



Identifying and classifying cow types based on spinal end deviation using machine learning

Mohsen Daneshmand Vaziri¹ | Abdollah Imanmehr² |

Mohsen Heidarisoltanabadi³

1. Researcher, Agricultural Engineering Research Department, Isfahan Agricultural and Natural Resources Research and Education Center, AREEO, Isfahan, Iran. E-mail: m.d.vaziri@gmail.com
2. Corresponding Author, Assistant professor, Agricultural Engineering Research Department, Isfahan Agricultural and Natural Resources Research and Education Center, AREEO, Isfahan, Iran. E-mail: imanmehr2000@gmail.com
3. Associated professor, Agricultural Engineering Research Department, Isfahan Agricultural and Natural Resources Research and Education Center, AREEO, Isfahan, Iran. E-mail: mheisol@gmail.com

Article Info

Article type: Research Article

Article history:

Received: July. 19, 2025

Revised: Aug. 30, 2025

Accepted: Sep. 16, 2025

Published online: Summer 2025

Keywords:

**Body condition scoring,
Cow rump curvature,
Machine learning algorithms,
Convolutional neural network,
Deep learning.**

ABSTRACT

In dairy farms, machine learning operations can be used to identify and classify cow types based on body condition scoring (BCS) using features extracted from images. In particular, machine learning algorithms can analyze the curvature of the spine, often by identifying key points and fitting a line or curve, to distinguish between different breeds of cattle and assess their condition. In this study, machine learning models that have been frequently used in computer science in recent years, including SVM, KNN, and CNN, were used in conjunction with a pre-trained deep learning network Resnet50 to enhance the success of the architectures. In each of the algorithms, image features were extracted, registered, and merged to identify the type of cows, and finally, the pre-trained CNN algorithm based on deep learning was able to correctly identify the type of cow with the highest accuracy (93 percent). Therefore, by combining this processing system with the imaging mechanism, it is possible to identify and classify cows based on various states and physical characteristics in cattle environments in a shorter, simpler, and more user-friendly time. This approach eliminates the need for manual extraction of livestock features, reduces the use of human resources, and achieves improved recognition accuracy.

Cite this article: Daneshmand Vaziri, M., Imanmehr, A., Heidarisoltanabadi, M., (2025) Identifying and classifying cow types based on spinal end deviation using machine learning, *Iranian Journal of Biosystem Engineering*, 56 (2), 51-67. <https://doi.org/10.22059/ijbse.2025.398902.665603>

© The Author(s).

Publisher: The University of Tehran Press.

DOI: <https://doi.org/10.22059/ijbse.2025.398902.665603>



EXTENDED ABSTRACT

Introduction

Dairy cow body condition scoring (BCS) is a vital management practice used to assess nutritional status, health, and productivity potential. Traditionally, BCS is performed manually by experienced evaluators who rely on visual and tactile cues. However, manual scoring is subjective, time-consuming, and prone to variability and human error, making it impractical for large-scale operations. Advances in computer vision and machine learning have enabled automated BCS systems, offering consistent and objective evaluations. A critical visual marker for BCS estimation is the curvature or deviation of the rump area (the terminal part of the spine). This morphological feature is closely related to body fat reserves and musculoskeletal health. Prior research has used 2D and 3D imaging with regression analysis to automate BCS. Yet many approaches require expensive 3D equipment or involve complex manual feature engineering. Recent developments in convolutional neural networks (CNNs), transfer learning, and pre-trained architectures such as ResNet50 have shown promise in automating feature extraction and classification tasks with high accuracy. The present study aims to design and evaluate a practical, image-based, automated system for intelligent detection and classification of cow types based on rump deviation using machine learning algorithms. The ultimate goal is to provide dairy farms with a low-cost, user-friendly, and real-time tool for BCS-related phenotyping to improve herd management efficiency.

Method

The study employed three machine learning algorithms—Support Vector Machine (SVM), K-Nearest Neighbors (KNN), and a Convolutional Neural Network (CNN) leveraging the ResNet50 architecture—for classifying cows into three types based on rump curvature: upward deviation (A type), downward deviation (B type), and horizontal (C type). A dataset of 150 images was collected from various farms, with 50 images per type, captured using standard digital cameras and smartphones. Images were preprocessed by cropping to isolate the rump area and were labeled and sorted into folders by type. The dataset was split into training, validation, and test sets in an 8:1:1 ratio. Feature extraction for SVM and KNN was performed using ResNet50 as a fixed feature extractor. CNN training used ResNet50 with fine-tuned layers for classification. Experiments were implemented in MATLAB R2021b. Evaluation metrics included accuracy, precision, recall (sensitivity), F1 score, confusion matrices, intersection over union (IoU), and mean average precision (mAP). For each algorithm, predictions on the test set were compared to ground-truth labels to compute performance metrics.

Results

The KNN classifier achieved an overall accuracy of 82%, with an F1 score averaging 81% across classes. Its confusion matrix revealed relatively high false positives, especially between A and C types, resulting in lower overlap scores (mean IoU ~67%). The SVM model showed improved performance, achieving 86% accuracy and an average F1 score of 85%, with better precision-recall balance and higher IoU (~75%). The CNN model using fine-tuned ResNet50 outperformed the others, achieving 91% accuracy, 93% precision, 90% recall, and an F1 score of 90%, with the highest mean IoU (~82%). Confusion matrices demonstrated that CNN produced the lowest misclassification rates among the three algorithms. CNN's high overlap values indicated strong alignment between predicted and actual classes, and its superior F1 score reflected balanced precision and recall. These results underscore the model's ability to extract subtle image features relevant to rump curvature and BCS-related phenotypes. Compared to prior studies reporting accuracies in the 82–97% range (using depth cameras, attention mechanisms, or multimodal data), this approach demonstrated comparable or better performance with simple 2D imaging and transfer learning. The system reduces manual feature engineering, enables real-time classification, and supports scalable deployment in dairy farms.

Conclusion

This study demonstrates the feasibility and effectiveness of using machine learning—particularly CNN with ResNet50—for automated classification of cow types based on rump curvature, serving as a proxy for body condition scoring. Among the tested methods, CNN–ResNet50 achieved the highest accuracy (91%) and F1 score (90%), outperforming KNN and SVM classifiers. The proposed system offers a practical, low-cost solution that eliminates the need for manual scoring, reduces labor, minimizes subjective error, and facilitates real-time herd management. Such tools can help dairy farmers make timely decisions on feeding and health interventions, ultimately improving productivity and animal welfare. Future work could expand the dataset, incorporate multimodal imaging, and deploy the model in field conditions to validate robustness and generalizability. Overall, the study confirms that deep learning with transfer learning on 2D RGB images can reliably support precision livestock farming by automating BCS estimation from visually salient anatomical

markers like rump curvature.

Author Contributions

Conceptualization, M.D.V. and A.I.; methodology, M.D.V., A.I. and M.H; software, M.D.V. and A.I; validation, M.D.V., A.I. and M.H; investigation, M.D.V and A.I.; resources, M.H; data curation, A.I; writing—original draft preparation, M.D.V. and A.I; writing—review and editing, A.I.; visualization, M.D.V.; supervision, A.I.; project administration, A.I.; funding acquisition, A.I., All authors have read and agreed to the published version of the manuscript.

Data Availability Statement

Data available on request from the authors.

Acknowledgements

The authors gratefully acknowledge the technical support from Isfahan Agricultural and Natural Resources Research and Education Center.

Ethical considerations

The authors avoided data fabrication, falsification, plagiarism, and misconduct.

Conflict of interest.

The author declares no conflict of interest.

تشخیص و دسته‌بندی تیپ گاو بر اساس انحراف انتهای ستون فقرات با استفاده از یادگیری ماشین

محسن دانشمند وزیری^۱ | عبدالله ایمان‌مهر^۲ | محسن حیدری سلطان‌آبادی^۳^۱. بخش تحقیقات فنی و مهندسی کشاورزی، مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی استان اصفهان، سازمان تحقیقات، آموزش و ترویج کشاورزی، اصفهان، ایران. رایانامه: m.d.vaziri@gmail.com^۲. نویسنده مسئول، بخش تحقیقات فنی و مهندسی کشاورزی، مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی استان اصفهان، سازمان تحقیقات، آموزش و ترویج کشاورزی، اصفهان، ایران. رایانامه: imanmehr2000@gmail.com^۳. بخش تحقیقات فنی و مهندسی کشاورزی، مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی استان اصفهان، سازمان تحقیقات، آموزش و ترویج کشاورزی، اصفهان، ایران. رایانامه: mheisol@gmail.com

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی	در مزارع پرورش گاو شیری، عملیات یادگیری ماشینی می‌تواند بر اساس امتیازدهی وضعیت بدنی (BCS) بهره‌گیری از ویژگی‌های استخراج‌شده از تصاویر برای شناسایی و طبقه‌بندی انواع گاوها مورد استفاده قرار گیرد. به‌طور خاص، الگوریتم‌های یادگیری ماشین می‌توانند انحنای ستون فقرات را اغلب با شناسایی نقاط کلیدی و برازش یک خط یا منحنی، تجزیه و تحلیل کنند تا بین نژادهای مختلف گاو تمایز قائل شوند و وضعیت آن را ارزیابی کنند. در این مطالعه، جهت تشخیص و طبقه‌بندی انواع تیپ گاو بر اساس وضعیت انحنای انتهای ستون فقرات (کفل) از مدل‌های یادگیری ماشین که در سال‌های اخیر به‌طور مکرر در علوم کامپیوتر مورد استفاده قرار گرفته‌اند، شامل KNN، SVM و CNN همراه با شبکه از پیش آموزش‌دیده مبتنی بر یادگیری عمیق Resnet50 به‌منظور افزایش موفقیت معماری‌ها استفاده شد. در هر یک از الگوریتم‌ها استخراج و ثبت و ادغام ویژگی‌های تصاویر برای تشخیص نوع تیپ گاوها انجام گرفت و در نهایت الگوریتم CNN از پیش آموزش‌دیده مبتنی بر یادگیری عمیق با بالاترین میزان دقت (۹۳ درصد) توانست نوع تیپ گاو را درست تشخیص دهد. بنابراین می‌توان با تلفیق این سیستم پردازشی با مکانیزم تصویربرداری، امکان تشخیص و طبقه‌بندی گاوها را بر اساس انواع حالات و مشخصات بدنی در محیط‌های گاو‌داری در مدت زمان کوتاه‌تر، ساده‌تر و کاربرپسند فراهم ساخت. این رویکرد نیاز به استخراج دستی ویژگی‌های دام را حذف می‌کند، بکارگیری نیروی انسانی را کاهش می‌دهد و به‌دقت تشخیص بهبودیافته‌ای دست می‌یابد.
واژه‌های کلیدی: امتیازدهی وضعیت بدنی، انحنای کفل گاو، الگوریتم‌های یادگیری ماشین، شبکه عصبی کانولوشنی، یادگیری عمیق.	

استناد: دانشمند وزیری؛ محسن، ایمان‌مهر؛ عبدالله، حیدری سلطان‌آبادی؛ محسن، (۱۴۰۴) تشخیص و دسته‌بندی تیپ گاو بر اساس انحراف انتهای ستون فقرات با استفاده

از یادگیری ماشین، مجله مهندسی بیوسیستم ایران/ایران، ۵۶ (۲)، ۶۷-۵۱. <https://doi.org/10.22059/ijbse.2025.398902.665603>

© نویسندگان.

ناشر: مؤسسه انتشارات دانشگاه تهران.

DOI: <https://doi.org/10.22059/ijbse.2025.398902.665603>

مقدمه

امتیازدهی وضعیت بدنی^۱ (BCS) یک روش مدیریتی مهم است که به‌عنوان ابزاری برای کمک به بهینه‌سازی تولید، ارزیابی سلامت و ارزیابی وضعیت تغذیه‌ای دام استفاده می‌شود. این روش به ارزیابی گله در مورد میزان ذخایر بدنی، به‌ویژه چربی و ماهیچه، که یک حیوان دارد، کمک می‌کند. اگر امتیازدهی وضعیت بدنی در فواصل برنامه‌ریزی‌شده در طول چرخه تولید انجام شود، در صورت نیاز می‌توان تغذیه و مدیریت را تغییر داد (Neary & Ann et al., 2002). برای گاوهای گله، وضعیت بدن آنها به‌عنوان یک شاخص عملی برای پیش‌بینی بهره‌وری گله، آزمایش و ارزیابی سطح مدیریت تغذیه و منعکس‌کننده بصری مدیریت تغذیه و وضعیت سلامت گاوها عمل می‌کند (Li et al., 2013; Paul et al., 2020). معمولاً، گروه‌های امتیازدهی دستی به پرورش‌دهندگان باتجربه نیاز دارند تا ارزیابی‌ها را با استفاده از بینایی و لمس انجام دهند، که منجر به فرآیندی زمان‌بر، پرزحمت و مستعد تأثیرات ذهنی می‌شود، بنابراین برآورده کردن نیازهای کاربردی در مزارع پرورش گاو در مقیاس بزرگ را چالش‌برانگیز می‌کند (Qiao et al., 2021; Wu et al., 2021). با این حال، با پیاده‌سازی بینایی ماشین در دامداری، BCS به‌تدریج به سمت اتوماسیون کامل در حال توسعه است (Roi et al., 2016). محققان امروزه از دوربین‌های دوبعدی یا سه‌بعدی به‌عنوان ابزارهای تصویربرداری برای به دست آوردن ویژگی‌های حیاتی بدن گاو و سپس استنباط BCS از طریق رگرسیون، طبقه‌بندی و پردازش تصویر استفاده می‌کنند (Song et al., 2019; Zhao et al., 2021). به‌عنوان مثال، در مطالعه‌ای از دوربین‌های سه‌بعدی برای به دست آوردن ابرهای نقطه‌ای متراکم از سطوح گاو استفاده شد و انحنای سطح بدن گاو با محاسبه انحنای گاوسی و انحنای میانگین اندازه‌گیری گردید تا مدلی برای محاسبه نمره وضعیت بدنی گاو بدست آید (Hansen et al., 2018).

Zin et al., (2020) از یک دوربین سه‌بعدی برای انجام تجزیه و تحلیل رگرسیون و تخمین نمره وضعیت بدنی با گرفتن ابرهای نقطه‌ای متراکم از سطوح گاو و تجزیه و تحلیل انحنای سطح استفاده کردند و به نتایج امیدوارکننده‌ای در بهبود دقت امتیازدهی دست یافتند. به‌طور مشابه، Imamura et al., (2017) یک سیستم ارزیابی خودکار BCS را با استفاده از دوربین‌های سه‌بعدی توسعه دادند و اثربخشی آن را در کاهش ذهنیت روش‌های امتیازدهی دستی تأیید کردند. اگرچه این رویکرد به‌طور قابل توجهی ذهنیت را کاهش داده و دقت امتیازدهی را افزایش می‌دهد، اما فرآیند استخراج ویژگی آن معمولاً بسیار پیچیده و از نظر محاسباتی پرهزینه است که کاربرد عملی آن را محدود می‌کند. اخیراً، روش‌های یادگیری عمیق مزایای قابل توجهی را در تشخیص تصویر و طبقه‌بندی تصویر نشان داده‌اند، به‌طور خودکار ویژگی‌های کلیدی را استخراج می‌کنند و پارامترهای شبکه را برای بهبود عملکرد از طریق یادگیری از مقادیر زیادی داده تنظیم می‌کنند (Redmon et al., 2016; Ren et al., 2017).

محققان یادگیری عمیق را برای امتیازدهی وضعیت بدن گاو با حاشیه‌نویسی مجموعه داده‌های گسترده از وضعیت بدن گاو و به‌کارگیری مدل‌هایی مانند شبکه‌های عصبی کانولوشنی^۲ (CNN) (Alvarez et al., 2019; Shigeta et al., 2018) و شبکه VGGNet (Liu & Qin, 2021) برای شناسایی تصاویر گاو، شناسایی مناطق مؤثر (Qiao et al., 2023) و پیش‌بینی وضعیت بدن گاو به‌کار برده‌اند. در تحقیقی یک مدل شبکه عصبی DET-CLS مبتنی بر YOLOv2 و ResNet50 ارائه شد که با تشخیص ناحیه مشخصه اطراف دم گاو و سپس طبقه‌بندی آن با استفاده از طبقه‌بندی‌کننده، به‌دقت ۹۴/۵٪ در محدوده اختلاف ۰/۵ واحدی دست یافتند (Li et al., 2019). Huang et al., (2023) یک مدل YOLO-MCE سبک وزن مبتنی بر YOLOv5s طراحی کردند که شامل توجه مختصات و MobileNetV3 برای افزایش تشخیص دم گاو و در عین حال کاهش پیچیدگی مدل و تضمین عملکرد در زمان واقعی است. این مطالعات با استفاده از یادگیری عمیق به نتایج خوبی دست یافته‌اند که امکان‌سنجی یادگیری عمیق در امتیازدهی وضعیت بدنی گاوهای شیری را تأیید می‌کند. در سال‌های اخیر، توسعه سامانه‌های خودکار برای ارزیابی امتیاز وضعیت بدنی (BCS) گاوهای شیری با استفاده از روش‌های یادگیری عمیق، به‌ویژه شبکه‌های عصبی کانولوشنی (CNN)، مورد توجه گسترده‌ای قرار گرفته است. این سامانه‌ها در برخی موارد بر استخراج ویژگی‌های سه‌بعدی از ناحیه پشت گاو متمرکز بوده‌اند و در موارد دیگر، استخراج خودکار ویژگی‌ها و طبقه‌بندی هم‌زمان توسط معماری‌های عمیق انجام شده است.

بررسی خودکار BCS برای مزارع بزرگ لبنی تجاری حیاتی می‌شود زیرا به کشاورزان کمک می‌کند تا در مقایسه با روش‌های دستی و امتیازدهندگان، گاوهای خود را بیشتر و به‌طور مداوم امتیازدهی کنند (Bewley et al., 2008). رویکردهای مختلف مبتنی بر رگرسیون و

1. Body Condition Score

2. Convolutional Neural Network

شبکه عصبی کانولوشنی (CNN) برای امتیازدهی خودکار وضعیت بدنی گاو در حال حاضر وجود دارد و برخی از سیستم‌های تجاری نیز در دسترس هستند. حوزه تحقیقاتی امتیازدهی خودکار وضعیت بدن گاو در سال‌های اخیر رشد سریعی داشته است و هر ساله شاهد افزایش آثار منتشر شده هستیم. دو رویکرد اصلی وجود دارد، یعنی مدل‌های مبتنی بر رگرسیون و مدل‌های مبتنی بر شبکه عصبی (Paul et al., 2020; Alvarez et al., 2018). رویکرد جدیدتر برای BCS خودکار گاو، استفاده از شبکه‌های عصبی است. برخی از رویکردها از تکنیک‌های مختلفی برای انجام استخراج ویژگی استفاده می‌کنند و از شبکه‌های عصبی به عنوان طبقه‌بندی‌کننده به جای رگرسیون استفاده می‌کنند. با این حال، برخی از رویکردها از CNNها برای انجام هر دو کار استخراج ویژگی و همچنین طبقه‌بندی استفاده می‌کنند. Alvarez et al., (2018) یکی از سیستم‌های اولیه BCS خودکار گاو را با استفاده از یک مدل مبتنی بر CNN توسعه دادند. در این مدل از یک دوربین عمقی نصب‌شده در بالا برای گرفتن عکس از پشت بدن گاو بدون استخراج ویژگی‌های آناتومیک خاص استفاده شد. پس از گرفتن تصویر عمقی، برای حذف نویز عمقی ناخواسته و با جداسازی فقط قسمت پشت گاو پردازش گردید. سپس از معماری SqueezeNet برای CNN به همراه تقویت داده‌ها استفاده شد که منجر به دقت ۹۴ درصد در بازه ۰/۵ BCS، ۷۸ درصد در بازه ۰/۲۵ BCS و دقت انطباق کامل ۴۰ درصد شد که از رویکردهای مبتنی بر رگرسیون خودکار پیشی گرفت (Iandola et al., 2016). این مطالعه پتانسیل سیستم‌های BCS بلادرنگ مبتنی بر CNN را برای استفاده تجاری برجسته کرد. محققان بعداً با معرفی یادگیری انتقالی با مدل VGG16 و مدل‌سازی گروهی، رویکرد خود را بهبود بخشیدند (Simonyan & Zisserman, 2015). در مطالعه‌ای دیگر از تصاویر سونوگرافی برای تعیین ضخامت چربی زیرپوستی به عنوان مرجع و از تصاویر عمقی برای آموزش CNN استفاده شد. محققان با استفاده از کانال‌های داده‌ای عمقی، طیف خاکستری و فاز، و به‌کارگیری معماری DenseNet، مدلی ارائه دادند که توانست ارتباط میان شاخص‌های آناتومیک و امتیاز BCS را به خوبی شناسایی کند (Yukun et al., 2019). Zhao et al., (2023) با استفاده از ابرنقاط سه‌بعدی و استخراج ویژگی‌هایی بر پایه پوسته محدب (Convex Hull) نقشه‌های ساختاری دقیقی از ناحیه پشت گاو تولید کرده و آن‌ها را به عنوان ورودی به معماری EfficientNet ارائه دادند. مدل پیشنهادی آن‌ها به دقت ۹۷/۶ درصد در بازه ۰/۵، دقت ۹۱/۲ درصد در بازه ۰/۲۵ و دقت انطباق کامل ۴۵ درصد دست یافت. با این حال، استفاده از داده‌های مربوط به تنها ۷۷ گاو علیرغم حجم تصویربرداری بالا (۵۱۱۹ تصویر) می‌تواند تعمیم‌پذیری مدل را محدود کند. در مطالعه‌ای مشابه با استفاده از استخراج ویژگی‌های هدایت‌شده با مکانیزم توجه (Attention-Guided Feature Extraction) از ابرنقاط سه‌بعدی و ترکیب آن با شبکه عصبی چندلایه، مدلی با دقت ۹۶ درصد در بازه ۰/۵، دقت ۸۰ درصد در بازه ۰/۲۵ و دقت انطباق دقیق ۴۹ درصد ارائه گردید که تاکنون از دقیق‌ترین روش‌های خودکار ارزیابی BCS به شمار می‌آید (Shi et al., 2023).

معرفی الگوریتم‌های یادگیری ماشین

الگوریتم ماشین بردار پشتیبان^۱ (SVM)

امروزه اغلب پژوهش‌ها در حوزه مدیریت تصویر از طریق طبقه‌بندی تصاویر انجام می‌پذیرد. فرآیند طبقه‌بندی تصاویر به کمک رایانه در حال حاضر یکی از مراحل پردازش در شناسایی تصویر است. روش طبقه‌بندی مؤثر و کارا کلید مدیریت بهینه تصاویر است. الگوریتم ماشین بردار پشتیبان یکی از الگوریتم‌های طبقه‌بندی است که به طور گسترده‌ای در طبقه‌بندی رایانه‌ای علوم زیستی به دلیل دقت بالا، قدرت طبقه‌بندی مناسب، انعطاف‌پذیری در مدل‌سازی منابع متنوع داده‌ها و قابلیت کار با داده‌های چند بعدی کاربرد دارد. الگوریتم ماشین بردار پشتیبان یکی از روش‌هایی است که بهترین نتیجه در طبقه‌بندی تصاویر ارائه می‌دهد. از مهم‌ترین ویژگی‌های تصویر که برای مقایسه از تصاویر استخراج می‌شوند، می‌توان به آنتروپی، میانگین، انحراف معیار، کنتراست، انرژی، همبستگی و گریز از مرکز اشاره کرد. با استخراج این ویژگی‌ها از تصاویر اولیه، الگوریتم ماشین بردار پشتیبان آموزش داده می‌شود و با ورود تصاویر جدید این الگوریتم قادر به طبقه‌بندی تصاویر خواهد بود.

الگوریتم K نزدیک‌ترین همسایه^۲ (KNN)


الگوریتم KNN یک الگوریتم یادگیری ماشین با ناظر ساده و با پیاده‌سازی آسان است. این الگوریتم می‌تواند برای حل مشکلات طبقه‌بندی^۴

1. Support Vector Machine (SVM)
2. K-Nearest Neighbors (KNN)
3. Supervised Machine Learning
4. Classification

و رگرسیون استفاده شود. الگوریتم یادگیری ماشین با ناظر، الگوریتمی است که بر داده‌های ورودی دارای برجسب متکی است تا از روی این داده‌ها آموزش ببیند و بتواند داده‌های جدید را برجسب‌گذاری کند. KNN برای طبقه‌بندی، نزدیک‌ترین همسایه‌ها را پیدا کرده و با اکثریت آرا نزدیک‌ترین همسایگان کلاس مورد نظر را پیش‌بینی می‌کند و برای مسائل رگرسیون، نزدیک‌ترین همسایه را پیدا کرده و با محاسبه‌ی میانگین مقدار نزدیک‌ترین همسایه‌ها، مقدار رگرسیون کلاس مدنظر را پیش‌بینی می‌کند. انتخاب مقدار مناسب K تنظیم پارامتر نامیده می‌شود و برای نتایج بهتر ضروری است. برای انتخاب مقدار K ریشه‌ی مربع یا رادیکال تعداد کل نقاط داده‌ی موجود در مجموعه‌ی داده را حساب می‌کنیم و برای یافتن نزدیک‌ترین همسایه از یکی از تکنیک‌های فاصله‌ی اقلیدسی^۲، فاصله‌ی منهتن^۳ و فاصله‌ی مینکوفسکی^۴ استفاده می‌گردد. از بین این تکنیک‌ها استفاده از فاصله اقلیدسی رایج‌تر است. فاصله‌ی اقلیدسی برای محاسبه‌ی فاصله‌ی میان دو نقطه در یک صفحه یا یک فضای سه‌بعدی استفاده می‌شود.

الگوریتم شبکه عصبی کانولوشنی Resnet50

یکی از تکنیک‌های تشخیص و طبقه‌بندی تصاویر استفاده از تقسیم‌بندی تصویر با استفاده از الگوریتم شبکه عصبی کانولوشنی (CNN) است. این الگوریتم یکی از قوی‌ترین ابزارها در تکنیک‌های تقسیم‌بندی تصویر است. لایه‌های شبکه عصبی یک فیلتر را از روی کل تصویر عبور می‌دهند. این فیلتر ویژگی‌هایی مانند لبه‌ها یا منحنی‌های تصویر را تشخیص می‌دهد. فیلترهای متعدد می‌توانند ویژگی‌های مختلف را شناسایی کنند. عملیات ورودی و فیلتر برای ایجاد یک نقشه با ویژگی خاص استفاده می‌گردد. این نقشه قدرت ویژگی‌های شناسایی شده را نشان می‌دهد. با قرار دادن چندین لایه کانولوشنی، شبکه می‌تواند ویژگی‌های سطح بالاتر و پیچیده‌تر را شناسایی کند (شکل ۱).



شکل ۱. معماری لایه‌های شبکه عصبی کانولوشنی

مدل ResNet50 یک معماری مدل عصبی کانولوشنی است که برای بینایی کامپیوتری و انجام وظایف مرتبط با تجزیه و تحلیل تصاویر طراحی شده است. این مدل به‌عنوان یکی از معروف‌ترین مدل‌های شبکه عصبی برای تشخیص تصاویر شناخته می‌شود و به دلیل کارایی بالا و قابلیت یادگیری انتقالی مورد استفاده قرار می‌گیرد. یکی از نکات برجسته در این معماری، استفاده از بلوک‌های ارتباطی است. این بلوک‌ها به شبکه این امکان را می‌دهند که با افزایش عمق، عملکرد بهبود یابد، به حدی که به راحتی بتواند با دقت بیشتری وظایف پیچیده‌تری را انجام دهد. این مدل از یک مجموعه داده پردازش تصویر شده که از پیش‌آموزش دیده، استفاده می‌کند که شامل دسته‌های متعددی از تصاویر است. استفاده از یک مدل از پیش آموزش دیده باعث افزایش سرعت و کارایی در یادگیری می‌شود. این به این معناست که مدل، اطلاعات کلی و جزئیات مفیدی را از تصاویر پیشین یاد گرفته و این اطلاعات را برای وظایف جدیدی به کار می‌برد.


مواد و روش‌ها

داده‌های تحقیق

عکس‌های تیپ‌های مختلف گاو بر اساس میزان انحراف ستون فقرات در انتهای بدن مورد استفاده در این مطالعه از دامداری‌های مختلف تهیه گردید. تصاویر گاوها از سه تیپ مختلف با ویژگی‌های انحراف انتهای ستون فقرات رو به پایین، انحراف انتهای ستون فقرات رو به

1. Regression
2. Euclidean distance
3. Manhattan distance
4. Minkowski distance

بالا و فاقد انحراف انتهای ستون فقرات (ستون فقرات افقی) تهیه و جمع‌آوری شد. برای عکس‌برداری از یک دوربین عکاسی و نیز موبایل (Xiaomi Redmi Note 7) مجهز به دوربین ۴۸ مگاپیکسلی استفاده شد. تعداد ۱۵۰ تصویر از هر تیپ گاو تهیه گردید که در مجموع تعداد ۴۵۰ تصویر مجموعه داده‌های این تحقیق را تشکیل دادند (شکل ۲).



شکل ۲. نمونه تصاویر از مجموعه داده‌ها: الف- نمای تیپ انحراف انتهای ستون فقرات رو به بالا (A type)، ب- نمای تیپ انتهای ستون رو به پایین (B type)، ج- نمای تیپ انحراف انتهای ستون فقرات افقی (C type)

آماده‌سازی تصاویر

به‌منظور آماده‌سازی داده‌های تصویری ابتدا برای افزایش دقت و سرعت آموزش الگوریتم‌ها، تصاویر گاوها برش خورده و فقط قسمت انتهایی بدن گاوها در تصاویر نگهداری شده‌اند (شکل ۳). برای هر یک از سه تیپ گاو پوشه‌ای مجزا با برچسب نام تیپ آماده شد و سپس تصاویر از شماره ۱ تا ۱۵۰ شماره‌گذاری شده و در پوشه مربوطه قرار داده شد که در مجموع تعداد ۳ پوشه آماده گردید و در یک پوشه مادر ذخیره شد. درنهایت تصاویر برچسب‌گذاری شده را به‌صورت تصادفی به مجموعه آموزشی، مجموعه اعتبارسنجی و مجموعه آزمایشی به نسبت ۸:۱:۱ تقسیم کردیم. جزئیات مجموعه داده در جدول ۱ نشان داده شده است.



شکل ۳. نمونه تصاویر برش خورده از سه نوع تیپ گاو مورد مطالعه

جدول ۱. تقسیم‌بندی داده‌های تصویری به نسبت ۸:۱:۱ جهت آموزش، اعتبارسنجی و آزمایش داده‌ها در شبکه عصبی

نام پوشه حاوی ۵۰ تصویر از هر تیپ گاو	تعداد تصاویر آموزشی	تعداد تصاویر اعتبارسنجی	تعداد تصاویر آزمایشی
تیپ انحراف انتهای ستون فقرات رو به بالا (A type)	۴۰	۵	۵
تیپ انحراف انتهای ستون فقرات رو به پایین (B type)	۴۰	۵	۵
تیپ انتهای ستون فقرات افقی (C type)	۴۰	۵	۵

تعیین دقت الگوریتم‌های یادگیری ماشین در تشخیص تیپ گاو

برای ارزیابی مطالعاتی که مبتنی بر یادگیری ماشینی هستند، معیارها یا آمارهای ارزیابی مختلفی می‌توانند مدل‌های یادگیری ماشین را ارزیابی کنند، اما اینکه کدام معیارها یا آمارهای ارزیابی استفاده شود به بیان مسئله و کاربرد خاص مدل یادگیری بستگی دارد. هر کدام از معیارها یا آمارهای ارزیابی ویژگی‌های خود را دارند و بر اساس عوامل مختلفی مانند مجموعه داده یا پلتفرم هدف، عملکرد متفاوتی دارند. معیارهایی که برای ارزیابی در یک مسئله طبقه‌بندی تصویر استفاده می‌شوند معمولاً شامل دقت، یادآوری، ماتریس اغتشاش، منحنی PR با تعیین mAP (میانگین دقت متوسط) است. به منظور ارزیابی اثربخشی الگوریتم‌های یادگیری ماشین در تشخیص تیپ گاو، ابتدا چهار معیار ارزیابی عملکرد استاندارد با استفاده از مقادیر ماتریس اغتشاشی محاسبه شدند. ماتریس‌های اغتشاشی برای نشان دادن داده‌های پیش‌بینی حیاتی از جمله یادآوری، صحت و دقت استفاده می‌شوند. آنها مقایسه مستقیم متغیرهایی مانند نرخ مثبت واقعی (TP)، نرخ مثبت کاذب (FP)، نرخ منفی کاذب (FN) و نرخ منفی واقعی (TN) را ارائه می‌دهند. یکی از مهم‌ترین گام‌ها پس از طراحی یک سیستم مبتنی بر روش‌های یادگیری ماشین، ارزیابی خروجی‌های آن روی مجموعه داده‌های دیده نشده (hold out) یا آزمایشی (test set) است. برای ارزیابی عملکرد الگوریتم‌های یادگیری ماشین که در شناسایی تیپ گاو بکار رفته از معیارهای مختلفی به شرح زیر استفاده خواهد شد (Sokolova & Lapalme, 2009):

دقت: اثربخشی یک طبقه‌بندی‌کننده، که عبارت است از درصد نمونه‌هایی که به درستی طبقه‌بندی شده‌اند و توسط رابطه ۱ محاسبه می‌شود:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad \text{رابطه ۱}$$

که: TP تعداد نمونه‌های دارای تیپ مورد نظر را دارند (مثلاً تیپ A) که درست تشخیص داده شده و FN تعداد نمونه‌های دارای تیپ مورد نظر را دارند (مثلاً تیپ A) که غلط تشخیص داده شده و TN تعداد نمونه‌های فاقد تیپ مورد نظر (مثلاً غیر تیپ A) که درست تشخیص داده شده و FP تعداد نمونه‌های فاقد تیپ مورد نظر (مثلاً غیر تیپ A) که غلط تشخیص داده شده است.

صحت: توانایی طبقه‌بندی‌کننده در عدم برچسب‌گذاری یک مثال منفی به عنوان مثبت است که توسط رابطه ۲ بدست می‌آید:

$$Precision = \frac{TP}{TP + FP} \quad \text{رابطه ۲}$$

یادآوری یا حساسیت: نشان‌دهنده توانایی طبقه‌بندی‌کننده در یافتن تمام نمونه‌های مثبت است و توسط رابطه ۳ محاسبه می‌شود:

$$Recall = \frac{TP}{TP + FN} \quad \text{رابطه ۳}$$

امتیاز (F1): بیانگر میانگین هارمونیک صحت و یادآوری است و یک معیار واحد برای ارزیابی کلی عملکرد سیستم ارائه می‌دهد. به بیان ریاضی، امتیاز F1 میانگین وزن‌دار از دقت و یادآوری است. بهترین مقدار برای F1، یک و بدترین مقدار صفر است و با کمک رابطه ۴ می‌توان آن را محاسبه کرد (Maimon & Rokach, 2010):

$$F1 = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad \text{رابطه ۴}$$

متوسط صحت: نشان‌دهنده میانگین تمام صحت‌های هر تیپ یا کلاس تشخیص داده شده توسط الگوریتم‌های یادگیری ماشین است و از طریق رابطه ۵ بدست می‌آید:

$$Average Precision(AP) = \sum_{k=0}^{k=n-1} [Recalls(k) - Recalls(k+1)] \times Precision(k) \quad \text{رابطه ۵}$$

انطباق روی هم: این معیار برای تعیین میزان درصد انطباق کادر رسم شده (جعبه پیش‌بینی) توسط الگوریتم‌های یادگیری ماشین با موضوع کلاس (جعبه زمینه) است. از آنجایی که تعیین درصد انطباق به صورت چسبی دارای خطا است لذا استفاده از این شاخص پیشنهاد

1. Accuracy
2. Precision
3. Recall
4. Sensitivity
5. Average Precision (AP)
6. Intersection Over Union (IOU)

می‌گردد و توسط رابطه ۶ محاسبه می‌شود:

$$\text{Intersection Over Union}(IOU) = \frac{TP}{FN+FP+TP} \quad \text{رابطه ۶}$$

میانگین متوسط صحت؛ این معیار برای ارزیابی دقت الگوریتم‌های یادگیری ماشین در تشخیص اشیا با پیش‌بینی‌های جعبه مرزی است. دقت را در سطوح مختلف یادآوری در نظر می‌گیرد و متوسط صحت در تیپ‌های گاو را محاسبه می‌کند. mAP بر مبنای مقایسه چارچوب پیش‌بینی و چارچوب هدف توسط رابطه ۷ محاسبه می‌شود. منطقی هست که دو چارچوب پیش‌بینی و هدف را باهم مقایسه کنیم تا ببینیم چقدر به هم نزدیک هستند.

$$mAP = \frac{1}{N} \sum_{i=1}^N AP \quad \text{رابطه ۷}$$

که: N تعداد کلاس‌ها برای تشخیص در الگوریتم‌های یادگیری ماشین و AP میانگین تمام صحت‌های هر کلاس تشخیص داده شده توسط الگوریتم‌های یادگیری ماشین است.

شرح آزمایش‌ها

این تحقیق به منظور معرفی کاربرد هوش مصنوعی در شناسایی تیپ گاوها انجام شده است و بکارگیری الگوریتم‌های هوش مصنوعی نقش مهمی در جلوگیری از اتلاف وقت و صرف هزینه‌های جاری دارند که موجب افزایش دقت و سرعت در تشخیص دام‌ها می‌گردد. در این تحقیق مجموع تصاویر بدست آمده و آماده شده از هر نوع تیپ گاو ۱۵۰ عدد است و از الگوریتم‌های یادگیری ماشین SVM، KNN و CNN با شبکه از پیش آموزش دیده Resnet50 به منظور تشخیص و طبقه‌بندی انواع تیپ گاو استفاده شد. ابتدا شبکه ResNet-50 با ۵۰ لایه عمیق شامل لایه‌های کانولوشنی، نرمال‌سازی دسته‌ای (Batch Normalization)، لایه‌های ReLU و بلوک‌های باقی‌مانده (Residual Blocks) بارگذاری شد. برای تطبیق با مسئله ۳ کلاس، لایه‌های پایانی اصلی شبکه شامل fully connected، softmax و Classification Layer حذف شدند و به جای آن، یک زنجیره از لایه‌های جدید اضافه شد که شامل:

یک fully connected layer با ۲۵۶ نورون و تابع فعال‌سازی ReLU

یک dropout layer با نرخ ۰/۵ برای جلوگیری از بیش‌برازش

یک fully connected layer نهایی با ۳ نورون (مطابق تعداد کلاس‌ها)

لایه‌های softmax و classification برای تولید احتمال طبقه‌بندی

به این ترتیب، شبکه ترکیبی از قدرت استخراج ویژگی عمیق ResNet-50 و لایه‌های سفارشی CNN برای تشخیص دقیق انواع تیپ گاو فراهم می‌کند. ترتیب لایه‌ها به گونه‌ای است که ابتدا ویژگی‌های سطح پایین و سطح بالا توسط ResNet استخراج می‌شود و سپس لایه‌های سفارشی به طبقه‌بندی نهایی سه کلاسه می‌پردازند. با کمک نرم‌افزار متلب R2021b آموزش و آزمایش الگوریتم‌های مورد نظر طی مراحل ذیل انجام گرفت: الف) فراخوانی تصاویر ب) استخراج ویژگی‌های تصاویر با استفاده از شبکه Resnet50 ج) طبقه‌بندی تصاویر با استفاده از الگوریتم‌های SVM، KNN و CNN (در این مرحله آموزش، آزمایش و اعتبارسنجی الگوریتم انجام می‌گیرد) ح) ترسیم ماتریس اغتشاش. در جدول ۲ آزمایش‌ها مربوط به این تحقیق و در شکل ۴ فلوچارت انجام هر آزمایش نشان داده شده است.

جدول ۲. آزمایش‌های تشخیص و طبقه‌بندی نوع تیپ گاو بر اساس وضعیت ستون فقرات


شماره آزمایش	شبکه معماری استفاده شده	الگوریتم طبقه‌بندی
۱	Resnet50	KNN
۲	Resnet50	SVM
۳	Resnet50	CNN

نتایج و بحث

آزمایش ۱ (الگوریتم KNN)

الگوریتم K نزدیک‌ترین همسایه (KNN) با استفاده از مدل Resnet50 توانست با دقت ۷۰ درصد و زمان اندک نوع تیپ گاو را شناسایی و

طبقه‌بندی نماید. در این کد مقدار K به صورت صریح برابر با ۵ تنظیم شده است زیرا یک مقدار پیش فرض رایج و متعادل است. مقدار ۵ یکی از مقادیر استاندارد و معمول برای شروع در الگوریتم KNN است. این مقدار تعادل خوبی بین نویز کم و سادگی مدل برقرار می‌کند. مقدار K بزرگ‌تر از ۱ باعث می‌شود که تصمیم‌گیری بر اساس اکثریت همسایگان باشد، نه صرفاً نزدیک‌ترین نمونه، که به کاهش تأثیر نمونه‌های نویزی کمک می‌کند. برای ارزیابی دقت طبقه‌بندی از شاخص‌های آماری مستخرج از ماتریس اغتشاش استفاده شده است (Duda et al., 2001). این ماتریس حاوی اطلاعات واقعی و اطلاعات پیش‌بینی شده است. برای استخراج شاخص‌های آماری ماتریس اغتشاش از مجموع ۱۵۰ تصویر برای هر تیپ گاو به صورت تصادفی ۳۰ تصویر انتخاب شدند (جدول ۳ و ۴).



شکل ۴. فلوچارت انجام آزمایش‌های تشخیص و طبقه‌بندی سه نوع تیپ گاو مورد مطالعه

جدول ۳. ماتریس اغتشاشی آزمون دقت طبقه‌بندی الگوریتم K نزدیک‌ترین همسایه (KNN)

پیش‌بینی \ واقعیت	تیپ A	تیپ B	تیپ C
تیپ A	۲۲	۱	۲
تیپ B	۰	۲۴	۲
تیپ C	۸	۵	۲۶

جدول ۴. تعیین مقادیر شاخص‌های ارزیابی الگوریتم K نزدیک‌ترین همسایه (KNN)

نوع تیپ گاو	True Positive (TP)	False Positive (FP)	False Negative (FN)	True Negative (TN)	صحت (%)	دقت (%)	یادآوری (%)	امتیاز F1 (%)	همپوشانی (%)
تیپ A	۲۲	۸	۳	۵۷	۸۸	۸۸	۷۳	۸۰	۶۷
تیپ B	۲۴	۶	۲	۵۸	۹۲	۸۰	۸۰	۸۶	۷۵
تیپ C	۲۶	۴	۱۳	۱۷	۶۷	۴۳	۸۷	۷۶	۶۰
میانگین کل	-	-	-	-	۸۲	۷۰	۸۰	۸۱	۶۷

آزمایش ۲ (الگوریتم SVM)

الگوریتم ماشین بردار پشتیبان (SVM) توانست نوع تیپ گاو را با دقت ۸۸ درصد تشخیص دهد. برای ارزیابی دقت طبقه‌بندی از شاخص‌های آماری مستخرج از ماتریس اغتشاش استفاده شده است. این ماتریس حاوی اطلاعات واقعی و اطلاعات پیش‌بینی شده است. برای استخراج شاخص‌های آماری از ماتریس اغتشاش از مجموع ۱۵۰ تصویر برای هر تیپ گاو به صورت تصادفی ۳۰ تصویر انتخاب شدند (جدول ۵ و ۶).

جدول ۵. ماتریس اغتشاش آزمون دقت طبقه‌بندی الگوریتم ماشین بردار پشتیبان (SVM)


پیش‌بینی واقعی	تیپ A	تیپ B	تیپ C
تیپ A	۲۵	۱	۳
تیپ B	۰	۲۶	۱
تیپ C	۵	۳	۲۶

جدول ۶. تعیین مقادیر شاخص‌های ارزیابی الگوریتم ماشین بردار پشتیبان (SVM)

نوع تیپ گاو	True Positive (TP)	False Positive (FP)	False Negative (FN)	True Negative (TN)	صحت (%)	دقت (%)	یادآوری (%)	امتیاز F1 (%)	همپوشانی (%)
تیپ A	۲۵	۵	۴	۵۶	۸۶	۸۴	۸۳	۸۴	۷۳
تیپ B	۲۶	۴	۱	۵۹	۹۶	۹۴	۸۷	۹۱	۸۴
تیپ C	۲۶	۴	۸	۵۲	۷۶	۸۷	۸۷	۸۱	۶۸
میانگین کل	-	-	-	-	۸۶	۸۸	۸۶	۸۵	۷۵

آزمایش ۳ (الگوریتم CNN)

نمودار روند آموزش و اعتبارسنجی (Accuracy / Loss) برای شبکه CNN-ResNet50 در شکل ۵ نشان می‌دهد مدل به خوبی همگرا شده و اختلاف معنی‌داری بین دقت آموزش و اعتبارسنجی وجود ندارد، که بیانگر پایداری شبکه و عدم بیش‌برازش است.



شکل ۵. نمودار آموزش و اعتبارسنجی شبکه CNN-ResNet50

الگوریتم CNN مدل Resnet50 توانست نوع تیپ گاو را با دقت ۹۳ درصد تشخیص دهد. این الگوریتم با استفاده از مدل Resnet50 توانست با دقت بالاتر نسبت به دو الگوریتم دیگر نوع تیپ گاو را شناسایی و طبقه‌بندی نماید. برای ارزیابی دقت طبقه‌بندی از شاخص‌های آماری مستخرج از ماتریس اغتشاش استفاده شده است. این ماتریس حاوی اطلاعات واقعی و اطلاعات پیش‌بینی شده است. برای استخراج شاخص‌های آماری از ماتریس اغتشاش از مجموع ۱۵۰ تصویر برای هر تیپ گاو به صورت تصادفی ۳۰ تصویر انتخاب شدند (جدول ۷ و ۸).

جدول ۷. ماتریس اغتشاش آزمون دقت طبقه‌بندی الگوریتم CNN

	تیپ C	تیپ B	تیپ A	پیش‌بینی
واقعی				
تیپ A	۲	۱	۲۶	
تیپ B	۰	۲۷	۰	
تیپ C	۲۸	۲	۴	

جدول ۸. تعیین مقادیر شاخص‌های ارزیابی الگوریتم CNN

نوع تیپ گاو	True Positive (TP)	False Positive (FP)	False Negative (FN)	True Negative (TN)	صحت (%)	دقت (%)	یادآوری (%)	امتیاز F1 (%)	همپوشانی (%)
تیپ A	۲۶	۴	۳	۵۷	۹۰	۹۲	۸۷	۸۸	۷۹
تیپ B	۲۷	۳	۰	۶۰	۱۰۰	۹۷	۹۰	۹۵	۹۰
تیپ C	۲۸	۲	۶	۵۴	۸۲	۹۱	۹۳	۸۷	۷۸
میانگین کل	-	-	-	-	۹۱	۹۳	۹۰	۹۰	۸۲

با توجه به جداول عملکرد الگوریتم‌های SVM، KNN، CNN مبتنی بر معماری Resnet50 برای طبقه‌بندی تیپ گاوها بر اساس وضعیت انحنای ناحیه انتهایی ستون فقرات؛ جهت ارزیابی و مقایسه هر یک از شاخص‌های صحت، دقت، یادآوری، امتیاز F1 و همپوشانی در الگوریتم‌های مذکور، نتایج در جدول ۹ قید گردید و نمونه‌ای از تصاویر تشخیص و طبقه‌بندی شده نوع تیپ گاو در شکل ۶ نشان داده شده است.

جدول ۹. مقایسه شاخص‌های عملکرد الگوریتم‌های یادگیری ماشین

نام الگوریتم	صحت (%)	دقت (%)	یادآوری (حساسیت) (%)	امتیاز F1 (%)	همپوشانی (%)
KNN-ResNet50	۸۲	۷۰	۸۰	۸۱	۶۷
SVM-ResNet50	۸۶	۸۸	۸۶	۸۵	۷۵
CNN-ResNet50	۹۱	۹۳	۹۰	۹۰	۸۲




شکل ۶. نمونه‌ای از تصاویر تشخیص داده شده نوع تیپ گاو توسط الگوریتم‌های SVM، KNN و CNN با مدل Resnet50

با توجه به جدول ۹، الگوریتم CNN با بهره‌گیری از ResNet50 با دستیابی به صحت ۹۱ درصد، دقت ۹۳ درصد و F1 برابر ۹۰ درصد بالاترین میزان موفقیت را در طبقه‌بندی بلادرنک به ثبت رساند، که نسبت به الگوریتم‌های KNN (F1=81%) و SVM (F1=85%) عملکرد برتری داشت. مقایسه نتایج با مطالعات پیشین نشان می‌دهد که استفاده از معماری‌های عمیق CNN در شناسایی ویژگی‌های ظریف دام،

مانند زاویه rump، نتایج دقیق‌تری نسبت به روش‌های سنتی فراهم می‌سازد. مشابه این نتایج، هو و همکاران (Hou et al., 2021) در تحقیقی با استفاده از CNN سبک‌وزن توانستند به دقت ۹۹/۷۶ درصد در شناسایی تصاویر rump دست یابند، اما تمرکز آن‌ها بر شناسایی فردی گاو بود و در محدوده تیپ‌شناسی قرار نمی‌گرفت؛ همچنین Alvarez et al., (2019) با به‌کارگیری تصاویر عمقی و ترکیب یادگیری انتقالی و مدل‌سازی مجموعه‌ای، دقت تخمین امتیاز وضعیت بدنی (BCS) را در حدود ۸۲-۹۷ درصد گزارش کردند که در محدوده‌ای همسو با دقت این مطالعه قرار دارد. همچنین در مطالعه‌ای جدید محققان به کمک بینایی ماشین و یادگیری عمیق توانستند ارزیابی ویژگی‌های خطی گاو را با دقت بالا پیاده‌سازی کنند و تأکید کردند که زاویه rump یکی از شاخص‌های حساس برای ارزیابی سلامت و تولیدمثل دام است (Devi et al., 2024). به‌طور کلی، یافته‌های پژوهش حاضر نه‌تنها عملکرد بالای CNN در طبقه‌بندی تیپ گاو را تأیید می‌کند، بلکه کارآمدی آن را در مقایسه با الگوریتم‌های کلاسیک در کاربردهای میدانی نیز به اثبات می‌رساند.

دقت بسیار بالا (۹۳ درصد)، همراه با همپوشانی مناسب (۸۲ درصد) نشان می‌دهد که این مدل توانسته ویژگی‌های پیچیده تصویری را به خوبی استخراج کند. همچنین، امتیاز F1 بالا نشان از توازن مناسب بین دقت و یادآوری دارد. این الگوریتم برای کاربردهای بلادرنگ و دقیق در محیط‌های دامداری هوشمند مناسب است. در تحقیقی مشابه، از شبکه‌ی CNN برای تشخیص BCS در گاوهای شیری استفاده شد در حالی که در این تحقیق تمرکز بر ناحیه‌ی خاص rump است. مدل پیشنهادی توانست با دقت حدود ۸۷ درصد وضعیت بدنی را در تصاویر پشتی گاو تشخیص دهد (Nguyen et al., 2018). در تحقیقی دیگر که با استخراج تصویر کل پشت گاو (مشابه انحنای ستون فقرات) و استفاده از مدل‌های CNN انجام شد دقتی حدود ۸۹ درصد گزارش شد (Wang et al., 2020). در تحقیق اخیر استفاده از الگوریتم CNN-ResNet50 دقت بالاتری دارد و از تکنیک‌های پیش‌آموزش‌دیده برای افزایش کارایی استفاده کرده است. در تحقیقی دیگر با اینکه تمرکز بر انحنای پشت برای شناسایی لنگش بوده و نه BCS. دقت شناسایی ۹۰ درصد گزارش شده است (Tian et al., 2020). با اینکه هدف تحقیق متفاوت است، اما از نظر استفاده از شبکه‌های عمیق و تفسیر فرم انحنای بدن مشابه کار اخیر است. در مطالعه‌ای دیگر ترکیبی از الگوریتم‌های کلاسیک و یادگیری عمیق برای ارزیابی وضعیت گاو استفاده شد. دقت کلی سیستم در حدود ۸۵ درصد بود (Amin et al., 2022). تحقیق اخیر با بهره‌گیری از ResNet50 و پردازش ویژگی‌های خاص انحنای ناحیه rump، عملکرد بهتری داشته است. مدل KNN-ResNet50 در مقایسه با سایر روش‌ها، ضعیف‌ترین عملکرد را نشان داده است. دقت پایین‌تر (۷۰ درصد) حاکی از بالا بودن نرخ مثبت کاذب است. همپوشانی کم (۶۷ درصد) نشان می‌دهد که مدل در تعیین دقیق مرز تیپ‌ها ضعف دارد. الگوریتم KNN به دلیل مشکلاتی از قبیل یکسان در نظر گرفتن تأثیر همه‌ی خصیصه‌ها در محاسبه‌ی فاصله‌ی رکورد جدید با همسایه‌های آن رکورد است حتی اگر برخی از این خصیصه‌ها برای عمل دسته‌بندی کم‌اهمیت‌تر باشند (مرادیان و سپهری‌فر، ۱۳۸۸). پیچیدگی محاسباتی الگوریتم KNN به دلیل است که برای طبقه‌بندی کردن هر الگوی آزمودن باید فاصله آن را تا تمام داده‌های آموزشی پیدا نماید. لذا نگهداری تمام داده‌های آموزشی نیاز به فضای ذخیره‌سازی زیادی دارد و در مقایسه با سایر الگوریتم‌های ماشین یادگیری، قدرت تشخیص و طبقه‌بندی تصاویر کمتری دارد (شفیعی و نخعی، ۱۳۹۷). مدل SVM-ResNet50 عملکرد نسبتاً خوبی داشته، به‌ویژه در دقت و یادآوری. این الگوریتم در طبقه‌بندی تیپ‌ها تعادلی میان تشخیص درست و کاهش خطاها برقرار کرده، اما به علت ساختار خطی‌محورش در تشخیص مرزهای غیرخطی (مانند فرم انحنا در تصاویر واقعی)، نسبت به CNN عقب‌تر است.

در نمودار شکل ۷، سه ماتریس اغتشاش برای الگوریتم‌های KNN، SVM و CNN با کمک مدل ResNet50 نشان داده شده‌اند. این ماتریس‌ها میزان صحت پیش‌بینی الگوریتم‌ها را برای سه کلاس «تیپ A»، «تیپ B» و «تیپ C» نمایش می‌دهند. در هر ماتریس، قطر اصلی (از بالا-چپ تا پایین-راست) نشان‌دهنده تعداد پیش‌بینی‌های صحیح برای هر تیپ است. اعداد خارج از قطر بیانگر نمونه‌هایی هستند که به‌اشتباه در تیپ‌های دیگر طبقه‌بندی شده‌اند (خطاهای مدل). الگوریتم CNN بهترین عملکرد را نشان می‌دهد: اغلب مقادیر روی قطر اصلی قرار دارند که بیانگر پیش‌بینی صحیح است، و کمترین خطا در تشخیص بین کلاس‌ها مشاهده می‌شود. الگوریتم SVM نیز عملکرد قابل قبولی دارد اما در مقایسه با CNN تعداد اشتباهات بیشتری دارد، به‌ویژه در طبقه‌بندی تیپ C. الگوریتم KNN بیشترین میزان خطا را دارد، به‌ویژه در تمایز میان تیپ‌های A و C که نشان‌دهنده حساسیت کمتر مدل به ویژگی‌های تمایز دهنده است.



شکل ۷. مقایسه ماتریس‌های اغتشاش سه الگوریتم‌های KNN، SVM و CNN با مدل ResNet50

نتیجه‌گیری

در این مطالعه از الگوریتم‌های SVM، KNN، CNN با مدل Resnet50 برای شناسایی و طبقه‌بندی انواع تیپ گاو (بر اساس وضعیت انحنای انتهای ستون فقرات) استفاده شد. کشاورزان و دامداران با بهره‌گیری از سیستم توسعه‌یافته مبتنی بر شبکه عصبی CNN می‌توانند با حداقل آموزش نرم‌افزاری در کمترین زمان ممکن از نوع تیپ گاو مطلع شوند. این مطالعه تجزیه و تحلیل و تشخیص نوع تیپ گاو را با استفاده از الگوریتم‌های ماشین یادگیری و تصاویر گرفته‌شده از انواع گاوها مورد بررسی قرار داد. در این الگوریتم‌ها شاخص‌های عملکردی از قبیل صحت، دقت، یادآوری، امتیاز F1 و همپوشانی در حد قابل قبول بالا می‌باشند. نتایج نشان داد که از بین الگوریتم‌های SVM، KNN، CNN با مدل Resnet50 الگوریتم CNN با مدل Resnet50 به دلیل داشتن بالاترین دقت به‌عنوان بهترین روش پیشنهادی در تشخیص نوع تیپ گاو معرفی می‌گردد. نتایج نشان داد که مدل CNN-ResNet50 با دستیابی به صحت ۹۱ درصد، دقت ۹۳ درصد و F1 برابر ۹۰ درصد برتری معناداری نسبت به مدل SVM-ResNet50 با صحت ۸۶ درصد و F1 معادل ۸۵ درصد و مدل KNN-ResNet50 با صحت ۸۲ درصد و F1 معادل ۸۱ درصد دارد. این یافته‌ها تأکیدی بر کارایی قابل توجه شبکه‌های عمیق در استخراج ویژگی‌های ظریف تصویری مانند انحنای ستون فقرات است که به‌ویژه در نظارت و مدیریت خودکار کیفیت تغذیه و سلامت دام‌ها کاربرد عملی دارد. بنابراین، پژوهش حاضر با تکیه بر انتقال یادگیری عمیق (ResNet50) و تحلیل تصویری RGB، موفق به تحقق دقت بالایی در طبقه‌بندی تیپ گاوها شد که با مطالعات گذشته هم‌راستا است و راهگشای کاربردی دامپروری دیجیتال است.

منابع

شفیعی، شیمای و نخعی، ناهید. (۱۳۹۷)، تکنیکی با هدف بهبود سرعت و دقت الگوریتم دسته‌بندی کننده KNN. *مجله نخبگان علوم و مهندسی*، جلد ۳ (۵)، ۱۳۴-۱۴۲.

مرادیان، مهدی و سپهری‌فر، محمدکاظم. (۱۳۸۸)، بهبود دقت الگوریتم KNN در داده‌کاوی با استفاده از قوانین وابستگی. *پانزدهمین کنفرانس بین‌المللی سالانه انجمن کامپیوتر ایران*. تهران، ۷۸۹۳۸. <https://civilica.com/doc/78938>.

REFERENCES

- Alvarez, J. R., Arroqui, M., Mangudo, P., Toloza, J., Jatip, D., Rodriguez, J., Teyseyre, A., Sanz, C., Zunino, A. & Machado, C. (2018). Body condition estimation on cows from depth images using Convolutional Neural Networks. *Comput. Electron. Agric.* 155, 12–22.
- Alvarez, J. R., Arroqui, M., Mangudo, P., Toloza, J., Jatip, D., Rodriguez, J. M., Teyseyre, A., Sanz, C., Zunino, A., Machado, C., Mateos, C. (2019). Estimating body condition score in dairy cows from depth images using convolutional neural networks, transfer learning and model Ensembling techniques. *Agronomy*. 9 (2), 90. <https://doi.org/10.3390/agronomy9020090>.
- Amin, A. K. M. R., Islam, M. T. & Hossain, M. S. (2022). Smart livestock monitoring: A computer vision-based approach to detect cattle body posture and condition. *IEEE Access*. 10, 114566–114579. <https://doi.org/10.1109/ACCESS.2022.3218910>
- Bewley, J., Peacock, A., Lewis, O., Boyce, R., Roberts, D., Coffey, M., Kenyon, S. & Schutz, M. (2008). Potential for Estimation of Body Condition Scores in Dairy Cattle from Digital Images. *J. Dairy Sci.* 91, 3439–3453.

- Devi, I., Sharma, R., Kumar, A., & Thakur, A. (2024). Deep learning aided computer vision system for automated linear type trait evaluation in dairy cows. *Smart Agricultural Technology*. 8, 100509. <https://doi.org/10.1016/j.atech.2024.100509>
- Duda, R. O., Hart, P. E., & Stork, D. G. (2001). *Pattern Classification*. Wiley-Interscience
- Hansen, M. F., Smith, M. L., Smith, L. N., Abdul Jabbar, K. & Forbes, D. (2018). Automated monitoring of dairy cow body condition, mobility and weight using a single 3D video capture device. *Comput. Ind.* 98, 14–22. <https://doi.org/10.1016/j.compind.2018.02.011>.
- Hou, H., Shi, W., Guo, J., Zhang, Z., Shen, W., & Kou, S. (2021). Cow Rump Identification Based on Lightweight Convolutional Neural Networks. *Information*. 12(9), 361. <https://doi.org/10.3390/info12090361>
- Huang, X. P., Feng, T., Guo, Y. Y. & Liang, D. (2023). Lightweight dairy cow body condition scoring method is based on improved YOLOv5s (in Chinese). *Nongye Jixie Xuebao/Trans. Chin. Soc. Agric. Mach.* 54, 287–296. <https://doi.org/10.6041/j.issn.1000-1298.2023.06.030>.
- Iandola, F., Han, S., Moskewicz, M., Ashraf, K., Dally, W. & Keutzer, K. (2016). SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5 MB model size. *arXiv:1602.07360*.
- Imamura, S., Zin, T.T., Kobayashi, I. & Horii, Y. (2017). Automatic evaluation of cow's body condition-score using 3D camera. *2017 IEEE 6th Global Conference on Consumer Electronics*. pp. 1–2. <https://doi.org/10.1109/GCCE.2017.8229435>.
- Li, J., Sun, P., Qin, C., Li, F.-d. & Wen, J. (2013). Research advance of body condition score in the management of feeding the dairy cows (in Chinese). *China Anim. Husb. Vet. Med.* 40, 115–119. <https://doi.org/10.3969/j.issn.1671-7236.2013.10.025>.
- Li, X., Hu, Z., Huang, X., Feng, T., Yang, X. & Li, M. (2019). Cow body condition score estimation with convolutional neural networks. *2019 IEEE 4th International Conference on Image, Vision and Computing (ICIVC)*. pp. 433–437. <https://doi.org/10.1109/icivc47709.2019.8981055>.
- Liu, Y. & Qin, J. (2021). Research and application of dairy cow's body condition score based on attention mechanism. *2021 IEEE 6th International Conference on Cloud Computing and Big Data Analytics (ICCCBDA)*. pp. 600–606. <https://doi.org/10.1109/icccbda51879.2021.9442608>.
- Maimon, O. & Rokach, L. (2010). *Data Mining and Knowledge Discovery Handbook*. 2nd ed. Springer Publishing Company, Incorporated.
- Moradian, M. & Sepehrifar, M. K. (2009), Improving the accuracy of the KNN algorithm in data mining using dependency rules. *15th Annual International Conference of the Iranian Computer Association*. Tehran, <https://civilica.com/doc/78938>. (In Persian).
- Nearby Micheil & Ann Yager. (2002). *Body Condition Scoring in Farm Animals*. Purdue University, Department of Animal Sciences, pp. 1-8.
- Nguyen, T. T., Van den Berg, J., van Mourik, S., & Hogeveen, H. (2018). Automatic body condition scoring in dairy cows using deep learning. *Computers and Electronics in Agriculture*. 153, 346–356. <https://doi.org/10.1016/j.compag.2018.08.046>.
- Paul, A., Mondal, S., Kumar, S., Kumari, T. (2020). Body condition scoring in dairy cows - a conceptual and systematic review. *Ind. J. Anim. Res.* 54 (8), 929–935. <https://doi.org/10.18805/ijar.B-3859>.
- Qiao, Y., Guo, Y. & He, D. (2023). Cattle body detection based on YOLOv5-ASFF for precision livestock farming. *Comput. Electron. Agric.* 204, 107579. <https://doi.org/10.1016/j.compag.2022.107579>.
- Qiao, Y., Kong, H., Clark, C., Lomax, S., Su, D., Eiffert, S. & Sukkarieh, S. (2021). Intelligent perception for cattle monitoring: a review for cattle identification, body condition score evaluation, and weight estimation. *Comput. Electron. Agric.* 185, 106143. <https://doi.org/10.1016/j.compag.2021.106143>.
- Redmon, J., Divvala, S., Girshick, R. & Farhadi, A. (2016). You only look once: unified, realtime object detection. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. pp. 779–788. <https://doi.org/10.1109/cvpr.2016.91>.
- Ren, S. Q., He, K. M., Girshick, R. & Sun, J. (2017). Faster R-CNN: towards real-time object detection with region proposal networks. *IEEE Trans. Pattern Anal. Mach. Intell.* 39 (6), 1137–1149. <https://doi.org/10.1109/TPAMI.2016.2577031>.
- Roi, S., Yael, E., Yisrael, P. & Ilan, H. (2016). Development of automatic body condition scoring using a low-cost 3-dimensional Kinect camera. *J. Dairy Sci.* 99 (9), 7714–7725. <https://doi.org/10.3168/jds.2015-10607>.
- Shafiei, Sh. & Nakhaei, N. (2018), A technique to improve the speed and accuracy of the KNN classifier algorithm. *Journal of Science and Engineering Elites*. Vol. 3(5). 134-142. (In Persian).
- Shi, W.; Dai, B.; Shen, W.; Sun, Y.; Zhao, K. & Zhang, Y. (2023). Automatic estimation of dairy cow body condition score based on attention-guided 3D point cloud feature extraction. *Comput. Electron. Agric.*

- 206, 107666.
- Shigeta, M., Ike, R., Takemura, H. & Ohwada, H. (2018). Automatic measurement and determination of body condition score of cows based on 3D images using CNN. *J. Rob. Mechatronics*. 30 (2), 206–213. <https://doi.org/10.20965/jrm.2018.p0206>.
- Simonyan, K. & Zisserman, A. (2015). Very Deep Convolutional Networks for Large-Scale Image Recognition. *arXiv:1409.1556*.
- Sokolova, M. & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Inf. Process. Manage.* 45 (4), 427–437.
- Song, X., Bokkers, E. A. M., van Mourik, S., Groot Koerkamp, P. W. G. & vander Tol, P. P. J. (2019). Automated body condition scoring of dairy cows using 3-dimensional feature extraction from multiple body regions. *J. Dairy Sci.* 102 (5), 4294–4308. <https://doi.org/10.3168/jds.2018-15238>.
- Tian, Y., Li, L., & Zhang, H. (2020). Automatic recognition of back posture in dairy cows for lameness detection using deep learning. *Computers and Electronics in Agriculture*. 177, 105708. <https://doi.org/10.1016/j.compag.2020.105708>.
- Wang, Y., Zhang, R., Liu, Y., & Fu, Z. (2020). Automatic estimation of dairy cow body condition score using back posture extraction with deep learning. *Biosystems Engineering*. 195, 186–198. <https://doi.org/10.1016/j.biosystemseng.2020.04.015>.
- Wu, Y., Li, Y., Zhao, Y., Yang, P., Li, Z. & Guo, H. (2021). Review of research on body condition score for dairy cows based on computer vision (in Chinese). *Nongye Jixie Xuebao/ Trans. Chin. Soc. Agric. Mach.* 52, 268–275. <https://doi.org/10.6041/j.issn.1000-1298.2021.S0.033>.
- Yukun, S., Pengju, H., Yujie, W., Ziqi, C., Yang, L., Baisheng, D., Runze, L. & Yonggen, Z. (2019). Automatic monitoring system for individual dairy cows based on a deep learning framework that provides identification via body parts and estimation of body condition score. *J. Dairy Sci.* 102, 10140–10151.
- Zhao, K., Liu, X. & Ji, J. (2021). Automatic body condition scoring method for dairy cows based on EfficientNet and convex Hull feature of point cloud (in Chinese). *Trans. Chin. Soc. Agric. Mach.* 52, 192–201 +173. <https://doi.org/10.6041/j.issn.1000-1298.2021.05.021>.
- Zhao, K., Zhang, M., Shen, W., Liu, X., Ji, J., Dai, B. & Zhang, R. (2023). Automatic body condition scoring for dairy cows based on efficient net and convex hull features of point clouds. *Comput. Electron. Agric.* 205, 107588.
- Zin, T. T., Seint, P. T., Tin, P., Horii, Y. & Kobayashi, I. (2020). Body condition score estimation based on regression analysis using a 3D camera. *Sensors*. 20 (13). <https://doi.org/10.3390/s20133705>.