)

² Postgraduate Program, Faculty of Systems and Informatics Engineering National University of San Marcos, Lima 15081, Peru; rivera@uenf.br

³ Mathematical Sciences Laboratory, State University of Norte Fluminense Rb de Janeiro 28013-602 Brazil

* Correspondence: samuel.lascano@upecc.edu.ec

Abstract

This study investigates stress detection in dairy cattle by integrating circadian rhythm analysis and deep learning. Behavior biomarkers including feeding, resting, and rumination, were continuously monitored using Nedap CowControl sensors over a 12-month period to capture seasonal variability. Circadian features were extracted using the Fast Fourier Transform (FFT) and deviations from expected 24 h patterns were quantified using Euclidean distance. These features were used to train a Long Short-Term Memory (LSTM) neural network to classify stress into three levels: normal, mild, and high. Expert veterinary observations of anomalous behaviors and environmental records were used to validate stress labeling. We continuously monitored 10 lactating Holstein cows for 365 days, yielding 87,600 raw hours and 3650 cow-days (one day per cow as the analytical unit). The Short-Time Fourier Transform (STFT, 36 h window, 1 h step) was used solely to derive daily circadian characteristics (amplitude, phase, coherence). STFT windows are not statistical samples. A 60 min window prior to stress onset was incorporated to anticipate stress conditions triggered by management practices and environmental stressors such as vaccination, animal handling, and cold stress. The proposed LSTM model achieved an accuracy of 82.3% and an AUC of 0.847, outperforming a benchmark logistic regression model (65% accuracy). This predictive capability, with a one-hour lead time, provides a critical window for preventive interventions and represents a practical tool for precision livestock farming and animal welfare monitoring.

Keywords: bovine stress; machine learning; circadian rhythm; activity level; Fast Fourier Transform; LSTM



Academic Editors: Richard J. Povinelli, Kiril Alexiev and Virginio Cantoni

Received: 18 July 2025

Revised: 4 October 2025

Accepted: 15 October 2025

Published: 24 October 2025

Citation: Rivera S.L.; Rivera L.; Benavides H.; Fernández Y. Artificial Intelligence and Circadian Thresholds for Stress Detection in Dairy Cattle. *Sensors* 2025, 25, 6544. <https://doi.org/10.3390/s25216544>

Copyright: © 2025 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

1. Introduction

Stress in cattle represents a critical challenge for modern livestock farming due to its direct impact on animal welfare and productivity. Factors such as intensive management practices, adverse environmental conditions, and disruptions to daily routines trigger physiological and behavioral responses that reduce feed intake, alter resting patterns, and increase susceptibility to diseases [1,2]. These alterations adversely affect milk quality and yield, reproductive efficiency, and overall profitability of the sector [3,4]. Consequently, the early and accurate detection of stress is essential for implementing management measures that promote animal welfare and productive sustainability.

3) Artículo Científico Revista Frontier Q1.

Technical and Infrastructure Barriers to Precision Livestock Farming in High-Andean Dairy Systems: A Documentary Analysis of Carchi (Ecuador) and Nariño (Colombia)



Technical and Infrastructure Barriers to Precision Livestock Farming in High-Andean Dairy Systems: A Documentary Analysis of Carchi (Ecuador) and Nariño (Colombia)

Samuel Lascano Rivera^{1*}, John Cortés Pozo², Geovanny Basantes Quelal², Hernán Benavides¹

¹ Research Department, State Polytechnic University of Carchi, Tulcán 040101 Ecuador*

² Carrera de Computación, Universidad Politécnica Estatal del Carchi, Tulcán, Ecuador

Correspondence:

Samuel Lascano Rivera

samuel.lascano@upec.edu.ec

Keywords: precision livestock farming; Internet of Things (IoT); RFID; high-Andean dairy systems; smallholders; Carchi; Nariño

Abstract

Precision Livestock Farming (PLF) is promoted as a way to increase productivity, animal welfare, and environmental sustainability in dairy systems. However, its adoption in the high-Andean border region of Nariño (Colombia) and Carchi (Ecuador) remains limited. This study identifies and analyzes the main technical and infrastructure barriers that limit the implementation of PLF technologies, particularly the Internet of Things (IoT) and Radio Frequency Identification (RFID) systems, in these highland dairy systems.

A qualitative documentary design was used, combining a comparative characterization of the dairy sector in Carchi and the Nariño highlands with a systematic review of scientific articles, theses, technical reports, and public policy documents (2004–2024). The information was organized into four analytical dimensions: (i) digital and physical infrastructure, (ii) human capital and digital literacy, (iii) economic viability and productive structure, and (iv) technological fit between available solutions and extensive grazing systems. An input-process-output indicator framework is also proposed to monitor the adoption of improved pasture management (PPM) in the region. The results reveal interdependent barriers: unstable connectivity and limited rural broadband; weak and unreliable electrical infrastructure; a marked digital literacy gap among producers; scarce and fragmented technical assistance; structural constraints stemming from small holdings and small herds; and the poor suitability of commercial PLM solutions designed primarily for intensive, confined systems for the complex Andean grazing landscapes. Under current conditions, large-scale technological modernization is not viable for typical small holder farms without structural interventions and tailored solutions. The study concludes that the transition of PLF in Nariño and Carchi requires coordinated action under a "Triple Helix" model (public sector, academia, private sector), the development of low-cost technologies adapted to the context, and long-term capacity-building strategies, instead of isolated equipment purchases or short-term pilot projects.

Referencias bibliográficas

- A. Arias, R., & L. Mader, T. (2020). *Efectos del clima sobre la producción bovina: aspectos generales, índices de confort y medidas de mitigación*. https://www.engormix.com/ganaderia/estres-ganaderia/efectos-clima-sobre-produccion_a45559/
- Alsaad, M., Fadul, M., & Steiner, A. (2019). Automatic lameness detection in cattle. *The Veterinary Journal*, 246, 35–44. <https://doi.org/10.1016/j.tvjl.2019.01.005>
- Alux Nutrition. (2021, octubre 14). *5 factores de estrés que representan hasta el 15% de los costos totales de producción pecuaria* | Nutrición animal. <https://www.linkedin.com/pulse/5-factores-de-estr%C3%A9s-que-representan-hasta-el-15-los-costos-/>
- Arablouei, R., Wang, Z., Bishop-Hurley, G. J., & Liu, J. (2022). *Multimodal sensor data fusion for in-situ classification of animal behavior using accelerometry and GNSS data*. <http://arxiv.org/abs/2206.12078>
- Arias, R. A., Universidad Austral de Chile, Mader, T. L., & University of Nebraska at Lincoln. (2020). *Efectos del clima sobre la producción bovina_ aspectos generales, índices de confort y medidas de mitigación* _ Engormix. *engormix*. <https://www.nationalgeographiccl.com/medio-ambiente/2024/01/que-es-la-sensacion-termica-y-como-afecta-al-cuerpo>
- Arya, N. (2022, mayo 16). *Popular Machine Learning Algorithms*. KD nuggets. <https://www.kdnuggets.com/2022/05/popular-machine-learning-algorithms.html>
- Ates, H. C., Nguyen, P. Q., Gonzalez-Macia, L., Morales-Narváez, E., Güder, F., Collins, J. J., & Dincer, C. (2022). End-to-end design of wearable sensors. *Nature Reviews Materials*, 7(11), 887–907. <https://doi.org/10.1038/s41578-022-00460-x>
- Balasso, P., Marchesini, G., Ughelini, N., Serva, L., & Andrighetto, I. (2021). Machine learning to detect posture and behavior in dairy cows: Information from an accelerometer on the animal's left flank. *Animals*, 11(10). <https://doi.org/10.3390/ani11102972>
- Balasso, P., Taccioli, C., Serva, L., Magrin, L., Andrighetto, I., & Marchesini, G. (2023). Uncovering Patterns in Dairy Cow Behaviour: A Deep Learning Approach with Tri-Axial Accelerometer Data. *Animals*, 13(11). <https://doi.org/10.3390/ani13111886>
- Becker, C. A., Aghalari, A., Marufuzzaman, M., & Stone, A. E. (2021). Predicting dairy cattle heat stress using machine learning techniques. *Journal of Dairy Science*, 104(1), 501–524. <https://doi.org/10.3168/jds.2020-18653>
- Bickert, W. G. (2011). Stress in Dairy Animals | Cold Stress: Management Considerations. En *Encyclopedia of Dairy Sciences* (pp. 555–560). Elsevier. <https://doi.org/10.1016/B978-0-12-374407-4.00466-0>
- BLASIO, A. L., CANO TORRES, R., & SANABRIA CERA, S. (2022, junio 27). *Nombre de la Unidad de Aprendizaje: ETOLOGÍA Y BIENESTAR ANIMAL*. https://veterinaria.uaemex.mx/images/Documentos_veterinaria/Oferta_educativa/Licenciatura_veterinaria/Unidades_Aprendizaje/Tercer_periodo/ETOLOGIA_Y_BIENESTAR_ANIMAL/ETOL_Y_BIEN_ANI_MP.pdf
- Borja García, & Peñasco Jaime Martín. (2018). *Vacas ciborg para escribir el futuro de los implantes en humanos*. <https://blogthinkbig.com/vacas-ciborg-wearables>.
- Brouwers, S. P., Simmler, M., Savary, P., & Scriba, M. F. (2023). Towards a novel method for detecting atypical lying down and standing up behaviors in dairy cows using accelerometers and machine learning. *Smart Agricultural Technology*, 4. <https://doi.org/10.1016/j.atech.2023.100199>
- Cantor, M. C., Casella, E., Silvestri, S., Renaud, D. L., & Costa, J. H. C. (2022). Using

- Machine Learning and Behavioral Patterns Observed by Automated Feeders and Accelerometers for the Early Indication of Clinical Bovine Respiratory Disease Status in Preweaned Dairy Calves. *Frontiers in Animal Science*, 3. <https://doi.org/10.3389/fanim.2022.852359>
- Carslake, C., Vázquez-Diosdado, J. A., & Kaler, J. (2021). Machine learning algorithms to classify and quantify multiple behaviours in dairy calves using a sensor—moving beyond classification in precision livestock. *Sensors (Switzerland)*, 21(1), 1–14. <https://doi.org/10.3390/s21010088>
- Carvajal Pérez, L. A., & Montenegro, G. F. (2020). Agronegocios de producción lechera en el Carchi: factores climáticos. *Visión Empresarial*, 10, 7–15. <https://doi.org/10.32645/13906852.1004>
- CEUPE. (2022, marzo 8). *Reconocimiento de patrones: qué es y cómo funciona*. CEUPE. <https://www.ceupe.com/blog/reconocimiento-de-patrones.html#:~:text=La%20actividad%20de%20identificar%20objetos,la%20ingenier%C3%ADa%20matem%C3%A1ticas%20e%20inform%C3%A1tica>
- Chapman, N. H., Chlingaryan, A., Thomson, P. C., Lomax, S., Islam, M. A., Doughty, A. K., & Clark, C. E. F. (2023). A deep learning model to forecast cattle heat stress. *Computers and Electronics in Agriculture*, 211. <https://doi.org/10.1016/j.compag.2023.107932>
- Charry, J. D., Navarro, S., & Odont, P. (2018). *Metodología de la Investigación y Principios en Publicación Científica* (Uninavarra, Vol. 1).
- Chaudhry, A. A., Mumtaz, R., Hassan Zaidi, S. M., Tahir, M. A., & Muzammil School, S. H. (2020). Internet of Things (IoT) and Machine Learning (ML) enabled Livestock Monitoring. *2020 IEEE 17th International Conference on Smart Communities: Improving Quality of Life Using ICT, IoT and AI (HONET)*, 151–155. <https://doi.org/10.1109/HONET50430.2020.9322666>
- Chung, H., Li, J., Kim, Y., Van Os, J. M. C., Brounts, S. H., & Choi, C. Y. (2020). Using implantable biosensors and wearable scanners to monitor dairy cattle's core body temperature in real-time. *Computers and Electronics in Agriculture*, 174. <https://doi.org/10.1016/j.compag.2020.105453>
- Congo, C. D., Chuquimarca, E. J., Torres, N. F., Quezada, N. G., & Garzón, J. P. (2024). Estimación del índice de temperatura humedad (ITH) para sistemas de producción bovina en Morona Santiago, resultado preliminar. *Archivos Latinoamericanos de Producción Animal*, 32(5), 131–135. <https://doi.org/10.53588/alpa.320514>
- CONtexto, ganadero. (2023, mayo 9). *Constantes fisiológicas en bovinos: claves para mantener la salud del ganado*. CONtexto ganadero. <https://www.contextoganadero.com/ganaderia-sostenible/constant-fisiologicas-en-bovinos-claves-para-mantener-la-salud-del-ganado>
- CONtexto Ganadero. (2023). Los diferentes tipos de estrés que pueden presentar los bovinos. *CONtexto Ganadero*. <https://www.contextoganadero.com/ganaderia-sostenible/los-diferentes-tipos-de-estres-que-pueden-presentar-los-bovinos>
- Da Silva Alex Vinicius. (2022). *Avaliação não invasiva do estresse térmico de bovinos: uma abordagem baseada em aprendizado de máquina e termografia de infravermelho*.
- Dac, H. H., Viejo, C. G., Lipovetzky, N., Tongson, E., Dunshea, F. R., & Fuentes, S. (2022). Livestock Identification Using Deep Learning for Traceability. *Sensors*, 22(21). <https://doi.org/10.3390/s22218256>
- Dang, T. H., Nkenyereye, L., Tran, V. T., & Chung, W. Y. (2024). Self-Powered Cattle Behavior Monitoring System Using 915 MHz Radio Frequency Energy Harvesting. *IEEE Access*, 12, 33779–33791. <https://doi.org/10.1109/ACCESS.2024.3360852>
- Darvesh, K., Khande, N., Avhad, S., & Khemchandani, M. (2023). IOT and AI based smart cattle health monitoring. *Journal of Livestock Science*, 14(3), 211–218. <https://doi.org/10.33259/jlivestsci.2023.211-218>

- Davison, C., Michie, C., Hamilton, A., Tachtatzis, C., Andonovic, I., & Gilroy, M. (2020). Detecting heat stress in dairy cattle using neck-mounted activity collars. *Agriculture (Switzerland)*, 10(6), 1–11. <https://doi.org/10.3390/agriculture10060210>
- Dineva, K., & Atanasova, T. (2023). Health Status Classification for Cows Using Machine Learning and Data Management on AWS Cloud. *Animals*, 13(20). <https://doi.org/10.3390/ani13203254>
- Ding, L., Lv, Y., Jiang, R., Zhao, W., Li, Q., Yang, B., Yu, L., Ma, W., Gao, R., & Yu, Q. (2022). Predicting the Feed Intake of Cattle Based on Jaw Movement Using a Triaxial Accelerometer. *Agriculture (Switzerland)*, 12(7). <https://doi.org/10.3390/agriculture12070899>
- Ding, L., Zhang, C., Yue, Y., Yao, C., Li, Z., Hu, Y., Yang, B., Ma, W., Yu, L., Gao, R., & Li, Q. (2025). Wearable Sensors-Based Intelligent Sensing and Application of Animal Behaviors: A Comprehensive Review. En *Sensors* (Vol. 25, Número 14). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/s25144515>
- dos Reis, B. R., Sujani, S., Fuka, D. R., Easton, Z. M., & White, R. R. (2025). Comparison among grazing animal behavior classification algorithms for use with open-source wearable sensors. *Smart Agricultural Technology*, 101133. <https://doi.org/10.1016/j.atech.2025.101133>
- El Moutaouakil, K., & Falih, N. (2024). A comparative study on time series data-based artificial intelligence approaches for classifying cattle feeding behavior. *Indonesian Journal of Electrical Engineering and Computer Science*, 33(1), 324–332. <https://doi.org/10.11591/ijeecs.v33.i1.pp324-332>
- Fan, B., Bryant, R., & Greer, A. (2022). Behavioral Fingerprinting: Acceleration Sensors for Identifying Changes in Livestock Health. *J*, 5(4), 435–454. <https://doi.org/10.3390/j5040030>
- Ferreira, C., Todorovic, M., Sugrue, P., Teixeira, S., & Galvin, P. (2025). Review: Emerging sensors and instrumentation systems for bovine health monitoring. En *Animal* (Vol. 19, Número 6). Elsevier B.V. <https://doi.org/10.1016/j.animal.2025.101527>
- Fondo Italo Ecuatoriano para el Desarrollo del Sostenible. (2024). *Carchi Lácteo FIEDS 008-2019 – Mejoramiento de la Competitividad de la Cadena de Valor Láctea de la Provincia del Carchi*.
- 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. En *Animal Health Research Reviews* (Vol. 23, Número 1, pp. 59–71). Cambridge University Press. <https://doi.org/10.1017/S1466252321000177>
- Gabriela, M., Trujillo, S., & Ángel Pérez Hernández, J. (2021). Metodología CRISP-DM en la gestión de proyecto de Data Mining. Caso enfermedades dermatológicas. En *International Conference on Project Management*.
- García, C. (2020). I Boletín+Eficiencia+procesos+en+ganadería+de+leche.ABRIL-21. *GANADERÍA DE PRECISIÓN*. <https://www.udea.edu.co/wps/wcm/connect/udea/da0189be-64a3-4033-be59-de6696584702/Boleti%CC%81n+Eficiencia+procesos+en+ganaderi%CC%81a+de+leche.ABRIL-21.pdf?MOD=AJPERES&CVID=nzS2vjG>
- Ghafoor, N. A., & Sitkowska, B. (2021). MasPA: A Machine Learning Application to Predict Risk of Mastitis in Cattle from AMS Sensor Data. *AgriEngineering*, 3(3), 575–583. <https://doi.org/10.3390/agriengineering3030037>
- Giannuzzi, D., Mota, L. F. M., Pegolo, S., Gallo, L., Schiavon, S., Tagliapietra, F., Katz, G., Fainboym, D., Minuti, A., Trevisi, E., & Cecchinato, A. (2022). In-line near-infrared analysis of milk coupled with machine learning methods for the daily prediction of blood

- metabolic profile in dairy cattle. *Scientific Reports*, 12(1). <https://doi.org/10.1038/s41598-022-11799-0>
- Gibbens, S. (2024, enero 24). *¿Qué es la sensación térmica y cómo afecta al cuerpo?* National Geographic. <https://www.nationalgeographicla.com/medio-ambiente/2024/01/que-es-la-sensacion-termica-y-como-afecta-al-cuerpo>
- Gjergji, M., De Moraes Weber, V., Otávio Campos Silva, L., Da Costa Gomes, R., De Araújo, T. L. A. C., Pistori, H., & Alvarez, M. (2020, julio 1). Deep Learning Techniques for Beef Cattle Body Weight Prediction. *Proceedings of the International Joint Conference on Neural Networks*. <https://doi.org/10.1109/IJCNN48605.2020.9207624>
- Gorczyca, M. T., & Gebremedhin, K. G. (2019). *Ranking of Environmental Heat Stressors for Dairy Cows Using Machine Learning Algorithms*. <https://www.sciencedirect.com/science/article/pii/S016816991931614X>
- Hernández, G., González-Sánchez, C., González-Arrieta, A., Sánchez-Brizuela, G., & Fraile, J. C. (2024). Machine Learning-Based Prediction of Cattle Activity Using Sensor-Based Data. *Sensors*, 24(10). <https://doi.org/10.3390/s24103157>
- Hevner, A. R., & Chatterjee, S. (2015). *Design Science Research in Information Systems*. http://eduglopedia.org/reference-syllabus/AIS_Reference_Syllabus_Design_Science_Research_in_IS.pdf
- Hevner, A. R., March, S. T., Park, J., & Ram, S. (2008). *Design Science in Information Systems Research*.
- Higaki, S., Darhan, H., Suzuki, C., Suda, T., Sakurai, R., & Yoshioka, K. (2021). An attempt at estrus detection in cattle by continuous measurements of ventral tail base surface temperature with supervised machine learning. En *Technology Report-Journal of Reproduction and Development* (Vol. 67, Número 1).
- Hosseininoorbin, S., Layeghy, S., Kusy, B., Jurdak, R., Bishop-Hurley, G. J., Greenwood, P. L., & Portmann, M. (2021). Deep learning-based cattle behaviour classification using joint time-frequency data representation. *Computers and Electronics in Agriculture*, 187. <https://doi.org/10.1016/j.compag.2021.106241>
- Ibarra Méndez, A. N. (2015). *BENEMÉRITA UNIVERSIDAD AUTÓNOMA DE PUEBLA*.
- INAMHI. (2025, junio). <https://servicios.inamhi.gob.ec/>. Instituto Nacional de Meteorología e Hidrología del Ecuador.
- Islam, M. A., Lomax, S., Doughty, A. K., Islam, M. R., & Clark, C. E. F. (2020). Automated monitoring of panting for feedlot cattle: Sensor system accuracy and individual variability. *Animals*, 10(9), 1–20. <https://doi.org/10.3390/ani10091518>
- Kaur, D., & Virk, A. K. (2025). Smart neck collar: IoT-based disease detection and health monitoring for dairy cows. *Discover Internet of Things*, 5(1). <https://doi.org/10.1007/s43926-025-00109-5>
- Knight, C. H. (2020). Review: Sensor techniques in ruminants: More than fitness trackers. *Animal*, 14(S1), S187–S195. <https://doi.org/10.1017/S1751731119003276>
- Lamanna, M., Bovo, M., & Cavallini, D. (2025). Wearable Collar Technologies for Dairy Cows: A Systematized Review of the Current Applications and Future Innovations in Precision Livestock Farming. En *Animals* (Vol. 15, Número 3). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/ani15030458>
- Lardy, R., Ruin, Q., & Veissier, I. (2023). Discriminating pathological, reproductive or stress conditions in cows using machine learning on sensor-based activity data. *Computers and Electronics in Agriculture*, 204. <https://doi.org/10.1016/j.compag.2022.107556>
- Lascano Rivera, S., Rivera Escriba, L. A., Balarezo-Urresta, L. R., & Castañeda-Albán, J. E. (2025). ‘Sensores inteligentes y técnicas de machine learning para la detección del estrés en ganado bovino. *Innova Science*, 3(3091–1680).
- Lasser, J., Matzhold, C., Egger-Danner, C., Fuerst-Waltl, B., Steininger, F., Wittek, T., & Klimek, P. (2021). Integrating diverse data sources to predict disease risk in dairy

- cattle—a machine learning approach. *Journal of Animal Science*, 99(11). <https://doi.org/10.1093/jas/skab294>
- Leandro. (2023, septiembre 14). *Identificación animal: Beneficios y herramientas disponibles*. Universo de la salud animal. <https://www.universodelasaludanimal.com/ganaderia/identificacion-animal-beneficios-y-herramientas-disponibles/>
- Lecun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. En *Nature* (Vol. 521, Número 7553, pp. 436–444). Nature Publishing Group. <https://doi.org/10.1038/nature14539>
- Li, Y., Shu, H., Bindelle, J., Xu, B., Zhang, W., Jin, Z., Guo, L., & Wang, W. (2022). Classification and Analysis of Multiple Cattle Unitary Behaviors and Movements Based on Machine Learning Methods. *Animals*, 12(9). <https://doi.org/10.3390/ani12091060>
- Liseune, A., den Poel, D. Van, Hut, P. R., van Eerdenburg, F. J. C. M., & Hostens, M. (2021). Leveraging sequential information from multivariate behavioral sensor data to predict the moment of calving in dairy cattle using deep learning. *Computers and Electronics in Agriculture*, 191. <https://doi.org/10.1016/j.compag.2021.106566>
- López-Villanueva, D., Palau, R., & Santiago, R. (2025). Analizando alternativas metodológicas para la investigación educativa: Design Science Research (DSR). *Universitas Tarraconensis Revista de Ciències de l'Educació*, 1, e4062. <https://doi.org/10.17345/ute.2025.4062>
- Magana, J., Gavojdian, D., Menahem, Y., Lazebnik, T., Zamansky, A., & Adams-Progar, A. (2023). Machine learning approaches to predict and detect early-onset of digital dermatitis in dairy cows using sensor data. *Frontiers in Veterinary Science*, 10. <https://doi.org/10.3389/fvets.2023.1295430>
- Manteca, X. M. E. ; D. C. de E. sobre B. de A. de; F. de V. de la U. A. (2021, diciembre 8). *¿Qué es el Bienestar Animal?* Engormix.
- Marques, T. C., Marques, L. R., Fernandes, P. B., de Lima, F. S., do Prado Paim, T., & Leão, K. M. (2024). Machine Learning to Predict Pregnancy in Dairy Cows: An Approach Integrating Automated Activity Monitoring and On-Farm Data. *Animals*, 14(11). <https://doi.org/10.3390/ani14111567>
- Martono, N. P., Sawado, R., Nonaka, I., Terada, F., & Ohwada, H. (2023). *Automated Cattle Behavior Classification Using Wearable Sensors and Machine Learning Approach* (pp. 58–69). https://doi.org/10.1007/978-981-99-7855-7_5
- Mendoza De Los Santos, O. E. (2022). La naturaleza de la ciencia: una introducción general desde el realismo científico. *CIENCIA ergo-sum*, 29(1). <https://doi.org/10.30878/ces.v29n1a10>
- Miller, G. A., Mitchell, M., Barker, Z. E., Giebel, K., Codling, E. A., Amory, J. R., Michie, C., Davison, C., Tachtatzis, C., Andonovic, I., & Duthie, C. A. (2020). Using animal-mounted sensor technology and machine learning to predict time-to-calving in beef and dairy cows. *Animal*, 14(6), 1304–1312. <https://doi.org/10.1017/S1751731119003380>
- Molina Casasnovas, R. (2018). *Monitorización del comportamiento porcino mediante tecnología RFID para la prevención de pérdidas*.
- Nedap Livestock Management. (s/f). *Sistema de vigilancia para vacas COWcontrol TM*. AgriEXPO. Recuperado el 2 de julio de 2024, de <https://www.agriexpo.online/es/prod/nedap-livestock-management/product-172197-63508.html>
- Neethirajan, S. (2022). Affective State Recognition in Livestock—Artificial Intelligence Approaches. En *Animals* (Vol. 12, Número 6). MDPI. <https://doi.org/10.3390/ani12060759>
- Nogoy, K. M. C., Park, J., Chon, S. Il, Sivamani, S., Park, M. J., Cho, J. P., Hong, H. K., Lee, D. H., & Choi, S. H. (2021). Precision detection of real-time conditions of dairy cows using an advanced artificial intelligence hub. *Applied Sciences (Switzerland)*, 11(24).

- <https://doi.org/10.3390/app112412043>
- Odeón, M. M. (2020, enero 21). *Estrés en ganado: causas y consecuencias (Parte I)*.
- Odeón, M. M., & Romera, S. A. (2017). Estrés en ganado: causas y consecuencias (Parte I) - Actualidad Ganadera. *Instituto de Virología, CICVYA-INTA*. <https://revistas.unne.edu.ar/index.php/vet/article/view/1556>
- Pacheco Liliana, Delgado Hector, & Cabrera Victor E. (2021). *Exploring machine learning algorithms for early prediction of clinical mastitis*. <https://www.sciencedirect.com/science/article/pii/S0958694621000790>
- Pacheco, V. M., de Sousa, R. V., Rodrigues, A. V. da S., Sardinha, E. J. de S., & Martello, L. S. (2020). Thermal imaging combined with predictive machine learning based model for the development of thermal stress level classifiers. *Livestock Science*.
- PALMA, M. (2023, mayo 11). *Factores que provocan estrés en las vacas*. Molinos Champion S.A.S. <https://www.molinoschampion.com/factores-que-provocan-estres-en-las-vacas/>
- Palma, O., Plà-Aragón, L. M., Mac Cawley, A., & Alborno, V. M. (2025). AI and Data Analytics in the Dairy Farms: A Scoping Review. En *Animals* (Vol. 15, Número 9). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/ani15091291>
- Pedraza Caro, J. D. (2023). La Inteligencia Artificial en la sociedad: Explorando su Impacto Actual y los Desafíos Futuros. *Universidad Politécnica de Madrid*.
- Pedrosa, V. B., Chen, S. Y., Gloria, L. S., Doucette, J. S., Boerman, J. P., Rosa, G. J. M., & Brito, L. F. (2024). Machine learning methods for genomic prediction of cow behavioral traits measured by automatic milking systems in North American Holstein cattle. *Journal of Dairy Science*, 107(7), 4758–4771. <https://doi.org/10.3168/jds.2023-24082>
- Peffer, K., Tuunanen, T., Rothenberger, M. A., & Chatterjee, S. (2007). A design science research methodology for information systems research. *Journal of Management Information Systems*, 24(3), 45–77. <https://doi.org/10.2753/MIS0742-1222240302>
- Pineda Pertuz, C. M. (2022). *Aprendiza automático y profundo en python* (Ediciones de la U).
- Pinillos, Dr., & García, R. (2022). *V ENCUESTO INTERNACIONAL DE INVESTIGADORES EN BIENESTAR ANIMAL*. https://bienestaranimal.org.uy/wp-content/uploads/2022/12/Libro-de-Resumenes_ISBN.pdf
- Polo Jiménez, S. D., Estrada Bárcenas, R., Legorreta Morales, L., & Ruiz Rangel, M. Á. (2010). *IMPORTANCIA DE LOS VALORES PARA EL EJERCICIO ÉTICO DE LA PROFESIÓN*.
- Proudfoot, K. L., & Ternman, E. (2024). Methods used for estimating sleep in dairy cattle. *JDS Communications*, 5(5), 374–378. <https://doi.org/10.3168/jdsc.2023-0474>
- Rahman, A., Smith, D. V., Little, B., Ingham, A. B., Greenwood, P. L., & Bishop-Hurley, G. J. (2018). Cattle behaviour classification from collar, halter, and ear tag sensors. *Information Processing in Agriculture*, 5(1), 124–133. <https://doi.org/10.1016/j.inpa.2017.10.001>
- Ray, S. (2024). Top 10 Machine Learning Algorithms to Use in 2024. *Analytics Vidhya*. <https://www.analyticsvidhya.com/blog/2017/09/common-machine-learning-algorithms/#h-9-dimensionality-reduction-algorithms>
- Riaboff, L., Poggi, S., Madouasse, A., Couvreur, S., Aubin, S., Bédère, N., Goumand, E., Chauvin, A., & Plantier, G. (2020). Development of a methodological framework for a robust prediction of the main behaviours of dairy cows using a combination of machine learning algorithms on accelerometer data. *Computers and Electronics in Agriculture*, 169. <https://doi.org/10.1016/j.compag.2019.105179>
- Romanzini, E. P., Watanabe, R. N., Fonseca, N. V. B., Berça, A. S., Brito, T. R., Bernardes, P. A., Munari, D. P., & Reis, R. A. (2022). Modern livestock farming under tropical conditions using sensors in grazing systems. *Scientific Reports*, 12(1). <https://doi.org/10.1038/s41598-022-06650-5>

- Salgado, H. H., Méthot, S., Remus, A., Létourneau-Montminy, M. P., & Pomar, C. (2021). A novel feeding behavior index integrating several components of the feeding behavior of finishing pigs. *Animal*, 15(7). <https://doi.org/10.1016/j.animal.2021.100251>
- Santana, T. C., Guiselini, C., Pandorfi, H., Vigoderis, R. B., Barbosa Filho, J. A. D., Soares, R. G. F., Araújo, M. de F., Gomes, N. F., Lima, L. D. de, & Santos, P. C. da S. (2025). Ethics, Animal Welfare, and Artificial Intelligence in Livestock: A Bibliometric Review. *AgriEngineering*, 7(7), 202. <https://doi.org/10.3390/agriengineering7070202>
- Sawada, T., Uchino, T., Martono, N. P., & Ohwada, H. (2023). Efficient Estimation of Cow's Location Using Machine Learning Based on Sensor Data. *Lecture Notes of the Institute for Computer Sciences, Social-Informatics and Telecommunications Engineering, LNICST*, 477 LNICST, 86–94. https://doi.org/10.1007/978-3-031-29126-5_7
- Schmeling, L., Elmamooz, G., Hoang, P. T., Kozar, A., Nicklas, D., Sünkel, M., Thurner, S., & Rauch, E. (2021). Training and validating a machine learning model for the sensor-based monitoring of lying behavior in dairy cows on pasture and in the barn. *Animals*, 11(9). <https://doi.org/10.3390/ani11092660>
- Shorten, P. R. (2023). Acoustic sensors for detecting cow behaviour. *Smart Agricultural Technology*, 3. <https://doi.org/10.1016/j.atech.2022.100071>
- Shu, H., Li, Y., Bindelle, J., Jin, Z., Fang, T., Xing, M., & Wang, W. (2021). *Predicting physiological responses of dairy cows using comprehensive variables I*.
- Strutzke, S., Fiske, D., Hoffmann, G., Ammon, C., Heuwieser, W., & Amon, T. (2019). Technical note: Development of a noninvasive respiration rate sensor for cattle. *Journal of Dairy Science*, 102(1), 690–695. <https://doi.org/10.3168/jds.2018-14999>
- Stygar, A. H., Frondelius, L., Berteselli, G. V., Gómez, Y., Canali, E., Niemi, J. K., Llonch, P., & Pastell, M. (2023). Measuring dairy cow welfare with real-time sensor-based data and farm records: a concept study. *Animal*, 17(12). <https://doi.org/10.1016/j.animal.2023.101023>
- Suárez V. Humberto, & Martínez G. Marcela. (2020). *Buenas prácticas y bienestar animal*. 2–109.
- Surana, J., & Sharma, S. K. (2024). International Journal of INTELLIGENT SYSTEMS AND APPLICATIONS IN ENGINEERING Predicting Cow Health with a Smart Framework: A Big Data and Deep Learning-Based IoT Approach. En *Original Research Paper International Journal of Intelligent Systems and Applications in Engineering IJISAE* (Vol. 2024, Número 12s, pp. 487–499). www.ijisae.org
- Taramuel Andrade, T. A., Cortez Tulcán, J. E., & Lascano Rivera, S. B. (s/f). *Tècniques de aprendizaje automático para la identificación del nivel de estrés en bovinos*.
- Tian, F., Wang, J., Xiong, B., Jiang, L., Song, Z., & Li, F. (2021). Real-Time Behavioral Recognition in Dairy Cows Based on Geomagnetism and Acceleration Information. *IEEE Access*, 9, 109497–109509. <https://doi.org/10.1109/ACCESS.2021.3099212>
- Toledo, I. M., Dahl, G. E., & De Vries, A. (2022). Dairy cattle management and housing for warm environments. En *Livestock Science* (Vol. 255). Elsevier B.V. <https://doi.org/10.1016/j.livsci.2021.104802>
- Tran, D. N., Nguyen, T. N., Khanh, P. C. P., & Trana, D. T. (2021). An IoT-based Design Using Accelerometers in Animal Behavior Recognition Systems. *IEEE Sensors Journal*. <https://doi.org/10.1109/JSEN.2021.3051194>
- Ungar, E. D., & Nevo, Y. (2025). Rhythms, Patterns and Styles in the Jaw Movement Activity of Beef Cattle on Rangeland as Revealed by Acoustic Monitoring. *Sensors*, 25(4). <https://doi.org/10.3390/s25041210>
- Van Dixhoorn, I., Aubé, L., Van Zyl, C., De Mol, R., Van Der Werf, J., Lardy, R., Mialon, M.-M., Van Reenen, K., & Veissier, I. (2024). *M E R S E N N E Peer Community Journal Section: Animal Science From data on gross activity to the characterization of animal behaviour: which metrics for which purposes?* <https://doi.org/10.24072/pci>

- van Engelen, J.E., Hoos, H.H. A survey on semi-supervised learning. *Mach Learn* **109**, 373–440 (2020). <https://doi.org/10.1007/s10994-019-05855-6>
- Veissier, I., Lardy, R., Mialon, M.-M., Ruin, Q., Antoine, V., & Koko, J. (2023). *Machine Learning applied to behaviour monitoring to detect diseases, reproductive events and disturbances in dairy cows* (Número 1). <https://hal.inrae.fr/hal-03943072>
- Vidal, G., Sharpnack, J., Pinedo, P., Tsai, I. C., Lee, A. R., & Martínez-López, B. (2023). Comparative performance analysis of three machine learning algorithms applied to sensor data registered by a leg-attached accelerometer to predict metritis events in dairy cattle. *Frontiers in Animal Science*, *4*. <https://doi.org/10.3389/fanim.2023.1157090>
- W Weck, S Solis, & L Adrián. (2020). *Inteligencia artificial en Latinoamérica* (Fundación Konrad Adenauer, Ed.).
- Wagner, N., Antoine, V., Mialon, M.-M., Lardy, R., Silberberg, M., Koho, J., Veissier, I., & Koko, J. (2020). Machine learning to detect behavioural anomalies in dairy cows under subacute ruminal acidosis Machine learning to detect behavioural anomalies in dairy cows under subacute ruminal acidosis Metabolic disease Data mining Real-Time Locating System. *Computers and Electronics in Agriculture*, *170*, 10. <https://doi.org/10.1016/j.compag.2020.105233i>
- Wagner, N., Mialon, M.-M., Helle Sloth, K., Lardy, R., Ledoux, D., Silberberg, M., & De Boyer Des Roches, A. (2020). *Detection of changes in the circadian rhythm of cattle in relation to disease, 1 stress, and reproductive events 2 3*.
- Wagner, N., Mialon, M.-M., Sloth, K. H., Lardy, R., Ledoux, D., Silberberg, M., de Boyer des Roches, A., & Veissier, I. (2021). Detection of changes in the circadian rhythm of cattle in relation to disease, stress, and reproductive events. *Methods*, *186*, 14–21. <https://doi.org/10.1016/j.ymeth.2020.09.003>
- Watanabe, R. N., Bernardes, P. A., Romanzini, E. P., Teobaldo, R. W., Reis, R. A., Munari, D. P., Braga, L. G., & Brito, T. R. (2021). Strategy to predict high and low frequency behaviors using triaxial accelerometers in grazing of beef cattle. *Animals*, *11*(12). <https://doi.org/10.3390/ani11123438>
- Wathes, C. M., Kristensen, H. H., Aerts, J.-M., & Berckmans, D. (2008). Is precision livestock farming an engineer's daydream or nightmare, an animal's friend or foe, and a farmer's panacea or pitfall? *Computers and Electronics in Agriculture*, *64*(1), 2–10. <https://doi.org/10.1016/j.compag.2008.05.005>
- Williams, M., & Zhan Lai, S. (2022). Classification of dairy cow excretory events using a tail-mounted accelerometer. *Computers and Electronics in Agriculture*, *199*, 107187. <https://doi.org/10.1016/j.compag.2022.107187>
- Wittenburg, D., Melzer, N., Willmitzer, L., Lisec, J., Kesting, U., Reinsch, N., & Reipsilber, D. (2013). Milk metabolites and their genetic variability. *Journal of Dairy Science*, *96*(4), 2557–2569. <https://doi.org/10.3168/jds.2012-5635>
- Woodward SJR, Edwards JP, Verhoeck KJ, Jago JG. Identifying and predicting heat stress events for grazing dairy cows using rumen temperature boluses. *JDS Commun*. 2024 Jan 15;5(5):431-435. doi: 10.3168/jdsc.2023-0482. PMID: 39310829; PMCID: PMC11410469.
- Zhang, Y., Zhang, Y., Gao, M., Dai, B., Kou, S., Fu, X., & Shen, W. (2022). *Digital twin perception and modeling method for 2 feeding behavior of dairy cows*. <https://ssrn.com/abstract=4463418>
- Zhao, K., Duan, Y., Chen, J., Li, Q., Hong, X., Zhang, R., & Wang, M. (2023). Detection of Respiratory Rate of Dairy Cows Based on Infrared Thermography and Deep Learning. *Agriculture (Switzerland)*, *13*(10). <https://doi.org/10.3390/agriculture13101939>
- Zhou, X., Xu, C., Wang, H., Xu, W., Zhao, Z., Chen, M., Jia, B., & Huang, B. (2022). The Early Prediction of Common Disorders in Dairy Cows Monitored by Automatic Systems with Machine Learning Algorithms. *Animals*, *12*(10).

<https://doi.org/10.3390/ani12101251>

Anexos



Anexo 1 Manual de usuario Cow System

The Circadian Cycle Analysis System!



Cow System

Contenido

Introducción	208
Ingreso	209
Farm.....	211
Web Scraping of Collars and Weather	212
Cycles Panel	213
Training History	214
Prediction and Activity Visualization.....	215
Add Reviewer.....	216

Introducción

Bienvenido al manual de usuario del Cow System, una plataforma tecnológica desarrollada para la gestión y monitoreo inteligente de ganado vacuno en tiempo real. Este sistema, alojado en <https://proyectos.upec.edu.ec/>, ha sido diseñado pensando en los productores, técnicos y administradores de fincas ganaderas que buscan optimizar sus procesos mediante el uso de herramientas digitales avanzadas.

Cow System integra módulos especializados que permiten no solo el seguimiento continuo del estado de las vacas, sino también la predicción de comportamientos, ciclos reproductivos y necesidades de entrenamiento, todo ello respaldado por técnicas de web scraping y análisis de datos en tiempo real.

A través de sus secciones Home, Farm, Web Scraping, Cycles, Training, Prediction, Real-Time Prediction, Add Reviewer, Configuration y Log Out el usuario podrá gestionar de forma integral su hato ganadero, tomar decisiones informadas y anticiparse a posibles eventos, mejorando así la productividad y el bienestar animal.


Este manual tiene como objetivo guiarlo paso a paso en el uso de cada funcionalidad, asegurando que pueda aprovechar al máximo todas las capacidades del sistema.

Ingreso

Ingresar a: proyectos.upec.edu.ec

Ingresar las credenciales, roles:

- Admin.
- Revisor.

A screenshot of a web browser displaying the login page for 'proyectos.upec.edu.ec'. The browser's address bar shows the URL. The login form is centered on the page and contains the following elements: a title 'Login', an 'Email' label above a text input field, a 'Password' label above another text input field, and a blue button labeled 'Enter' at the bottom.

Nota: Si accede como revisor, únicamente podrá visualizar los datos relacionados con las vacas, los entrenamientos y las predicciones. Solo el administrador tiene permisos para editar cualquiera de estas secciones.

1. La primera pantalla corresponde a la bienvenida, donde se presenta el **Sistema de Análisis del Ciclo Circadiano (Circadian Cycle Analysis System)**.

En el lado izquierdo se encuentra el sidebar o panel de navegación con las distintas opciones disponibles.

The screenshot shows a web browser window with the address bar displaying `proyectos.upec.edu.ec`. The browser's address bar and tabs are visible at the top. On the left side, there is a dark grey sidebar menu for the "Cow System". The menu items are: Home (highlighted), Farm, Web Scraping, Cycles, Training, Prediction, Add Reviewer, Configuration, and Log Out. At the bottom of the sidebar, it says "User: Administrador". The main content area is white and features a welcome message: "Welcome to the Circadian Cycle Analysis System!". Below this, it states: "This system is designed for the San Francisco de Huaca farm and allows:". A bulleted list follows: "Automatically perform **web scraping** of data from smart cow collars.", "Obtain and analyze local **weather** data in real time.", "Train **LSTM** artificial intelligence models to analyze circadian cycles.", and "Predict cow stress in cold weather conditions, aiding decision-making on the farm." At the bottom of the main content area, there is a light blue box with the text: "Use the side menu to access scraping, analysis, prediction, and data management features."

Cow System

- Home
- Farm
- Web Scraping
- Cycles
- Training
- Prediction
- Add Reviewer
- Configuration
- Log Out

User: Administrador

Welcome to the Circadian Cycle Analysis System!

This system is designed for the San Francisco de Huaca farm and allows:

- Automatically perform **web scraping** of data from smart cow collars.
- Obtain and analyze local **weather** data in real time.
- Train **LSTM** artificial intelligence models to analyze circadian cycles.
- Predict cow stress in cold weather conditions, aiding decision-making on the farm.

Use the side menu to access scraping, analysis, prediction, and data management features.

Farm

Pantalla de la granja: En esta sección se visualiza la información de las vacas registradas en el sistema. Desde aquí, es posible agregar nuevas vacas, así como editar o eliminar la información existente.

Cow information Add cow

Select a cow to view the saved records at the bottom.

ID	Name	Date of Birth	Earring Number	Reply	Actions
1	Joya	2020-01-02	468	984000006503534	Edit Delete
2	Rosa	2016-10-31	479	984000006503549	Edit Delete
3	Luly	2017-12-10	499	984000006503542	Edit Delete
4	Cris	2019-02-03	1870	984000006503535	Edit Delete
5	Elyn	2013-02-02	1872	984000006503553	Edit Delete
6	Cummy	2017-05-03	1884	984000006503569	Edit Delete
7	Mishu	2018-02-02	1886	984000006503554	Edit Delete
8	Chela	2018-02-02	1894	984000006503533	Edit Delete
9	Santa	2009-02-02	4012	984000006503548	Edit Delete

Al seleccionar una vaca dentro de la tabla, se despliega los datos disponibles desde 01/01/2024 y puede realizar filtros para ver la data

Información detallada de la vaca: Luna

Información General

ID:	10
Nombre:	Luna
Fecha de nacimiento:	2019-08-14
Número de arete:	4145
Responder:	984000006503563

Filtros

Filtrar por fecha: Calendario

[Filtrar](#) [Limpiar filtro](#)

Estadísticas de Actividades

Total de registros: 100	Tipos de actividad: 4
other: 26 registros (26.0%) - 7.06 horas	resting: 28 registros (28.0%) - 7.70 horas
rumination: 25 registros (25.0%) - 5.99 horas	eating: 21 registros (21.0%) - 4.25 horas

Registros de Actividad

Fecha	Hora	Actividad	Duración (horas)	Ancho	Ancho Modificado	Timestamp
2025-07-23	13:00:28	other	0.27	158.00	140.71	2025-07-23 13:00:28

Web Scraping of Collars and Weather

Pantalla de Web Scraping: En esta sección se puede activar o desactivar el web scraping para el sistema de collares Nedap Now, así como para la recolección de datos desde la página de AccuWeather de Huaca.

Además, se muestra la información correspondiente al último raspado realizado.

Web Scraping of Collars and Weather

Enable Scheduled Web Scraping Disable Scheduled Web Scraping Generate Random Data

Collar Data (latest)

Earring	Cow's Name	Class	Duration (h)	Time
468	Joya	eating	0.2208333333333333	13:00:27.681224
468	Joya	resting	0.3575	13:00:27.681708
468	Joya	resting	0.19944444444444445	13:00:27.681879
468	Joya	resting	0.2222222222222222	13:00:27.682020
479	Rosa	rumination	0.2883333333333333	13:00:27.728359
479	Rosa	rumination	0.2586111111111111	13:00:27.728706

Weather (latest hour)


AccuWeather Huaca, Carchi

Temperatura: 13°C

- RealFeel®: 16°
- RealFeel Shade™: 11°
- Índice UV máx.: 5 Moderado
- Viento: SE 12 km/h
- Ráfagas de viento: 30 km/h
- Humedad: 78 %
- Punto de rocío: 9° C
- Presión: → 1031 mb
- Nubosidad: 97 %
- Visibilidad: 8 km

Dentro de la pantalla ciclos, está el panel donde se puede dirigir a los entrenamientos como a la predicción, así como en el panel izquierdo.

Cycles Panel



Esta pantalla, Gestiona el entrenamiento de modelos y visualice predicciones de estrés y actividad de las vacas. Aquí se puede ver el historial de entrenamiento, inicie nuevos procesos y revise su configuración.

Visualización de predicciones

Vea datos históricos y predicciones de estrés y actividad en tiempo real.

Training History

Pantalla de Entrenamientos: En esta sección se muestra si el entrenamiento del modelo LSTM se realizó exitosamente o no. También se presenta la fecha en la que se ejecutó dicho entrenamiento.

The screenshot displays the 'Training History' page of the 'Cow System'. The page features a sidebar with navigation links: Home, Farm, Web Scraping, Cycles (selected), Training, Prediction, Add Reviewer, Configuration, and Log Out. The user is identified as 'Administrador'. The main content area shows a grid of training records for six cows. Each record includes the cow's name, the training date and time, the configuration parameters, the state, and a message.


Cow	Training Date/Time	Configuration	State	Message
Vaca_10	2025-07-18 10:14:21	timesteps=24, epochs=100, batch_size=24	Exitoso	Entrenamiento completado para vaca 10
Vaca_9	2025-07-18 09:16:11	timesteps=24, epochs=100, batch_size=24	Exitoso	Entrenamiento completado para vaca 9
Vaca_8	2025-07-18 08:12:07	timesteps=24, epochs=100, batch_size=24	Exitoso	Entrenamiento completado para vaca 8
Vaca_7	2025-07-18 07:04:22	timesteps=24, epochs=100, batch_size=24	Exitoso	Entrenamiento completado para vaca 7
Vaca_6	2025-07-18 05:56:01	timesteps=24, epochs=100, batch_size=24	Exitoso	
Vaca_5	2025-07-18 04:48:14	timesteps=24, epochs=100, batch_size=24	Exitoso	

Pantalla de Predicción: En esta sección se presenta un gráfico interactivo desarrollado con Dash, donde se visualiza la predicción del nivel de estrés de cada vaca.

Además, se puede observar el nivel de actividad diaria, el comportamiento del ciclo circadiano y la evolución temporal de las predicciones. Esta información permite identificar patrones de comportamiento anormales y tomar decisiones informadas para mejorar el bienestar animal.

Prediction and Activity Visualization

Esta pantalla permite observar el estrés por vaca



Add Reviewer

Pantalla de Gestión de Revisores: En esta sección se pueden agregar nuevos revisores, así como editar o eliminar los existentes. Los revisores cuentan con permisos limitados, permitiéndoles únicamente inspeccionar el sistema sin realizar modificaciones.

Add Reviewer

Name



Email

Enter a valid email address

Password

Phone number

Enter exactly 10 digits

Add Reviewer

Anexo 2 Instrumento de Validación por Juicio de Expertos



**UNIVERSIDAD NACIONAL MAYOR DE SAN
MARCOS**

Facultad de Ingeniería de Sistemas e Informática
Unidad de Posgrado

**Tesis: «Predicción del estrés por frío del ganado
lechero utilizando
técnicas de aprendizaje automático»**

I. DATOS DEL EXPERTO E IDENTIFICACIÓN DEL FORMULARIO

1. Apellidos y nombres del experto	
2. Especialidad/área	
3. Grado académico	
4. Institución de adscripción	
5. Años de experiencia profesional	
6. Correo electrónico	
7. Teléfono (opcional)	

Declaro haber leído el documento y realizar esta evaluación de manera objetiva, manteniendo la confidencialidad de la información.

Lugar _____ y fecha: _____ Firma: _____

II. INSTRUCCIONES

A continuación, evalúe el artefacto/módulo predictivo (FFT + LSTM) y su documentación asociada. Utilice la siguiente escala Likert para cada ítem. Si un ítem no aplica a su área, marque N/A y fundamente en observaciones.

1 = Muy deficiente	2 = Deficiente	3 = Aceptable	4 = Bueno	5 = Excelente
--------------------	----------------	---------------	-----------	---------------

III. MATRIZ DE EVALUACIÓN (ESCALA 1–5; N/A)

A. Relevancia técnica

Ítem	Descripción	1	2	3	4	5
A1	A1. Precisión del modelo (exactitud, F1, ROC/PR) acorde a la literatura del área.	☐	☐	☐	☐	☐

A2	A2. Robustez frente a datos ruidosos o faltantes; control de fuga temporal (walk-forward, LOCO).	☐	☐	☐	☐	☐
A3	A3. Interpretabilidad básica del sistema (rasgos circadianos, umbrales, análisis de errores).	☐	☐	☐	☐	☐
A4	A4. Reproducibilidad y trazabilidad (pipeline, hiperparámetros, versión de datos/modelo).	☐	☐	☐	☐	☐

B. Aplicabilidad práctica en entorno productivo

Ítem	Descripción	1	2	3	4	5
B1	B1. Utilidad clínica/operativa de las alertas para decisiones en tiempo real (refugio/manejo).	☐	☐	☐	☐	☐
B2	B2. Tiempo de respuesta y factibilidad de operación 24/7 con recursos disponibles.	☐	☐	☐	☐	☐
B3	B3. Facilidad de uso para personal de campo; claridad de paneles e indicadores.	☐	☐	☐	☐	☐
B4	B4. Integración con IoT/sensores y plan de mantenimiento/calibración.	☐	☐	☐	☐	☐

C. Innovación y aporte científico

Ítem	Descripción	1	2	3	4	5
C1	C1. Novedad del enfoque (filtrado circadiano + LSTM) respecto a líneas base.	☐	☐	☐	☐	☐
C2	C2. Contribución al conocimiento en ganadería de	☐	☐	☐	☐	☐

	precisión/bienestar animal.					
C3	C3. Potencial de generalización (otras razas, climas, granjas).	☐	☐	☐	☐	☐

D. Presentación y documentación del artefacto

Ítem	Descripción	1	2	3	4	5
D1	D1. Claridad y suficiencia de la documentación técnica (diagramas, arquitectura, métricas).	☐	☐	☐	☐	☐
D2	D2. Consistencia entre objetivos, métodos y resultados reportados.	☐	☐	☐	☐	☐
D3	D3. Calidad formal (redacción, estilo, referencias actualizadas).	☐	☐	☐	☐	☐

IV. OBSERVACIONES CUALITATIVAS POR DIMENSIÓN

A. Relevancia técnica

- Fortalezas:
- Oportunidades de mejora:
- Recomendación específica:

B. Aplicabilidad práctica en entorno productivo

- Fortalezas:
- Oportunidades de mejora:
- Recomendación específica:

C. Innovación y aporte científico

- Fortalezas:
- Oportunidades de mejora:
- Recomendación específica:

D. Presentación y documentación del artefacto

- Fortalezas:
- Oportunidades de mejora:
- Recomendación específica:

V. PUNTAJE GLOBAL E INTERPRETACIÓN

Suma los puntajes válidos (excluya N/A) y divídalos para el número de ítems respondidos para obtener el promedio global.

Promedio 4.50 – 5.00	Excelente: apto para implementación y publicación, ajustes menores de forma.
Promedio 4.00 – 4.49	Muy bueno: aprobable con observaciones menores/medias.
Promedio 3.50 – 3.99	Aprobable con observaciones: requiere mejoras metodológicas o de documentación.
Promedio < 3.50	Requiere ajustes sustantivos antes de considerar su aprobación.
Recomendación del experto	Aprobar / Aprobar con observaciones / No aprobar (marcar y justificar).

Comentario final del experto (obligatorio):

VALIDEZ DE CONTENIDO (OPCIONAL)

Para cada ítem, califique Relevancia, Claridad y Coherencia en escala 1–4 (1=No relevante/No claro/No coherente; 4=Muy relevante/Muy claro/Muy coherente). El I-CVI por ítem se calcula como la proporción de expertos que marcaron 3 o 4. El S-CVI/Ave es el promedio de I-CVI.

Ítem	Relevancia (1–4)	Claridad (1–4)	Coherencia (1–4)	Obs.
A1	☐ 1 ☐ 2 ☐ 3 ☐ 4	☐ 1 ☐ 2 ☐ 3 ☐ 4	☐ 1 ☐ 2 ☐ 3 ☐ 4	
A2	☐ 1 ☐ 2 ☐ 3 ☐ 4	☐ 1 ☐ 2 ☐ 3 ☐ 4	☐ 1 ☐ 2 ☐ 3 ☐ 4	
A3	☐ 1 ☐ 2 ☐ 3 ☐ 4	☐ 1 ☐ 2 ☐ 3 ☐ 4	☐ 1 ☐ 2 ☐ 3 ☐ 4	
A4	☐ 1 ☐ 2 ☐ 3 ☐ 4	☐ 1 ☐ 2 ☐ 3 ☐ 4	☐ 1 ☐ 2 ☐ 3 ☐ 4	
B5	☐ 1 ☐ 2 ☐ 3 ☐ 4	☐ 1 ☐ 2 ☐ 3 ☐ 4	☐ 1 ☐ 2 ☐ 3 ☐ 4	
B6	☐ 1 ☐ 2 ☐ 3 ☐ 4	☐ 1 ☐ 2 ☐ 3 ☐ 4	☐ 1 ☐ 2 ☐ 3 ☐ 4	
B7	☐ 1 ☐ 2 ☐ 3 ☐ 4	☐ 1 ☐ 2 ☐ 3 ☐ 4	☐ 1 ☐ 2 ☐ 3 ☐ 4	
B8	☐ 1 ☐ 2 ☐ 3 ☐ 4	☐ 1 ☐ 2 ☐ 3 ☐ 4	☐ 1 ☐ 2 ☐ 3 ☐ 4	
C9	☐ 1 ☐ 2 ☐ 3 ☐ 4	☐ 1 ☐ 2 ☐ 3 ☐ 4	☐ 1 ☐ 2 ☐ 3 ☐ 4	
C10	☐ 1 ☐ 2 ☐ 3 ☐ 4	☐ 1 ☐ 2 ☐ 3 ☐ 4	☐ 1 ☐ 2 ☐ 3 ☐ 4	
C11	☐ 1 ☐ 2 ☐ 3 ☐ 4	☐ 1 ☐ 2 ☐ 3 ☐ 4	☐ 1 ☐ 2 ☐ 3 ☐ 4	
D12	☐ 1 ☐ 2 ☐ 3 ☐ 4	☐ 1 ☐ 2 ☐ 3 ☐ 4	☐ 1 ☐ 2 ☐ 3 ☐ 4	
D13	☐ 1 ☐ 2 ☐ 3 ☐ 4	☐ 1 ☐ 2 ☐ 3 ☐ 4	☐ 1 ☐ 2 ☐ 3 ☐ 4	
D14	☐ 1 ☐ 2 ☐ 3 ☐ 4	☐ 1 ☐ 2 ☐ 3 ☐ 4	☐ 1 ☐ 2 ☐ 3 ☐ 4	

Nota: Sugerido aplicar a ≥ 3 expertos; aceptar ítems con I-CVI ≥ 0.78 y S-CVI/Ave ≥ 0.85 .

DATOS DEL ARTEFACTO E INSUMOS EVALUADOS

Nombre del artefacto / módulo	Cow System
Versión y fecha	02/2025
Repositorio/URL	https://proyectos.upec.edu.ec/
email: revisor@upec.edu.ec	password: revisor2025
Documentación técnica adjunta	Manual de usuario
Responsable de contacto	Samuel Lascano Rivera

Anexo 3 Resultados de exámenes de sangre

Vaca Joya: En Día 1 se observa desacople temporal: NEFA sube mientras ACTH baja, consistente con (i) respuestas con diferente latencia (endócrina vs. metabólica) y/o (ii) retroalimentación negativa del eje HHA tras un pico previo no capturado en POST. En Día 2, ambos biomarcadores aumentan levemente en POST, sugiriendo un estímulo más moderado o adaptación respecto al día 1. La figura 27 (A) respalda la validez convergente del constructo si coocurre con ventanas frías y dt elevados en D1 POST. El desfase NEFA–ACTH subraya la necesidad de integrar biomarcadores + comportamiento (dt) + contexto SFT y analizar lags (por ejemplo, 0–3 h) en los modelos.




Figura (A) Resultados Vaca Joya

La Figura (B) ilustra el panel de visualización del sistema en operación real para la vaca “Joya”, durante el intervalo de fechas correspondiente al periodo de evaluación (septiembre de 2025), coherente con las ventanas consideradas en los experimentos de clasificación. En la gráfica se muestran simultáneamente la actividad horaria registrada por el collar (línea azul), el componente circadiano estimado (línea verde), la predicción del modelo LSTM (línea punteada) y las etiquetas de estrés asignadas (Normal/Mild/High), junto con el punto de corte temporal a partir del cual se emite la alerta (línea vertical discontinua). El hecho de que la dinámica observada y las fechas

de los episodios Mild/High coincidan con los resultados cuantitativos reportados en el conjunto de prueba respalda la consistencia entre el desempeño “de laboratorio” y el comportamiento del sistema ya desplegado, mostrando que las métricas de clasificación se traducen en señales operativas útiles para la vigilancia diaria en granja.

Activity and Stress Prediction Visualization





Figura (B) Resultados Vaca Joya

Vaca Rosa: A diferencia de otros casos con desfase, la figura 28 demuestra copropagación en ambos días (NEFA↑ y ACTH↑ en POST), más pronunciada en D2 (pico ACTH). Esto sugiere un estímulo térmico sostenido o una sensibilización entre días, con latencias relativamente alineadas entre la respuesta endócrina y la metabólica. La co-ocurrencia de NEFA↑ y ACTH↑ en POST respalda la validez convergente del constructo de estrés por frío en ROSA.



Activity and Stress Prediction Visualization





Figura C Resultados Vaca Rosa

Vaca Luly: En ambos días hay co-elevación NEFA–ACTH en POST, la figura 29 indica el acoplamiento entre la respuesta metabólica y la activación del eje HHA. La magnitud sugiere pico endócrino más fuerte en D1 y pico metabólico más alto en D2, compatible con latencias distintas (ACTH más temprana, NEFA más sostenida) y/o diferencias en carga térmica/energética entre días. Este individuo aporta un caso robusto de validez convergente del constructo de estrés por frío.



Prediction and Activity Visualization

Activity and Stress Prediction Visualization





Figura D Resultados Vaca Luly

Vaca Cris: Hay co-elevación sincronizada NEFA–ACTH en los dos POST, en la figura 30 se evidencia la respuesta amplificada del Día 2. Esto sugiere estimulación térmica más severa o acumulativa el segundo día, y latencias cortas entre la respuesta endocrina y la metabólica. CRIS es un ejemplo nítido de validez convergente (biomarcadores alineados).



Prediction and Activity Visualization

Activity and Stress Prediction Visualization





Figura E Resultados Vaca Cris


Vaca Elyn: Existe co-elevación marcada de NEFA y ACTH en D2 POST, mientras que en D1 la reacción es tenue (NEFA↑ leve; ACTH casi estable) ver la figura 31. Esto sugiere estimulación térmica más intensa o acumulación hacia el segundo día, con latencia entre el calentamiento del eje HHA (sube desde D2 PRE) y la mayor

movilización lipídica (salto en D2 POST). ELYN ilustra un caso de convergencia tardía: el constructo de estrés por frío se confirma especialmente en D2,



Prediction and Activity Visualization


Activity and Stress Prediction Visualization



Datos, predicción y estrés para la vaca ID: 5

Figura F Resultados Vaca Elyn

Vaca Cummy: En los dos días hay co-elevación NEFA–ACTH en POST, como se observa en la figura 32; el Día 2 muestra la respuesta más fuerte (ambos picos), compatible con estímulo térmico más intenso o acumulación/priming entre días y latencias cortas entre la señal endócrina y la metabólica. Cummy es un ejemplo de convergencia sincronizada.



Activity and Stress Prediction Visualization





Figura G Resultados Vaca Cummy

Vaca Mishu: Hay desacople NEFA–ACTH, como se observa en la figura 33, cuando ACTH cae en D1 POST, NEFA sube levemente; y cuando ACTH alcanza su pico en D2 PRE, NEFA está en mínimo, recuperándose recién en D2 POST. Esto sugiere latencias distintas (endócrina más temprana, metabólica retardada) y posible lag corto entre ambas señales. MISHU aporta un caso de convergencia con desfase.



Activity and Stress Prediction Visualization





Figura H Resultados Vaca Mishu

Vaca Chela: En Día 1 hay anti-correlación (NEFA $\uparrow$ mientras ACTH $\downarrow$), como se observa en la figura 34, compatible con latencias distintas o retroalimentación negativa del eje HHA tras un pico previo. En Día 2 persiste NEFA baja y estable mientras ACTH se reactiva, lo que sugiere desfase o un estímulo térmico moderado donde la movilización lipídica no se expresa. CHELA es un caso de desacople.



Activity and Stress Prediction Visualization





Figura I29 Resultados Vaca Chela

Vaca Santa: ACTH muestra un incremento moderado en D1 POST, figura 35, mientras NEFA disminuye ligeramente y permanece muy bajo en todo el periodo. Esto sugiere estímulo térmico leve/moderado o alta resiliencia metabólica de SANTA; también puede influir el piso analítico del ensayo de NEFA. SANTA es un caso de baja señal útil para justificar: (i) normalización robusta



Activity and Stress Prediction Visualization





Figura J Resultados Vaca Santa

Vaca Luna: D1 muestra NEFA $\uparrow$ fuerte con ACTH casi plana (posible respuesta metabólica predominante o pico hormonal fuera de muestreo) como se observa en la figura 36. En D2 hay co-elevación marcada, especialmente un salto desproporcionado de ACTH, compatible con estímulo térmico intenso o acumulación entre días; NEFA acompaña con pico alto, sugiriendo latencias cortas. LUNA es un caso de convergencia tardía y potente



Activity and Stress Prediction Visualization




Figura K Resultados Vaca Luna