



Detection of fat and chicken adulteration in lamb using VIS/NIR spectroscopy and LDA model

Amir Kazemi¹ | Asghar Mahmoudi² | Hadi Veladi³ | Arash Javanmard⁴

1. Corresponding Author, department of biosystem engineering, Faculty of agriculture, University of Tabriz, Tabriz, Iran.

E-mail: a.kazemi@tabrizu.ac.ir

2. department of biosystem engineering, Faculty of agriculture, University of Tabriz, Tabriz, Iran. E-mail:

a_mahmoudi@tabrizu.ac.ir

3. Department of Electrical and Computer, University of Tabriz, 29 Bahman Blvd., Tabriz, Iran

E-mail: veladi@tabrizu.ac.ir

4. Department of Animal Science, University of Tabriz, 29 Bahman Blvd., Tabriz, Iran

E-mail: a.javanmard@tabrizu.ac.ir

Article Info

Article type: Research Article

Article history:

Received: Jan. 3, 2025

Revised: May. 1, 2025

Accepted: June. 21, 2025

Published online: Spring 2025

Keywords:

*Spectroscopy,
Adulteration,
Meat,
PCA,
LDA*

ABSTRACT

Meat adulteration, as one of the most essential and nutritious human food sources, poses significant health and economic threats to consumers. This study investigates the detection of adulteration in minced lamb meat with fat and chicken meat using VIS/NIR spectroscopy in the range of 200–1100 nm. Adulterated samples were manually prepared at weight-based adulteration levels of 5%, 10%, 15%, and 20%. A total of 190 samples, each weighing 10 grams, were analyzed. To eliminate additive and scattering effects in the spectral data, various preprocessing methods, including derivatives and scatter correction, were applied. Principal Component Analysis (PCA) was employed for variable reduction and clustering, while Linear Discriminant Analysis (LDA) with different preprocessing techniques was used to classify the meat samples. The best accuracy, 76.70% for 3-class data and 89.92% for 9-class data, was achieved using Savitzky-Golay preprocessing. The results demonstrate the high potential of VIS/NIR spectroscopy combined with chemometric methods in detecting adulteration in minced lamb meat. The findings of this study can play an effective role in improving food quality and safety and mitigating risks associated with adulterated meat products.

Cite this article: Kazemi, A., Mahmoudi, A., Veladi, H., Javanmard, A., (2025). Detection of fat and chicken adulteration in lamb using VIS/NIR spectroscopy and LDA model, *Iranian Journal of Biosystem Engineering*, 56 (1), 71-82. <https://doi.org/10.22059/ijbse.2025.388079.665577>

© The Author(s).

Publisher: The University of Tehran Press.

DOI: <https://doi.org/10.22059/ijbse.2025.388079.665577>



EXTENDED ABSTRACT

Introduction

Meat is one of the essential food products for the human diet, which is widely consumed by consumers due to its nutritional value and palatability. According to the Food and Agriculture Organization (FAO), there has been a growing demand for high-value meats such as beef and lamb. To meet the increasing consumer expectations for the production of safe, high-quality, and cost-effective products, scientists are exploring some methods to ensure meat quality.

Authenticity is a crucial quality factor for desirability. Several traditional methods exist for assessing meat safety and quality.

For this reason, non-destructive and rapid methods are being investigated to improve efficiency in detecting fraud in the meat industry. Vibrational spectroscopy is one of the most common analytical methods for assessing the quality of meat and meat products in recent years. Infrared spectroscopy is a vibrational spectroscopy technique based on the interaction between infrared waves and the material under study. In this study, the extent of adulteration in minced lamb meat was determined using NIR spectroscopy and chemometric methods (statistical chemistry). The adulteration involved mixing lamb fat or chicken meat with lamb meat. After conducting experiments and relevant analyses, the efficiency of the method was evaluated.

Material and methods

This study investigates the detection of adulteration in lamb meat with fat and chicken meat using VIS/NIR spectroscopy in the wavelength range of 200 to 1100 nm. Adulterated samples were manually prepared with weight-based adulteration levels of 5%, 10%, 15%, and 20%. A total of 190 samples were examined, each weighing 10 grams. To eliminate additive and scattering effects in the spectral data, various preprocessing methods, including derivatives and scattering correction techniques, were applied. Principal Component Analysis (PCA) was used for variable reduction and data clustering, while Linear Discriminant Analysis (LDA) models, combined with different preprocessing approaches, were employed to classify the meat samples.

Results

The best prediction accuracy was achieved using Savitzky-Golay preprocessing with the accuracy of 70.76% for the 9-class data and 92.89% for the 3-class datasets. The best clustering results were obtained using the PCA model with Savitzky-Golay (SG) preprocessing. The first two principal components (PCs) captured the majority of the variance within the dataset (95%).

Discussion

One of the key findings of this study is that spectroscopy, as a non-destructive method, is capable of detecting low levels of adulteration without the need for sample destruction. However, it is recommended that future research focus on enhancing the accuracy and practical applicability of this technique in industrial or regulatory settings by expanding sample diversity, employing deep learning models, and investigating the most informative spectral regions for sample discrimination.

Author Contributions

Amir Kazemi: Conceptualization, Methodology, Software, Formal analysis, Investigation, Resources, Data curation, Writing–review & editing, Project administration, Writing–Original Draft.

Asghar Mahmoudi: Project administration, Investigation, software, supervision, validation,

Hadi Veladi: Methodology, Investigation, Data curation, Investigation

Arash Javanmard: Methodology, Software, Writing–review & editing

All authors have read and agreed to the published version of the manuscript.

Data Availability

Data available on request from the authors.

Acknowledgements

The authors gratefully acknowledge Dr. Mostafa Khojastehnazhand for his instructive suggestions during preparation of first draft of manuscript.

Ethical considerations

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

Conflict of interest

The author declares no conflict of interest.

تشخیص تقلب چربی و گوشت مرغ در گوشت گوسفند با استفاده از طیف‌سنجی VIS/NIR و مدل LDA

امیر کاظمی^۱ | اصغر محمودی^۲ | هادی ولادی^۳ | آرش جوانمرد^۴ |

۱. نویسنده مسئول، گروه مهندسی بیوسیستم، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران. رایانامه: a.kazemi@tabrizu.ac.ir

۲. گروه مهندسی بیوسیستم، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران. رایانامه: a_mahmoudi@tabrizu.ac.ir

۳. گروه مهندسی برق، دانشکده مهندسی برق و کامپیوتر، دانشگاه تبریز، تبریز، ایران. رایانامه: veladi@tabrizu.ac.ir

۴. گروه علوم دامی، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران. رایانامه: a.javanmard@tabrizu.ac.ir

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی	
تاریخ دریافت: ۱۴۰۳/۱۰/۱۴	
تاریخ بازنگری: ۱۴۰۴/۲/۱۱	
تاریخ پذیرش: ۱۴۰۴/۳/۳۱	
تاریخ انتشار: بهار ۱۴۰۴	
واژه‌های کلیدی:	
طیف‌سنجی،	
تقلب،	
گوشت،	
PCA،	
LDA.	

استناد: کاظمی؛ امیر، محمودی؛ اصغر، ولادی؛ هادی، جوانمرد؛ آرش، (۲۰۲۵). تشخیص تقلب چربی و گوشت مرغ در گوشت گوسفند با استفاده از طیف‌سنجی VIS/NIR

و مدل LDA. مجله مهندسی بیوسیستم ایران/ ایران، ۵۶ (۱)، ۸۲-۷۱. <https://doi.org/10.22059/ijbse.2025.388079.665577>



© نویسندگان.

ناشر: مؤسسه انتشارات دانشگاه تهران.

DOI: <https://doi.org/10.22059/ijbse.2025.388079.665577>

مقدمه

گوشت یکی از محصولات غذایی ضروری برای رژیم غذایی انسان است که به دلیل ارزش غذایی و دلپذیر بودن و غنی بودن از پروتئین‌ها، لیپیدها، ویتامین‌ها و مواد معدنی به طور عمده توسط مصرف کنندگان مورد استفاده قرار می‌گیرد. بطوریکه طبق آمار، انتظار می‌رود مصرف گوشت تا سال ۲۰۲۸ در مقایسه با سال‌های (۲۰۱۸-۲۰۱۶) به میزان ۱/۲ درصد افزایش یابد و این در حالی است که تقاضا برای برخی گوشت‌های محبوب و ارزشمند مانند گوشت گاو و گوسفند نسبت به سایر گوشت‌ها افزایش خواهد یافت (Candoğan et al., 2021). اما متأسفانه، مزایای اقتصادی و سادگی جایگزینی به دلیل شباهت در ویژگی‌های ظاهری، پتانسیل تقلب جایگزینی و یا اختلاط با گوشت‌های ارزان‌تر و بی کیفیت را افزایش می‌دهد. جایگزینی گوشت‌های ارزان قیمت یا مواد غیرگوشتی تقلبی در گوشت و محصولات گوشتی صنعت گوشت را با یک مشکل جدی رو به رو کرده است که نه تنها اقتصاد، کیفیت و ایمنی گوشت را نیز تحت تأثیر قرار می‌دهد، بلکه موضوعات مذهبی را نیز در بر می‌گیرد. برای مثال مسلمانان و یهودیان به دلایل مذهبی گوشت خوک را در رژیم غذایی خود ندارند (Barbin et al., 2019; Deniz et al., 2018; Rady & Adededeji, 2018).

گوشت چرخ کرده یک محصول مهم گوشتی برای شرکت‌های غذایی و مصرف کنندگان است، زیرا به طور گسترده در محصولات غذایی مانند سوسیس، همبرگر، کوفته و بسیاری از غذاهای دیگر استفاده می‌شود. با این حال، چرخ کردن باعث از بین رفتن ویژگی‌های مورفولوژیکی گوشت می‌شود و زمینه را برای تقلب فراهم می‌کند (Hu et al., 2017). بنابراین عملاً تشخیص یک نوع گوشت چرخ کرده از نوع دیگر گوشت چرخ کرده بدلیل حذف ساختارهای فیزیولوژیکی بسیار سخت است. در نتیجه داشتن روش‌های تحلیلی قابل اعتماد برای تأیید اصالت گوشت و شناسایی تقلب در گوشت ضروری است.

برخی از روش‌های سنتی و تحلیلی مانند کروماتوگرافی، جداسازی الکتروفورزی پروتئین‌ها و تکنیک‌های مبتنی بر DNA که برای تأیید کیفیت و ایمنی گوشت استفاده می‌شوند، دارای ضعف‌هایی مانند زمان‌بر و خسته کننده بودن، ماهیت مخرب داشتن و نیاز به نیروی انسانی ماهر هستند (Kamruzzaman et al., 2016). بنابراین، تکنیک‌های سریع، غیرمخرب و قابل اعتماد مورد نیاز هستند. در میان این روش‌ها، تکنیک‌های طیف‌سنجی مادون قرمز (IR) به طور گسترده برای بررسی کیفی مواد غذایی استفاده می‌شوند. این تکنیک‌ها سریع و مقرون به صرفه هستند، نیاز به آماده‌سازی نمونه ندارند، سازگار با محیط زیست هستند و استفاده از آن‌ها آسان است. همچنین می‌توان از آن‌ها برای کنترل فرآیند آنلاین در خط تولید استفاده کرد و اطلاعات کمی و کیفی در مورد ترکیبات شیمیایی نمونه را بوسیله این تکنیک بدست آورد (De Girolamo et al., 2020).

اخیراً تحقیقاتی در حوزه تشخیص اصالت گوشت با استفاده از روش‌های غیرمخرب انجام گرفته است. برای مثال، لنگ و همکاران از طیف‌سنجی NIR در محدوده $5400-12500 \text{ cm}^{-1}$ برای شناسایی گوشت خوک و اردک در گوشت چرخ کرده گاو استفاده کردند. در این مطالعه، مدل‌های تحلیل تفکیکی (DA) و حداقل مربعات جزئی (PLS) با تکنیک‌های مختلف انتخاب طول موج و پیش‌پردازش به کار گرفته شدند. مدل DA با طول موج انتخاب شده و بدون روش‌های پیش‌پردازش بهترین عملکرد را داشت و به ترتیب برای داده‌های دوتایی و سه‌تایی به دقت ۱۰۰٪ و درصد ۹۹/۵ بدست آمدند (Leng et al., 2020). در تحقیقی دیگر (Weng et al., 2020) از طیف‌سنجی بازتابی به مادون قرمز (VIS/NIR) همراه با روش‌های چندمتغیره برای شناسایی تقلب در گوشت چرخ کرده گاو استفاده کردند. مدل‌های شبکه عصبی کانولوشن عمیق (DCNN) و تحلیل مؤلفه اصلی (PCA) نوع تقلب را با دقت بیش از ۹۹٪ شناسایی کردند. در پیش‌بینی سطوح تقلب، مدل جنگل تصادفی (RF) با طول موج‌های انتخابی بهترین نتایج را برای گوشت گاو مخلوط با گوشت خوک ارائه داد و ضریب تعیین پیش‌بینی (R_p^2) و ریشه میانگین مربع خطای پیش‌بینی (RMSEP) به ترتیب ۰/۹۷۳ و ۲/۱۴۵ بودند. مطالعه‌ای توسط (Kazemi et al., 2022) به بررسی طبقه‌بندی گوشت گوسفند خالص و گوشت تقلبی با چربی با درصد اختلاط ۵، ۱۰، ۱۵ و ۲۰ درصد با استفاده از طیف‌سنجی مادون قرمز (VIS/NIR) و روش‌های چندمتغیره پرداخت. مدل رگرسیون حداقل مربعات جزئی تحت اعتبارسنجی متقاطع برای تعیین کمیت سطح تقلب نمونه‌ها استفاده شد. بهترین نتیجه این مدل با پیش‌پردازش SNV با ضریب همبستگی پیش‌بینی $R_p^2 = 0.7651$ درصد و ریشه میانگین مربعات خطای پیش‌بینی RMSEP=0.76 بود.

مدل‌های مختلف شیمی‌سنجی بر اساس کاربرد آنها، ویژگی‌های داده‌ها و تکنیک‌های پیش‌پردازش مورد استفاده، از نظر عملکردی متفاوت هستند. با توجه بررسی‌های ما، تحقیقی که به بررسی تشخیص تقلب چربی و گوشت مرغ در گوشت گوسفند چرخ کرده با استفاده از مدل تشخیصی خطی (LDA) همراه با روش طیف‌سنجی مادون قرمز مرئی پردازد یافت نشد. بنابراین در تحقیق حاضر به بررسی

امکان تشخیص همزمان تقلب چربی و گوشت مرغ در گوشت گوسفند چرخ کرده با استفاده از پیش‌پردازش‌های مختلف و مدل آنالیز مولفه‌های اساسی (PCA) و مدل آنالیز تشخیص خطی (LDA) پرداخته خواهد شد.


مواد و روش‌ها

آماده‌سازی نمونه‌ها


گوشت خالص گوسفند و چربی خالص از یک قصابی محلی و گوشت مرغ از یک سوپرمارکت محلی در بناب، آذربایجان شرقی، ایران تهیه شد. چربی‌ها و ضایعات قابل مشاهده از گوشت گوسفند حذف شدند تا تأثیر آنها بر نتایج نهایی مدل‌ها کاهش یابد و گوشت به قطعات کوچک بریده شد تا بتوان آن‌را چرخ کرد. نمونه‌های تقلبی شامل گوشت گوسفند مخلوط با مرغ و چربی بودند و میزان تقلب به ترتیب ۵، ۱۰، ۱۵ و ۲۰ درصد وزنی بود. این درصد تقلبات انتخاب شدند چون تقلب در سطوح بالاتر با توجه به تفاوت‌های رنگی قابل ملاحظه‌ای بین گوشت گوسفند و مرغ یا چربی به راحتی قابل تشخیص است. برای مثال، برای تهیه نمونه‌های تقلبی گوشت گوسفند با مرغ به میزان ۵ درصد، ۹/۵ گرم گوشت گوسفند با ترازوی با دقت دو صفر اندازه‌گیری شد و با ۰/۵ گرم مرغ مخلوط گردید. نمونه‌های گوشت شامل دو گروه بودند. گروه اول شامل نمونه‌های خالص گوشت گوسفند بود که ۳۰ نمونه تهیه شد. سپس، برای هر کلاس نمونه تقلبی تعداد ۲۰ نمونه آماده سازی شد. بدین منظور ۸۰ نمونه برای تقلب با مرغ (۲۰ نمونه برای چهار کلاس با درصدهای تقلب ذکر شده) و ۸۰ نمونه برای تقلب با چربی (۲۰ نمونه برای چهار کلاس تقلب) آماده سازی شد. بنابراین در مجموع ۱۶۰ نمونه (۸۰ نمونه تقلبی با مرغ و ۸۰ نمونه تقلبی با چربی) گوشت تقلبی و ۳۰ نمونه گوشت خالص گوسفند آماده سازی شد. بنابراین، مجموعاً ۱۹۰ نمونه (خالص و تقلبی) برای آزمایش‌ها آماده‌سازی شدند. نمونه‌ها با یک چرخ‌گوشت (Naniwa MT-1500) چرخ شدند. برای جلوگیری از مخلوط شدن اجزای نمونه‌ها با یکدیگر، قطعات چرخ‌گوشت به طور منظم بین استفاده‌های متوالی با آب شسته شده و با حوله خشک شدند. هر نمونه حدود ۱۰ گرم بود و به صورت دستی به شکل یک دیسک آماده شد، سپس در یک پتری دیش خشک و تمیز قرار گرفت. تمامی نمونه‌های گوشت گوسفند در روز ذبح تهیه و حداکثر تا ۲۴ ساعت پس از ذبح مورد استفاده قرار گرفتند. نمونه‌ها در این مدت در دمای یخچال (حدود ۴ درجه سانتی‌گراد) نگهداری شدند تا فرایندهای بیوشیمیایی پس از مرگ در حد استاندارد باقی بماند و تأثیرگذاری آنها بر خواص طیفی کنترل شود. همچنین، همه نمونه‌ها تحت شرایط یکسان نگهداری شدند تا تأثیر این عامل بر مدل کاهش یابد.

برداشت طیف‌ها

برای انجام آزمون از یک دستگاه طیف‌سنج (Aurora4000 (photonTec Berlin GmbH, Germany) مرئی-مادون قرمز نزدیک در محدوده ۱۱۰۰-۲۰۰ نانومتر استفاده شد (شکل ۱). دقت طیف‌سنج مورد استفاده ۰/۷۵ نانومتر (FWHM) بود. نسبت سیگنال به نویز ۳۰۰:۱ بود. هر نمونه در جایگاه مربوطه قرار داده شد و منبع نور در فاصله مناسب نسبت به نمونه قرار گرفت و به وسیله یک لنز، نور منبع بر روی یک نقطه از نمونه متمرکز شد. فیبر نوری در فاصله مناسبی بر سطح نمونه قرار گرفت تا طیف بازتابی از سطح نمونه را به آشکارساز بفرستد. سپس طیف نوری توسط آشکارساز به سیگنال الکتریکی تبدیل و بر روی سیستم موجود در آزمایشگاه نمایش داده شد. برای انجام طیف‌سنجی هر نمونه، تلاش شد تا طیف بازتاب نمونه در طول موج ۶۰۰ نانومتر (که به‌عنوان پیک قوی در این نوع نمونه‌ها دیده می‌شود) در دستگاه ثبت و ذخیره شود. سپس داده‌های عددی ذخیره شده به نرم‌افزار اکسل منتقل شدند (بدین صورت که یک محور (محور x) شامل داده‌های مربوط به طول موج بود که بین ۲۰۰ تا ۱۱۰۰ نانومتر بود و محور y نیز شامل داده‌های عددی یا همان دامنه مربوط به هر طیف بود. سپس داده‌ها از اکسل به نرم افزار Unscrambler ورژن ۱۰/۴ وارد شدند و برای مراحل بعدی تحلیل شامل پیش‌پردازش و ارائه مدل آماده شدند.



(الف)



(ب)

شکل ۱. سیستم طیف‌سنجی به کار برده شده (الف) دید جانبی از ستاپ اپتیکی (ب) نمای بالا از آرایش اجزا و نمونه

پیش‌پردازش داده‌ها

در کنار اطلاعات شیمیایی، طیف‌ها حاوی اطلاعات نامربوط دیگری مانند نویز، اثر پراکندگی و موارد دیگری نیز هستند که استفاده از روش‌های پیش‌پردازش برای حذف اطلاعات نامربوط و نویز در داده‌های طیفی را بسیار ضروری می‌کند (Wang et al., 2022). در حال حاضر، چندین روش پیش‌پردازش وجود دارد که می‌توان آن‌ها را به دو دسته اصلی تقسیم‌بندی کرد: مشتقات طیفی و روش‌های تصحیح پراکندگی (Rinnan et al., 2009). روش‌های مختلف مشتق‌گیری و هموارسازی طیفی، مانند فیلترهای مشتق چندجمله‌ای Savitzky-Golay (SG) و الگوریتم Norris-Williams، برای حذف تغییرات خط پایه و جداسازی قله‌های هم‌پوشانی شده پیشنهاد شده‌اند. این روش‌ها باعث افزایش وضوح طیفی و نسبت سیگنال به نویز می‌شوند (Moghaddam et al., 2022). روش‌های توزیع نرمال استاندارد (SNV) و تصحیح پراکندگی فرآینده (MSC)، همچنین اغلب برای حذف اثرات پراکندگی استفاده می‌شوند. این روش‌ها می‌توانند تأثیر اندازه ذرات جامد (پراکندگی نور و تفاوت در طول مسیر مؤثر) یا اثر پراکندگی بر داده‌های طیفی را تا حدی کاهش دهند (Wang et al., 2022). در تحقیق حاضر، روش‌های مختلف پیش‌پردازش اعمال شده و عملکرد مدل‌های طبقه‌بندی با استفاده از این روش‌های

پیش‌پردازش ارزیابی شد. ابتدا داده‌های طیفی با استفاده از روش هموارسازی Savitzky-Golay (S-G) با اندازه پنجره‌ای معادل ۱۵، هموار شدند. سپس روش‌های SNV، MSC، مشتق اول (D1) و ترکیب آن‌ها برای حذف یا تصحیح اثرات خط پایه و پراکندگی اعمال شدند.

مدل‌سازی

در مطالعه حاضر، برای بررسی طبقه‌بندی نمونه‌های خالص و تقلبی و همچنین ارزیابی عملکرد تکنیک‌های مختلف پیش‌پردازش، مدل PCA به‌عنوان مدل بدون نظارت و مدل LDA به‌عنوان مدل با نظارت اعمال شدند. روش PCA یک روش آماری است که برای ساده‌سازی داده‌های پیچیده و بزرگ استفاده می‌شود. PCA یکی از پرکاربردترین و مؤثرترین تحلیل‌های آماری برای کاهش ابعاد متغیرها در مجموعه داده‌ها است که به‌طور گسترده در مطالعات مربوط به تقلب در مواد غذایی در سراسر جهان استفاده می‌شود. در این روش، با تبدیل داده‌ها به مؤلفه‌های جدیدی که به آن‌ها مؤلفه‌های اصلی (PC) گفته می‌شود، معمولاً نمودار داده‌ها در فضای دوبعدی-PC1 (PC2) رسم می‌شود تا درصد پوشش داده‌ها در هر بُعد مشخص شود. هر مؤلفه اصلی مقدار معینی از واریانس داده‌ها را پوشش می‌دهد، به‌طوری‌که بیشترین مقدار متعلق به PC1 است (Khojastehnazhand & Roostaei, 2022). کاربردهای اصلی روش PCA عموماً شامل کاهش تعداد متغیرها، نمایش تفاوت بین مواد غذایی تقلبی و خالص، و یافتن رابطه بین متغیرها و نمونه‌ها به‌صورت بدون نظارت است. در تحقیق حاضر مدل PCA روی طیف‌های پیش‌پردازش‌شده برای طبقه‌بندی داده‌های سه و نه کلاس اعمال شد. مجموعه داده سه کلاسه شامل نمونه‌های خالص و تقلبی با چربی و مرغ است و مجموعه داده نه کلاسه شامل نمونه‌های خالص و تقلبی با سطوح مختلف تقلب است. ماتریس داده مورد استفاده برای مدل PCA شامل ۳۵۵۲ ستون (طول موج ثبت شده در محدوده ۱۱۰۰-۲۰۰ نانومتر) و ۱۹۰ ردیف برای نمونه‌ها است. مدل آنالیز تشخیصی خطی (LDA) یکی دیگر از تکنیک‌های شناخته‌شده به صورت یادگیری نظارت شده است که برای حل مسائل طبقه‌بندی با حداقل دو کلاس استفاده می‌شود. مدل LDA به‌عنوان یک روش طبقه‌بندی با نظارت، مشابه PCA برای کاهش ویژگی‌ها به فضای با بعد کم استفاده می‌شود. این رویکرد شیمی‌سنجی، نسبت واریانس بین کلاس‌ها را در برابر واریانس درون کلاسی حداکثر می‌کند، بنابراین جداسازی حداکثری کلاس‌ها را تضمین می‌کند (Kazemi et al., 2023; Pan et al., 2014). بنابراین نمونه‌هایی که در نزدیکی هم قرار دارند در یک کلاس قرار می‌گیرند و نمونه‌هایی که متعلق به کلاس‌های مختلف هستند از هم دور قرار می‌گیرند. در تحقیق حاضر مدل LDA با تابع کرنل خطی و اعتبارسنجی متقاطع یگانه (leave-one-out) استفاده شد. در این روش، ۷۰ درصد از نمونه‌ها به‌عنوان نمونه‌های کالیبراسیون در نظر گرفته شدند و ۳۰ درصد از نمونه‌ها به‌عنوان نمونه‌های تست. برای ارزیابی توانایی مدل‌ها، سه پارامتر آماری به نام حساسیت، اختصاصیت و نرخ طبقه‌بندی صحیح (CCR) استفاده شدند و در روابط ۱ تا ۳ ارائه شده‌اند:

$$\text{Sensitivity} = \frac{TP}{TP+FN} \quad \text{رابطه ۱}$$

$$\text{Specificity} = \frac{TN}{TN+FN} \quad \text{رابطه ۲}$$

$$\text{CCR}(\%) = \frac{TP+TN}{TP+FN+TN+FN} \quad \text{رابطه ۳}$$

TP، TN، FP و FN به‌ترتیب تعداد نمونه‌های صحیح شناسایی شده، نمونه‌های نادرست به درستی شناسایی شده، نمونه‌های صحیح رد شده و نمونه‌های نادرست رد شده را نشان می‌دهند (Rashvand et al., 2016).


نتایج و بحث

تحلیل داده‌های طیفی

میانگین طیف‌های گوشت خالص و نمونه‌های تقلبی با سطوح تقلب در شکل ۲ ارائه شده است. طیف NIR شامل ویژگی‌های طیفی مرتبط با باندهای جذب برخی از ترکیبات شیمیایی است. بر هم کنش‌ها بین اتم‌های بیومولکول‌های مختلف باعث تفاوت در قدرت جذب باندهای NIR به عنوان تابعی از خصوصیات ساختاری و هندسی آنهاست. در ناحیه مرئی، باند جذب در ۴۵۰ نانومتر با باند جذب Soret هم‌گلوبین اریتروسیت مرتبط است (Rady & Adedeji, 2018). پیک کوچک در حدود ۹۷۴ نانومتر به دلیل باندهای جذب آب مرتبط با اورتون دوم کشش O-H است (Kamruzzaman et al., 2012). پیک در حدود ۵۷۰ نانومتر به دلیل جذب اکسی‌میوگلوبین است. باندهای جذب در

۹۴۸ نانومتر به اورتون دوم کشش O-H مربوط بوده و با محتوای رطوبت نمونه‌ها ارتباط دارد (Dixit et al., 2017; Millar et al., 1996).


با توجه به شکل ۲ بررسی‌های طیفی نشان داد که ناحیه ۵۰۰-۶۰۰ نانومتر به دلیل شدت سیگنال پایین و نبود تغییرات مشخص بین نمونه‌ها نقش چندانی در تفکیک نمونه‌های خالص و تقلبی نداشت. در مقابل، بیشترین تفاوت در بازه ۵۵۰-۶۵۰ نانومتر مشاهده شد. تفاوت طیفی در بازه ۵۵۰-۶۵۰ نانومتر مربوط به دئوکسی‌میوگلوبین و اکسی‌میوگلوبین است که به ترتیب رنگ قرمز مایل به بنفش و قرمز گیلانی گوشت قرمز را ایجاد می‌کنند. این اشکال میوگلوبین در ناحیه مرئی تا نزدیک به مادون قرمز طیف در بازه ۵۵۰-۶۵۰ نانومتر غالب هستند و در تعیین رنگ و تازگی گوشت نقش اساسی دارند (Peyvasteh et al., 2019).



شکل ۲. تحلیل مولفه‌های اصلی طیف‌های بازتابی برداشت شده از نمونه‌ها

مدل PCA

مدل PCA به داده‌های پیش‌پردازش‌شده با الگوریتم‌های مختلف اعمال شد تا جداسازی داده‌ها بررسی شود. شکل ۳ نمودار اسکور داده سه کلاسه را نشان می‌دهد. طبق بررسی‌های انجام گرفته، بهترین نتایج خوشه‌بندی توسط مدل PCA با استفاده از پیش‌پردازش SG به دست آمد. دو مولفه اصلی (PC) اول بیشترین واریانس داده‌ها در مجموعه داده‌ها را نشان دادند. بنابراین، در این نمودار هر نمونه بر اساس مقادیر مولفه اول و دوم آن ترسیم شده است. مطابق شکل ۳، PC1 حدود ۹۰٪ از واریانس کل را توضیح می‌دهد، در حالی که PC2 حدود ۵٪ را توضیح می‌دهد. در این نمودار، نمونه‌هایی که طیف‌های مشابهی دارند، تمایل به خوشه‌بندی یا تجمع در کنار یکدیگر دارند. نمونه‌های خالص به طور قابل قبولی در کنار یکدیگر خوشه‌بندی شده‌اند، اما برخی از نمونه‌های تقلبی با مرغ و نمونه‌های تقلبی با چربی همپوشانی دارند. بنابراین جداسازی نمونه‌های خالص با نمونه‌های تقلبی به خوبی امکانپذیر است. در تحقیق مشابهی پرز و همکاران مدل PCA را برای جداسازی ۳ کلاس سینه، ران، و کتف مرغ استفاده کردند. مولفه‌های اصلی اول و دوم به ترتیب ۹۴/۴ درصد و ۴/۸ درصد از کل واریانس را نشان داد (Nolasco Perez et al., 2018). مشابه تحقیق حاضر، داده‌های قسمت‌های ران و کتف در نمودار PCA همپوشانی داشتند، اما جداسازی واضحی بین این نمونه‌ها و داده‌های سینه مرغ قابل مشاهده بود.



شکل ۳. نمودار اسکور بدست آمده برای سه کلاس

مدل LDA

جدول ۱. نتایج طبقه‌بندی مدل LDA برای مجموعه داده ۳ کلاس و ۹ کلاس را نشان می‌دهد. نتایج برای الگوریتم‌های پیش‌پردازش مختلف نشان داده شده است.

جدول ۱. دقت بدست آمده برای مدل LDA با پیش‌پردازش‌های مختلف

Preprocessing	9 Classes		3 Classes	
	Calibration	Prediction	Calibration	Prediction
SG	۷۶/۷۴	۷۶/۷	۸۹/۹۲	۸۹/۹۲
SG + MSC	۶۴/۳۴	۶۴/۳	۸۲/۱۷	۸۲/۱۷
SG + SNV	۶۲/۰۲	۶۲/۰	۸۲/۹۵	۸۲/۹۵
SG + D1	۵۰/۳۹	۵۰/۳۹	۶۷/۴۴	۶۸/۲
SG + MSC + D1	۵۷/۳۶	۵۷/۳۶	۶۵/۸۹	۶۵/۸۹
SG + D1 + MSC	۵۱/۹۴	۵۱/۹۴	۶۴/۳۴	۶۴/۳۴

با توجه به جدول ۱. برای طبقه‌بندی گوشت خالص گوسفند از گوشت‌های تقلبی، مدل LDA با استفاده از پیش‌پردازش SG عملکرد بهینه‌ای نشان داد و به ترتیب دقت پیش‌بینی ۷۶/۷ درصد برای مجموعه داده ۹ کلاس (یک کلاس گوشت خالص و هشت کلاس شامل چهار کلاس برای تقلب با مرغ با چهار درصد تقلب مختلف و چهار کلاس برای تقلب با چربی با چهار درصد تقلب مختلف) و ۸۹/۹۲ درصد برای مجموعه داده ۳ کلاس (گوشت خالص، گوشت تقلبی با مرغ و گوشت تقلبی با چربی) بدست آمد. عملکرد بهتر پیش‌پردازش SG را می‌توان به توانایی آن در نرم‌سازی داده‌ها نسبت داد، در حالیکه ویژگی‌های طیفی ضروری را برای تمایز کلاس‌ها حفظ می‌کند. با توجه به نتایج، استفاده از روش‌های پیش‌پردازش دیگر مانند MSC، SNV یا D1 منجر به کاهش دقت شد. این نتیجه احتمالاً بدلیل ایجاد نویز و یا از بین رفتن اطلاعات ضروری برای تشخیص تفاوت‌های درصد تقلب توسط این پیش‌پردازش‌ها باشد. رحمان و همکاران از مدل LDA برای جداسازی کوفته گوشت گاو خالص و کوفته تقلب شده با گوشت موش استفاده کردند. مدل LDA به طور موفقیت‌آمیز محتویات لیپید استخراج شده از کوفته‌ها را با دقت ۱۰۰ درصد طبقه‌بندی کرد (Rohman et al., 2011). بنابراین در این تحقیق نیز مشابه تحقیق ما

کارایی مدل LDA همراه با روش‌های طیف‌سنجی برای طبقه‌بندی نمونه‌های گوشت اثبات شد. برای بررسی عملکرد مدل در تشخیص و جداسازی هر کلاس، ماتریس اغتشاش برای مجموعه داده ۹ کلاس بررسی شد (جدول ۲).

جدول ۲. ماتریس اغتشاش مدل LDA برای داده نه کلاس

	class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
Class1	۹	۰	۰	۰	۰	۰	۰	۰	۰
Class2	۰	۲	۲	۱	۰	۰	۱	۰	۰
Class3	۰	۱	۳	۰	۰	۰	۲	۰	۰
Class4	۰	۲	۱	۲	۰	۰	۰	۰	۱
Class5	۰	۰	۳	۱	۰	۰	۰	۲	۰
Class6	۰	۳	۰	۱	۱	۰	۱	۰	۰
Class7	۰	۰	۰	۰	۰	۱	۵	۰	۰
Class8	۰	۰	۰	۰	۰	۰	۱	۳	۲
Class9	۰	۰	۰	۰	۰	۰	۰	۰	۶
sensitivity	۱	۰/۳۳	۰/۵	۰/۳۳	۰	۰	۰/۸۳	۰/۵	۱
specificity	۱	۰/۸۸	۰/۸۸	۰/۹۴	۰/۹۸	۰/۹۸	۰/۹۰	۰/۹۶	۰/۹۴
CCR	۱۰۰	۲۵	۳۳	۴۰	۰	۰	۵۰	۶۰	۶۶

در کلاس شماره ۱ که همان گوشت خالص است ۹ نمونه برای داده‌های تست (۳۰٪ از تعداد ۳۰ نمونه) وجود داشت و برای کلاس‌های بعدی هر کلاس شامل ۶ نمونه (۳۰٪ از ۳۰ نمونه) وجود داشت. بر اساس ماتریس مورد نظر جداسازی برای مثال برای کلاس شماره ۱ جداسازی بسیار خوب انجام شده بود و امام ۹ نمونه به درستی در کلاس شماره ۱ تشخیص داده شده بودند. جداسازی برای کلاس شماره ۹ نیز خوب بود به طوریکه ۶ نمونه به درستی در کلاس شماره ۹ تشخیص داده شد. اما برای جداسازی در کلاس‌های شماره ۵ و ۶ ضعیف‌ترین بود به طوریکه هیچ یک از نمونه‌ها به درستی تشخیص داده نشدند که احتمالاً به دلیل تفاوت‌های کم ویژگی‌های طیفی بود که مدل LDA قادر به شناسایی کامل آنها نبود. به طور کلی تقلب با چربی مقادیر CCR بالاتری نسبت به تقلب با گوشت مرغ در سطوح مشابه نشان داد که نشان‌دهنده جداسازی بهتر طیفی برای چربی است. برای بررسی دقت طبقه‌بندی داده ۳ کلاس، جدول ۳. پارامترهای آماری را برای این مجموعه داده نشان می‌دهد. با توجه به جدول ۳. طبقه‌بندی این مجموعه داده به طور قابل قبولی انجام شد.

جدول ۳. ماتریس اغتشاش مدل LDA برای داده سه کلاس

	Class1	Class2	Class3
Class1	۹	۰	۰
Class2	۰	۱۸	۶
Class3	۰	۶	۱۸
sensitivity	۱	۰/۷۵	۰/۷۵
specificity	۱	۰/۸۰	۰/۸۰
CCR	۱۰۰	۷۵	۷۵

نتیجه‌گیری

در این پژوهش از طیف‌سنجی در محدوده مرئی-نزدیک مادون قرمز (۲۰۰ تا ۱۱۰۰ نانومتر) برای شناسایی تقلب در گوشت چرخ‌کرده گوسفند با افزودن چربی یا گوشت مرغ استفاده شد. نتایج نشان داد که ترکیب روش‌های پیش‌پردازش مانند S-G با مدل‌های طبقه‌بندی نظیر LDA می‌تواند دقت مناسبی در تمایز بین نمونه‌های خالص و ناخالص فراهم آورد. بهترین عملکرد مدل با دقت ۸۹/۹۲ درصد برای مجموعه ۹ کلاسه به دست آمد که نشان‌دهنده حساسیت بالای روش طیف‌سنجی نسبت به تغییرات در ترکیب گوشت است. از یافته‌های مهم این تحقیق آن است که روش طیف‌سنجی بدون نیاز به تخریب نمونه، قادر است سطوح پایین تقلب را نیز تشخیص دهد. با این حال، پیشنهاد می‌شود در پژوهش‌های آتی، با گسترش تنوع نمونه‌ها، بهره‌گیری از مدل‌های یادگیری عمیق، و بررسی نواحی طیفی با بیشترین اهمیت در تمایز نمونه‌ها، دقت و کاربردپذیری این روش در محیط‌های صنعتی یا نظارتی ارتقا یابد.

References

- Barbin, D., Badaró, A., Honorato, D., Ida, E., & Shimokomaki, M. (2019). Identification of turkey meat and processed products using near infrared spectroscopy. *Food Control*, 107, 106816. doi:10.1016/j.foodcont.2019.106816
- Candoğan, K., Altuntas, E. G & ,İğci, N. (2021). Authentication and Quality Assessment of Meat Products by Fourier-Transform Infrared (FTIR) Spectroscopy. *Food Engineering Reviews*, 13(1), 66-91. doi:10.1007/s12393-020-09251-y
- De Girolamo, A., Cervellieri, S., Mancini, E., Pascale, M., Logrieco, A. F., & Lippolis, V. (2020). Rapid Authentication of 100% Italian Durum Wheat Pasta by FT-NIR Spectroscopy Combined with Chemometric Tools. *Foods*, 9(11). doi:10.3390/foods9111551
- Deniz, E., Gunes Altuntas, E., Ayhan, B., İğci, N., Demiralp, D & ,Candogan, K. (2018). Differentiation of beef mixtures adulterated with chicken or turkey meat using FTIR spectroscopy. *Journal of Food Processing and Preservation*, 42, e13767. doi:10.1111/jfpp.13767
- Dixit, Y., Casado-Gavaldà, M. P., Cama-Moncunill, R., Cama-Moncunill, X., Markiewicz-Keszycska, M., Cullen, P. J., & Sullivan, C. (2017). Developments and Challenges in Online NIR Spectroscopy for Meat Processing. *Compr Rev Food Sci Food Saf*, 16(6), 1172-1187. doi:10.1111/1541-4337.12295
- Hu, Y., Zou, L., Huang, X., & Lu, X. (2017). Detection and quantification of offal content in ground beef meat using vibrational spectroscopic-based chemometric analysis. *Sci Rep*, 7(1), 15162. doi:10.1038/s41598-017-15389-3
- Kamruzzaman, M., Barbin, D., ElMasry, G., Sun, D.-W & ,Allen, P. (2012). Potential of hyperspectral imaging and pattern recognition for categorization and authentication of red meat. *Innovative Food Science & Emerging Technologies*, 16, 316-325. doi:<https://doi.org/10.1016/j.ifset.2012.07.007>
- Kamruzzaman ,M., Makino, Y., & Oshita, S. (2016). Rapid and non-destructive detection of chicken adulteration in minced beef using visible near-infrared hyperspectral imaging and machine learning. *Journal of Food Engineering*, 170, 8-15. doi:<https://doi.org/10.1016/j.jfoodeng.2015.08.023>
- Kazemi, A., Mahmoudi, A., & Khojastehnazhand, M. (2023). Detection of sodium hydrosulfite adulteration in wheat flour by FT-MIR spectroscopy. *Journal of Food Measurement and Characterization*, 17(2), 1932-1939. doi:10.1007/s11694-022-01-۷۶۳x
- Kazemi, A., Mahmoudi, A., Veladi, H., Javanmard, A., & Khojastehnazhand, M. (2022). Rapid identification and quantification of intramuscular fat adulteration in lamb meat with VIS-NIR spectroscopy and chemometrics methods. *Journal of Food Measurement and Characterization*, 16(3), 2400-2410. doi:10.1007/s11694-022-01352-y
- Khojastehnazhand, M., & Roostaei, M. (2022). Classification of seven Iranian wheat varieties using texture features. *Expert Systems with Applications*, 199, 117014. doi:<https://doi.org/10.1016/j.eswa.2022.117014>
- Leng, T., Li, F., Xiong, L., Xiong, Q., Zhu, M., & Chen, Y. (2020). Quantitative detection of binary and ternary adulteration of minced beef meat with pork and duck meat by NIR combined with chemometrics. *Food Control*, 113, 10.۷۲۰۳doi:<https://doi.org/10.1016/j.foodcont.2020.107203>
- Millar, S. J., Moss, B. W., & Stevenson, M. H. (1996). Some observations on the absorption spectra of various myoglobin derivatives found in meat. *Meat Science*, 42(3), 277-288. doi:[https://doi.org/10.1016/0964-6560\(96\)00045\(۹۴\)۱۷۴۰X](https://doi.org/10.1016/0964-6560(96)00045(۹۴)۱۷۴۰X)
- Nobari Moghaddam, H., Tamiji, Z., Akbari Lakeh, M., Khoshayand, M. R., & Haji Mahmoodi, M. (2022). Multivariate analysis of food fraud: A review of NIR based instruments in tandem with chemometrics. *Journal of Food Composition and Analysis*, 107, 104343. doi:<https://doi.org/10.1016/j.jfca.2021.104343>
- Nolasco Perez, I. M., Badaró, A. T., Barbon, S., Jr., Barbon, A. P. A., Pollonio, M. A. R., & Barbin, D. F. (2018). Classification of Chicken Parts Using a Portable Near-Infrared (NIR) Spectrophotometer and Machine Learning. *Appl Spectrosc*, 72(12), 1774-1780. doi:10.1177/0003702818788878
- Pan, F., Song, G., Gan, X., & Gu, Q. (2014). Consistent feature selection and its application to face recognition. *Journal of Intelligent Information Systems*, 43, 307-321. doi:10.1007/s10844-014-0324-5
- Peyvasteh, M., Popov, A., Bykov, A., & Meglinski, I. (2019). Meat freshness evaluation using visible to near-infrared spectroscopy (Conference Presentation).
- Rady, A., & Adedeji, A. (2018). Assessing different processed meats for adulterants using visible-near-infrared spectroscopy. *Meat Science*, 136, 59-67. doi:<https://doi.org/10.1016/j.meatsci.2017.10.014>
- Rashvand, M., Omid, M., Mobli, H., & Firouz, M. S. (2016). Adulteration detection in olive oil using dielectric technique and data mining. *Sensing and Bio-Sensing Research*, 11, 33-36. doi:<https://doi.org/10.1016/j.sbsr.2016.10.005>



- Rinnan, Å., Berg, F. v. d., & Engelsen, S. B. (2009). Review of the most common pre-processing techniques for near-infrared spectra. *TrAC Trends in Analytical Chemistry*, 28(10), 1201-1222. doi:<https://doi.org/10.1016/j.trac.2009.07.007>
- Rohman, A., Sismindari, Erwanto, Y., & Che Man, Y. B. (2011). Analysis of pork adulteration in beef meatball using Fourier transform infrared (FTIR) spectroscopy. *Meat Science*, 88(1), 91-95. doi:<https://doi.org/10.1016/j.meatsci.2010.12.007>
- Wang, H.-P., Chen, P., Dai, J.-W., Liu, D., Li, J.-Y., Xu, Y.-P., & Chu, X.-L. (2022). Recent advances of chemometric calibration methods in modern spectroscopy: Algorithms, strategy, and related issues. *TrAC Trends in Analytical Chemistry*, 153, 116648. doi:<https://doi.org/10.1016/j.trac.2022.116648>
- Weng, S., Guo, B., Tang, P., Yin, X., Pan, F., Zhao, J., . . . Zhang, D. (2020). Rapid detection of adulteration of minced beef using Vis/NIR reflectance spectroscopy with multivariate methods. *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy*, 230, 118005. doi:<https://doi.org/10.1016/j.saa.2019.118005>