



Development and Evaluation of an Intelligent Machine Vision System for Detecting Chicken Gizzard Adulteration in Minced Red Meat

Mobin Rezazadeh¹ | Sajad Kiani² | Mahdi Ghasemi Varnamkhasti³ | Zahra Izadi⁴

1. Mechanical Engineering of Biosystems Department, Faculty of Agriculture, Shahrekord University, Shahrekord, Iran.

E-mail: mobinrezazadeh905@gmail.com

2. Corresponding Author, Biosystems Engineering Department, Faculty of Agriculture, Sari University of Agricultural Sciences and Natural Resources, Sari, Iran. E-mail: s.kiani@sanru.ac.ir

3. Corresponding Author, Mechanical Engineering of Biosystems Department, Faculty of Agriculture, Shahrekord University, Shahrekord, Iran. E-mail: ghasemymahdi@gmail.com

4. Mechanical Engineering of Biosystems Department, Faculty of Agriculture, Shahrekord University, Shahrekord, Iran. E-mail: z.zahraizadi@gmail.com

Article Info

ABSTRACT

Article type: Research Article

Article history:

Received: July. 8, 2025

Revised: Sep. 28, 2025

Accepted: Sep. 29, 2025

Published online: Summer 2025

Keywords:

*Artificial neural network,
Image processing,
Food fraud,
Modeling*

In this study, an intelligent machine-vision system was developed and evaluated for detecting chicken gizzard adulteration in ground red mutton-veal meat, using digital images captured by a mobile phone. To this end, standard samples of minced red meat (55% mutton and 45% beef) with varying proportions of chicken gizzard (0 to 100%) were prepared, and images were captured in a laboratory environment both directly from the sample surface and through plastic wrap packaging. The color features (RGB) of the images were extracted using the MATLAB image processing toolbox, and modeling was performed employing statistical and machine learning methods, including Principal Component Analysis (PCA), Partial Least Squares Regression (PLSR), and Multilayer Perceptron (MLP) neural networks. The best performance of the linear PLSR model for estimating the adulteration percentage yielded an $R^2V=0.7$ and $RMSEV=16.51$ under conditions without plastic wrap, whereas the nonlinear MLP model achieved an $R^2V=0.97$ and $RMSEV=6.673$. These results were lower (0.9 and 12.54) for the data acquisition through plastic wrap due to the light reflections caused by the covering. Furthermore, the MLP classifier achieved classification accuracies of 85%, 96.4%, 92.6%, 73.7%, 76.2%, and 96.7% for adulteration levels 0-10%, 10-20%, 20-30%, 30-40%, 40-50%, and above 50%, respectively. The average precision, sensitivity, and F1 score for the developed model were obtained as 0.975, 0.974, and 0.975, respectively. The results showed that this non-destructive method is both fast and reliable for identifying gizzard fraud in ground meat, and can serve as a basis for developing meat quality control systems.

Cite this article: Rezazadeh, M., Kiani, S., Ghasemi Varnamkhasti, M., & Izadi, Z (2025). Development and Evaluation of an Intelligent Machine Vision System for Detecting Chicken Gizzard Adulteration in Minced Red Meat, *Iranian Journal of Biosystem Engineering*, 56 (2), 90-105. <https://doi.org/10.22059/ijbse.2025.398182.665600>

© The Author(s).

Publisher: University of Tehran Press.

DOI: <https://doi.org/10.22059/ijbse.2025.398182.665600>



EXTENDED ABSTRACT

Introduction

Food adulteration is a significant issue that impacts food safety, consumer trust, and regulatory compliance globally. One common form of adulteration in meat products involves the unauthorized addition of cheaper or lower-quality ingredients to higher-value meats. Specifically, the adulteration of chicken gizzard—a low-cost offal—into minced red meat, such as beef and mutton, poses both economic and health concerns. Traditional methods for detecting such adulteration often involve destructive, time-consuming, and costly laboratory analyses, which limit their applicability for rapid quality control.

This study aims to develop and evaluate an intelligent machine vision system capable of detecting chicken gizzard adulteration in minced red meat through non-destructive and rapid analysis. The core objective is to assess the feasibility of using digital color images captured by a mobile phone to identify and quantify the presence of chicken gizzard in mixtures of beef and mutton meat. By leveraging advances in image processing and machine learning, this approach offers a cost-effective and efficient solution for detecting food fraud.

Materials and Methods

To simulate real-world adulteration scenarios, standard minced red meat samples were prepared with a fixed base composition of 55% mutton and 45% beef. Chicken gizzard was added to these base samples in varying proportions, ranging from 0% (pure red meat) to 100% (pure chicken gizzard), creating a comprehensive gradient of adulteration levels for analysis.

Image acquisition was performed in a typical laboratory environment to evaluate the system's robustness under less controlled circumstances. Each sample was imaged in two ways: directly from the exposed meat surface and through transparent plastic wrap packaging, simulating commercial retail conditions.

The color features of the captured images were extracted in the RGB (Red, Green, Blue) color space using MATLAB's image processing toolbox. These color components served as the primary input variables for subsequent modeling.

Data analysis involved a combination of statistical and machine learning techniques. Principal Component Analysis (PCA) was first applied to visually discriminate the samples and identify the most significant color features related to adulteration. Partial Least Squares Regression (PLSR), a linear modeling technique, was then used to predict the percentage of chicken gizzard adulteration based on the extracted RGB features. To capture nonlinear relationships and enhance prediction accuracy, a Multilayer Perceptron (MLP) neural network was also developed and trained on the dataset.

Results

The analysis revealed a clear trend in color changes corresponding to increasing levels of chicken gizzard adulteration. This shift in color composition reflects the intrinsic differences in tissue pigmentation between red meat and chicken gizzard, providing a reliable basis for discrimination.

Quantitative evaluation of the models showed that the linear PLSR model achieved a coefficient of determination (R^2) of 0.7 and a root mean square error (RMSE) of 16.51 when predicting adulteration levels in images captured without plastic wrap. While this indicates moderate accuracy, the nonlinear MLP model significantly outperformed PLSR, achieving an R^2 of 0.97 and RMSE of 6.67 under the same conditions. This demonstrates the superior capability of nonlinear modeling in capturing complex relationships between color features and adulteration levels. These results were lower (0.9 and 12.54) for the data acquisition through plastic wrap due to the light reflections caused by the covering. Furthermore, the MLP model was implemented as a classifier to categorize samples into discrete adulteration intervals: 0–10%, 10–20%, 20–30%, 30–40%, 40–50%, and above 50%. The classification accuracies achieved were 85%, 96.4%, 92.6%, 73.7%, 76.2%, and 96.7%, respectively. The average precision, sensitivity, and F1 score for the developed model were obtained as 0.975, 0.974, and 0.975, respectively. These results indicate that the system can reliably detect levels of adulteration ranging from low to high.

Conclusion

This study demonstrates that color image analysis combined with advanced machine learning techniques offers a non-destructive, rapid, and reliable method for detecting chicken gizzard adulteration in minced red meat. The developed machine vision system effectively distinguishes adulterated samples and accurately estimates the level of adulteration, particularly when employing nonlinear models such as MLP neural networks. The ability to perform such analysis through images captured even under less controlled lighting conditions and through plastic wrap packaging highlights the practical applicability of the system in real-world food quality control environments. This approach can serve as a foundation for developing automated,



software-based quality assurance tools in the food industry, enhancing the detection of food fraud and protecting consumer interests. Future work may focus on expanding the system to detect other types of adulterants, integrating hyperspectral imaging techniques for improved sensitivity, and developing user-friendly interfaces to facilitate adoption by food producers and regulatory agencies.

Authorship Contribution

Mobin Rezazadeh: Writing – original draft, Methodology, Data curation, Software, Formal analysis.

Sajad Kiani: Writing – review and editing, Formal analysis, Investigation, Data curation, Validation.

Mahdi Ghasemi Varnamkhasti: Review and edit, conceptualize, supervise, and manage project administration.

Zahra Izadi: Advisor, methodology, and resources.

Data Availability

Data available on request from the authors. All the data used in this original research are presented throughout the text and in the form of Tables and Figures.

Ethical considerations

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

Funding

This research did not receive any specific grant from funding agencies in the public, commercial, or not-for-profit sectors.

Conflict of interest

The author declares no conflict of interest.

توسعه و ارزیابی یک سامانه بینایی ماشین هوشمند به منظور تشخیص تقلب سنگدان مرغ در گوشت قرمز چرخ کرده

مبین رضازاده^۱ | سجاد کیانی^۲ | مهدی قاسمی ورنامخواستی^۳ | زهرا ایزدی^۴

۱- گروه مهندسی مکانیک بیوسیستم، دانشکده کشاورزی دانشگاه شهرکرد، شهرکرد، ایران. رایانامه: mobinrezazadeh905@gmail.com

۲- نویسنده مسئول: گروه مهندسی مکانیک بیوسیستم، دانشکده کشاورزی، دانشگاه علوم کشاورزی و منابع طبیعی ساری، ساری، ایران. رایانامه:

s.kiani@sanru.ac.ir

۳- نویسنده مسئول: گروه مهندسی مکانیک بیوسیستم، دانشکده کشاورزی، دانشگاه شهرکرد، شهرکرد، ایران. رایانامه:

ghasemymahdi@gmail.com

۴- گروه مهندسی مکانیک بیوسیستم، دانشکده کشاورزی، دانشگاه شهرکرد، شهرکرد، ایران. رایانامه: z.zahraizadi@gmail.com

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی	در این پژوهش سامانه‌ای هوشمند مبتنی بر بینایی ماشین با بهره‌گیری از تحلیل رنگی تصاویر دیجیتال گرفته شده با تلفن همراه برای تشخیص تقلب افزودن سنگدان مرغ به گوشت قرمز گوسفندی-گوساله چرخ شده توسعه داده و ارزیابی شد. بدین منظور، نمونه‌هایی مرسوم گوشت قرمز چرخ شده (۵۵٪ گوسفند و ۴۵٪ گوساله) با درصد‌های مختلف سنگدان (۰ تا ۱۰۰ درصد) تهیه و در شرایط نورپردازی محیطی آزمایشگاه مستقیم از روی نمونه و از روی بسته سلفونی تصویربرداری شدند. ویژگی‌های رنگی (R، G، و B) تصاویر نمونه‌ها در محیط متلب استخراج و با روش‌های یادگیری ماشین شامل تحلیل مؤلفه‌های اصلی (PCA)، رگرسیون حداقل مربعات جزئی (PLSR) و شبکه عصبی مصنوعی پرسپترون چندلایه (MLP) مدل‌سازی انجام شد. بهترین نتایج مدل PLSR برای تخمین درصد تقلب با ضریب تعیین R^2 و شاخص RMSR در حالت بدون پوشش سلفون برابر با ۰/۷ و ۱۶/۵۱ حاصل شد. این شاخص‌ها برای مدل MLP برابر با ۰/۹۷ و ۶/۶۷۳ بدست آمد در صورتی که نتایج برای حالت با پوشش سلفون به دلیل انعکاس‌های نوری پوشش پایین‌تر (۰/۹۰ و ۱۲/۵۴) بدست آمد. مدل طبقه‌بند MLP با دقت‌های ۸۵٪، ۹۶/۴٪ و ۹۲/۶٪، ۷۳/۷٪، ۷۶/۲٪ و ۹۶/۷٪ به ترتیب نمونه‌های تقلبی ۱۰٪، ۲۰٪، ۳۰٪، ۴۰٪، ۵۰٪ و بیش از ۵۰٪ را طبقه‌بندی کرد. میانگین‌های صحت، حساسیت و F1 score برای مدل ایجاد شده به ترتیب ۰/۹۷۵، ۰/۹۷۴ و ۰/۹۷۵ بدست آمد. نتایج نشان داد این روش غیرمخرب، سریع و قابل اعتماد برای شناسایی تقلب سنگدان در گوشت چرخ کرده است و می‌تواند به عنوان مبنایی برای توسعه سامانه‌های کنترل کیفیت گوشت مورد استفاده قرار گیرد.
واژه‌های کلیدی: پردازش تصویر، تقلب غذایی، شبکه‌های عصبی مصنوعی، مدل‌سازی	

استاد: رضازاده، مبین؛ کیانی، سجاد؛ قاسمی ورنامخواستی، مهدی؛ ایزدی، زهرا (۱۴۰۴). توسعه و ارزیابی یک سامانه بینایی ماشین هوشمند به منظور

تشخیص تقلب سنگدان مرغ در گوشت قرمز چرخ کرده، مجله مهندسی بیوسیستم ایران، ۵۶ (۲)، ۱۰۵-۹۰.



<https://doi.org/10.22059/ijbse.2025.398182.665600>

© نویسندگان.

ناشر: مؤسسه انتشارات دانشگاه تهران.

DOI: <https://doi.org/10.22059/ijbse.2025.398182.665600>

مقدمه

گوشت یک ماده غذایی سرشار از پروتئین است که مصرف آن برای سلامت مغز و جسم انسان بسیار ضروری می‌باشد. حذف آن از رژیم غذایی می‌تواند باعث اضافه‌وزن و بی‌حالی، بیماری‌های قلبی-عروقی، افسردگی، استرس و حملات عصبی و بیش‌فعالی شود. پروتئین موجود در آن جهت ارتقای رشته‌های عصبی مغز حائز اهمیت است (Azari et al., 2021). علاوه بر این حاوی برخی از مواد مغذی و ویتامین‌های بسیار مهم از جمله ویتامین B12، D، پروتئین با کیفیت بالا، چندین اسید آمینه و اسیدهای چرب امگا ۳ است. حذف گوشت از سبد غذایی به معنای عدم دریافت این مواد مغذی مهم است که می‌تواند در طولانی مدت به بدن آسیب برساند. غنی بودن گوشت از پروتئین‌های ارزشمند حاوی اسیدهای آمینه ضروری برای بدن، مواد معدنی مانند آهن و روی، انواع ویتامین‌ها و انرژی کافی سبب می‌شود تا آن را در دسته بهترین و کامل‌ترین مواد غذایی طبقه‌بندی کنند (Dehnavi et al., 2005). بر اساس آمارهای سازمان جهانی بهداشت، میانگین مصرف گوشت قرمز در ایران حدود ۱۲/۵ کیلوگرم در سال برای هر نفر است (WHO, 2024).

گوشت چرخ‌کرده یکی از فرآورده‌های گوشتی پرمصرف در آشپزی ایرانی است که از ترکیب گوشت‌های قرمز گوسفند (۵۵ تا ۶۰ درصد) و گوساله (۴۰ تا ۴۵ درصد) تهیه می‌شود. این نوع گوشت با استفاده از دستگاه چرخ‌گوشت تأمین می‌شود تا به‌صورت خمیری و یکنواخت درآید. گوشت چرخ‌کرده به‌عنوان یکی از پرمصرف‌ترین فرآورده‌های گوشتی، در تولید محصولات مختلفی نظیر همبرگر، سوسیس، کالباس و کباب نقش دارد. ساختار همگن این محصول، اگرچه آماده‌سازی و مصرف آن را آسان‌تر می‌سازد، اما شناسایی نوع گوشت و تشخیص تقلب در آن را دشوار کرده است (Dean et al., 2005). عرضه فله‌ای و تنوع ترکیبات اولیه، امکان سوء استفاده و افزودن اجزای غیرمجاز یا ارزان قیمت را افزایش می‌دهد، به‌ویژه در کشورهایی که نظارت ضعیف‌تری اعمال می‌شود (Morsy & Sun, 2013). توسعه و به‌کارگیری روش‌های نوین برای شناسایی و تحلیل ترکیبات گوشت، به عنوان یک اقدام کلیدی در راستای حفظ کیفیت و اصالت محصولات گوشتی، ضروری است. همچنین، ایجاد استانداردهای دقیق و نظارت‌های مستمر بر زنجیره تأمین این محصولات می‌تواند به تقویت اعتماد مصرف‌کنندگان و ارتقاء ایمنی غذایی کمک شایانی نماید. همچنین تقلب در نمونه‌ها به‌صورت اختلاط آلاینش مرغی در آنها، چه در فرآورده‌های صنعتی دارای نشان استاندارد مانند محصولات فرآوری شده و نیمه فرآوری شده و چه در گوشت‌های خام قابل مشاهده است بطوری که در مجموع، ۲۳ درصد از نمونه‌های اخذ شده از نظر اصالت گوشت مورد تأیید قرار نمی‌گیرند (Sadeghpour et al., 2019). مخلوط کردن سنگدان مرغ با ترکیب گوشت گوسفند و گوساله از شایع‌ترین تقلبات در گوشت چرخ‌کرده است. در راستای مقابله با این چالش، روش‌های آزمایشگاهی متعددی توسعه یافته است. روش‌هایی نظیر واکنش زنجیره‌ای پلیمرز (PCR)، کروماتوگرافی گازی، طیف‌سنجی جرمی و میکروسکوپی الکترونی دقت بالایی دارند؛ اما پرهزینه، زمان‌بر و نیازمند تجهیزات پیشرفته و نیروی متخصص هستند و همچنین امکان استفاده از آن‌ها خارج از آزمایشگاه وجود ندارد (Ballin, 2010).

یکی از روش‌های نوین در سنجش کیفیت و تقلب در مواد غذایی، استفاده از بینایی ماشین است. بینایی ماشین علاوه بر سرعت بخشیدن در کار، اقتصادی نیز است و در بحث نظارت و ارزیابی بسیار کاربردی است. این روش توانایی بالایی در تشخیص و درجه‌بندی خودکار تقلب در مواد غذایی با استفاده از مقایسه رنگ و ساختار بافت نمونه‌ها دارد. بینایی ماشین به مجموعه‌ای از روش‌ها و فناوری‌هایی اطلاق می‌شود که برای تحلیل خودکار تصاویر به کار می‌رود و در کاربردهایی چون کنترل کیفیت، هدایت ماشین، نظارت خودکار و بسته‌بندی محصولات مورد استفاده قرار می‌گیرد (Minaei et al., 2017). این فناوری در حوزه کشاورزی نیز برای ارزیابی محصولات به‌ویژه از نظر ویژگی‌های ظاهری نظیر رنگ، اندازه و شکل در خارج از آزمایشگاه گسترش یافته است. در ادامه تعدادی از کاربردهای این سامانه در کیفیت‌سنجی گوشت آورده شده است.

در پژوهشی با استفاده از تحلیل پردازش تصاویر نشان دادند که درصد گوشت گزارش شده در محصول تولیدی کارخانه با میزان به دست آمده پس از آزمون بافت‌شناسی از نظر آماری اختلاف معنی‌داری با یکدیگر نداشتند. همچنین نتایج بررسی میزان افزودنی‌های گیاهی با استفاده از روش بافت‌شناسی و تحلیل تصویری با میزان گزارش شده آن از طرف واحد تولیدی نیز از نظر آماری فاقد اختلاف معنی‌دار بودند (Asadi et al., 2023). جهت تخمین مقدار چربی گوشت قرمز از فناوری پردازش تصویر استفاده شد (Dosti Irani et al., 2013). این مطالعه پتانسیل تحلیل بافت، در ترکیب با تحلیل رنگی تصویر، را برای پیش‌بینی تردی گوشت نشان داد. همچنین با تجزیه و تحلیل تصاویر و محاسبه پیکسل‌های مربوط به ناحیه چربی میزان دقت و صحت الگوریتم جهت شناسایی و بررسی دو نوع بافت گوشت و چربی

خالص به ترتیب برابر با ۹۹/۶۵ و ۹۹/۲۱ درصد گزارش شد. در پژوهشی دیگر با نمونه برداری قسمت های مشخص شده گوشت گوساله و قراردادن آن ها در دو محیط رایج (دمای ۸ درجه سلسیوس) و استاندارد (دمای ۳ درجه سلسیوس) و تصویربرداری از آن ها در زمان های مختلف و سپس تجزیه و تحلیل تصاویر به وسیله فناوری پردازش تصویر توانستند سامانه ای راه اندازی کنند که تازگی گوشت را بررسی و مشخص کند (Javadi, et al., 2017). برای نظارت سریع و غیرمخرب محتوای TVB-N^۱ در طول خشک کردن گوشت پخته از سامانه تصویربرداری فراطیفی^۲ (HSI) در محدوده طیفی ۴۰۰ تا ۱۰۰۰ نانومتر استفاده شد (Yang et al., 2017). مدل های کالیبراسیون چندمتغیره حداقل مربعات جزئی^۳ (PLSR) و ماشین های بردار پشتیبان حداقل مربعات^۴ (LS - SVM) در محدوده طیفی کامل با دقت قابل قبول محتوای TVB-N را تخمین زدند. در مطالعه ای دیگر با استفاده از یک حسگر رنگی محتوای پروتئین نمونه های متعدد گوشت خوک فرآوری شده با استفاده از شبکه عصبی پرسپترون چند لایه^۵ (MLP) و مدل های پیش بینی PLSR با موفقیت ارزیابی شد (Ma et al., 2019). سامانه تصویربرداری برای ارزیابی تقلب های گیاهی و حیوانی در گوشت چرخ کرده در سطوح ۱ تا ۵۰ درصد مورد استفاده قرار گرفت (Rady et al., 2021). در این پژوهش نتایج نشان داد تعیین و تشخیص سطح مواد افزودنی با مقادیر $R^2=0.98$ و خطای کمتر از ۲/۵٪ تعیین شد. در پژوهشی دیگر بیان شد که محتوای خون در گوشت جزء حیاتی آن از منظر حلال بودن و بهداشت مواد غذایی است؛ زیرا چگونگی کشته شدن حیوان یا پرند را مشخص می کند که نقش حیاتی نیز در کیفیت بافت گوشت دارد. (Koekoeh et al., 2022). آنها روش پردازش تصویر را به عنوان ابزاری مقرون به صرفه، مؤثر و مفید برای تعیین محتوای خونی گوشت را ارائه و به وسیله آن توانستند حلال بودن و نبودن گوشت را تعیین کنند. در جدیدترین پژوهش با استفاده از تصویربرداری از گوشت خالص آلپاکا^۶ و استفاده از روش های شیمی سنجی^۷ تقلب در این محصول با افزودنی های گوشت گاو و خوک با دقت قابل قبول تشخیص داده شد (Cruz et al., 2024). با توجه به پژوهش های انجام شده فناوری بینایی ماشین با بهره گیری از الگوریتم های یادگیری ماشین امکان ارزیابی سریع و دقیق کیفیت گوشت را فراهم می سازد و در کنار روش های تحلیلی سنتی، می تواند نقش مهمی در ارتقای ایمنی غذایی و پیشگیری از تقلب ایفا کند. سامانه های بینایی ماشین برای عملکرد دقیق و قابل اطمینان نیازمند نورپردازی مناسب و کنترل شده هستند. نور یکی از عوامل کلیدی است که کیفیت تصویر ثبت شده توسط دوربین را به شدت تحت تأثیر قرار می دهد و کمبود یا افزایش نامناسب نور می تواند منجر به کاهش وضوح، ایجاد سایه ها، بازتاب های ناخواسته و کاهش کنتراست تصویر شود. این موضوع یکی از چالش های مهم در کاربرد سامانه های بینایی ماشین برای تشخیص تقلب در محیط های واقعی خارج از آزمایشگاه است. برای غلبه بر این چالش استفاده از الگوریتم های تطبیق پذیر با تغییرات نوری و کالیبراسیون تجهیزات تصویربرداری ضروری است. در این پژوهش امکان سنجی انجام اصالت سنجی گوشت قرمز چرخ شده با استفاده از تصاویر دوربین تلفن همراه در محیط با نورپردازی فروشگاه (نورپردازی از سقف) بررسی شد. بنابراین اهداف این پژوهش عبارت بودند از: (۱) طراحی و پیاده سازی سامانه بینایی ماشین هوشمند مجهز به نرم افزار آنالیز تصویر و (۲) ارزیابی سامانه پیاده سازی شده در تشخیص درصد تقلب سنگدان مرغ در ترکیب گوشت چرخ کرده گوسفندی-گوساله در محیط فروشگاه.

مواد و روش ها

تهیه و آماده سازی نمونه ها

برای شبیه سازی فرایند تقلب در گوشت چرخ کرده، گوشت گوساله (سردست) و گوسفندی (قلوه گاه) با کیفیت بالا و تازه تهیه و با ترکیب استاندارد و وزنی ۴۵٪ گوشت گوساله و ۵۵٪ گوشت گوسفندی با دستگاه چرخ گوشت صنعتی چرخ و ترکیب شدند. سنگدان تازه مرغ نیز تهیه و مشابه با نمونه های گوشت چرخ شده. نمونه های گوشت چرخ شده تقلبی بعد از اضافه کردن سنگدان چرخ شده با درصدهای مختلف از سنگدان مرغ، ۰٪ تا ۱۰۰٪ با بازه ۵٪ تقلب (۰٪ گوشت چرخ شده خالص و ۱۰۰٪ سنگدان چرخ شده خالص) تهیه شدند. تمامی ۲۱ عدد نمونه به منظور یکنواختی مجدد چرخ شدند.

1- Total Volatile Basic Nitrogen

2- Hyperspectral Imaging

3- Partial Least Squares

4- Least squares

5- Multilayer Perceptron

6- Alpaca

7- Chemometrics

تصویربرداری از نمونه‌ها

فرایند پردازش تصاویر با تصویربرداری آغاز می‌شود. در این مرحله، تصاویر نمونه‌ها با استفاده از دوربین تلفن همراه (Galaxy S21 FE 5G) با مشخصات ۳۲ مگاپیکسل، لنز ۲۶ میلی‌متری و در محیط آزمایشگاه با نور پردازشی مرسوم از سقف بر روی نمونه (لامپ‌های سقفی مهتابی ۴ ردیفه) انجام شد. تصاویر نمونه‌ها در دو حالت با پوشش سلفون و بدون پوشش سلفون از فاصله ۲۰ سانتی‌متری تهیه شدند (شکل ۱). در هر حالت سه تکرار تصویر برداری انجام شد بطوریکه بعد از هر تصویر نمونه مجدداً مخلوط و تصویر برداری انجام شد. با توجه به پیش‌بینی احتمال ناهمگنی در نمونه‌ها، هر تصویر نمونه به ۱۰ تصویر تقسیم و ۳۰ تصویر برای هر نمونه ذخیره شد. در نهایت ۶۳۰ تصویر (۳×۱۰×۲۱) برای هر حالت تصویر برداری ذخیره شد.



شکل ۱. الف) تلفن همراه و نحوه تصویربرداری، ب) تصویر رنگی نمونه گوشت چرخ کرده گوسفندی-گوساله بدون پوشش سلفون و ب) با پوشش سلفون

پردازش تصویر و استخراج ویژگی‌ها

تصاویر دریافتی به منظور استخراج ویژگی‌های نمونه‌ها باید پردازش شوند. پردازش شامل دو بخش اصلی پیش‌پردازش و پس‌پردازش است. در گام نخست، تصاویر بارگذاری و هر تصویر به اندازه‌های ۱۰×۱۰ پیکسل تقسیم بندی شد. در پیش‌پردازش، به منظور بهبود کیفیت تصویر و افزایش دقت تحلیل‌های بعدی، حذف نویزهای زائد یکی از مراحل حیاتی است. برای این کار از فیلتر هموار کننده 'میانگین' برای پیش‌پردازش هر قطعه تصویر استفاده شد. این نوع فیلتر با کاهش تداخل‌های ناخواسته و تغییرات ناگهانی شدت روشنایی در تصاویر، باعث هموار شدن و ساده‌سازی داده‌های تصویری می‌شوند. سپس، کانال‌های رنگی قطعات تصاویر شامل قرمز (R)، سبز (G) و آبی (B) برای هر تصویر استخراج و میانگین هر کانال هر قطعه محاسبه شد. تصاویر و ویژگی‌های عددی به‌منظور ایجاد مدل‌های هوشمند ذخیره شدند. ازجمله ابزار پردازش تصویر نرم‌افزار متلب (2024a) برای پردازش تصاویر استفاده شد.

داده‌کاوی و ایجاد مدل‌های هوشمند

داده‌های رنگی به‌دست‌آمده از نمونه‌های خالص و تقلبی با بهره‌گیری از تحلیل مولفه‌های اصلی^۳ (PCA)، جهت نمایش بصری مورد بررسی قرار گرفتند. همچنین، برای تخمین درصد تقلب، از مدل‌های رگرسیون خطی PLSR، مدل غیرخطی رگرسیونی MLP و مدل طبقه‌بندی MLP استفاده شد.

تحلیل PCA

تحلیل PCA یک روش نمایش پراکنش داده‌ها و همچنین کاهش ابعاد داده‌ها بدون از دست دادن اطلاعات مهم است. در این روش، متغیرها ابتدا استانداردسازی و سپس ماتریس کوواریانس محاسبه و مؤلفه‌های اصلی (PCs) به عنوان بردارهای ویژه این ماتریس استخراج می‌شوند که حداکثر واریانس داده‌ها را در جهت‌های عمود بر هم توصیف می‌کنند. انتخاب تعداد مؤلفه‌های اصلی بر اساس مقدار واریانس تجمعی توضیح داده شده توسط هر مؤلفه (مقدار ویژه) صورت می‌گیرد، به‌طوری که مؤلفه‌هایی انتخابی در مجموع بیش از ۹۰ درصد واریانس داده‌ها را پوشش دهند. از نمودار بارگذاری^۴ و نمودار امتیازها^۵ این تحلیل برای تفسیر همپوشانی نمونه‌های گوشت اصل و نمونه‌های تقلبی استفاده شد. در نمودار بارگذاری، ارتباط هر متغیر با مؤلفه‌های اصلی مشخص می‌شود؛ به عبارت دیگر، این نمودار نشان‌گر

1- Smoothing filter
2- Mean filter
3- Principal Component Analysis
4- Loading Plot
5- Score Plot

میزان سهم هر متغیر رنگی در ساخت مؤلفه‌های استخراج شده است (Haute et al., 2023; Gewers et al., 2021). نمودار امتیازها نیز نمایشی از نمونه‌ها یا مشاهدات در فضای جدیدی است که توسط مؤلفه‌های اصلی تعریف شده است. در این نمودار، هر نقطه نمایانگر یک نمونه است و موقعیت آن نسبت به مؤلفه‌های اصلی (معمولاً دو مؤلفه اول) ترسیم می‌شود. این امر امکان شناسایی الگوها، خوشه‌بندی و تجسم ساختار داده‌ها را فراهم می‌کند (Kiani et al., 2023).

تحلیل و مدل سازی خطی با PLSR

مدل رگرسیون PLSR یک روش پیشرفته آماری است که به‌طور ویژه برای مدل‌سازی روابط بین مجموعه‌های چندمتغیره طراحی شده است. این روش از طریق استخراج مؤلفه‌های نهفته که حداکثر واریانس مشترک بین متغیرهای رنگی پیش‌بینی و درصد هر نوع گوشت (اصل یا تقلبی) را توضیح می‌دهند، عمل می‌کند. در شرایطی که داده‌ها با چالش‌هایی مانند همخطی چندگانه، تعداد کم مشاهدات، یا ابعاد بالاتر متغیرهای مستقل نسبت به نمونه‌ها مواجه هستند کاربرد دارد (Sampaio et al. 2017; Edris et al., 2024 a & 2024b). الگوریتم مدل PLSR با محاسبه وزن‌هایی برای متغیرهای آشکار، مقادیر متغیرهای پنهان را به‌عنوان ترکیبات خطی نشانگرها برآورد می‌کند و سپس از این مقادیر برای تخمین استفاده می‌نماید. در نمودار PLSR، هر مؤلفه نهفته به عنوان ترکیبی خطی از متغیرهای X (مقادیر رنگی) و Y (درصد تقلب) تعریف شده و الگوریتم به صورت تکراری وزن‌هایی را محاسبه می‌کند تا این مؤلفه‌ها بیشترین ارتباط ممکن را با یکدیگر داشته باشند.

ارزیابی مدل با شاخص‌های ضریب تعیین (R^2) و ریشه میانگین مربعات خطا (RMSE) انجام می‌شود. مقدار مناسب R^2 بیانگر توانایی قابل قبول مدل در تبیین تغییرات داده‌ها (Y و X) است. همچنین RMSE به عنوان معیاری از میزان خطای پیش‌بینی، در سطوحی قرار دارد که نشان‌دهنده دقت قابل قبول مدل در برآورد مقادیر واقعی است. ترکیب این دو شاخص، نشان‌دهنده تعادل مطلوب بین دقت پیش‌بینی و قدرت تبیین مدل است (Chenyu et al., 2022).

مدل سازی غیر خطی و طبقه‌بندی با شبکه‌های عصبی مصنوعی MLP

مدل MLP به‌عنوان یکی از پرکاربردترین مدل‌های شبکه عصبی مصنوعی، ابزاری قدرتمند برای تحلیل و مدل‌سازی روابط غیرخطی در داده‌ها محسوب می‌شود. این شبکه از حداقل سه لایه (ورودی، پنهان و خروجی) تشکیل شده که هر لایه شامل نورون‌هایی با توابع فعال‌سازی غیرخطی مانند سیگموئید است (Varshney et al., 2011). فرآیند یادگیری از طریق الگوریتم پس‌انتشار^۲ خطا انجام می‌شود که با محاسبه گرادیان خطا و تنظیم تکراری وزن‌های اتصالات، مدل را برای کاهش خطای پیش‌بینی بهینه می‌کند. در شبکه مورد استفاده نورون‌های لایه میانی از ۳ تا ۳۰ با بازه ۳ تغییر داده و بهترین مدل از نظر عملکرد ذخیره شد. ۰/۷۰ داده‌ها برای آموزش، ۰/۱۵ درصد داده‌ها برای ارزیابی و ۰/۱۵ درصد باقیمانده برای آزمون مورد استفاده قرار گرفت. تابع فعالیت سیگموئید برای لایه میانی و تابع فعالیت خطی برای لایه خروجی استفاده شد.

همچنین مدل MLP علاوه بر تخمین درصد تقلب به عنوان یک مدل طبقه‌بند نیز مورد استفاده قرار گرفت. برای ارزیابی عملکرد مدل از ماتریس اغتشاش^۳ و منحنی مشخصه عملیاتی گیرنده^۴ (ROC) استفاده می‌شود (Pernice et al., 2011). ماتریس اغتشاش با تفکیک پیش‌بینی‌های مدل به چهار دسته مثبت‌های صحیح^۵ (TP)، منفی‌های صحیح^۶ (TN)، مثبت‌های کاذب^۷ (FP) و منفی‌های کاذب^۸ (FN)، امکان محاسبه معیارهای دقیقی مانند دقت^۹ (رابطه ۱)، صحت^{۱۰} (رابطه ۲)، حساسیت یا نرخ مثبت صحیح^۱ (TPR) (رابطه ۳) و F1 score (رابطه ۴) را فراهم می‌کند. این ماتریس به‌طور خاص در شناسایی رفتار مدل در مواجهه با داده‌های نامتوازن کلاس‌ها کاربرد دارد. نمودار ROC با ترسیم نرخ مثبت‌های صحیح (TPR) در برابر نرخ مثبت‌های کاذب (FPR) در آستانه‌های تصمیم‌گیری مختلف، عملکرد مدل را

1- Sigmoid

2- Backpropagation

3- Confusion Matrix

4- Receiver Operating Characteristic Curve

5- True Positive

6- True Negative

7- False Positive

8- False Negative

9- Accuracy

1 - Precision 0

1 - Sensitivity (True Positive Rate) or Recall

در سطوح مختلف قطعیت پیش‌بینی تحلیل می‌کند. استفاده از منحنی ROC در این زمینه، علاوه بر ارائه نمای بصری از عملکرد مدل‌ها، معیار عددی قابل اتکایی برای مقایسه کارایی الگوریتم‌های دسته‌بندی فراهم می‌کند. این روش به ویژه در حوزه یادگیری ماشین نظارتی^۱ به عنوان ابزاری استاندارد برای اعتبارسنجی و بهینه‌سازی مدل‌های دسته‌بندی شناخته شده است. ترکیب ماتریس اغتشاش برای تحلیل جزئیات خطاها و نمودار ROC برای ارزیابی کلی عملکرد، چارچوب کاملی برای سنجش اثربخشی مدل‌های MLP در مسائل طبقه‌بندی دودویی فراهم می‌نماید (Singh et al., 2021).

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


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

$$\text{Sensitivity/Recall} = \frac{TP}{TP + FN} \quad \text{رابطه (۳)}$$

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

نتایج و بحث

تصاویر نمونه‌ها با استفاده از الگوریتم‌های پردازش تصویر، پیش پردازش، قطعه‌بندی و مقادیر میانگین ویژگی‌های رنگی نمونه‌ها استخراج و ذخیره شد. نمودارهای شکل (۲)، تغییرات چشمگیر مقادیر میانگین کانال‌های رنگی R، G و B را برای نمونه‌ها با درصد تقلب مختلف نشان می‌دهند. این نوسانات می‌تواند نشان‌دهنده تغییرات سریع و پویا در محتوای رنگی تصاویر مورد بررسی باشد. تحلیل دقیق‌تر نمودارها، وجود الگوهای تکراری در نوسانات مقادیر رنگی R، G و B را آشکار می‌سازد که نمایانگر ویژگی‌های ساختاری تکرار شونده است. همچنین، در برخی بازه‌های تقلب، نوسانات کانال‌های رنگی به صورت همزمان رخ می‌دهد که بیانگر وجود همبستگی معنی‌دار میان این کانال‌ها است. این همبستگی ممکن است ناشی از تغییرات همزمان در شرایط نوری محیط یا ویژگی‌های ترکیبی رنگی موجود در تصویر نمونه باشد. تحلیل دقیق این نوسانات و الگوهای همبستگی با استفاده از روش‌های داده‌کاوی می‌تواند به درک بهتر ساختار رنگی و دینامیک محتوای تصویری کمک کند.




شکل ۲. تغییرات رنگی نمونه‌های گوشت چرخ کرده تقلبی از صفر تا ۱۰۰ درصد تقلب (رنگ قرمز مولفه R، رنگ سبز مولفه G، رنگ آبی مولفه B) (الف) بدون پوشش سلفون و (ب) با پوشش سلفون

نتایج تحلیل PCA

نتایج تحلیل PCA داده‌های رنگی نمونه‌های گوشت چرخ کرده مورد مطالعه در نمودارهای شکل (۳ الف و ب، راست) آورده شده است. نتایج نشان می‌دهد نمونه‌های تقلبی، که با رنگ‌هایی از قرمز روشن تا قرمز تیره نمایش داده شده‌اند، با افزایش درصد تقلب (افزایش میزان

سنگدان مرغ افزوده شده)، به سمت چپ نمودار حرکت کرده و فاصله بیشتری از نمونه‌های خالص (فاقد سنگدان مرغ) می‌گیرند. با این حال، برخی همپوشانی‌ها میان نمونه‌ها وجود دارد که نشان‌دهنده اشتراکاتی در ویژگی‌های برخی نمونه‌هاست. در این نمودارها، گروه سبز رنگ معرف نمونه‌های کاملاً خالص با میزان تقلب صفر درصد است. گروه‌های با رنگ سبز روشن، زرد و قرمز به ترتیب نشان‌دهنده نمونه‌هایی با درصدهای مختلف تقلب از ۵٪ تا ۱۰۰٪ هستند. نزدیکی نمونه‌ها در هر گروه رنگی بیانگر شباهت ویژگی‌های شیمیایی و فیزیکی آن‌ها است؛ به این معنا که نمونه‌های قرارگرفته در یک گروه رنگی، خصوصیات مشترکی دارند که آن‌ها را از سایر گروه‌ها متمایز می‌کند. جداسازی نسبی گروه‌ها در نمودارهای PCA به وضوح نشان می‌دهد که با افزایش درصد تقلب، اختلاف رنگی میان نمونه‌ها افزایش یافته و تفکیک گروه‌ها بهتر انجام می‌شود. این موضوع تأیید می‌کند که با ایجاد مدل‌های هوشمند می‌توان نمونه‌های تقلبی از نمونه‌های خالص بر اساس ویژگی‌های رنگی تفکیک شوند. همچنین، تصاویر ارائه شده در شکل (۳ الف و ب، چپ) مربوط به نمودار بارگذاری ویژگی‌های رنگی هستند. این نمودارها نیز نشان می‌دهند که هر سه مؤلفه رنگی R، G و B نقش قابل توجهی در تشخیص این تقلب دارند. بنابراین، می‌توان نتیجه گرفت که هر سه مؤلفه رنگی می‌توانند به طور مؤثری در مدل‌سازی و شناسایی تقلب سنگدان مرغ در نمونه‌های گوشت چرخ‌کرده مورد استفاده قرار گیرند و ترکیب این ویژگی‌ها دقت مدل‌های تشخیص تقلب را افزایش می‌دهد.




شکل ۳. نمودار امتیازهای (راست) و بارگذاری (چپ) تحلیل PCA، (الف) نمونه‌های بدون پوشش سلفون و (ب) با پوشش سلفون

نتایج تحلیل PLSR

عملکرد مدل رگرسیون PLSR برای پیش‌بینی مقادیر درصد تقلب سنگدان مرغ در نمونه‌های گوشت چرخ شده در شکل ۴ (الف و ب) آورده شده است. شاخص‌های کلیدی شامل شیب خط رگرسیون، عرض از مبدأ، ریشه میانگین مربعات خطا^۱ و ضریب تعیین (R^2) به منظور سنجش دقت و توانایی مدل در پیش‌بینی مورد استفاده قرار گرفتند. مدل‌سازی PLSR با داده‌های برداشت شده بدون و با پوشش سلفون برای تخمین درصد تقلب سنگدان مرغ در گوشت چرخ شده انجام شد. نتایج نشان داد که بهترین مدل از نظر مقدار $RMSE=16.51$ و ضریب $R^2=0.7025$ برای حالت اول بدست آمد. نتایج به دست آمده نشان می‌دهد که مدل مورد نظر دارای خطای پیش‌بینی متوسطی است که نشان‌دهنده اختلاف میانگین مربعات خطا بین مقادیر واقعی و پیش‌بینی شده است و هرچه این مقدار کمتر باشد، دقت مدل بالاتر خواهد بود. این مقدار R^2 حاکی از آن است که مدل توانسته است بخش عمده‌ای از واریانس داده‌ها را تبیین کند و

1 - Slope
2 - Offset
3 - RMSE


عملکرد نسبتاً قابل قبولی در پیش‌بینی داشته باشد. با این حال، برای ارزیابی جامع‌تر، لازم است RMSE با دامنه متغیر هدف (درصد تقلب) مقایسه شود. با این نتایج مدل‌سازی با روش‌های غیر خطی و مقایسه نتایج توجیه‌پذیر است.



شکل ۴. نمودار نتایج تحلیل PLSR، الف) نمونه‌های بدون پوشش سلفون و ب) نمونه‌های با پوشش سلفون

نتایج مدل هوشمند MLP

نتایج مدل‌سازی برازشی با استفاده از شبکه عصبی چندلایه MLP با استفاده از مقادیر ورودی RGB رنگی در شکل (۵ الف و ب) آورده شده است. ستون سمت چپ نتایج آموزش مدل با ۷۰٪ داده‌ها، ستون میانی نتایج ارزیابی مدل حین آموزش با ۱۵٪ درصد داده‌ها و ستون سمت راست نتایج آزمون مدل با ۱۵٪ درصد داده‌ها (داده‌های مجزا) می‌باشند. در این مدل‌ها یک لایه ورودی با سه نورون برای مقادیر رنگی، یک لایه میانی با ۱۰ نورون و تابع فعالیت سیگموئید، و یک لایه خروجی با تابع فعالیت خطی استفاده شد. مدل‌سازی در دو حالت مختلف داده‌پردازی نمونه‌های با و بدون پوشش سلفون برای تخمین درصد تقلب سنگدان مرغ در گوشت چرخ شده انجام شد. نتایج نشان می‌دهد که بهترین مدل از نظر مقدار ضریب تعیین $R^2 = 0.97$ برای حالت اول (شکل ۵-الف) و مشابه با مدل PLSR برای حالت بدون پوشش سلفون بدست آمد. در شکل (۵-الف)، مدل با این مقدار R^2 در آزمون و مقادیر مشابه در مجموعه آموزش (0.97) و در مجموعه اعتبارسنجی (0.96)، نشان‌دهنده برازش بسیار خوب مدل است. همچنین مقادیر پایین RMSE در آموزش ($6/7$)، در اعتبارسنجی ($8/74$) و در آزمون ($6/673$) دقت بالایی پیش‌بینی مدل را تأیید. نزدیکی مقادیر R^2 و RMSE در سه مجموعه داده، بیانگر تعمیم‌پذیری مطلوب مدل است. بنابر این نتایج می‌توان بیان کرد که یک مدل غیر خطی مانند MLP نتایج دقیق‌تری نسبت به مدل خطی PLSR در تخمین درصد تقلب سنگدان مرغ در گوشت چرخ شده را دارد و می‌توان به عنوان یک مدل کارا مورد استفاده قرار گیرد. در شکل (۵-ب) عملکرد مدل در حالت استفاده از داده‌های که با پوشش سلفون برداشت شده‌اند را نشان می‌دهد. ضریب تعیین $R^2 = 0.90$ بدست آمده، پایین‌تر از حالت شکل (۵-الف) ولی قابل پذیرش است.




شکل ۵. نمودار نتایج مدل سازی با MLP با داده‌های برداشت شده از الف) نمونه‌های بدون پوشش سلفون و ب) نمونه‌های با پوشش سلفون


طبقه‌بندی با ماتریس اغتشاش بوسیله مدل MLP

در این مدل سازی نمونه‌های مورد آزمون در ۶ گروه نمونه‌های تقلبی، ۰-۱۰٪، ۱۰-۲۰٪، ۲۰-۳۰٪، ۳۰-۴۰٪، ۴۰-۵۰٪ و بیش از ۵۰٪ در نظر گرفته شدند و مجدد مدل MLP طبقه‌بند آموزش داده شد. نتایج بصورت ماتریس اغتشاش در شکل (۶ الف و ب) برای ۲ حالت داده‌برداری آورده شده است. ماتریس اغتشاش برای ارزیابی عملکرد مدل طبقه‌بندی ایجاد شده است و درایه‌های روی قطر اصلی ماتریس نشان‌دهنده نمونه‌هایی هستند که به درستی طبقه‌بندی شده‌اند، در حالی که سایر درایه‌ها موارد اشتباه را نشان می‌دهند. هر سطر نمایانگر کلاس واقعی و هر ستون نمایانگر کلاس پیش‌بینی شده است. با استفاده از این ماتریس می‌توان به سادگی مشاهده کرد که مدل در تشخیص کدام کلاس‌ها اشتباه بیشتری داشته و در کدام موارد عملکرد بهتری داشته است. این جدول امکان تحلیل دقیق‌تر عملکرد مدل را نسبت به صرفاً محاسبه دقت فراهم می‌کند. بهترین نتایج در شکل (۶-الف) برای حالت داده‌برداری بدون پوشش سلفون بدست آمده است که مدل طبقه‌بند MLP با دقت‌های ۸۵٪، ۹۶٪، ۹۲٪، ۷۳٪، ۷۶٪ و ۹۶٪ گروه‌های نمونه‌های تقلبی تعریف شده را از هم تفکیک کرده است. همچنین برای این مدل میانگین‌های صحت، حساسیت و F1 score به ترتیب ۰/۹۷۵، ۰/۹۷۴ و ۰/۹۷۵ بدست آمد. برای حالت داده‌برداری با پوشش سلفون (شکل ۶-ب) مدل طبقه‌بند MLP با دقت‌های ۷۶٪، ۸۹٪، ۷۲٪، ۹۱٪، ۹۵٪ و ۹۶٪ گروه‌های نمونه‌های تقلبی تعریف شده را از هم تفکیک کرده است. همچنین برای این مدل میانگین‌های صحت، حساسیت و F1 score به ترتیب ۰/۹۷۵، ۰/۹۵۷ و ۰/۹۰۹ بدست آمد.

منحنی ROC یکی از روش‌های استاندارد و کارآمد برای ارزیابی عملکرد الگوریتم‌های طبقه‌بندی است که ترکیبی از دو شاخص TPR و FPR را در قالب یک نمودار (شکل ۷ الف و ب) نمایش می‌دهد که امکان بررسی جامع‌تر و دقیق‌تر عملکرد مدل را فراهم می‌کند. حساسیت نشان‌دهنده توانایی مدل در شناسایی نمونه‌های مثبت واقعی و صراحت بیانگر توانایی مدل در شناسایی نمونه‌های منفی واقعی است. در این منحنی، محور افقی مقدار FPR و محور عمودی مقدار TPR را نشان می‌دهد. هرچه منحنی به گوشه بالا-چپ نزدیک‌تر باشد که در شکل‌های (۷ الف) این اتفاق افتاده است، مدل عملکرد بهتری دارد؛ زیرا در این حالت، نرخ مثبت صحیح بالا و نرخ مثبت کاذب پایین است. اگر منحنی به قطر اصلی (خط ۴۵ درجه) نزدیک باشد، مدل عملکردی مشابه یک پیش‌بینی تصادفی دارد.



شکل ۶. ماتریس‌های اغتشاش و نتایج طبقه‌بندی نمونه‌ها با مدل MLP با داده‌های برداشت شده از الف) نمونه‌های بدون پوشش سلفون و ب) نمونه‌های با پوشش سلفون



شکل ۷. نمودار ROC طبقه‌بندی نمونه‌ها با مدل MLP با داده‌های برداشت شده از الف) نمونه‌های بدون پوشش سلفون و ب) نمونه‌های با پوشش سلفون

در سال‌های اخیر، شناسایی تقلب در محصولات گوشتی به یکی از موضوعات مهم در حوزه امنیت غذایی تبدیل شده است و پژوهش‌های مشابه متعددی به استفاده از فناوری‌های نوین مانند بینایی ماشین و یادگیری ماشین برای این منظور پرداخته‌اند. در مقایسه با روش‌های سنتی و شیمیایی که معمولاً زمان‌بر، پرهزینه و مخرب هستند، رویکرد مبتنی بر تحلیل رنگ تصاویر دیجیتال، به عنوان یک روش غیرمخرب، سریع و مقرون به صرفه مطرح شده است. در پژوهش با استفاده از تصویربرداری فراطیفی و الگوریتم‌های یادگیری ماشین، موفق به شناسایی تقلب در گوشت شده‌اند که نشان‌دهنده قابلیت بالای روش‌های تصویری در این حوزه است. از سوی دیگر، بسیاری از پژوهش‌های مشابه عمدتاً به استفاده از مدل‌های خطی یا الگوریتم‌های پایه محدود بوده‌اند که در مقایسه با مدل غیرخطی MLP ارائه شده در این مطالعه، دقت کمتری در تخمین درصد تقلب و طبقه‌بندی نمونه‌ها نشان داده‌اند (Chen et al., 2025). در مطالعاتی دیگر نیز به بررسی کاربردهای بینایی ماشین در شناسایی تقلب در انواع دیگر محصولات گوشتی پرداخته‌اند و نتایج مشابهی در دقت و قابلیت اطمینان گزارش کرده‌اند که نشان می‌دهد تحلیل رنگ تصاویر روشی قابل تعمیم و موثر در حوزه‌های مختلف صنعت گوشت است (Shen et al., 2024). یکی از چالش‌های مهم در تصویربرداری برای این کاربرد، تأثیر شرایط نوری و بسته‌بندی بر کیفیت داده‌ها است. یافته‌های این مطالعه مبنی بر کاهش دقت در شرایط تصویربرداری با پوشش سلفون به دلیل انعکاس‌های نوری، با نتایج پژوهش Meenu و همکاران (۲۰۲۱) همخوانی دارد (Meenu et al., 2021). علاوه بر این، برخلاف بسیاری از مطالعات آزمایشگاهی که در شرایط کاملاً کنترل شده انجام شده‌اند، این پژوهش با شبیه‌سازی شرایط واقعی بسته‌بندی و نورپردازی محیط آزمایشگاه، به سمت کاربردهای عملی و صنعتی حرکت کرده است. در مجموع، نتایج این پژوهش نه تنها با یافته‌های مطالعات پیشین همسو است، بلکه با بهره‌گیری از مدل‌های پیشرفته یادگیری ماشین و توجه به شرایط واقعی محیطی، گامی مؤثر در جهت توسعه سامانه‌های کنترل کیفیت خودکار و قابل اعتماد در صنعت غذا برداشته است.

نتیجه‌گیری

مطالعه حاضر با تمرکز بر استفاده از تحلیل تصاویر رنگی و مدل‌های یادگیری ماشین گامی مهم در ساده‌سازی و تسهیل فرآیند تشخیص تقلب در گوشت چرخ کرده برداشته است. نتایج این پژوهش که با ضریب تعیین $R^2=0.97$ و دقت طبقه‌بندی میانگین بالای ۹۰ درصد (۹۱/۳ و ۹۰/۵ درصد برای بدون و با پوشش سلفون) بیانگر پیشرفت قابل توجهی در کاربرد شبکه‌های عصبی چندلایه برای تحلیل تصاویر رنگی در محصولات گوشتی است. همچنین این مطالعه نشان داد که استفاده از تحلیل رنگ تصاویر دیجیتال در ترکیب با مدل‌های یادگیری ماشین، به ویژه شبکه عصبی MLP، روشی غیرمخرب، سریع و قابل اعتماد برای شناسایی تقلب افزودن سنگدان مرغ به گوشت قرمز چرخ کرده است. قابلیت عملکرد موفق این سیستم در شرایط نوری کمتر کنترل شده و از طریق بسته‌بندی سلفونی، نشان‌دهنده پتانسیل بالای آن برای کاربرد در محیط‌های واقعی و صنعتی است، جایی که شرایط ایده‌آل همواره فراهم نیست. این روش می‌تواند به عنوان پایه‌ای مستحکم برای توسعه سامانه‌های نرم‌افزاری خودکار کنترل کیفیت در صنعت غذا به کار گرفته شود و به طور قابل توجهی در بهبود فرآیندهای تشخیص تقلب‌های غذایی نقش ایفا کند. با توجه به اهمیت حفظ سلامت و حقوق مصرف‌کنندگان، این فناوری می‌تواند به افزایش اعتماد مشتریان و ارتقای استانداردهای کیفی محصولات غذایی کمک کند.

REFERENCES

- Azari, N.Z., Mahmoudian, F., & Shahsuni Mojard, L. (2021). *Meat Products Industries: Studying the Nutritional Value of Red Meat*. Fourth International Conference on Interdisciplinary Studies in Food Industries and Nutritional Sciences of Iran, Tehran, <https://civilica.com/doc/1262624>
- Ballin, N.Z. (2010). *Authentication of meat and meat products*. Meat science, 86 (3), 577-587.
- Chen, H., Tan, C., Lin, Z. (2025). *Identification of beef adulteration based on near-infrared spectroscopy and an ensemble of radical basis function network*. Journal of Food Composition and Analysis, 143, 107633.
- Chenyu, L., Xinlian Z., Tanya T.N, Jinyuan L., Tsungchin W., Ellen L., Xin M.T. (2022). Partial least squares regression and principal component analysis: similarity and differences between two popular variable reduction approaches. General Psychiatry, 35:e100662. <https://doi.org/10.1136/gpsych-2021-100662>
- Dean, T., Brendan, M., Gerard, D. (2005). *Using Unlabelled Data to Update Classification Rules with Applications in Food Authenticity Studies*. Journal of the Royal Statistical Society Series C: Applied Statistics, 55 (1), 1–14. <https://doi.org/10.1111/j.1467-9876.2005.00526.x>
- Dehnavi Dehghan, M. A., Kohzadi, N., and Khalilian, S. (2005). *Investigating structural change in meat*



- demand through nonparametric revealed preferences test. Fifth Agricultural Economics Conference, University of Sistan and Baluchestan.
- Dosti Irani, O., & Golzarian, M.R. (2013). *Design and evaluation of image processing algorithm for estimating fat content of red meat*. 8th National Congress of Agricultural Machinery Engineering (Biosystems) and Mechanization of Iran, Mashhad, <https://civilica.com/doc/284547>
- Edris, M., Ghasemi-Varnamkhasti, M., Kiani, S., Yazdanpanah, H., & Izadi, Z. (2024a). Identifying the authenticity and geographical origin of rice by analyzing hyperspectral images using unsupervised clustering algorithms. *Journal of Food Composition and Analysis*, 125, 105737.
- Edris, M., Ghasemi-Varnamkhasti, M., Kiani, S., Yazdanpanah, H., & Izadi, Z. (2024b). Application of fuzzy clustering algorithm and hyperspectral images for rice authentication. *Iranian Journal of Biosystems Engineering*, 55(2), 79-92.
- Gewers, F.L., Ferreira, G.R., Arruda, H.F.D., Silva, F.N., Comin, C.H., Amancio, D.R., & Costa, L.F. (2021). *Principal Component Analysis: A Natural Approach to Data Exploration*. *ACM computing surveys*, 54 (4): 70:1–70:34.
- Haute, S.V., Nikkhah, A., Malavi, D., & Kiani, S. (2023). Prediction of essential oil content in spearmint (*Mentha spicata*) via near-infrared hyperspectral imaging and chemometrics. *Scientific Reports*, 13(1), 4261.
- Javadi, K., Ghasemi-Varnamkhasti, M., and Sabzi, N. (2017). *Freshness detection of beef using image processing and response surface*. *Iranian Journal of Food Science and Technology Research*, 13(2), 251-261.
- Kiani, S., Rahimzadeh, H., Kalantari, D., & Moradi-Sadr, J. (2023). Aroma modeling and quality evaluation of spearmint (*Mentha spicata* subsp. *spicata*) using electronic nose technology coupled with artificial intelligence algorithms. *Journal of Applied Research on Medicinal and Aromatic Plants*, 35, 100473.
- Koekoeh, S., Riana, P., Nugrahaeni, P. A., Ronald, T., & La Jumadin, P. (2022). *Meat quality detection using imaging and AI analysis*. In *Proceedings of the 2nd International Conference on Research and Development (ICORAD)*, 41–48. <https://doi.org/10.47841/icorad.v1i2.94>
- Ma, J., Sun, D. W., Pu, H., Wei, Q., & Wang, X. (2019). Protein content evaluation of processed pork meats based on a novel single shot (snapshot) hyperspectral imaging sensor. *Journal of Food Engineering*, 240, 207–213.
- Meenu, M., Kurade, C., Neelapu, B.C., Kalra, S., Ramaswamy, H.S., & Yu, Y. (2021). *A concise review on food quality assessment using digital image processing*. *Trends in Food Science & Technology*, 118, 106-124.
- Asadi, M.R., Kalantari Hessari, A., Ghaemmagami, S.S., Mosleh, N., Ghorbanzadeh, B., & Abdi., P. (2023). *Meat products components using histological method and image analysis software*. *Veterinary Research and Biologic Products*, 1, 102-112. DOI: [10.22092/vj.2022.358361.1966](https://doi.org/10.22092/vj.2022.358361.1966). Minaei, S., Kiani, S., Ayyari, M., & Ghasemi-Varnamkhasti, M. (2017). *A portable computer-vision-based expert system for saffron color quality characterization*. *Journal of applied research on medicinal and aromatic plants*, 7, 124-130.
- Morsy, N, & Sun, D.W. (2013). Robust linear and non-linear models of NIR spectroscopy for detection and quantification of adulterants in fresh and frozen-thawed minced beef. *Meat Science*, 93 (2), 292-302.
- Pernice, V., Staude, B., Cardanobile, S., & Rotter, S. (2011). *How structure determines correlations in neuronal networks*. *Plos Computational Biology*, 7(5), e1002059.
- Rady, A. M., Adedeji, A., & Watson, N. J. (2021). Feasibility of utilizing color imaging and machine learning for adulteration detection in minced meat. *Journal of Agriculture and Food Research*, 6, 100251.
- Sadeghpour, A., Pirzadeh Khalil, A., Sehatkhah., M., & Khandaghi, J. (2019). Detecting adulteration and checking the authenticity of meat and meat products using chemical properties and PCR technique in Tabriz city. *Health and Hygiene of Ardabil*, 11(4), 478-488.
- Sampaio, P. S., Castanho, A., Almeida, A.S., Oliveira, J., & Brites, C. (2020). *Identification of Rice Flour Types With Near-Infrared Spectroscopy Associated With PLS-DA and SVM Methods*. *European Food Research and Technology* 246: 527–537.
- Singh, P., Singh, N., Kant Singh, K., & Akansha, S. (2021). *Chapter 5 - Diagnosing of disease using machine learning*. *Machine Learning and the Internet of Medical Things in Healthcare*, 89-111. <https://doi.org/10.1016/B978-0-12-821229-5.00003-3>
- Shen, C., Wang, R., Nawazish, H., Wang, B., Cai, K., Xu, B. (2024). *Machine vision combined with deep learning-based approaches for food authentication: An integrative review and new insights*. *Comprehensive Review*, 23(6), e70054. <https://doi.org/10.1111/1541-4337.70054>
- Varshney, L.R., Chen, B.L., Paniagua, E., Hall, D.H., & Chklovskii, D.B. (2011). *Structural properties of the*

Caenorhabditis elegans neuronal network. PLoS computational biology, 7(2), e1001066.

World Health Organization. (2024). *Red meat consumption in Iran and the world*. <https://www.who.int>

Yang, Q., Sun, D. W., & Cheng, W. (2017). Development of simplified models for nondestructive hyperspectral imaging monitoring of TVB-N contents in cured meat during drying process. *Journal of Food Engineering*, 192, 53–60.