

Original Article

Intelligent Monitoring of Broilers Behavior in Poultry Farms Using Deep Learning

Hossein Akhtari¹, Hossein Navid¹, Abasalt Bazrafshan¹, Majid Olyayee², Ali Ghaffarnezhad¹

1-Department of Biosystem Engineering, Faculty of Agriculture, University of Tabriz, Tabriz. Iran.

2- Department of Animal Science, Faculty of Agriculture, University of Tabriz. Iran.

ARTICLE INFO

ABSTRACT

Keywords:

Machine vision,
Broiler behavior,
Automated monitoring,
Smart agriculture,
Smart poultry,
Deep learning

Introduction

Poultry production serves as a crucial sector in the global food supply chain by offering a cost effective and protein rich source of nutrition to meet the demands of a rapidly growing population. As global consumption of poultry meat continues to increase, ensuring the health and welfare of broiler chickens has become more essential than ever. One key indicator of flock health and environmental quality in broiler production systems is animal behavior. Monitoring behaviors such as feeding, drinking, and general activity can provide valuable insights into welfare status, environmental conditions, and management efficiency. However, conventional methods for behavior monitoring typically rely on manual observation, which is labor-intensive, inconsistent, and impractical for large scale or continuous surveillance in commercial settings.

Advancements in computer vision and deep learning have opened new possibilities for automating behavior analysis in livestock farming. In particular, object detection models based on convolutional neural networks (CNNs) have shown high accuracy in detecting animals and recognizing specific postures or activities. This study explores the application of YOLOv11s, a recent lightweight yet powerful object detection model, to recognize and classify broiler behaviors from top view images captured in a real poultry farm environment. The primary aim is to develop an efficient and real-time monitoring system that can automatically detect key behaviors, reduce human intervention, and ultimately support precision poultry farming with enhanced animal welfare management.

Received:

June 29, 2025

Revised:

August 27, 2025

Accepted:

September 28, 2025

Materials and Methods

This study was conducted at the research poultry farm of the university of Tabriz. Images of broiler chickens were captured from 48 separate pens to monitor their spatial distribution and behaviors. The top view imaging setup helped minimize occlusions and provided a clear view of the broilers' positions and actions. The collected images were annotated manually by experts into three behavioral categories: normal, feeding, and drinking. Preprocessing steps were applied to the raw images to enhance model training. These included resizing, normalization, and data augmentation techniques such as horizontal flipping and brightness adjustment. The dataset was divided into training, validation, and testing subsets, considering class imbalance

* Corresponding Author:

navid@tabrizu.ac.ir

How to cite:

Akhtari, H. Navid, H. Bazrafshan, A. Olyayee, M. Ghaffarnezhad, Jamshidi, A. (2025). *Intelligent Monitoring of Broilers Behavior in Poultry Farms Using Deep Learning*. Journal of Agricultural Mechanization, 10 (3):31-42.

<https://doi.org/10.22034/jam.2025.67931.1329>



This is an open-access article under the CC BY NC license

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



and ensuring representative distribution of behaviors. Specific attention was given to improving the annotation quality to support accurate model learning.

For behavior detection, the YOLOv11s model a lightweight version of the YOLOv11 object detection architecture was employed due to its high inference speed and accuracy. The model was customized and trained using fine-tuned hyperparameters to achieve optimal performance. The training process was monitored using metrics such as loss convergence and mean Average Precision (mAP) at IoU 0.5. This setup enabled effective and real-time detection of broiler behaviors in smart poultry farming systems.

Results and Discussion

The YOLOv11s model was successfully trained to detect and classify three distinct broiler behaviors: feeding, drinking, and normal activity, based on top view images collected from 48 pens in a research oriented poultry facility. The model achieved a mean Average Precision (mAP) of 90% at IoU threshold 0.5, demonstrating high overall accuracy in behavior recognition. It performed particularly well in detecting feeding behavior (99% precision) and drinking behavior (89% precision), while performance for normal behavior was slightly lower (82%) due to the underrepresentation of this class during annotation. Although mild overfitting was observed during training, this issue was alleviated through regularization techniques such as dropout and early stopping, allowing the model to generalize well to unseen data.

Spatial analysis of detections revealed clear clustering of feeding and drinking behaviors around feeders and drinkers, respectively, while instances of normal activity were more evenly distributed across the pen space. This distribution pattern not only validates the behavioral labels but also suggests that the system can be used to assess flock dynamics and detect anomalies in movement or engagement. Furthermore, the lightweight architecture of YOLOv11s enabled real-time inference with minimal computational overhead, making it a practical solution for continuous on farm monitoring. These results are consistent with trends reported in prior studies using deep learning for animal behavior detection, while offering a novel, efficient, and scalable approach tailored for precision poultry farming.

Conclusion

This study demonstrated the effectiveness of the YOLOv11s deep learning model for automated recognition of broiler behaviors from top view images. The model accurately classified three key behaviors: feeding, drinking, and normal activity, using lightweight processing suitable for real-time monitoring. High detection accuracy, particularly for feeding (99%) and drinking (89%), along with acceptable performance for normal behavior (82%), confirmed the reliability of the proposed system in practical scenarios. Spatial patterns of the behaviors also aligned with expected distributions, reinforcing the validity of the detection results. The findings suggest that integrating YOLOv11s into smart poultry farming systems can enhance real-time flock observation, reduce human labor, and improve management decision making. The lightweight nature of the model makes it suitable for edge deployment, enabling cost effective and scalable solutions for precision livestock monitoring. Overall, this research highlights the feasibility of using deep learning for intelligent broiler behavior analysis, contributing to better welfare, health assessment, and efficient poultry production.

Acknowledgement

The authors would like to express their sincere appreciation to the staff of the KhalatPoushan Research Station at the University of Tabriz and the students of the poultry research facility for providing support and resources during the data collection process.



پایش هوشمند رفتار جوجه‌ها در مزارع پرورش طیور با استفاده از یادگیری عمیق

حسین اختری^۱، حسین نوید*^۱، اباضلت بذرافشان^۱، مجید علیایی^۲، علی غفارنژاد^۱

تاریخ دریافت: ۱۴۰۴/۰۴/۰۸ تاریخ بازنگری: ۱۴۰۴/۰۷/۰۵ تاریخ پذیرش: ۱۴۰۴/۰۷/۰۶

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

۲- گروه علوم دامی - دانشکده کشاورزی - دانشگاه تبریز - تبریز - ایران.

E-mail: navid@tabrizu.ac.ir

* نویسنده مسئول

چکیده

تولید طیور نقش حیاتی در تأمین پروتئین مقرون به صرفه برای تغذیه جمعیت رو به رشد جهان دارد. مدیریت بهینه مرغداری‌ها یکی از عوامل کلیدی در تولید مؤثر و با کیفیت گوشت طیور به شمار می‌رود. پراکنش مکانی جوجه‌های گوشتی می‌تواند به عنوان یک شاخص مدیریتی برای شناسایی سلامت یا مشکلات موجود در گله عمل کند. در حال حاضر، بازرسی‌های متعدد روزانه توزیع جوجه‌ها در مرغداری‌ها به صورت دستی انجام می‌شود که این فرایند نه تنها زمان‌بر و طاقت‌فرسا است، بلکه مستعد خطاهای انسانی نیز می‌باشد. روش‌های بینایی ماشین مبتنی بر هوش مصنوعی از جمله رویکردهایی هستند که قادرند چالش‌های ناشی از روش‌های دستی در سیستم‌های مدیریت مرغداری‌ها را برطرف کنند. در این تحقیق، یادگیری عمیق به عنوان یکی از شاخه‌های هوش مصنوعی با هدف تشخیص وضعیت جوجه‌ها مورد بررسی قرار گرفت. پس از تصویربرداری از نمای بالا از ۴۸ پن (محوطه نگهداری) در مرغداری تحقیقاتی دانشگاه تبریز، برخی پردازش‌های اولیه روی تصاویر اعمال شد. این اقدامات با هدف بهبود فرآیند آموزش و افزایش دقت مدل پیشنهادی انجام گرفت. در مرحله بعد، پس از بهبود و سفارشی کردن معماری مدل و اصلاح فرآیند آموزش، از نسخه سبک و کم حجم یولو نسخه ۱۱ کوچک که یکی از مدل‌های جدید و مطرح در حوزه یادگیری عمیق است، برای آموزش و ارزیابی وضعیت جوجه‌ها استفاده شد. استفاده از این مدل و نسخه مربوطه با هدف دستیابی به دقت بالا همراه با سرعت مناسب برای پردازش در زمان واقعی انجام شد. کاهش تدریجی اتلاف در روند آموزش و اعتبارسنجی مدل ارائه شده، نشان‌دهنده دستیابی مدل به تعادل و آموزش بهینه بود. مدل یولو نسخه ۱۱ کوچک با دستیابی به میانگین دقت متوسط ۹۰٪ (mAP 0.5) توانست عملکرد قابل توجهی در شناسایی رفتار جوجه‌ها ارائه دهد. به‌ویژه، در تشخیص رفتار خوردن با دقت ۹۹٪ و نوشیدن با دقت ۸۹٪ عملکرد مطلوبی داشت. با این حال، دقت پایین‌تر در شناسایی رفتار معمولی (۸۲٪) عمدتاً ناشی از برچسب‌گذاری ناکافی این رفتار بود. به طور کلی، نتایج نشان داد که یولو نسخه ۱۱ کوچک با ایجاد تعادل میان دقت و سرعت، گزینه‌ای کارآمد برای پایش زمان واقعی رفتار جوجه‌ها در سیستم‌های مدیریت هوشمند مرغداری محسوب می‌شود.

کلمات کلیدی: بینایی ماشین، رفتار جوجه‌ها، پایش خودکار، کشاورزی هوشمند، مرغداری هوشمند، یادگیری عمیق



۱- مقدمه

پیش‌بینی‌ها حاکی از آن است که جمعیت جهان تا سال ۲۰۵۰ به ۹/۲ میلیارد نفر خواهد رسید (Tilman *et al.*, 2011). از طرفی، دام‌ها و طیور سهم بزرگی (تقریباً ۳۰ درصد) از مصرف روزانه پروتئین انسان از طریق محصولاتمانند گوشت، شیر، تخم‌مرغ و غیره را دارند (McLeod, 2011). بنابراین، رشد جمعیت جهان به دامپروری وابستگی بالایی دارد و برای تأمین نیازهای جمعیت رو به رشد انسان، لازم است تولیدات دامی و طیور افزایش یابد. از سوی دیگر، صنعت طیور با چالش‌های مربوط به افزایش تقاضا و همچنین نیاز به افزایش بهره‌وری روبه‌رو بوده و خواهد بود. در میان بسیاری از چالش‌های مطرح در مرغداری‌ها، نگرانی‌های رفاهی جوجه‌ها^۱، تحت سیستم‌های مدیریتی فشرده است (Chai *et al.*, 2019; Chai *et al.*, 2018). با توجه به پیش‌بینی کمبود نیروی کار در مشاغل کشاورزی در آینده (Hertz & Zahniser, 2013)، شناسایی مشکلات و ناهنجاری‌های جوجه‌ها به‌موقع می‌تواند دشوارتر شود، که این امر می‌تواند سلامت و بهره‌وری جوجه‌ها را تحت تأثیر قرار دهد (Kashiha *et al.*, 2013). علاوه بر این، پیش‌بینی شده است در سال ۲۰۵۰، تعداد ۳۷ میلیارد مرغ تولید خواهد شد تا پاسخگوی نیازهای غذایی فزاینده باشد (Yitbarek, 2019). بنابراین، استفاده از فناوری‌های پیشرفته برای جمع‌آوری داده‌ها، تحلیل‌ها و تصمیم‌گیری در مدیریت مرغداری‌ها ضروری است. دامپروری دقیق^۲ (PLF) به توسعه و استفاده از فناوری‌ها مختلف برای بهبود تولید طیور و مواجهه با چالش‌های مدیریت مرغداری‌ها اشاره دارد (Werner & Jarfe, 2003).

بینایی ماشین^۳ یکی از فناوری‌های نوین با قابلیت‌های چشمگیر در مدیریت مزارع دام و طیور است، چرا که تحقیقات اخیر نشان داده‌اند این فناوری می‌تواند با دقت بالا فرآیندهای پایش^۴، تشخیص و تحلیل وضعیت حیوانات را بهبود بخشد و نقش مؤثری در افزایش بهره‌وری و کاهش وابستگی به نیروی کار انسانی داشته باشد (Balasubramaniam *et al.*, 2025; Bhuiyan & Wree, 2023). پردازش تصویر^۵ یکی از رویکردهای مطرح در حوزه بینایی ماشین است که توانایی پایش و تحلیل وضعیت جوجه‌ها را دارد. در یک مطالعه، روشی مبتنی بر پردازش تصویر برای بررسی توزیع فضایی جوجه‌های گوشتی در یک مرغداری آزمایشی توسعه و ارزیابی شد. از آنجا که توزیع مناسب جوجه‌ها در کف سالن نشانه‌ای از سلامت گله^۶

است، این روش با هدف خودکارسازی فرآیند بازرسی، که معمولاً به‌صورت دستی امری زمان‌بر بود، مورد بررسی قرار گرفت. برای این منظور، سطح پن‌های^۷ پرورش به‌طور مجازی به سه منطقه نوشیدن، تغذیه و استراحت تقسیم شد تا مدل بتواند موقعیت جوجه‌ها را در تصاویر تشخیص دهد. در بخش پردازش تصویر، از روش‌های مختلف تشخیص اهداف بر پایه طبقه‌بندی^۸ فضای رنگی در نرم‌افزار متلب^۹ R2019b استفاده شد. پس از بررسی گزینه‌های مختلف، فضای رنگی GB به دلیل دقت و سرعت بالاتر انتخاب شد. سپس، تصاویر با استفاده از الگوریتم اُتسو^{۱۰} (Otsu, 1975) دوبعدی به فرمت دودویی^{۱۱} تبدیل شده و پس از اعمال فرسایش مورفولوژیکی^{۱۲}، پس‌زمینه حذف گردید. در ادامه، حدود ۷۰۰۰ نمونه از نواحی حضور جوجه‌ها در تصاویر ثبت‌شده بین سنین ۱۸ تا ۳۵ روزگی استخراج شد و برای آموزش^{۱۳} یک مدل شبکه عصبی پس‌انتشار^{۱۴} (BP) (Hecht-Nielsen, 1992) جهت تحلیل توزیع کف سالن مورد استفاده قرار گرفت. همچنین، ۲۰۰ تصویر دیگر برای ارزیابی مدل به کار رفت. نتایج نشان داد که دقت شناسایی جوجه‌ها در مناطق نوشیدن و تغذیه به ترتیب تقریباً برابر ۹۴ و ۹۵ درصد بود و ضریب همبستگی (R) مقدار ۰/۹۹۶ را به‌دست آورد. در نهایت، این روش از نظر سرعت پردازش و دقت شناسایی با الگوریتم‌های K-Means (Likas *et al.*, 2003) و FCM (Bezdek *et al.*, 1984) مقایسه شد که نشان داد روش پیشنهادی عملکرد بهتری در تفکیک جوجه‌ها از پس‌زمینه دارد. عمده خطاهای شناسایی شده در این تحقیق به دلیل تداخل تجهیزات سالن مانند زنجیرهای دان‌خوری و خطوط آب‌خوری ایجاد شد (Y. Guo *et al.*, 2020).

در تحقیقات گذشته بهره‌گیری از روش‌های مبتنی بر پردازش تصویر و یادگیری ماشین^{۱۵} (Jordan & Mitchell, 2015) نتایج ارزشمندی را در راستای تجزیه و تحلیل وضعیت جوجه‌ها و سایر رویکردهای مدیریتی در مرغداری‌ها به ارمغان آورده است. در کنار این مسائل روش‌های مذکور می‌تواند معایبی از جنبه‌های مختلف داشته باشد. در روش‌های مبتنی بر یادگیری ماشین و پردازش تصویر، فرآیند شامل پیش‌پردازش^{۱۶}، بخش‌بندی^{۱۷}، استخراج و انتخاب ویژگی، و در نهایت طبقه‌بندی یا رگرسیون^{۱۸} است. این روش‌ها اگرچه در محیط‌های کنترل‌شده عملکرد خوبی دارند، اما به دلیل پیچیدگی پس‌زمینه، تغییرات نور و مشکلات انسداد در محیط‌های واقعی، عمومی‌سازی و استحکام کافی ندارند. همچنین،

¹⁰ Otsu

¹¹ binary

¹² Morphological erosion

¹³ Train

¹⁴ Back propagation neural network

¹⁵ Machine Learning

¹⁶ Pre processing

¹⁷ Segmentation

¹⁸ Regression

¹ Poultry welfare

² Precision Livestock Farming

³ Machine Vision

⁴ Monitoring

⁵ Image processing

⁶ Flock

⁷ Pen

⁸ Classification

⁹ MATLAB

می‌تواند به شناسایی دما، وزن، رفتار و سایر پارامترهای مدیریتی گله کمک کند (Depuru *et al.*, 2024).



شکل ۱- طرحواره کلی مربوط به کاربرد شبکه‌های عصبی کانولوشنی در مدیریت مرغداری‌ها

Fig 1. A general framework for the application of convolutional neural networks in poultry management

از چند معماری^۶ شبکه عصبی کانولوشنی برای پایش رفتار جوجه‌های گوشتی شامل تغذیه، آشامیدن، ایستادن و استراحت جهت آموزش و ارزیابی استفاده گردید. برای تشکیل مجموعه داده^۷، تصاویر از نمای بالا در روزهای ۲، ۹، ۱۶ و ۲۳ پرورش جوجه‌ها ثبت شد و در هر مرحله ۳۰۰ نمونه از هر رفتار استخراج گردید که پس از افزایش داده‌ها، به ۱۰۲۰۰ تصویر برای هر روز افزایش یافت. عملکرد مدل‌های مختلف شبکه عصبی کانولوشنی در شناسایی رفتارها بررسی شد و نتایج نشان داد که DenseNet-264 (Huang *et al.*, 2017) با دقت ۸۸/۵، ۹۷، ۹۴/۵ و ۹۰ درصد به ترتیب در روزهای ۲، ۹، ۱۶ و ۲۳ بهترین عملکرد را دارد. همچنین در ادامه با افزودن یک تکنیک مکانیزم توجه^۸، مدل بهبود یافت اما همچنان نسخه اصلی بهترین عملکرد کلی را نشان داد (Guo *et al.*, 2022).

بررسی نتایج و تجزیه و تحلیل تحقیقات مختلف نشان می‌دهد که استفاده از یادگیری عمیق، به‌ویژه شبکه‌های عصبی کانولوشنی، روشی مؤثر برای پایش رفتار جوجه‌ها در سیستم‌های پرورشی تجاری و پژوهشی است. در این تحقیق، تلاش شده است تا با استفاده از معماری و مدل نوین شبکه‌های عصبی کانولوشنی، رفتار جوجه‌ها در سالن مرغداری شناسایی و به سه دسته معمولی، خوردن و آشامیدن طبقه‌بندی شوند. همچنین، در این فرآیند، رویکرد داده‌های ترکیبی در برچسب‌گذاری^{۱۱} نیز مورد بررسی قرار گرفته است. بهره‌گیری از

نیاز به مهندسی ویژگی و کاهش ابعاد داده‌ها دارند. در مقابل، روش‌های بر پایه یادگیری عمیق^۱ (LeCun *et al.*, 2015) با استفاده از شبکه‌های عصبی کانولوشنی^۲ (CNNs) (O'shea & Nash, 2015) بسیاری از این مراحل را به‌طور خودکار حذف می‌کند و معایب موجود در روش‌های یادگیری ماشین و پردازش تصویر را بسیار کاهش داده و در نهایت دقت بالاتری را ارائه می‌دهد (Okinda *et al.*, 2020).

شبکه‌های عصبی کانولوشنی ریشه در توسعه شبکه‌های عصبی مصنوعی دارند. تحقیقات در این حوزه تقریباً از سال ۱۹۵۸ شروع شد و با حل چالش‌های متعدد در هر مقطع به وضعیت کنونی رسیده است. نقطه عطف در پیشرفت شبکه‌های عصبی کانولوشنی در سال ۲۰۱۲ بود که مجموعه داده ImageNet (Deng *et al.*, 2009) برای توسعه این نوع شبکه‌ها ایجاد شد. Krizhevsky *et al.* (2012) با ارائه معماری AlexNet بر پایه شبکه‌های عصبی کانولوشنی، دقت طبقه‌بندی را از ۷۴/۲ به ۸۴/۷ درصد افزایش دادند. در چند سال اخیر، استفاده از معماری‌ها و مدل‌های مختلف و متعدد شبکه‌های عصبی کانولوشنی در سیستم‌های مدیریتی مرغداری‌ها بواسطه تحقیقات گوناگون به وضوح قابل مشاهده است. کاربرد شبکه‌های عصبی کانولوشنی در مدیریت مرغداری‌ها در شکل ۱ به‌طور خلاصه قابل مشاهده است.

با هدف پایش و ردیابی^۳ رفتار جوجه‌های گوشتی به‌منظور شناسایی بیماری‌ها در مراحل اولیه و امکان جداسازی سریع و درمان جوجه‌های بیمار، همچنین جلوگیری از گسترش عوامل بیماری‌زا و تأمین سلامت کل گله، از مدل یولو^۴ (Redmon *et al.*, 2016) نسخه ۵ کوچک صرفاً جهت تشخیص و طبقه‌بندی جوجه‌ها استفاده شد. داده‌های مورد نیاز این تحقیق شامل تصاویر جوجه‌های گوشتی در سنین ۱ تا ۴ هفته بود که از منابع آنلاین^۵ جمع‌آوری شد. در طول فرآیند جمع‌آوری داده‌ها، توجه ویژه‌ای به تعادل کلاس‌ها برای جلوگیری از عملکرد ضعیف مدل به دلیل داده‌های نامتعادل شد. پس از آموزش مدل با ۲۵۰۰۰ تصویر، جوجه‌ها بر اساس سن به چهار گروه سنی طبقه‌بندی شدند و مدل با دقت ۹۶ درصد بهترین عملکرد را در شناسایی و طبقه‌بندی جوجه‌ها نشان داد. پس از آموزش، مدل به قالب خاصی تبدیل شد تا قابلیت ردیابی جوجه‌ها در زمان واقعی^۶ را داشته باشد. نتایج تحقیق نشان داد که این مدل قادر به شناسایی و طبقه‌بندی جوجه‌ها در فریم‌های^۷ ویدیویی و ردیابی آن‌ها است که

⁶ Real-time

⁷ Frames

⁸ Architecture

⁹ Dataset

¹⁰ Attention mechanism

¹¹ Annotation

¹ Deep Learning

² Convolutional neural network

³ Tracking

⁴ YOLO (You Only Look Once)

⁵ Online

پایتون است، انجام شد (Wspanialy et al., 2020). این ابزار امکان رسم دقیق جعبه‌های محیطی و اختصاص برچسب‌های رفتاری را فراهم کرده و به بهبود کیفیت داده‌های آموزشی کمک می‌کند.

پس از اتمام فرآیند برچسب‌گذاری، داده‌ها به سه مجموعه آموزش (۸۰٪)، اعتبارسنجی^۲ (۱۰٪) و آزمایش^۳ (۱۰٪) تقسیم شدند. علاوه بر این، در ابتدای فرآیند آموزش مدل، برخی عملیات پیش‌پردازش به‌صورت خودکار انجام گرفت تا داده‌ها برای پردازش بهینه شوند. این مراحل شامل تبدیل تصاویر به قالب مناسب برای ورودی مدل، نرمال‌سازی^۴ داده‌ها جهت بهبود پایداری شبکه و به‌کارگیری تکنیک‌های داده‌افزایی^۵ (مانند تغییر اندازه^۶، تغییر مقیاس^۷ و تغییر شدت روشنایی^۸) بود. این اقدامات نقش مهمی در بهبود عملکرد مدل و افزایش تعمیم‌پذیری^۹ آن دارند. مهم‌ترین داده‌افزایی انجام شده مربوط به تکنیک موزائیک^{۱۰} بود. در این تکنیک چند تصویر ورودی با چند تکنیک داده‌افزایی اعمال شده با هم ترکیب می‌شوند تا یک تصویر جدید ایجاد شود که شامل چندین جوجه از تصاویر مختلف است. در این تحقیق، مقدار ۲۰ به‌عنوان تعداد دوره‌هایی که در آن‌ها این نوع داده‌افزایی اعمال نشده، در نظر گرفته شد. به این معنا که ۲۰ دوره پایانی آموزش بدون اعمال این تکنیک اجرا شد. هدف از این رویکرد آن بود که در مراحل ابتدایی، مدل با داده‌های متنوع‌تری آموزش ببیند، در حالی که در مراحل پایانی، تصاویر واقعی‌تری بدون تغییرات مصنوعی بیش از حد به مدل ارائه شوند. این روش نه‌تنها به افزایش تنوع داده‌های آموزشی کمک می‌کند، بلکه موجب بهبود تعمیم‌پذیری مدل و عملکرد دقیق‌تر آن در شرایط واقعی می‌شود. در شکل، نمونه‌ای از تصویر با تکنیک موزائیک و برچسب‌های اعمال شده نمایش داده شده است. در شکل ۲، لیبل‌های ۰، ۱ و ۲ به ترتیب نشان‌دهنده‌ی رفتار خوردن، آشامیدن و معمولی هستند.

این نوع فناوری‌ها می‌تواند به بهبود دقت و کارایی سیستم‌های پایش و مدیریت جوجه‌ها کمک قابل ملاحظه‌ای بکند.

۲- مواد و روش‌ها

۲-۱- جمع‌آوری و آماده‌سازی داده‌ها

برای دستیابی به نتایج دقیق در تحقیقات مبتنی بر یادگیری عمیق، تهیه یک مجموعه داده مناسب از هر نظر ضروری است. دو عامل مهم در جمع‌آوری داده‌ها، کمیت و کیفیت آن‌ها هستند. در این پژوهش، داده‌ها شامل تصاویر رنگی (RGB) از نمای بالای هر پن در مرغداری ایستگاه تحقیقاتی خلعت‌پوشان دانشگاه تبریز بود. فرآیند تصویربرداری از هفته دوم پرورش جوجه‌های گوشتی آغاز شد و تا پایان دوره، به‌صورت دوره‌ای در فواصل چندروزه ادامه یافت. در هنگام ثبت تصاویر، دقت زیادی برای رعایت استانداردهای کیفیت داده به‌کار گرفته شد. از جمله این موارد می‌توان به توزیع متناسب جوجه‌ها، تعداد کافی در هر تصویر، و شرایط نوری متفاوت اشاره کرد. رعایت این اصول نقش مهمی در بهبود فرآیند آموزش مدل و افزایش دقت تشخیص دارد (Q. Guo et al., 2020).

برچسب‌گذاری داده‌ها یکی از مراحل کلیدی در آماده‌سازی مجموعه داده است، زیرا مدل یادگیری عمیق تصاویر را همراه با برچسب‌هایشان دریافت کرده و براساس آن‌ها آموزش می‌بیند. دقت در این مرحله تأثیر مستقیمی بر عملکرد مدل و دقت نهایی آن دارد، و هرگونه خطا یا عدم دقت در برچسب‌گذاری می‌تواند بر کیفیت خروجی تأثیر منفی بگذارد. در این پژوهش، حدود ۵۰۰ تصویر از مجموعه داده ثبت‌شده، برچسب‌گذاری شدند. رفتارهای موردنظر شامل رفتار معمولی، خوردن و آشامیدن بودند که برای هر جوجه در تصویر، جعبه‌های محیطی^۱ رسم شده و رفتارهای مربوطه به آن‌ها اختصاص داده شد. برای رفتار خوردن و آشامیدن، تمامی موارد شناسایی و برچسب‌گذاری شدند تا پوشش کاملی از این دو رفتار در داده‌های آموزشی ایجاد شود. در این مطالعه، منظور از رفتار معمولی حالتی است که جوجه‌ها درگیر هیچ‌یک از رفتارهای خاص هدف (خوردن یا آشامیدن) نبوده و ممکن است در وضعیت ایستاده، نشسته یا در حال حرکت در محیط باشند. اما در مورد رفتار معمولی، تنها بخشی از جوجه‌ها برچسب‌گذاری شده و برخی دیگر بدون برچسب باقی ماندند. این تصمیم برای تقویت تعمیم‌پذیری و بررسی تأثیر آن بر روی دقت خروجی انجام شد. فرآیند برچسب‌گذاری با استفاده از ابزار LabelImg که یک نرم‌افزار متن‌باز مبتنی بر زبان برنامه‌نویسی

⁶ Resize

⁷ Scale change

⁸ Brightness

⁹ Generalizability

¹⁰ Mosaic

¹ Bounding Boxes

² Validation

³ Test


⁴ Normalization

⁵ Augmentation

یولو نسخه ۱۱ کوچک^۲ نسخه‌ای بهینه‌شده از مدل پایه یولو است که با معماری سبک‌تر، سرعت پردازش بالاتر و دقت بهبودیافته، عملکرد دقیق‌تری در تشخیص اشیاء و رفتارها ارائه می‌دهد. این مدل با بهینه‌سازی فرآیند استخراج ویژگی‌ها^۳ و یادگیری چندمقیاسی^۴، به‌ویژه در تشخیص اشیاء کوچک و رفتارهای جزئی، دقت بالاتری دارد. همچنین، بهره‌گیری از تکنیک‌های پیشرفته در کاهش نویز و افزایش تفکیک‌پذیری کلاس‌ها، آن را به گزینه‌ای ایده‌آل برای کاربردهای بلادرنگ، مانند نظارت هوشمند در محیط‌های پویا حتی در سیستم‌های تعبیه شده^۵ تبدیل کرده است. با توجه به این مزایا، در این تحقیق از یولو نسخه ۱۱ کوچک برای پایش و تحلیل رفتار جوجه‌های گوشتی در مرغداری استفاده شد تا امکان شناسایی سریع و دقیق وضعیت آن‌ها فراهم شود.

در شکل ۳ عملکرد مدل‌های یولو نسخه ۱۱ در اندازه‌های مختلف را از نظر سرعت و دقت با نسخه‌های قبلی یولو مقایسه می‌کند. بر اساس این نمودارها، مدل یولو نسخه ۱۱ نسبت به نسخه‌های قبلی خود پیشرفت‌های چشمگیری در دقت و سرعت داشته است. این مدل با کاهش ۲۲ درصدی تعداد پارامترها نسبت به یولو نسخه ۸ متوسط (Varghese & Sambath, 2024)، بدون کاهش دقت، بهینه‌سازی محاسباتی بهتری ارائه می‌دهد. همچنین، یولو نسخه ۱۱ در وظایف مختلف بینایی کامپیوتر، از جمله تخمین ژست^۶، تشخیص اشیاء، طبقه‌بندی تصاویر، و بخش‌بندی، عملکرد مطلوبی دارد. بهبود معماری شبکه و فرآیندهای آموزش باعث شده تا این مدل با حفظ دقت بالا، سرعت پردازش بیشتری داشته باشد. در آزمایش‌ها، یولو نسخه ۱۱ اندازه x به دقت ۵۴/۵ درصد در میانگین دقت متوسط بین ۰/۵ تا ۰/۹۵ با تأخیر ۱۳ میلی‌ثانیه دست یافته که بالاتر از تمام نسخه‌های قبلی یولو است. نسخه‌های سبک‌تر مانند یولو نسخه ۱۱ کوچک نیز در بازه ۲ الی ۶ میلی‌ثانیه، دقت بالایی در حد ۴۷ درصد ارائه داده‌اند، که آن را به گزینه‌ای ایده‌آل برای کاربردهای زمان واقعی تبدیل می‌کند. در مجموع، یولو نسخه ۱۱ با استفاده بهینه از منابع محاسباتی و معماری پیشرفته، نسبت به نسل‌ها و نسخه‌های قبلی خود تعادل بهتری بین دقت و سرعت برقرار کرده است (Khanam & Hussain, 2024).

فرآیند آموزش مدل مستلزم تنظیم دقیق فرآیندهای^۷ است که بر اساس ارزیابی عملکرد در مراحل آموزش و اعتبارسنجی، بهینه‌سازی شده‌اند تا مقادیر نهایی هر یک تعیین گردد. این



شکل ۲- نمونه‌ای از تصویر نهایی برای آموزش مدل

Fig 2. Sample of the final image used for model training

۲-۲- پیکربندی مدل

انتخاب مدل و معماری مناسب و متناسب با هدف مورد نظر، یکی دیگر از عوامل کلیدی در موفقیت تحقیقات مرتبط بر یادگیری عمیق است. شناسایی محل و رفتار جوجه‌ها با استفاده از شبکه‌های عصبی کانولوشنی، هدف اصلی این تحقیق بود. سیستم‌های مدیریتی در مرغداری‌ها نیازمند پاسخگویی سریع به وضعیت و رفتار جوجه‌ها همراه با دقت بالا هستند. از این رو، لازم است از مدل‌هایی استفاده شود که توانایی ارائه نتایج دقیق و سریع را داشته باشند. به همین دلیل، در این تحقیق از مدل پایهی یولو (Redmon et al., 2016) برای شناسایی و تشخیص رفتار جوجه‌ها بهره گرفته شد.

مدل یولو یک مدل قدرتمند در تشخیص اشیاء^۱ است که قابلیت شناسایی چندین شیء در یک تصویر را در آن واحد دارد. این مدل به دلیل سرعت بالا و دقت مطلوب، در کاربردهای زمان واقعی مانند نظارت بر رفتار جوجه‌ها در مرغداری‌ها بسیار مناسب است. نسخه‌های مختلف یولو طی چند سال گذشته با بهبودهای مختلف در سرعت، دقت و کارایی، در حال توسعه هستند. هر نسخه جدید از این مدل معمولاً با بهبود در معماری شبکه، استفاده از تکنیک‌های بهینه‌سازی و بهبود عملکرد در شرایط مختلف، ویژگی‌های جدیدی به ارمغان می‌آورد. این مدل‌ها از معماری‌های پیچیده و مکانیزم‌های پیشرفته‌ای مانند anchor boxes و non-maximum suppression برای کاهش خطا و افزایش دقت استفاده می‌کنند.

⁵ Embedded system

⁶ Pose estimation


⁷ Hyperparameters

¹ Object detection

² Yolo11s

³ Feature extraction

⁴ Multi-scale




شکل ۴- نمودار اتلاف آموزش و اعتبارسنجی
Fig 4. Training and validation loss curve

نتایج حاصل شده بر اساس داده‌های آزمایش که هیچگونه مشارکتی در حین آموزش نداشتند در جدول ۱ براساس معیارهای مطرح ارائه شده است. نتایج ارائه شده عملکرد مدل را در تشخیص رفتارهای مختلف جوجه‌ها شامل خوردن، آشامیدن و رفتار معمولی ارزیابی می‌کند. معیارهای دقت، یادآوری و میانگین دقت (mAP) در سطوح مختلف گزارش شده‌اند. میانگین دقت متوسط ۹۰/۶ درصد بوده که نشان‌دهنده عملکرد قابل قبول آن در تشخیص رفتارها است. در بین کلاس‌ها، رفتار خوردن با دقت ۹۴ درصد و یادآوری ۱۰۰ درصد بهترین عملکرد را داشته است. لازم به ذکر است که تعداد نمونه‌های مربوط به رفتار خوردن و نوشیدن نسبت به رفتار معمولی بسیار کم بود. این عدم تعادل در تعداد داده‌ها باعث شد که مدل به دلیل کمبود این دو رفتار در زیر مجموعه آزمایشی، دقت بالاتری در شناسایی آنها نشان دهد. به عبارت دیگر، مدل قادر بود تا رفتارهای خوردن و نوشیدن را با دقت بالا شبیه‌سازی کند، چرا که تعداد کمتری از نمونه‌ها به آن اختصاص داشت و مدل تمرکز بیشتری بر روی آن‌ها داشت. در تحقیقات آینده، توجه به این مسئله و بهبود توزیع داده‌ها در کلاس‌های مختلف می‌تواند تأثیر زیادی بر عملکرد مدل و دقت شناسایی تمامی رفتارها داشته باشد.

رفتار معمولی، پایین‌ترین میزان دقت ۷۵/۸٪ و یادآوری ۷۷/۸٪ را ثبت کرده است. این امر می‌تواند به دلیل دشواری بیشتر در تمایز این رفتار از سایر کلاس‌ها یا وجود نمونه‌هایی باشد که به‌عنوان رفتار معمولی برچسب‌گذاری نشده‌اند. بر اساس نتایج، برخی رفتارهای معمولی جوجه‌ها ممکن است به دلیل نبود برچسب در حین آموزش نادیده گرفته شده باشند که می‌تواند بر دقت مدل در این کلاس تأثیر بگذارد. این امر نشان می‌دهد که برچسب‌گذاری دقیق‌تر و متعادل‌تر داده‌های آموزشی می‌تواند تأثیر مثبتی بر عملکرد کلی مدل داشته

فرایامترها شامل اندازه دسته‌های ورودی^۱، تعداد دوره‌های آموزش^۲، نرخ یادگیری^۳ و سایر تنظیمات تأثیرگذار بر عملکرد مدل هستند. پس از اتمام آموزش، مدل نهایی با استفاده از معیارهای ارزیابی استاندارد در حوزه تشخیص، از جمله دقت^۴، سرعت پردازش، میزان یادآوری^۵ و سایر شاخص‌های مرتبط، مورد تحلیل و بررسی قرار گرفت تا کارایی آن سنجیده شود.



شکل ۳- مقایسه بول نسخه ۱۱ با سایر اندازه‌های این نسخه و نسل‌های قبلی مدل یولو (Redmon et al., 2016)

Fig 3. Comparison of YOLOv11 with other sizes of this version and previous YOLO (Redmon et al., 2016) generations

۳- نتایج و بحث

گام نخست در تحلیل عملکرد مدل، بررسی روند آن در طول فرآیند آموزش است. ارزیابی میزان اتلاف^۶ در مراحل آموزش و اعتبارسنجی می‌تواند اطلاعات ارزشمندی درباره کیفیت یادگیری مدل ارائه دهد. نمودارهای مربوط که در شکل ۴ ارائه شده، روند تغییرات میزان اتلاف را در طول ۴۰ دوره آموزش نمایش می‌دهند. در این نمودارها، اتلاف آموزش (نمودار سبز) و اتلاف اعتبارسنجی (نمودار نارنجی) به تفکیک نشان داده شده‌اند. در ابتدای آموزش، هر دو مقدار نسبتاً بالا هستند اما با پیشرفت دوره‌های آموزشی، کاهش می‌یابند. نوسانات شدید در اتلاف اعتبارسنجی طی چند دوره اول نشان‌دهنده بی‌ثباتی مدل در مراحل اولیه آموزش است که به مرور کاهش یافته و به سمت همگرایی^۷ حرکت می‌کند. پس از حدود ۲۰ دوره، هر دو نمودار به مقدار ثابتی نزدیک می‌شوند که نشان‌دهنده پایداری و همگرایی مدل است. این روند بیانگر آن است که مدل توانسته الگوهای داده‌ها را یاد بگیرد و دچار حالاتی نظیر بیش‌برازش^۸، واگرایی^۹ و غیره نشده است.

⁶ Loss

⁷ Convergence

⁸ Overfitting

⁹ Divergence

¹ Batch-size

² Epochs

³ Learning rate

⁴ Precision

⁵ Recall



شکل ۵- عملکرد مدل بر روی تصاویر آزمون
Fig5. Model performance on test images

ماتریس اغتشاش^۱ ارائه شده در شکل ۶ عملکرد مدل یولو نسخه ۱۱ کوچک را در شناسایی رفتار جوجه‌ها در سه کلاس معمولی، خوردن و آشامیدن نمایش می‌دهد. در این ماتریس، محور افقی نشان‌دهنده کلاس‌های واقعی^۲ و محور عمودی بیانگر خروجی مدل^۳ است. خانه‌های روی قطر اصلی تعداد نمونه‌هایی را نشان می‌دهند که به درستی طبقه‌بندی شده‌اند، در حالی که سایر خانه‌ها نشان‌دهنده مواردی هستند که مدل آن‌ها را به اشتباه در کلاس‌های دیگر قرار داده است. شدت رنگ نیز بیانگر فراوانی نمونه‌ها در هر خانه بوده و رنگ‌های تیره‌تر نشان‌دهنده مقادیر بیشتر هستند.

تحلیل این ماتریس نشان می‌دهد که مدل در شناسایی رفتارهای آشامیدن و خوردن عملکرد بهتری داشته، اما در تفکیک رفتار معمولی با چالش‌هایی روبه‌رو است. به‌طور خاص، درصد قابل توجهی از نمونه‌ها به‌عنوان رفتار معمولی طبقه‌بندی شده‌اند، که این موضوع احتمالاً ناشی از عدم برچسب‌گذاری برخی رفتارهای معمولی در داده‌های آموزشی است. به عنوان نمونه، ۸۱ مورد از جوجه‌ها که برچسب رفتاری نداشتند، توسط مدل در دسته معمولی قرار گرفته‌اند. این مسئله می‌تواند بر دقت کلی مدل تأثیر بگذارد و نشان‌دهنده نیاز به بهبود فرآیند برچسب‌گذاری داده‌ها برای افزایش تفکیک‌پذیری رفتارها است.

باشد. همچنین، میانگین زمان پردازش برای هر تصویر ۲/۸ میلی ثانیه بر روی واحد پردازنده گرافیکی بوده که نشان‌دهنده توانایی مدل در پردازش بلادرنگ است، عاملی که در کاربردهای عملی نظیر پایش خودکار مرغداری‌ها اهمیت زیادی دارد.

در شکل ۵ دو نمونه از تصاویر مربوط به زیرمجموعه آزمایش که توسط مدل شناسایی و طبقه‌بندی شده‌اند، نمایش داده شده است. با بررسی و تحلیل دقیق این تصاویر، مشاهده می‌شود که مدل توانسته است به طور مؤثر رفتار جوجه‌ها را شناسایی و به درستی طبقه‌بندی کند. علاوه بر این، مدل توانسته بود جوجه‌هایی را که قبلاً برچسب‌گذاری نشده و در روند آموزش دخالتی در آن‌ها صورت نگرفته است را نیز به درستی ولی با دقت کمتر شناسایی و طبقه‌بندی کند. این نتایج، توانایی بالای مدل یولو نسخه ۱۱ کوچک را در تعمیم‌پذیری و دقت در شناسایی و کلاس‌بندی رفتار جوجه‌ها نشان می‌دهد. این ویژگی، مدل را به ابزاری قابل اعتماد برای کاربردهای عملی در محیط‌های واقعی تبدیل می‌کند.

جدول ۱- نتایج عملکرد مدل بر روی داده‌های آزمایشی


Table1. Model performance results on test datas

کلاس(رفتار)	دقت(%)	یادآوری(%)	میانگین دقت متوسط (%) 0.5	زمان تشخیص به ازای یک تصویر (ms)
کل کلاس‌ها All classes	83.5	88.9	90.6	2.8
خوردن Eating	94	100	99.5	
آشامیدن Drinking	80.7	88.9	89.5	
معمولی Normal	75.8	77.8	82.9	

³ Predict

¹ Confusion matrix

² Target



شکل ۶- ماتریس اغتشاش طبقه‌بندی رفتارها

Fig 6. Confusion matrix for behavior classification

هوشمند بر رفتار حیوانات به خصوص جوجه‌ها در مرغداری مورد استفاده قرار گیرد.

با توجه به نتایج به‌دست‌آمده، جهت تحقیقات آینده پیشنهاد می‌شود که برای بهبود عملکرد مدل در تشخیص رفتارهای جوجه‌ها، تنوع و کیفیت داده‌های آموزشی افزایش یابد و فرآیند برچسب‌گذاری با دقت بیشتری انجام شود، به‌ویژه در کلاس رفتارهای معمولی که احتمال دارد برخی نمونه‌ها بدون برچسب باقی مانده باشند. همچنین، پیشنهاد می‌شود که از مدل‌های ترکیبی یا چندمرحله‌ای برای جداسازی بهتر کلاس‌های مشابه استفاده شود. در نهایت، بررسی عملکرد مدل در شرایط واقعی و مقایسه آن با روش‌های سنتی پایش رفتار، می‌تواند به کاربرد عملی این سیستم در صنعت مرغداری کمک کرده و مسیر توسعه فناوری‌های نظارت هوشمند را هموارتر سازد.

سپاس‌گزاری

نویسندگان مراتب قدردانی صمیمانه خود را از کارکنان ایستگاه تحقیقاتی خلعت‌پوشان دانشگاه تبریز و دانشجویان مرغداری تحقیقاتی طیور مستقر در این ایستگاه، به‌واسطه‌ی فراهم‌سازی امکانات لازم و پشتیبانی ارزشمند در طول فرآیند جمع‌آوری داده‌ها، ابراز می‌دارند.

منابع

Balasubramaniam, S., Vijesh Joe, C., Prasanth, A., & Kumar, K. S. (2025). *Computer Vision Systems in Livestock Farming, Poultry Farming, and Fish Farming: Applications, Use Cases, and Research Directions*.

۴- نتیجه‌گیری نهایی

در این پژوهش، مدل یولو نسخه ۱۱ کوچک برای تشخیص و طبقه‌بندی رفتارهای جوجه‌ها از نمای بالا مورد بررسی قرار گرفت. نتایج ارزیابی نشان داد که این مدل با داشتن معماری بهینه، دقت و سرعت مناسبی برای پردازش زمان واقعی دارد. عملکرد مدل در تشخیص رفتار خوردن بسیار مطلوب بود و با دقت ۹۴ درصد و یادآوری ۱۰۰ درصد بالاترین میزان تفکیک‌پذیری را ثبت کرد. در مقابل، رفتار معمولی به دلیل تنوع گسترده و احتمال عدم برچسب‌گذاری برخی نمونه‌ها، پایین‌ترین دقت (۷۵/۸ درصد) و یادآوری (۷۷/۸ درصد) را داشت. بررسی روند آموزش و اعتبارسنجی مدل نیز نشان داد که مقدار اتلاف در طول آموزش به‌تدریج کاهش یافته و مدل توانسته به تعادل برسد.

همچنین، تحلیل معیارهای ارزیابی نشان داد که مدل از نظر پردازشی کارآمد بوده و با میانگین ۲/۸ میلی‌ثانیه برای هر تصویر، توانایی پردازش زمان واقعی را دارد. این ویژگی، مدل را به گزینه‌ای مناسب برای پایش خودکار در مرغداری‌ها تبدیل می‌کند. با این حال، برای بهبود عملکرد به‌ویژه در کلاس رفتارهای معمولی، افزایش کیفیت و دقت در برچسب‌گذاری داده‌ها می‌تواند نقش مؤثری ایفا کند. در نهایت، یولو نسخه ۱۱ کوچک با بهره‌گیری از طراحی بهینه، کاهش تعداد پارامترها و افزایش دقت استخراج ویژگی‌ها، نشان داد که در مقایسه با نسخه‌های پیشین، تعادل بهتری بین دقت و سرعت برقرار کرده و می‌تواند به‌عنوان یک راهکار نوین در حوزه نظارت

- Hecht-Nielsen, R. (1992). *Theory of the backpropagation neural network*. In *Neural networks for perception* (pp. 65-93). Elsevier.
<https://doi.org/https://doi.org/10.1016/B978-0-12-741252-8.50010-8>
- Hertz, T., & Zahniser, S. (2013). *Is there a farm labor shortage?* American Journal of Agricultural Economics, 95(2), 476-481.
<https://doi.org/https://www.jstor.org/stable/23358420>
- Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). *Densely connected convolutional networks*. Proceedings of the IEEE conference on computer vision and pattern recognition,
- Jordan, M. I., & Mitchell, T. M. (2015). *Machine learning: Trends, perspectives, and prospects*. Science, 349(6245), 255-260.
<https://doi.org/https://doi.org/10.1126/science.aaa8415>
- Kashiha, M., Pluk, A., Bahr, C., Vranken, E., & Berckmans, D. (2013). *Development of an early warning system for a broiler house using computer vision*. Biosystems Engineering, 116(1), 36-45.
<https://doi.org/https://doi.org/10.1016/j.biosystemseng.2013.06.004>
- Khanam, R., & Hussain, M. (2024). *Yolov11: An overview of the key architectural enhancements*. arXiv preprint arXiv:2410.17725.
<https://doi.org/https://doi.org/10.48550/arXiv.2410.17725>
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). *Imagenet classification with deep convolutional neural networks*. Advances in neural information processing systems, 25.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). *Deep learning*. nature, 521(7553), 436-444.
<https://doi.org/https://doi.org/10.1038/nature14539>
- Likas, A., Vlassis, N., & Verbeek, J. J. (2003). *The global k-means clustering algorithm*. Pattern recognition, 36(2), 451-461. [https://doi.org/https://doi.org/10.1016/S0031-3203\(02\)00060-2](https://doi.org/https://doi.org/10.1016/S0031-3203(02)00060-2)
- McLeod, A. (2011). *World Livestock 2011-Livestock in food security*.
- O'shea, K., & Nash, R. (2015). *An introduction to convolutional neural networks*. arXiv preprint arXiv:1511.08458.
<https://doi.org/https://doi.org/10.48550/arXiv.1511.08458>
- Okinda, C., Nyalala, I., Korohou, T., Okinda, C., Wang, J., Achieng, T., Wamalwa, P., Mang, T., & Shen, M. (2020). *A review on computer vision systems in monitoring of poultry: A welfare perspective*. Artificial Intelligence in Agriculture, 4, 184-208.
<https://doi.org/https://doi.org/10.1016/j.aiia.2020.09.002>
- Computer Vision in Smart Agriculture and Crop Management, 221-258.
<https://doi.org/https://doi.org/10.1002/9781394186686.ch10>
- Bezdek, J. C., Ehrlich, R., & Full, W. (1984). *FCM: The fuzzy c-means clustering algorithm*. Computers & geosciences, 10(2-3), 191-203.
[https://doi.org/https://doi.org/10.1016/0098-3004\(84\)90020-7](https://doi.org/https://doi.org/10.1016/0098-3004(84)90020-7)
- Bhuiyan, M. R., & Wree, P. (2023). *Animal behavior for chicken identification and monitoring the health condition using computer vision: A systematic review*. IEEE access, 11, 126601-126610.
<https://doi.org/https://doi.org/10.1109/ACCESS.2023.3331092>
- Chai, L., Xin, H., Wang, Y., Oliveira, J., Wang, K., & Zhao, Y. (2019). *Mitigating particulate matter generation in a commercial cage-free hen house*. Transactions of the ASABE, 62(4), 877-886.
- Chai, L., Zhao, Y., Xin, H., Wang, T., & Soupir, M. L. (2018). *Mitigating airborne bacteria generations from cage-free layer litter by spraying acidic electrolysed water*. Biosystems Engineering, 170, 61-71.
<https://doi.org/https://doi.org/10.1016/j.biosystemseng.2018.03.013>
- Deng, J., Dong, W., Socher, R., Li, L.-J., Li, K., & Fei-Fei, L. (2009). *Imagenet: A large-scale hierarchical image database*. 2009 IEEE conference on computer vision and pattern recognition,
- Depuru, B. K., Putsala, S., & Mishra, P. (2024). *Automating poultry farm management with artificial intelligence: Real-time detection and tracking of broiler chickens for enhanced and efficient health monitoring*. Tropical Animal Health and Production, 56(2), 75.
<https://doi.org/https://doi.org/10.1007/s11250-024-03922-2>
- Guo, Q., Jin, S., Li, M., Yang, Q., Xu, K., Ju, Y., Zhang, J., Xuan, J., Liu, J., & Su, Y. (2020). *Application of deep learning in ecological resource research: Theories, methods, and challenges*. Science China Earth Sciences, 63, 1457-1474.
<https://doi.org/https://doi.org/10.1007/s11430-019-9584-9>
- Guo, Y., Aggrey, S. E., Wang, P., Oladeinde, A., & Chai, L. (2022). *Monitoring behaviors of broiler chickens at different ages with deep learning*. Animals, 12(23), 3390.
<https://doi.org/https://doi.org/10.3390/ani12233390>
- Guo, Y., Chai, L., Aggrey, S. E., Oladeinde, A., Johnson, J., & Zock, G. (2020). *A machine vision-based method for monitoring broiler chicken floor distribution*. Sensors, 20(11), 3179.
<https://doi.org/https://doi.org/10.3390/s20113179>

- Otsu, N. (1975). *A threshold selection method from gray-level histograms*. Automatica, 11(285-296), 23-27. <https://doi.org/https://doi.org/10.1109/TSMC.1979.4310076>
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). *You only look once: Unified, real-time object detection*. Proceedings of the IEEE conference on computer vision and pattern recognition,
- Tilman, D., Balzer, C., Hill, J., & Befort, B. L. (2011). *Global food demand and the sustainable intensification of agriculture*. Proceedings of the national academy of sciences, 108(50), 20260-20264. <https://doi.org/https://doi.org/10.1073/pnas.1116437108>
- Varghese, R., & Sambath, M. (2024). *Yolov8: A novel object detection algorithm with enhanced performance and robustness*. 2024 International Conference on Advances in Data Engineering and Intelligent Computing Systems (ADICS),
- Werner, A., & Jarfe, A. (2003). *Programme book of the joint conference of ECPA-ECPLF*.
- Wspanialy, P., Brooks, J., & Moussa, M. (2020). *An image labeling tool and agricultural dataset for deep learning*. arXiv preprint arXiv:2004.03351. <https://doi.org/https://doi.org/10.48550/arXiv.2004.03351>
- Yitbarek, M. B. (2019). *Livestock and livestock product trends by 2050*. IJAR, 4, 30.