

Original Article

Intelligent Health Monitoring of Dairy Cattle Using Artificial Intelligence-Based Signal Processing: An Integrated Approach in Precision Agriculture and Internet of Things (IoT) Systems

Hossien Navid *¹, Hadi Rahmanzadeh Bahram ¹, Ali Hosseinkhani ²

1. Dept. of Biosystems Engineering, Faculty of Agriculture, University of Tabriz, Tabriz, Iran.

2. Animal Nutrition Engineering Group, Faculty of Agriculture, University of Tabriz, Tabriz, Iran.

ARTICLE INFO

Keywords:

Smart Farming,
livestock Monitoring,
Discrete Wavelet
Transform,
Deep Learning,
Internet of Things (IoT)

Received:
September 01, 2025

Revised:
June 08, 2026

Accepted:
June 09, 2026

*Corresponding author:
navid@tabrizu.ac.ir

ABSTRACT

Precision livestock farming has emerged as an effective approach for improving animal health, welfare, and production efficiency through continuous behavioral monitoring. Among the various behavioral indicators, feeding and rumination are recognized as two of the most informative physiological activities because changes in these behaviors are closely associated with metabolic disorders, digestive diseases, and overall animal health. Conventional monitoring techniques, including visual observation and camera-based systems, are labor-intensive, costly, and difficult to implement in large-scale dairy farms. Consequently, the development of low-cost intelligent monitoring systems capable of real-time behavioral analysis has become an important research objective.

Introduction

This study presents a comparative investigation of two signal processing approaches for dairy cattle behavior recognition using a low-power piezoelectric sensing system integrated with artificial intelligence techniques. The primary objective was to evaluate the effectiveness of conventional time-domain feature extraction and Discrete Wavelet Transform (DWT)-based feature extraction for identifying feeding and rumination behaviors while considering both classification accuracy and computational efficiency. The proposed framework combines wearable sensing, wireless data acquisition, signal preprocessing, deep learning, and Internet of Things (IoT) communication into a unified monitoring platform suitable for precision livestock farming.

Materials and Methods

Data acquisition was performed at the dairy farm of the University of Tabriz using a piezoelectric sensor mounted on the animal's halter to capture jaw movement vibrations during different activities. An ESP32 microcontroller was employed for signal acquisition and Bluetooth communication with a mobile application, enabling wireless data collection and storage. The recorded datasets were transferred to a cloud storage platform for subsequent processing in Python using the Google Colab environment. Signal preprocessing included digital noise filtering, Min-Max normalization, and segmentation into fixed-length windows containing 20–30 samples. Because of the imbalance between behavioral classes, particularly the limited number of feeding samples, the Synthetic Minority Over-sampling Technique (SMOTE) was applied to generate balanced training data.

How to cite:

Navid, H., Rahmanzadeh Bahram, H., and Hosseinkhani, A. (2026). *Intelligent Health Monitoring of Dairy Cattle Using Artificial Intelligence-Based Signal Processing: An Integrated Approach in Precision Agriculture and Internet of Things (IoT) Systems*. Journal of Agricultural Mechanization, 11(1):71-84. <https://doi.org/10.22034/jam.2026.68349.1338>



This is an open-access article under the CC BY NC license
(<https://creativecommons.org/licenses/by-nc/4.0/>)



Results and Discussion

Two independent feature extraction strategies were investigated. In the first approach, statistical time-domain descriptors, including the mean, standard deviation, minimum, and maximum values, were extracted from each signal segment. In the second approach, Discrete Wavelet Transform (DWT) was employed to obtain time-frequency representations capable of capturing transient characteristics of jaw movements. Both feature sets were subsequently used to train identical one-dimensional Convolutional Neural Network (1D-CNN) models implemented in TensorFlow/Keras. The network architecture consisted of successive convolutional, batch normalization, activation, pooling, dropout, and fully connected layers. Model optimization was performed using the Adam optimizer with categorical cross-entropy loss, while Early Stopping and adaptive learning-rate reduction were incorporated to improve convergence and prevent overfitting. Model performance was evaluated using validation accuracy, precision, recall, F1-score, confusion matrices, and learning curves.

The experimental results demonstrated clear differences between the two signal processing strategies. The time-domain approach achieved the highest overall performance, reaching a validation accuracy of 78.86%, while requiring only 21.68 minutes for model training and approximately 0.17 million trainable parameters. In contrast, the DWT-based approach achieved a validation accuracy of approximately 76%, required 23.44 minutes of training time, and increased the model complexity to approximately 0.19 million parameters. These findings indicate that eliminating wavelet transformation significantly reduces computational complexity while maintaining superior classification performance, making the proposed approach particularly suitable for resource-constrained intelligent monitoring systems.

A detailed analysis of individual behavioral classes revealed different strengths for the two approaches. For the Feeding class, the DWT-based method achieved a slightly higher F1-score (0.7627) than the time-domain approach (0.752), suggesting that time-frequency decomposition can better represent the transient and irregular characteristics of feeding behavior. Conversely, the time-domain method produced superior performance for Rumination, achieving an F1-score of approximately 0.9903, compared with 0.9888 obtained by the DWT-based model. Since rumination exhibits highly repetitive and periodic jaw movements, its essential characteristics can be effectively captured using simple statistical features without requiring computationally expensive spectral analysis.

The comparative evaluation indicates that the selection of signal processing techniques should be guided by the intended operational objectives of intelligent livestock monitoring systems. For large-scale dairy farms where computational resources, energy consumption, and implementation costs are important considerations, the conventional time-domain approach provides an excellent balance between classification accuracy, processing speed, and model simplicity. In contrast, DWT-based analysis may be advantageous in applications requiring enhanced sensitivity for detecting feeding behavior, despite its higher computational cost.

Conclusion

Overall, this study demonstrates that accurate behavioral monitoring of dairy cattle can be achieved using a low-cost piezoelectric sensing platform combined with deep learning techniques. The proposed framework offers a practical solution for IoT-enabled precision livestock farming by integrating wearable sensing, wireless communication, intelligent signal processing, and automated behavioral classification. The results further suggest that computationally efficient time-domain feature extraction represents the most suitable strategy for real-time deployment in practical livestock monitoring systems, while wavelet-based analysis remains a promising complementary technique for applications requiring more detailed characterization of complex behavioral patterns. These findings contribute to the development of intelligent animal health monitoring systems capable of supporting sustainable dairy farming through continuous, automated, and data-driven behavioral assessment.



پایش هوشمند سلامت گاو شیری با پردازش سیگنال مبتنی بر هوش مصنوعی: راهکاری یکپارچه در کشاورزی دقیق و سیستم‌های اینترنت اشیا (IoT)

حسین نوید^{۱*}، هادی رحمن‌زاده بهرام^۱، علی حسینخانی^۲

تاریخ پذیرش: ۱۴۰۵/۰۳/۱۹

تاریخ بازنگری: ۱۴۰۵/۰۳/۱۸

تاریخ دریافت: ۱۴۰۴/۰۶/۱۰

۱- گروه مهندسی بیوسیستم، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران.

۲- گروه مهندسی تغذیه دام، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران.

E-mail: navid@tabrizu.ac.ir

* نویسنده مسئول:

چکیده

این مطالعه باهدف مقایسه دو روش پردازش سیگنال (بدون تبدیل موجک و با تبدیل موجک گسسته (DWT)) در پایش هوشمند فعالیت‌های گاو شیری انجام شد. با توجه به اهمیت کشاورزی دقیق و پایش سلامت دام، تمرکز اصلی بر تحلیل عملکرد این روش‌ها در تشخیص الگوهای حیاتی مانند تغذیه (Feeding) و نشخوار (Rumination) قرار گرفت. داده‌های مورد استفاده از حسگر پیزوالکتریک با فرکانس نمونه‌برداری ۲۴ هرتز جمع‌آوری شد و با استفاده از تکنیک‌های پیشرفته یادگیری عمیق و پردازش سیگنال تحلیل گردید. نتایج نشان داد که روش بدون DWT با دقت اعتبارسنجی ۷۸/۸۶٪، زمان آموزش کوتاه‌تر (۲۱/۶۸ دقیقه) و پیچیدگی مدل کمتر (M۰/۱۷ پارامتر)، به‌عنوان گزینه بهینه برای سیستم‌های عملیاتی با محدودیت منابع محاسباتی شناخته می‌شود. با این حال، روش با DWT در کلاس Feeding بهبود جزئی در F1-Score (۷۶۲۷/۰ نسبت به ۷۵۲/۰) نشان داد که حاکی از پتانسیل آن در پایش دقیق‌تر فعالیت‌های حیاتی است. در مقابل، عملکرد روش بدون DWT در تشخیص کلاس Rumination با $F1-Score \approx ۰/۹۹۹$ برتری واضحی داشت. این پژوهش راهکاری کاربردی برای توسعه سامانه‌های IoT در کشاورزی هوشمند ارائه می‌کند و تأکید می‌نماید که انتخاب روش پردازش سیگنال باید مبتنی بر اولویت‌های عملیاتی (دقت، سرعت، با تمرکز بر کلاس‌های خاص) باشد. همچنین پیشنهاد می‌شود که اثرات این روش‌ها در حوزه‌های گسترده‌تری مانند پردازش تصاویر سنجش از دور و رباتیک کشاورزی مورد بررسی قرار گیرد.

کلمات کلیدی: کشاورزی هوشمند، پایش دام، تبدیل موجک گسسته، یادگیری عمیق، اینترنت اشیا (IoT)

۱- مقدمه

نشخوار به عنوان یکی از رفتارهای فیزیولوژیک کلیدی در گاوهای شیری، نقش حیاتی در سلامت، رفاه و بهره‌وری این حیوانات ایفا می‌کند. مطالعات متعدد نشان می‌دهد که کاهش زمان نشخوار می‌تواند نشانگر ابتلا به بیماری‌های متابولیک نظیر کتوز، اسیدوز و اختلالات گوارشی باشد (Soriani *et al.*, 2013, Beauchemin, 2018 and Stangaferro *et al.*, 2016). در مقابل، روش‌های سنتی پایش این رفتار، مانند مشاهده بصری یا سیستم‌های مبتنی بر دوربین، به دلیل هزینه بالا، نیاز به نیروی انسانی متخصص و عدم کارایی در محیط‌های بزرگ، با محدودیت‌های جدی مواجه هستند (Chen *et al.*, 2017, and White *et al.*, 2017). برای نمونه، پژوهش Reiter و همکاران نشان داد که هزینه استفاده از حسگرهای تجاری مانند SCR Tags به ازای هر رأس گاو بیش از ۲۰۰ دلار است و نیاز به تعویض باتری هر ۶ ماه دارد (Reiter, *et al.*, 2018).

در پاسخ به این چالش‌ها، فناوری‌های نوین مبتنی بر پردازش سیگنال و یادگیری عمیق به عنوان راهکاری امیدبخش مطرح شده‌اند. تحقیقات اولیه توسط (Penning, 1983) و (Rutter *et al.*, 1997) استفاده از حسگرهای فشار و صدا را برای تشخیص نشخوار بررسی کردند. در سال‌های اخیر، شتاب‌سنج‌های سه محوره به دلیل دقت بالا در ثبت حرکات فک و سر گاو مورد توجه قرار گرفته‌اند (Rayas-Amor *et al.*, 2017 and Benaissa Said, 2019).

مطالعه (Bikker, *et al.*, 2014) نشان داد که نصب حسگرهای شتاب‌سنج بر روی گوش گاو می‌تواند دقت ۸۹٪ در تشخیص رفتارهای نشخوار و تغذیه فراهم کند.

تبدیل موجک گسسته (DWT) به عنوان یکی از روش‌های پیشرفته پردازش سیگنال، امکان استخراج همزمان ویژگی‌های زمانی و فرکانسی را فراهم می‌کند. پژوهش‌های (Shen, *et al.*, 2020) و (Tian, *et al.*, 2013) تأکید کرده‌اند که استفاده از موجک Daubechies 4 (db4) به دلیل شباهت به الگوی جویدن گاو، بهترین نتایج را در تشخیص نشخوار ارائه می‌دهد. این روش در مقایسه با تبدیل فوریه سریع (FFT)، قادر به کاهش نویزهای محیطی و بهبود دقت تا ۱۵٪ است (Ungar & Rutter, 2006 and Laca & WallisDeVries, 2000). از سوی دیگر، پیشرفت‌های اخیر در حوزه یادگیری عمیق تحول بزرگی در طبقه‌بندی رفتارهای دام ایجاد کرده است. مدل‌های ترکیبی مانند CNN + LSTM با قابلیت شناسایی الگوهای پیچیده زمانی-مکانی، به دقت‌های بالای ۹۵٪ دست یافته‌اند (Mei *et al.*, 2023 and Chang *et al.*, 2022). مطالعه (TIAN *et al.*)

(al, 2021) نیز نشان داد که ادغام داده‌های شتاب و ژئومغناطیس با استفاده از شبکه‌های عصبی کانولوشنی، دقت تشخیص را تا ۹۷٪ افزایش می‌دهد.

در حوزه ارتباطات بی‌سیم، فناوری‌های کم‌مصرفی مانند LoRaWAN^۱ به دلیل پوشش چندکیلومتری و مصرف انرژی پایین، به عنوان گزینه‌ای ایده‌آل برای سیستم‌های IoT در کشاورزی شناخته شده‌اند (Alvarenga *et al.*, 2016). این پروتکل امکان انتقال داده‌های حسگرها به پلتفرم‌های ابری را با حداقل تأخیر فراهم می‌کند و در پژوهش‌های متعددی مانند (Pereira *et al.*, 2017) و (Giovanettia *et al.*, 2017) مورد تأیید قرار گرفته است. با وجود پیشرفت‌های چشمگیر، خلأهای تحقیقاتی قابل توجهی باقی مانده است:

۱. فرکانس نمونه‌برداری پایین: اکثر مطالعات از فرکانس‌های بالا (۵۰ ≤ هرتز) استفاده کرده‌اند که مصرف انرژی را افزایش می‌دهد (Kappes *et al.*, 2021).

۲. یکپارچه‌سازی سخت‌افزار و نرم‌افزار: پژوهش‌های محدودی به طراحی سیستم‌های عملیاتی کم‌هزینه پرداخته‌اند (Nydegger *et al.*, 2012).

این پژوهش باهدف پر کردن این خلأها، سیستمی یکپارچه متشکل از چهار مؤلفه کلیدی طراحی کرده است:

۱. حسگر پیزوالکتریک کم‌مصرف با فرکانس نمونه‌برداری ۲۴ هرتز.

۲. مقایسه دو روش مبتنی بر ویژگی‌های زمانی و روش مبتنی بر تبدیل موجک گسسته (DWT) برای استخراج ویژگی‌های طیفی-زمانی.

۳. ارتباطات LoRaWAN برای انتقال داده‌ها.

۲- مواد و روش‌ها

۲-۱- حسگرها و سخت‌افزار

در این تحقیق، از حسگر پیزوالکتریک و برد ESP32 برای ضبط و تجزیه و تحلیل رفتار نشخوار گاوهای شیری استفاده شده است. این سخت‌افزار به گونه‌ای طراحی شده است که امکان ارتباط بلوتوثی با یک اپلیکیشن نصب شده روی موبایل را فراهم می‌کند و داده‌ها به صورت بی‌سیم به سیستم انتقال می‌یابند. داده‌برداری در مرکز گاوداری دانشگاه تبریز انجام گرفته است (شکل ۱).




شکل ۱- داده برداری با سامانه پایش نشخوار گاو (برچسب گذاری داده‌های رفتار گاو)

Fig 1. Data collection employing the ruminant monitoring system (annotation of cattle behavioral data).

انتخاب شد. پس از انتقال داده‌ها به Google Colab، عملیات پیش‌پردازش شامل حذف نویز (با استفاده از فیلترهای دیجیتال) و نرمال‌سازی (به روش Min-Max) انجام شد. در شکل ۲ نمونه‌ای از سیگنال‌های ضبط شده برای رفتارهای مختلف گاو نمایش داده شده است.

۲-۲- دیتاست و پیش‌پردازش داده‌ها

داده‌های خام حاصل از حسگرها پس از ضبط، در پلتفرم Google Drive ذخیره شدند تا امکان دسترسی آسان و تجزیه و تحلیل در محیط‌های مختلف فراهم شود. تمامی مراحل پیش‌پردازش، استخراج ویژگی و تحلیل سیگنال‌ها با استفاده از زبان برنامه‌نویسی پایتون و در محیط Google Colab انجام گرفت. این پلتفرم به دلیل دسترسی رایگان به منابع محاسباتی ابری و پشتیبانی از کتابخانه‌های پیشرفته،



شکل ۲- نمونه سیگنال‌های ضبط شده برای رفتارهای مختلف گاو.

Fig 2. Representative recorded signals corresponding to different behavioral states in cattle.

فراخوانی تابع `pywt.wavedec` (از کتابخانه PyWavelets) استخراج گردید.

۲-۳-۲- ساخت و آموزش مدل:

یک شبکه عصبی کانولوشنی (CNN) با معماری زیر در پایتون طراحی شد: لایه‌های `Conv1D` و `MaxPooling1D` برای استخراج ویژگی‌های مکانی لایه‌های `Dense` و `Dropout` برای کاهش بیش برآزش و همچنین `Batch Normalization` برای بهبود پایداری آموزش.

تابع فعال‌سازی `Swish` (پایاده‌سازی شده با کتابخانه TensorFlow) در لایه‌های میانی و مدل با `Adam Optimizer` (نرخ یادگیری اولیه: ۰/۰۰۱) و تابع هزینه `Categorical Crossentropy` آموزش داده شد.

برای تحلیل دقیق‌تر، داده‌ها به پنجره‌های زمانی با طول مشخص (مانند ۲۰ یا ۳۰ نقطه) تقسیم شدند. سپس ویژگی‌های زمانی (میانگین، انحراف معیار، مینیمم، ماکزیمم) و ویژگی‌های موجکی (با استفاده از تبدیل موجک گسسته) از هر پنجره استخراج گردید. این فرآیند با کتابخانه‌های پایتون مانند `NumPy` و `Pandas` پیاده‌سازی شد. به دلیل عدم تعادل در توزیع کلاس‌ها (مانند تعداد کم نمونه‌های کلاس Feeding)، از تکنیک `SMOTE` (پایاده‌سازی شده با کتابخانه `imbalanced-learn` در پایتون) برای تولید نمونه‌های مصنوعی و متعادل‌سازی کلاس‌ها استفاده شد.

۲-۳-۱- تحلیل سیگنال با استفاده از تبدیل موجک

۲-۳-۱- تجزیه و تحلیل سیگنال:

اسپکتروگرام داده‌ها با استفاده از تبدیل موجک گسسته (DWT) و کتابخانه `PyWavelets` در پایتون ترسیم شد. ویژگی‌های موجکی با

۳-۲-۳- آموزش مدل

آموزش مدل با ۲۰۰ اپاک و اندازه دسته ۲۵۶ انجام شد. از EarlyStopping (با تحمل ۱۰ دور آموزشی) و ReduceLROnPlateau (برای تنظیم پویای نرخ یادگیری) به منظور جلوگیری از کاهش بیش برآزش و بهینه‌سازی فرآیند آموزش استفاده گردید.

۳-۲-۴- ارزیابی مدل

عملکرد مدل با معیارهای دقت (Accuracy)، Recall و F1-Score ارزیابی شد.

نتایج با استفاده از ماتریس اغتشاش (پیاده‌سازی شده با کتابخانه Scikit-learn) و نمودارهای یادگیری (تاریخچه دقت و Loss) تحلیل گردید و در نهایت مصورسازی داده‌ها و نتایج با کتابخانه‌های Matplotlib و Seaborn انجام شد.


۳- نتایج و بحث

۳-۱- تحلیل نمودارهای روش مبتنی بر ویژگی‌های زمانی^۱

۳-۱-۱- نمودار دقت (Accuracy History)

شکل ۳ نشان می‌دهد که دقت مدل در مجموعه آموزش (Train) و اعتبارسنجی (Validation) طی دوره آموزش چگونه تغییر می‌کند.

دقت مدل در مجموعه آموزش به سرعت افزایش می‌یابد و به حدود ۷۵٪ رسیده است و همچنین دقت مدل در مجموعه اعتبارسنجی نسبتاً ثابت است و به حوالی ۷۰-۷۵٪ رسیده است. در نهایت بوضوح مشخص است که مدل به درستی آموزش داده شده است و دقت بالایی در هر دو مجموعه train و validation دارد. اختلاف بین دقت train و validation کم است، که نشان می‌دهد مدل به خوبی تعمیم‌پذیر است. وجود Early Stopping نشان می‌دهد که مدل در دوره‌های بعدی از آموزش از overfitting جلوگیری شده است.




شکل ۳- نمودار تغییرات دقت در هر دور آموزشی (روش مبتنی بر ویژگی‌های زمانی).

Fig 3. Training accuracy over epochs using the time-domain feature-based approach.

۳-۱-۲- نمودار افت (Loss History)

لذا این نمودار نشان می‌دهد که مقدار خطا در هر دو مجموعه train و validation به درستی کاهش یافته است. اختلاف بین خطا train و validation کم است، که نشان می‌دهد مدل به خوبی تعمیم‌پذیر است. استفاده از روش‌هایی مثل Early Stopping و ReduceLROnPlateau منجر به پایداری مدل شده است.

نمودار افت در شکل ۴ نشان می‌دهد که افت مدل در مجموعه آموزش (Train) و اعتبارسنجی (Validation) طی دوره آموزش چگونه تغییر می‌کند. خطای مدل در مجموعه آموزش به سرعت کاهش می‌یابد و به حدود ۰/۶ رسیده است. خطای مدل در مجموعه اعتبارسنجی نسبتاً ثابت است و به حوالی ۰/۶ - ۰/۷ رسیده است.




شکل ۴- نمودار افت (Loss History)
Fig 4. Training and validation loss history.

۳-۱-۳- ماتریس اغتشاش (Confusion Matrix)

ماتریس اغتشاش در شکل ۵ نشان می‌دهد که: مدل به خوبی کلاس‌ها را تشخیص می‌دهد، اما برخی از اشتباهات وجود دارد و کلاس rumination به خوبی تشخیص داده شده است بدون False Positive و اما کلاس‌های idle و other دارای تعداد قابل توجهی False

Positive و False Negative هستند. در مجموع نشاندهنده این مطلب است که مدل به خوبی کلاس‌های مختلف را تشخیص می‌دهد، اما کلاس‌هایی مانند idle و other نیازمند بهبود دارند. می‌توان از روش‌هایی مثل SMOTE یا وزن‌دهی کلاس‌ها برای بهبود کلاس‌های ضعیف استفاده کرد.



شکل ۵- ماتریس اغتشاش (روش مبتنی بر ویژگی‌های زمانی)
Fig 5. Confusion matrix (time-domain feature-based method).


۴-۱-۳- نمودار اهمیت ویژگی‌ها (Feature Importance)

نمودار اهمیت ویژگی‌ها در شکل ۶ نشان می‌دهد که ویژگی Mean مهم‌ترین نقش را در تشخیص رفتارهای مختلف دارد. سایر ویژگی‌ها مانند Std، Min، Max و Median اهمیت کمتری دارند، اما می‌توان از آن‌ها برای بهبود مدل استفاده کرد.

به طور کلی، مدل به خوبی آموزش دیده و دقت بالایی در شناسایی رفتارها دارد، اما کلاس‌های Idle و Other ضعیف‌تر هستند و نیاز به

بهبود دارند. نقاط قوت مدل شامل استفاده مؤثر از ویژگی‌های زمانی (Mean, Std, Min, Max) و نشانه‌های کمتر Overfitting است، و نقاط ضعف آن، اشتباهات قابل توجه (FN و FP) در کلاس‌های ضعیف است.

در ادامه، تحلیل نمودارهای پردازش سیگنال با استفاده از تبدیل موجک ارائه خواهد شد.



شکل ۶- نمودار اهمیت ویژگی‌ها (روش مبتنی بر ویژگی‌های زمانی)


Fig 6. Feature importance plot (time-domain feature-based method).

۲-۳- روش ترکیبی زمان-فرکانس^۱

روش دوم شامل استفاده از تکنیک‌های زیر:

- Other: الگوهای کلاس other دارای الگوهای مشخص تری هستند، که می‌تواند به عنوان شاخص‌های مفید برای تشخیص این کلاس استفاده شود.
- Feeding: الگوهای کلاس feeding دارای الگوهای قابل توجهی در فرکانس‌های بالاتر هستند.
- Rumination: الگوهای کلاس Rumination به‌طور واضح و قوی‌تر نمایش داده شده‌اند، که نشان می‌دهد این کلاس به‌درستی شناسایی می‌شود.
- تبدیل موجک گسسته (DWT) به‌خوبی ویژگی‌های زمانی-فرکانسی رفتارهای مختلف را نمایش می‌دهد.
- الگوهای کلاس rumination به‌وضوح قابل شناسایی هستند، که نشان می‌دهد این کلاس به‌درستی شناسایی می‌شود.
- کلاس‌های idle و other نسبتاً ضعیف‌تر عمل کرده‌اند.

- تبدیل موجک گسسته : (DWT) برای استخراج ویژگی‌های زمانی-فرکانسی.
- شبکه‌های عصبی: برای طبقه‌بندی و تشخیص الگوهای مختلف.
- در ادامه، به تجزیه و تحلیل نمودارهای آماری مختلف مربوط به این روش بررسی می‌شود؛
- نمودارهای تبدیل موجک در شکل ۷ نشان می‌دهند که:
- Idle: الگوهای زمانی-فرکانسی کلاس idle به‌صورت منظم و پراکنده‌تر هستند.



شکل ۷- نمودارهای تبدیل موجک (Wavelet Transform)


Fig 7. Wavelet transform plots.

- مدل به درستی آموزش داده شده است و دقت بالایی در هر دو مجموعه train و validation دارد.

همچنین شکل ۸ نشان می دهد که دقت مدل در مجموعه آموزش به سرعت افزایش یافته و به حدود ۷۶٪ رسیده است و دقت مدل در مجموعه اعتبارسنجی نیز به صورت ثابت در حدود ۷۵٪ باقی مانده است لذا مدل به خوبی آموزش داده شده است و دقت بالایی در هر دو مجموعه دارد. وجود Early Stopping و ReduceLROnPlateau منجر به جلوگیری از Overfitting شده است.

نمودار تغییرات دقت در شکل ۸ نشان می دهد که:

- دقت مدل در مجموعه آموزش (Train) و اعتبارسنجی (Validation) طی دوره آموزش چگونه تغییر می کند.
- دقت مدل در مجموعه آموزش به سرعت افزایش می یابد و به حدود ۷۵٪ رسیده است.
- دقت مدل در مجموعه اعتبارسنجی نسبتاً ثابت است و به حوالی ۷۰-۷۵ درصد رسیده است.




شکل ۸- نمودار تغییرات دقت در هر دور آموزشی (ترکیبی زمان-فرکانس)

Fig 8. Accuracy variation per training epoch (time-frequency hybrid method).

خوبی دارد، اما نیازمند بهبود است لذا مدل به خوبی کلاس‌های مختلف را تشخیص می‌دهد، اما کلاس‌های idle و other نیازمند بهبود هستند.

ماتریس درهم‌ریختگی در شکل ۹ نشان می‌دهد که:

کلاس rumination به خوبی شناسایی شده است (بدون False Positive). کلاس‌های idle و other دارای تعداد قابل توجهی False Positive و False Negative هستند. کلاس feeding نیز عملکرد



شکل ۹- ماتریس اغتشاش (Confusion Matrix)


Fig 9. Confusion matrix (time-frequency hybrid method).

به طور کلی، روش ترکیبی زمان-فرکانس با استفاده از DWT ویژگی‌های زمانی-فرکانسی را به خوبی استخراج می‌کند و کلاس‌های حیاتی به درستی شناسایی می‌شوند. مدل دقت بالایی در هر دو مجموعه آموزش و اعتبارسنجی دارد. با این حال، کلاس‌های Idle و Other ضعیف‌تر عمل کرده‌اند و نیاز به بهبود دارند که می‌توان با تکنیک‌هایی مانند SMOTE، وزن‌دهی کلاس‌ها یا استفاده از شبکه‌های عصبی ترکیبی (CNN + LSTM) این ضعف‌ها را کاهش داد.

نمودار شکل ۱۰ عملکرد کلاس‌های حیاتی (Feeding و Rumination) را بر اساس معیارهای Precision، Recall و F1-Score نشان می‌دهد.

Feeding: دقت و بازیابی نسبتاً بالایی دارد، اما تعادل بین Precision و Recall هنوز قابل بهبود است.

Rumination: عملکرد بسیار خوبی دارد و هر سه معیار تقریباً برابر ۱ هستند.



شکل ۱۰- نمودار عملکرد کلاس‌های حیاتی (Critical Classes Performance)

Fig 10. Performance plot for critical behavioral classes.

(۷۶٪ دقت، ۲۳/۴۴ دقیقه زمان آموزش و $M=0.19$ پارامتر) نشان می‌دهد. این نتایج حاکی از آن است که حذف تبدیل موجک، علاوه بر کاهش بار محاسباتی (۲ دقیقه افزایش زمان آموزش در روش DWT-Based)، سادگی مدل، کاهش حجم مدل، کاهش انرژی مورد نیاز برای پردازش و کاهش فضای مورد نیاز برای پردازش را نیز به همراه دارد.

در ادامه دو روش پردازش سیگنال مقایسه شده تا نقاط ضعف و قوت هر کدام با وضوح بیشتری مشخص شوند. بر اساس جدول (۱)، روش مبتنی بر عدم استفاده از تبدیل موجک (Non-Wavelet-Based) با دقت اعتبارسنجی $0.78/86\%$ ، زمان آموزش کوتاه‌تر ($21/68$ دقیقه) و پیچیدگی مدل کمتر (0.17 میلیون پارامتر)، عملکرد برتری نسبت به روش مبتنی بر تبدیل موجک گسسته (DWT-Based) دارد.

جدول ۱- خلاصه مقایسه عملکرد دو روش تحلیل سیگنال.

Table 1. Summary comparison of the performance of the two signal analysis methods.

Method	Validation Accuracy	Training Time (min)	Model Parameters	Feeding F1	Rumination F1
Non-Wavelet-Based	0.7886	21/68	M=0.17	0.752	0.9903
DWT-Based	0.7627	23/44	M=0.19	0.7627	0.9888

۱-۲-۳- ارزیابی کلاس‌های حیاتی

در کلاس تغذیه (Feeding)، روش DWT-Based با F1-Score برابر ۰/۷۶۲۷ نسبت به روش Non-Wavelet-Based (۰/۷۵۲) بهبود جزئی (۱/۱٪) نشان داد. در مقابل، برای کلاس نشخوار (Rumination)، روش Non-Wavelet-Based با F1-Score برابر ۰/۹۹۰۳، عملکردی برتر از روش DWT-Based (۰/۹۸۸۸) داشت. این تفاوت‌ها بیانگر آن است که تبدیل موجک گسسته در تشخیص الگوهای پیچیده‌تر (مانند تغذیه) مفید است، اما برای رفتارهای با الگوی پایدارتر (مانند نشخوار)، روش ساده‌تر کفایت می‌کند.

۴- نتیجه‌گیری نهایی

بر اساس مقایسه جامع دو روش پردازش سیگنال (بدون تبدیل موجک و با تبدیل موجک گسسته (DWT)) در پایش فعالیت‌های گاو شیری، نتایج زیر حاصل شد:

۱-۴- دقت و کارایی

روش بدون DWT با دقت اعتبارسنجی ۷۸/۸۶٪، زمان آموزش کوتاه‌تر (۲۱/۶۸ دقیقه) و پیچیدگی مدل کمتر (۰/۱۷ M پارامتر)، به‌عنوان گزینه بهینه برای سیستم‌های عملیاتی با محدودیت منابع محاسباتی شناسایی شد. این روش به دلیل سادگی و سرعت بالا، برای پایش در مقیاس بزرگ (مانند گاوداری‌های صنعتی) مناسب است.

روش با DWT اگرچه از نظر دقت کلی (۷۶٪) و زمان آموزش (۲۳ دقیقه) عملکرد ضعیف‌تری داشت، اما بهبود جزئی در F1-Score کلاس Feeding (۰/۷۶۲۷ نسبت به ۰/۷۵۲) نشان داد. این بهبود نشان می‌دهد که تبدیل موجک گسسته با استخراج ویژگی‌های طیفی-زمانی، می‌تواند در شناسایی الگوهای پیچیده‌تر (مانند فعالیت تغذیه) مؤثر باشد.

۲-۴- عملکرد کلاس‌های حیاتی

کلاس Rumination روش بدون DWT با F1-Score برابر ۰/۹۹، عملکردی استثنایی در تشخیص رفتارهای مرتبط با نشخوار نشان داد. این نتیجه تأیید می‌کند که برای رفتارهای با الگوی پایدار، روش‌های ساده‌تر نیز کفایت می‌کنند.

کلاس Feeding: بهبود ۱/۱٪ در روش DWT-Based، علیرغم کوچک بودن، از نظر عملیاتی حائز اهمیت است؛ چرا که پایش دقیق تغذیه به عنوان یک شاخص کلیدی در پیشگیری از بیماری‌های متابولیک (مانند کتوز و اسیدوز) نقش حیاتی ایفا می‌کند.

۳-۴- پیشنهاد کاربردی

۱. سیستم‌های بزرگ مقیاس: در گاوداری‌های صنعتی با محدودیت منابع سخت‌افزاری، روش بدون DWT به دلیل سادگی، سرعت و هزینه پایین، گزینه ارجح است.

۲. پایش کلاس‌های حساس: در مواردی که تمرکز بر پایش تغذیه (به عنوان یک رفتار حیاتی) است، روش با DWT با وجود نیاز به بهبود، می‌تواند به عنوان مکمل استفاده شود.

۳. توسعه فناوری: ادغام این روش‌ها با پردازش لبه (Edge Computing) و یادگیری تقویتی، می‌تواند مصرف انرژی را کاهش داده و دقت را در کلاس‌های کم‌نمونه (مانند Idle و Other) افزایش دهد.

۴-۴- تأثیر پژوهش بر کشاورزی هوشمند

این پژوهش با ارائه یک چارچوب کم‌هزینه و کارآمد، گامی مؤثر در راستای کشاورزی دقیق و پایش سلامت دام برداشته است. روش Non-Wavelet-Based به دلیل سادگی الگوریتم و کاهش پیچیدگی محاسباتی، قادر است با سیستم‌های پردازشی ساده مانند گوشی تلفن همراه و منابع محدود به‌خوبی اجرا شود و نیازی به سخت‌افزارهای پر قدرت یا سامانه‌ها و مرکز داده‌های ثابت پیچیده که قیمت‌های بالایی دارند، ندارد، بنابراین استفاده از این روش برای پایش بلادرنگ در مقیاس بزرگ، بدون تحمیل هزینه‌های اضافی، امکان‌پذیر است. همچنین سیستم پیشنهادی با بهره‌گیری از فناوری IoT و هوش مصنوعی، امکان مانیتورینگ بلادرنگ رفتارهای دام را فراهم می‌کند و زمینه را برای توسعه راهکارهای یکپارچه در حوزه‌هایی مانند رباتیک کشاورزی، سنجش از دور و بهینه‌سازی مصرف منابع هموار می‌سازد.

۵- منابع

- Alvarenga, I., Borges, L., Palkovič, J., Rodina, V., & Oddy, a. (2016). *Using a three-axis accelerometer to identify and classify sheep behaviour at pasture*. Appl. Animal Behaviour Sci, 91–99. <https://doi.org/10.1016/j.applanim.2016.05.026>
- Beauchemin, K. (2018). *Invited review: current perspectives on eating and rumination activity in dairy cows*. J. Dairy Sci, 101 (6), 4762–4784. <https://doi.org/10.3168/jds.2017-13706>
- Benaissa Said, T. F. (2019). *Classification of ingestive-related cow behaviours using RumiWatch halter and neck-mounted accelerometers*. Appl Anim Behav Sci, 211:9–16. <https://doi.org/10.1016/j.applanim.2018.12.003>
- Bikker, J., van Laar, H., Rump, P., Doorenbos, J., van Meurs, K., Griffioen, G., & Dijkstra, J. (2014). *Technical note: evaluation of an ear-attached movement sensor to record cow feeding behavior*

- Rutter, S., Champion, R., & Penning, P. (1997). *An automatic system to record foraging behaviour in free-ranging ruminants*. Appl. Anim. Behav. Sci, Vol, 54, 185–195. [https://doi.org/10.1016/S0168-1591\(96\)01191-4](https://doi.org/10.1016/S0168-1591(96)01191-4)
- Shen, W., Cheng, F., Zhang, Y., Wei, X., Fu, Q., & Zhang, Y. (2020). *Automatic recognition of ingestive-related behaviors of dairy cows based on triaxial acceleration*. Inf. Process. Agric, 7, 427–443. Retrieved from <https://doi.org/10.1016/j.inpa.2019.10.004>
- Soriani, N., Panella, G., & Calamari, L. (2013). *Rumination time during the summer season and its relationships with metabolic conditions and milk production*. J. Dairy Sci, vol. 96 (8), 5082–5094. <https://doi.org/10.3168/jds.2013-6620>
- and activity. J. Dairy Sci, 97, 2974–2979. <http://dx.doi.org/10.3168/jds.2013-7560>
- Chang, A. Z., Fogarty, E., Moraes, L., & García-Guerra, A. (2022). *Detection of rumination in cattle using an accelerometer ear-tag: A comparison of analytical methods and individual animal and generic models*. Comput. Electron. Agric, 192, 106595. <https://doi.org/10.1016/j.compag.2021.106595>
- Giovanettia, V., Decandiaa, M., & Molle, G. (2017). *Automatic classification system for grazing, ruminating and resting behaviour of dairy sheep using a tri-axial accelerometer*. Livestock Sci, 196:, 42–8. <https://doi.org/10.1016/j.livsci.2016.12.011>
- Kappes, R., Knob, D., & Scheid, A. (2021). *Evaluation of an electronic system for monitoring dairy cow rumination in a grazing based system*. Trop Anim Health Prod, 53, 379. Retrieved from <https://doi.org/10.1007/s11250-021-02833-w>
- Laca, E., & WallisDeVries, M. (2000). *Acoustic measurement of intake and grazing behaviour of cattle*. Grass Forage Sci, Vol, 55(2), 97–104. <https://doi.org/10.1046/j.1365-2494.2000.00203.x>
- Mei, L., Wu, Y., Li, G., Liu, M., Hu, R., Zou, H., Peng, Y. (2023). *Classification of cow behavior patterns using inertial measurement units and a fully convolutional network model*. J. Dairy Sci, Vol, 106, 1351–1359. Retrieved from <https://doi.org/10.3168/jds.2022-22350>
- Nydegger, F., nger A, M., & Frey, H. (2012). *Research activities using the ART-MSR method of automatic recording and interpretation of rumination and feeding behavior*. Plant Cell Tissue Organ Cult, 46(3):, 251–6.
- Penning, P. (1983). *A technique to record automatically some aspects of grazing and ruminating behaviour in sheep*. Grass Forage Sci., Vol 38, 89–96.
- Pereira, G., Heins , B., & Endres, M. (2017). *Technical note: Validation of an ear-tag accelerometer sensor to determine rumination, eating, and activity behaviors of grazing dairy cattle*. J Dairy Sci, 101(3):, 2492–5. <https://doi.org/10.3168/jds.2016-12534>
- Rayas-Amor, A., Morales-Almara 'z , E., Licon-Vela 'zquez, G., Vieyra-Alberto, R., & Lama, M. (2017). *Triaxial accelerometers for recording grazing and ruminating time in dairy cows: An alternative to visual observations*. J Veter Behav Clin Appl Res, 20, 102–8. <https://doi.org/10.1016/j.jveb.2017.04.003>
- Reiter, S., Sattlecker, G., Lidauer, L., Kicking, F., Ohlschuster, M., Auer, W., Iwersen, M. (2018). *Evaluation of an ear-tag-based accelerometer for monitoring rumination in dairy cows*. J. Dairy Sci., 101 (4),, 3398–3411. Retrieved from <https://doi.org/10.3168/jds.2017-12686>