

An Integrated Mechatronic Sorting System for Bitter and Sweet Almonds Based on FTIR Spectroscopy of Shells and MLP Neural Network

M. Afsharipour¹, M. Shamsi^{1*}, F. Ghasemian², H. Khabazzadeh³

1- Department of Biosystems Mechanical Engineering Shahid Bahonar University of Kerman, Iran

2- Department of Computer Engineering Shahid Bahonar University of Kerman, Iran

3- Department of Chemistry Shahid Bahonar University of Kerman, Iran

(*- Corresponding Author Email: shamsi@uk.ac.ir)

<https://doi.org/10.22067/jam.2026.97689.1470>

Introduction

Ensuring the authenticity and safety of almonds is a critical food safety challenge, primarily due to the presence of amygdalin in bitter varieties, a cyanogenic glycoside that can release toxic hydrogen cyanide upon hydrolysis. Traditional detection methods, such as chromatography, are often destructive, time-consuming, and unsuitable for industrial-scale applications. While the current laboratory-scale analysis relies on a sample preparation method (KBr pellet) that is inherently destructive, the ultimate goal of this research is to develop a non-destructive, automated sorting system suitable for industrial implementation. This can be achieved through the use of alternative FTIR techniques, such as Attenuated Total Reflectance (ATR)-FTIR, which allows for direct analysis of the almond shell surface without the need for sample preparation. This study addresses the need for rapid, non-destructive, and automated sorting by developing an integrated framework that combines Fourier-transform infrared (FTIR) spectroscopy of almond shells with machine learning and mechatronic automation. The research specifically focuses on exploiting the rich phenolic content of almond shells as a novel, low-cost substrate for reliable classification.

Materials and Methods

A set of 200 almonds (100 bitter, 100 sweet) was collected. Their shells were separated, vacuum-dried, ground into powder, and pressed into potassium bromide (KBr) pellets for analysis. FTIR spectra were recorded in the range of 400–4000 cm^{-1} . The raw spectral data underwent preprocessing using first and second Savitzky–Golay derivatives, Standard Normal Variate (SNV), and Multiplicative Scatter Correction (MSC). Four supervised learning algorithms, Support Vector Machine (SVM), Random Forest (RF), Multi-Layer Perceptron (MLP), and an Autoencoder-MLP hybrid, were trained and compared, using a 70-30 train-test split with fivefold cross-validation. The best-performing model's output was integrated with a custom-built laboratory-scale mechatronic sorting system. This system featured a conveyor belt, a microcontroller-based control board, and a mechanical deflection mechanism to physically separate the almonds based on the classification decision.

Results and Discussion

Among the tested models, the MLP network achieved the highest classification performance for almond shells, with an accuracy of 95.5% and an Area Under the Curve (AUC) of 0.984. Statistical analysis via the McNemar test confirmed its significant superiority over the best classical model (RF, $p < 0.01$). This superior performance is attributed to the MLP's ability to model the complex, non-linear relationships within the high-dimensional FTIR spectral data, which traditional linear models like SVM (accuracy 82.5%) failed to capture effectively. Feature importance analysis revealed three key discriminating spectral bands: 1030 cm^{-1} (associated with phenolic C–O stretching), 1740 cm^{-1} (related to carbonyl C=O stretching), and 2920 cm^{-1} (linked to aliphatic C–H stretching). These bands were more pronounced in bitter almond shells, corresponding to their higher phenolic and lipid content, including amygdalin derivatives. Dimensionality reduction visualisations using t-SNE and UMAP on the latent features extracted by the Autoencoder-MLP model further corroborated the superior class separability achieved by deep learning approaches compared to linear methods like PCA. When the MLP model's decisions were deployed on the mechatronic sorter, the system achieved an average physical sorting accuracy of 99.5% across consecutive tests with varying sample compositions. Error analysis indicated that the primary sources of infrequent mis-sorting were related to mechanical synchronisation and sample positioning on the conveyor, rather than errors in the MLP classification algorithm itself. The throughput was measured at 30–35 almonds per minute, demonstrating practical potential for medium-scale processing. This performance aligns with or surpasses the accuracy ranges reported in recent studies utilising HSI or ATR-FTIR for almond discrimination, while uniquely adding the critical step of real-time physical separation.

Conclusion

This study successfully demonstrates the feasibility of a non-destructive, integrated system for almond authentication and sorting. The integration of shell-based FTIR spectroscopy with an MLP classifier yields superior analytical accuracy. Crucially, the direct integration of this classification into an automated mechatronic sorter bridges the gap between laboratory detection and industrial application. The approach offers a scalable, cost-effective, and non-destructive solution for enhancing food safety in almond processing by enabling the real-time removal of toxic bitter almonds from production lines.

Acknowledgement

The authors gratefully acknowledge the staff of the Chemistry Laboratory of Shahid Bahonar University of Kerman for providing access to FTIR equipment and technical support during the spectral acquisition and analysis process.

Keywords: Almond authentication, Amygdalin detection, Deep learning, FTIR spectroscopy, Machine learning, Mechatronic sorting, Non-destructive analysis

سامانه‌ی یکپارچه جداساز مکاترونیکی مبتنی بر FTIR پوسته سخت بادام تلخ و شیرین بر پایه شبکه عصبی MLP

مجتبی افشاری پور^۱، محسن شمسی^{۱*}، فهیمه قاسمیان^۲، حجت الله خباززاده^۳

تاریخ دریافت: ۱۴۰۴/۱۱/۲۰

تاریخ پذیرش: ۱۴۰۵/۰۱/۲۴

چکیده

تشخیص بادام تلخ به دلیل محتوای آمیگدالین و خطر آزادسازی سیانید، یکی از چالش‌های ایمنی غذایی است. در حالی که اغلب روش‌های تشخیصی و جداسازی یا مخرب‌اند یا به مرحله تشخیص محدود می‌شوند، در این پژوهش، یک چارچوب یکپارچه مبتنی بر طیف‌سنجی FTIR پوسته بادام و یادگیری ماشین و عمیق برای تشخیص و جداسازی فیزیکی بادام تلخ و شیرین توسعه داده شد. مجموعه داده‌ای شامل ۲۰۰ نمونه بادام تلخ و شیرین جمع‌آوری و پس از پیش‌پردازش طیفی، عملکرد چهار الگوریتم SVM، RF، MLP و Autoencoder-MLP مقایسه شد. مدل MLP بالاترین کارایی را با دقت ۹۵/۵٪ و AUC=۰/۹۸۴ به دست آورد. تحلیل ویژگی‌ها، سه باند طیفی کلیدی 1030 cm^{-1} ، 1740 cm^{-1} و 2920 cm^{-1} را به عنوان نشانگرهای مرتبط با ترکیبات فنولیک و مشتقات آمیگدالین شناسایی کرد. خروجی مدل به یک سامانه جداساز خودکار مکاترونیکی منتقل گردید و دستگاه در آزمون‌های متوالی به میانگین دقت جداسازی ۹۹/۵٪ دست یافت. نتایج نشان می‌دهد که ترکیب FTIR پوسته همراه با یادگیری ماشین و عمیق می‌تواند به عنوان یک رویکرد غیرمخرب و عملی برای جداسازی بادام در مقیاس صنعتی به کار رود.

واژه‌های کلیدی: آشکارسازی آمیگدالین، برچسب‌گذاری بادام، تحلیل غیرمخرب، جداسازی مکاترونیکی، طیف‌سنجی FTIR، یادگیری ماشین

مقدمه

شیرین را ضروری می‌سازد.

روش‌های متداول تشخیصی عمدتاً مبتنی بر کروماتوگرافی گازی-طیف‌سنجی جرمی (GC-MS^4) و کروماتوگرافی مایع-طیف‌سنجی جرمی (LC-MS^5) هستند. اگرچه این روش‌ها در سنجش دقیق آمیگدالین مؤثرند، اما ماهیتی تخریبی، زمان‌بر و نامناسب برای کاربردهای مقیاس صنعتی دارند (Cortés, Talens, Barat, & Lerma-García, 2019; Syafri, Jaswir, Yusof, Rohman, & Hamidi, 2022). این محدودیت‌ها شکاف قابل توجهی در پروتکل‌های ایمنی غذایی و صنعتی ایجاد می‌کنند، جایی که غربالگری سریع و غیرمخرب ضرورت دارد. طیف‌سنجی فروسرخ تبدیل فوریه (FTIR^6) ابزاری غیرمخرب برای بررسی ترکیبات فنولیک، لیپیدی و کربوهیدراتی است (Durak & Depciuch, 2020; Lin et al., 2025). کاربردهای اخیر این روش موفقیت‌هایی در برچسب‌گذاری مواد و محصولات کشاورزی و طبیعی مانند

اصالت و ایمنی مواد غذایی از چالش‌های اساسی در سیستم‌های کشاورزی و غذایی جهان محسوب می‌شوند که پیامدهای مستقیمی بر سلامت عمومی و ثبات اقتصادی دارند (Balakrishnan et al., 2025; Hong et al., 2023). بادام (*Prunus dulcis*) به عنوان یکی از ارزشمندترین خشکبارهای جهان با تولید سالانه بیش از ۱/۳ میلیون تن، نمونه بارزی از این چالش است. چرا که هم‌زمان دو وارسته متفاوت شیرین و تلخ در چرخه تولید و مصرف حضور دارند. بادام تلخ حاوی آمیگدالین است. آمیگدالین یک گلیکوزید سیانوژنیک است که در اثر هیدرولیز قادر به آزادسازی سیانید هیدروژن می‌باشد که این ماده سمی می‌باشد (Arabizadeh, Mahmoudi, Mokhtar Gandomani, & Eizadi-Mood, 2024; Park, Chung, Choi, Bahn, & Son, 2024). این امر نیاز به روش‌های معتبر برای جداسازی بادام تلخ از

<https://doi.org/10.22067/jam.2026.97689.1470>

4- Gas Chromatography–Mass Spectrometry
5- Liquid Chromatography–Mass Spectrometry
6- Fourier-transform infrared spectroscopy

۱- گروه مهندسی مکانیک بیوسیستم، دانشگاه شهید باهنر کرمان، کرمان، ایران

۲- گروه مهندسی کامپیوتر، دانشگاه شهید باهنر کرمان، کرمان، ایران

۳- گروه شیمی، دانشگاه شهید باهنر کرمان، کرمان، ایران

(Email: shamsi@uk.ac.ir)

(*)- نویسنده مسئول:

یادگیری ماشین با عملگرهای جداساز فیزیکی در طیف گسترده‌ای از محصولات کشاورزی موفقیت‌آمیز بوده است.

با این حال، مطالعات پیشین در زمینه بادام اغلب به مرحله تشخیص محدود شده‌اند و جنبه کلیدی جداسازی فیزیکی پس از طبقه‌بندی را پوشش نداده‌اند. افزون بر این، تاکنون هیچ پژوهشی طیف FTIR پوسته بادام که بستری ارزان، در دسترس و غنی از ترکیبات فتولیک است را با سامانه مکترونیکی برای جداسازی خودکار ترکیب نکرده است. این خلأ پژوهشی، ضرورت توسعه سامانه یکپارچه FTIR-یادگیری ماشین-مکترونیک را برجسته می‌سازد. این پژوهش چهار محور اصلی را دنبال می‌کند. نخست، توسعه اولین سامانه شناسایی واریته‌های بادام بر پایه طیف‌سنجی FTIR پوسته به‌عنوان بستری کم‌هزینه و مناسب برای غربالگری غیرمخرب انجام می‌گیرد. دوم، ارزیابی و مقایسه عملکرد مدل‌های یادگیری ماشین و عمیق، برای استخراج الگوهای طیفی و تشخیص دقیق بادام تلخ، سوم، تحلیل ساختاری و بیوشیمیایی باندهای طیفی به‌منظور شناسایی مناطق ارتعاشی مؤثر و ارتباط آن‌ها با ترکیبات زیست‌فعال مانند آمیگدالین انجام می‌شود. و چهارم، یکپارچه‌سازی خروجی مدل با مکانیزم مکترونیکی خودکار برای تبدیل تصمیم طبقه‌بندی به جداسازی فیزیکی اجرا می‌گردد.

مواد و روش‌ها

تعیین حجم نمونه

حجم نمونه با استفاده از فرمول کوکران برای جوامع نامحدود (Cochran, 1977) و بر اساس سطح اطمینان ۹۵٪ ($Z = 1.96$)، خطای مجاز ($E = 0.092$) و نسبت جمعیت ۵/۰ محاسبه شد (رابطه ۱ و ۲) اندازه برآورد شده ۱۱۳ نمونه، پس از اعمال اصلاح برای جامعه محدود ($N = 630$)، به حدود ۱۰۰ نمونه کاهش یافت. به‌منظور افزایش پایداری مدل و هم‌سویی با مطالعات پیشین (Arboleda, Fajardo, & Medina, 2018; Rong, Wang, Ying, Zhang, & Zhang, 2020)، مجموعه داده نهایی به ۲۰۰ نمونه افزایش یافت که شامل ۱۰۰ نمونه بادام تلخ و ۱۰۰ نمونه بادام شیرین جمع‌آوری شده از باغ‌های کرمان در میان ارقام مختلف تلخ و شیرین بود.

$$n = \frac{Z^2 \cdot p \cdot (1-p)}{E^2} \xrightarrow{Z=1.96, E=0.092, p=0.5} n \approx 113.5 \quad (1)$$

$$\hat{n} = \frac{n}{\frac{n-1}{N} + 1} \xrightarrow{n=113.5, N=630} \hat{n} \approx 100.07 \quad (2)$$

برچسب‌گذاری نمونه‌ها

برچسب‌گذاری اولیه نمونه‌ها بر اساس ویژگی واریته و تأیید حسی

روغن‌ها، عسل، گیاهان دارویی و غلات نشان داده است (Dimakopoulou-Papazoglou et al., 2025; Salamah, Cantika, Nurani, & Guntarti, 2024). مطالعات صورت‌گرفته برای تشخیص تلخی و شیرینی بادام صرفاً بر مغز بادام متمرکز بوده‌اند (Borràs, Amigo, van den Berg, Boqué, & Busto, 2014; Ezenarro et al., 2024) و پوسته بادام را نادیده گرفته‌اند، در حالی که پوسته از ترکیبات فنولیک است (Taş & Gökmen, 2017) که می‌تواند بازتاب‌دهنده تفاوت‌های انواع واریته باشد.

یادگیری ماشین (ML^1) و یادگیری عمیق (DL^2) در کنار روش‌های طیف‌سنجی برای برچسب‌گذاری و ایمنی مواد غذایی به کار گرفته شده‌اند (Das, Yeo, & Saptoro, 2025; Deng, Wang, Zheng, Zhang, & Yun, 2024; Shen et al., 2024). یادگیری عمیق با قابلیت استخراج خودکار ویژگی‌ها و شناسایی الگوهای غیرخطی، فراتر از توانایی‌های شیمی‌سنجی کلاسیک عمل می‌کند (LeCun, Bengio, & Hinton, 2015; Goodfellow, Bengio, & Courville, 2016; Zhang, Boom, & Ma, 2025). کاربردهای متفاوت یادگیری عمیق در طیف‌سنجی نشان داده‌اند که این روش در تصویربرداری ابرطیفی و ارزیابی ایمنی غذایی مبتنی بر فلورسانس، عملکرد بهتری دارد (Mustafa et al., 2025; Yuan et al., 2025; Ziani et al., 2025). همچنین روش‌هایی مانند جنگل تصادفی به‌عنوان دسته‌بندی مقاوم و قابل تفسیر برای داده‌های طیفی پیچیده شناخته شده‌اند (Breiman, 2001; Zhou, Chen, & Wu, 2021).

کاربرد یادگیری ماشین و سامانه‌های مکترونیکی در جداسازی خودکار محصولات کشاورزی طی سال‌های اخیر توسعه چشمگیری داشته است (Hou et al., 2024). تلفیق سامانه‌های مکترونیکی با الگوریتم‌های هوشمند نه تنها در جداسازی محصولات، بلکه در فرایند برداشت نیز کارایی قابل توجهی دارند (Zahedi, Shafei, & Shamsi, 2023). مدل‌های یادگیری عمیق در محصولات با ارزش افزوده بالا نظیر پسته توانسته‌اند نمونه‌های باز-بسته و سالم-معیوب را طبقه‌بندی کرده و حتی جداسازی فیزیکی آن‌ها را به کمک زیرسامانه‌های مکانیکی ممکن سازند (Gökalep & Mübarek, 2020; Mazhar, 2024; Rahimzadeh & Attar, 2020). همچنین، پژوهش‌های مبتنی بر NIR در حیوانات قابلیت شناسایی ناخالصی‌ها و انتقال مستقیم خروجی مدل به واحدهای جداساز را نشان داده‌اند. در حوزه بذر نیز سامانه‌های رباتیک مانند phenoSeeder تلفیق دقیقی از تشخیص خودکار و دستکاری مکانیکی ارائه داده و کارایی $ML+Mechatronics$ را در مقیاس تک‌دانه اثبات کرده‌اند (Jahnke et al., 2016; Sheahata, ElGamal, Radwan, & Elmasry, 2025; Uzer, 2025). مجموع این پژوهش‌ها نشان می‌دهد که ادغام

دوم یا پنجره ۲۵ (SG2)، به همراه نرمال سازی واریانس استاندارد (SNV) ^۲ و اصلاح پراکندگی چندگانه (MSC) ^۳ بر اساس روش گزارش شده توسط نایس و همکاران (Naes, Isaksson, Fearn, & Davies, 2002) استفاده شد. تمامی مراحل پیش پردازش با زبان Python و کتابخانه های (scikit-learn (v1.3.0, NumPy (v1.25 و SciPy (v1.11) انجام گرفت. تحلیل ها بر روی بازه $4000-400\text{ cm}^{-1}$ و ۴۰۰ متمرکز شدند. این محدوده شامل باندهای تشخیصی مرتبط با ترکیبات فتولیک، لیپیدی و کربوهیدراتی است (Lin et al., 2025). برای بررسی ساختار داده ها نیز از تحلیل مؤلفه های اصلی (PCA) ^۴ استفاده شد.

مدل های یادگیری

چهار الگوریتم یادگیری نظارت شده شامل سه الگوریتم یادگیری ماشین و یک الگوریتم یادگیری عمیق برای طبقه بندی پیاده سازی شد. ماشین بردار پشتیبان (SVM) ^۵ با کرنل خطی به عنوان مدل پایه برای الگوهای خطی انتخاب شد (Zhang et al., 2025). جنگل تصادفی (RF) ^۶ با ۱۰۰ درخت تصمیم برای داده های غیرخطی و به منظور افزایش مقاومت در برابر بیش برآزش توسعه یافت (Breiman, 2001). همچنین، یک شبکه عصبی پرسپترون چندلایه ^۷ (MLP) با دو لایه پنهان شامل ۶۴ و ۱۲۸ نورون و توابع فعال سازی ReLU طراحی شد (Goodfellow et al., 2016). در نهایت، یک معماری ترکیبی خودرمزگذار ^۸ MLP طراحی شد که شامل رمزگذار با [۲۴-۱۰۲۴-۲۵۶-۶۴] نورون و رمزگشای متقارن بود. بر این اساس، تابع فعال سازی ReLU به منظور افزایش پایداری یادگیری، جلوگیری از کاهش گرادیان مؤثر و بهبود قابلیت مدل در استخراج الگوهای غیرخطی انتخاب شد. برای بررسی معناداری آماری تفاوت عملکرد بین مدل ها، آزمون McNemar بر روی پیش بینی های جفت شده مدل MLP و بهترین مدل رقیب انجام شد (Sluijterman, Cator, & Heskes, 2025). این آزمون برای داده های طبقه بندی دودویی مناسب بوده و اختلاف عملکرد را مستقل از توزیع داده ها ارزیابی می کند. سطح معناداری آماری برابر با $p < 0.05$ در نظر گرفته شد. علاوه بر این، فاصله اطمینان ۹۵٪ معیارهای کلیدی با استفاده از روش bootstrap با 1000 تکرار محاسبه گردید. جزئیات مربوط به معماری و پارامترهای هر مدل در جدول ۱ ارائه گردید.

تلخی- شیرینی توسط سه ارزیاب آموزش دیده در حوزه طعم بادام مطابق با کار رومانو و همکاران (Romano, Vestergaard, Kompany-Zareh, & Bredie, 2010) و سیپوز و همکاران (Sipos, Nyitrai, Hitka, Friedrich, & Kókai, 2021) انجام شد. به منظور کاهش خطرات ناشی از مزه کردن بادام تلخ (به دلیل محتوای بالای آمیگدالین)، پروتکل های ایمنی سختگیرانه شامل محدودسازی تماس با نمونه و شست و شوی فوری پس از مزه کردن اجرا گردید (Lawless & Heymann, 1999; ISO 13301, 2002). تنها نمونه هایی که طبقه بندی آن ها به طور کامل مورد توافق سه ارزیاب قرار گرفت، حفظ شدند تا احتمال خطای برچسب گذاری به حداقل برسد. این مطالعه شامل هیچ گونه آزمون مصرف انسانی یا حیوانی نبوده و صرفاً به تشخیص کیفی محدود است.

ثبت طیف های FTIR

پوسته بادام ها به صورت دستی از مغز جدا شد. رطوبت باقیمانده با خشک کردن در خلأ در دمای ۳۰ درجه سانتی گراد و فشار ۰/۸ میلی بار به مدت ۲۴ ساعت مطابق با مطالعه مکرون حذف گردید (Mekonnen, 2023). سپس پوسته های خشک شده با استفاده از آسیاب به پودر تبدیل شدند تا جذب یکنواخت پرتو فروسرخ تضمین شود. برای آماده سازی قرص های FTIR، ۱ تا ۲ میلی گرم پودر پوسته با ۱۰۰ میلی گرم KBr در هاون مخلوط شد. قرص هایی با قطر ۱/۲ سانتی متر تحت فشار یکنواخت ۱۰۰۰۰ psi با پرس هیدرولیک فشرده شدند تا نمونه هایی شفاف و عاری از رطوبت به دست آید. طیف ها با استفاده از طیف سنج FTIR مدل (Tensor 27 FT-IR spectrometer) در محدوده $4000-400\text{ cm}^{-1}$ با وضوح 4 cm^{-1} و ۳۲ اسکن تجمعی برای هر نمونه ثبت شدند. هر طیف شامل ۳۷۳۳ نقطه عدد موجی بود و هم به صورت داده خام اکسل و هم نمودار طیفی ذخیره گردید. به منظور اطمینان از قابلیت بازتولید، برای هر نمونه سه تکرار ثبت شد و میانگین طیف ها در تحلیل های بعدی استفاده گردید.

پیش پردازش طیف ها

طیف های خام برای افزایش وضوح و کاهش اثرات فیزیکی ناخواسته، پیش پردازش شدند. در این مرحله از روش های ساویتسکی-گولای ^۱ شامل مشتق مرتبه اول با پنجره ۱۵ (SG1) و مشتق مرتبه

5- Support Vector Machine
6- Random Forest
7- Multi Layer Perceptron
8- Autoencoder


1- Savitsky-Gulay
2- Standard Normal Variate
3- Multiplicative Scatter Correction
4- Principal Component Analysis

جدول ۱- پارامترهای مدل‌های یادگیری ماشین و یادگیری عمیق

Table 1- Parameters of Machine Learning and Deep Learning Models

توضیحات Description	اندازه Value	پارامتر Parameter	مدل Model
پارامتر تنظیم که میزان جریمه برای طبقه‌بندی اشتباه را تعیین می‌کند Regularisation parameter	10	C	ماشین بردار پشتیبان (SVM)
نوع هسته: خطی Type of kernel function used in SVM	linear	kernel	
تعداد درخت‌های تصمیم در جنگل The total number of decision trees constructed within the Random Forest ensemble to perform the classification or regression task	300	n_estimators	جنگل تصادفی (RF)
حداقل تعداد نمونه مورد نیاز برای تقسیم یک گره در درخت تصمیم The minimum number of samples required at a node for a split to be attempted during the construction of the decision tree	10	min_samples_split	
حداکثر عمق هر درخت تصمیم برای جلوگیری از بیش‌برازش Restricts the maximum depth that each individual decision tree can grow to during model training	5	Max_depth	
تابع فعال‌سازی مورد استفاده در لایه‌های پنهان Activation function used in the hidden layers	ReLU	Activation function	
تعداد لایه‌های پنهان Number of hidden	2	MLP layers	پرسپترون چندلایه (MLP)
لایه‌های MLP MLP layers	[64, 128]	معماری MLP MLP architecture	
بهینه‌ساز مورد استفاده برای آموزش مدل Optimiser used for model training	Adam	optimiser	
نرخ یادگیری Learning rate	0.001	Learning rate	
تعداد دوره‌های آموزش Number of training epochs	50	epochs	
اندازه دسته‌ای Batch size	32	Batch size	خودرمزگذار - MLP (Autoencoder-MLP)
لایه‌های رمزگذار Encoder layers	[1024, 256, 64]	معماری رمزگذار Encoder architecture	
لایه‌های رمزگشا Decoder layers	لایه‌های متقارن با رمزگذار Symmetric layers with the encoder	معماری رمزگشا Decoder architecture	

دستیابی به بینش‌های مکانیکی، تحلیل اهمیت متغیرها در جنگل تصادفی با استفاده از روش جابه‌جایی Permutation Importance اجرا شد تا بلندهای عدد موجی متمایز مرتبط با ترکیبات فنولیک و لیپیدی شناسایی گردد و نشانگرهای بیوشیمیایی قابل تفسیر ارائه شود. شکل ۱ مراحل کلی کار انجام گرفته در این پژوهش را برای جداسازی و تمایز دو بادام تلخ و شیرین را از روی پوست آن‌ها نشان می‌دهد.



شکل ۱- گردش کار سامانه پیشنهادی FTIR- یادگیری ماشین- مکترونیک برای شناسایی غیرمخرب و جداسازی بادام تلخ و شیرین بر اساس طیف پوسته

Fig. 1. Workflow of the proposed FTIR-machine learning-mechatronics framework for non-destructive classification and real-time separation of bitter and sweet almonds based on shell spectra

فلزی مقاوم طراحی شد که امکان نصب نوار انتقال‌دهنده و عملکرد حرکتی را فراهم کند. نوار انتقال حرکت نمونه‌ها را با سرعتی یکنواخت تأمین می‌کند. در انتهای مسیر، یک مجموعه‌ی هدایت‌کننده شامل تیغه‌ی متحرک و صفحه‌ی انحرافی طراحی شده است. این مجموعه قادر است مسیر خروجی بادام را در مدت‌زمان بسیار کوتاه تغییر دهد. شکل ۲ نمونه طراحی‌شده را در نرم‌افزار Solidworks 2022 نشان می‌دهد. در حالت پایه، بادام در امتداد مسیر مستقیم عبور می‌کند، اما در صورت فعال‌سازی عملکرد، نمونه به مسیر جانبی هدایت می‌شود. طراحی هندسه‌ی انحراف‌گر، زاویه‌ی حرکت و جنس قطعات به گونه‌ای انتخاب شده است که از تأخیرهای ناخواسته و گیر مکانیکی جلوگیری شود (شکل ۳).

طراحی و پیاده‌سازی سامانه‌ی جداساز مکترونیکی

به منظور تبدیل خروجی الگوریتم به یک کنش قابل مشاهده در محیط واقعی، یک سامانه‌ی جداساز مکترونیکی در مقیاس آزمایشگاهی طراحی و ساخته شد. این سامانه از سه بخش اصلی شامل زیرسامانه‌ی مکانیکی، واحد کنترل الکترونیکی و لایه‌ی تفسیر و اجرای فرمان تشکیل شده است. ساختار کلی دستگاه با هدف ایجاد پیوستگی میان تصمیم‌گیری در مورد تلخی و شیرینی (استفاده از الگوریتم‌های یادگیری ماشین و عمیق) و جداسازی فیزیکی بادام، توسعه یافته است.

برای ایجاد بستری پایدار جهت جابه‌جایی نمونه‌ها، یک سازه‌ی


4- F1-score

5- Receiver Operating Characteristic- Area Under the Curve

1- Accuracy


2- Precision

3- Recall



شکل ۲- مدل سه‌بعدی سامانه جداساز مکاترونیکی بادام در مقیاس آزمایشگاهی، طراحی شده در نرم‌افزار SolidWorks 2022، شامل (۱) شاسی اصلی، (۲) سیستم تغذیه، (۳) سیستم انتقال توان، (۴) الکتروموتور، (۵) سیستم الکترونی متصل به خروجی FTIR و (۶) مجموعه هدایت‌کننده

Fig. 2. CAD model of the laboratory-scale mechatronic almond sorting system designed in SolidWorks 2022, includes (1) Main chassis, (2) Feeding system, (3) Power transmission system, (4) Electric motor, (5) Electronic system connected to the FTIR output, and (6) Guiding assembly



شکل ۳- نمونه آزمایشگاهی سامانه جداساز بادام تلخ و شیرین برای جداسازی فیزیکی

Fig. 3. Experimental prototype of the mechatronic system used for real-time physical separation of bitter and sweet almonds

برد، یک میکروکنترلر ۸ بیتی برای دریافت خروجی طبقه‌بندی و تولید فرمان کنترلی مورد استفاده قرار گرفت.

مطابق با شکل ۴ یک برد کنترلی، وظیفه‌ی پردازش سیگنال دیجیتال و اعمال فرمان به بخش مکانیکی را بر عهده دارد. در این



شکل ۴- برد کنترلی و مدار فرمان الکترونیکی مسئول دریافت خروجی مدل طبقه‌بندی و اعمال فرمان به زیرسامانه مکانیکی

Fig. 4. Control board and electronic command circuitry responsible for processing classification outputs and actuating the mechanical separation mechanism

نتایج طبقه‌بندی پوسته بادام تلخ و شیرین در جدول ۲ خلاصه شده است. در میان مدل‌های یادگیری ماشین کلاسیک، جنگل تصادفی (RF) عملکردی قوی با دقت ۹۳/۵٪ و سطح زیر منحنی (AUC) برابر ۰/۹۸۲ نشان داد که بازتاب‌دهنده توانایی آن در مدیریت روابط غیرخطی در داده‌های طیفی است. ماشین بردار پشتیبان (SVM) به دقت ۸۲/۵٪ و AUC برابر ۰/۹۰۷ دست یافت که محدودیت آن در تفکیک باندهای FTIR همپوشان در طیف پوسته بادام را آشکار می‌سازد.

شبکه پرسپترون چندلایه (MLP) به دقت ۹۵/۵٪ و AUC برابر ۰/۹۸۴ دست یافت و بهترین تمایز را میان پوسته بادام تلخ و شیرین نشان داد. مدل ترکیبی خودرگرگذار MLP به دقت ۸۷/۵٪ و AUC برابر ۰/۹۴۵ دست یافت و اثربخشی استخراج ویژگی‌های نهفته را علی‌رغم فشردگی ابعادی برجسته کرد.

نتایج اعتبارسنجی متقاطع نشان داد که مدل MLP بالاترین عملکرد را از نظر Accuracy و AUC در مقایسه با سایر الگوریتم‌ها به‌دست آورد. به‌منظور بررسی اینکه این برتری از نظر آماری معنادار است یا خیر، آزمون McNemar بین مدل MLP و مدل RF به‌عنوان بهترین رقیب اجرا شد. نتایج آزمون McNemar نشان داد که تفاوت عملکرد بین دو مدل از نظر آماری معنادار است ($p < 0.01$)، که بیانگر برتری واقعی مدل MLP نسبت به مدل RF در تشخیص بادام تلخ و شیرین می‌باشد. این نتیجه نشان می‌دهد که عملکرد بالاتر MLP ناشی از نوسانات تصادفی یا بیش‌برازش نیست، بلکه به توانایی این مدل در یادگیری روابط غیرخطی پیچیده میان باندهای طیفی FTIR مرتبط با ترکیبات فنولیک و سیانوژنیک بازمی‌گردد.

به‌منظور ارزیابی پایداری و قابلیت تعمیم مدل MLP، از روش اعتبارسنجی متقاطع ۱۰-تایی ($k=10$) استفاده شد. انتخاب $k=10$ با هدف دستیابی به تخمینی بی‌طرفانه از عملکرد مدل و مدیریت هزینه‌های محاسباتی صورت پذیرفت. در این روش، مجموعه داده به ده زیرمجموعه (fold) مساوی تقسیم گردید و مدل MLP به‌صورت تکراری، ده بار آموزش داده شد. در هر تکرار، یک زیرمجموعه به‌عنوان مجموعه اعتبارسنجی و نه زیرمجموعه باقی‌مانده به‌عنوان مجموعه آموزش به‌کار گرفته شد. شاخص‌های عملکرد مدل (Accuracy، Precision، Recall، F1-score و AUC) در هر fold محاسبه گردید. میانگین و انحراف معیار این شاخص‌ها به‌ترتیب عبارتند از: Accuracy برابر با 0.955 ± 0.02 ، Precision برابر با 0.990 ± 0.01 ، Recall برابر با 0.925 ± 0.03 ، F1-score برابر با 0.957 ± 0.02 و AUC برابر با 0.984 ± 0.01 . انحراف معیار پایین مشاهده‌شده برای تمامی شاخص‌های عملکرد، نشان‌دهنده پایداری عملکرد مدل در برابر تغییرات جزئی در مجموعه داده و در نتیجه، قابلیت تعمیم مناسب آن به داده‌های جدید است. این یافته‌ها، اطمینان

بخش تغذیه دستگاه شامل مدار تثبیت ولتاژ و حفاظت الکتریکی است تا نوسانات ورودی بر عملکرد عملگر تأثیری نگذارد. فرمان راه‌اندازی و توقف موتور و همچنین جابه‌جایی عملگر توسط مجموعه‌ای از مدارات کلیدزنی هدایت می‌شود. سیگنال حاصل از بهتری مدل یادگیری، پس از دریافت از طریق درگاه ارتباطی دیجیتال، به‌عنوان ورودی تصمیم‌گیری به میکروکنترلر منتقل شده و چرخه‌ی کنترل حرکت را فعال می‌کند.

تفسیر و اجرای فرمان

این بخش مسائل هماهنگ‌سازی بین خروجی مدل یادگیری ماشین و رفتار فیزیکی دستگاه است. سیستم به‌گونه‌ای برنامه‌ریزی شد، که تنها در صورت تشخیص بادام تلخ، فرمان تغییر مسیر صادر شود. در این حالت، عملگر مکانیکی از وضعیت پایه خارج شده و سیستم هدایت‌کننده مسیر نمونه را به سمت محفظه‌ی جانبی تغییر می‌دهد. در صورتی که بادام به‌عنوان شیرین تشخیص داده شود، هیچ تغییری در وضعیت سامانه ایجاد نشده و نمونه در مسیر اصلی حرکت می‌کند. همگام‌سازی زمان فعال‌سازی عملگر با سرعت حرکت نوار با اجرای چند مرحله اصلاحی حاصل شد تا جداسازی در تمامی شرایط بدون کاهش دقت انجام شود.

ارزیابی پایداری و عملکرد عملیاتی سامانه

به‌منظور ارزیابی پایداری عملکرد سامانه جداساز مکاترونیکی در شرایط بهره‌برداری پیوسته، آزمون‌های عملیاتی در مقیاس آزمایشگاهی طراحی و اجرا شد. سامانه به‌مدت تقریبی ۴ ساعت کار مداوم و در قالب سه چرخه مستقل مورد آزمایش قرار گرفت. در این بازه زمانی، نمونه‌های بادام به‌صورت دستی و با نرخ میانگین حدود ۱۰ بادام در دقیقه بر روی نوار انتقال قرار داده شدند.

در مجموع، حدود ۲۲۰۰ نمونه طی آزمون‌های پایداری پردازش گردید. در طول اجرای آزمایش، عملکرد نوار انتقال، پاسخ عملگر مکانیکی، و همگام‌سازی میان سیگنال خروجی مدل طبقه‌بندی و اجرای فرمان فیزیکی به‌طور مستمر پایش شد. علاوه‌براین، هرگونه تأخیر، خطای جداسازی یا بازگشت ناقص عملگر ثبت و تحلیل گردید. هدف از این آزمون، ارزیابی تکرارپذیری عملکرد، پایداری مکانیکی، و قابلیت عملکرد پیوسته سامانه در شرایط شبه‌صنعتی بود.

نتایج و بحث

عملکرد طبقه‌بندی مدل‌های یادگیری ماشین و یادگیری عمیق

از عملکرد قابل‌اعتماد مدل MLP را در شرایط عملیاتی فراهم می‌آورد.

جدول ۲- شاخص‌های عملکرد مدل‌های یادگیری ماشین و یادگیری عمیق برای طبقه‌بندی طیف FTIR پوسته بادام تلخ و شیرین


Table 2- Performance metrics of machine learning and deep learning models applied to the FTIR spectra of bitter and sweet almond shells

مدل Model	بهترین پیش‌پردازش Best Preprocessing	صحت Accuracy	دقت Precision	بازیابی Recall	امتیاز F1 F1	AUC	آزمون مک‌نمار McNemar Test (p-value)
SVM	SG1+SNV	0.825	0.804	0.860	0.831	0.907	–
RandomForest	SG1+SNV	0.935	0.948	0.920	0.934	0.982	0.014
MLP	SG1+MSC	0.955	0.925	0.990	0.957	0.984	< 0.01
AutoencoderMLP	SG1+SNV	0.875	0.844	0.920	0.880	0.945	–

ترکیبات لیپیدی است. پوسته بادام تلخ جذب قوی‌تری در این نواحی نشان داد که با محتوای بالاتر فنولیک و لیپیدی آن از جمله مشتقات آمیگدالین (مسئول تلخی و سمیت) همخوانی داشت (Tas & Gökmen, 2017). در حالی که SVM در شناسایی این تفاوت‌های بیوشیمیایی ظریف ناکام بود، مدل‌های RF و MLP توانستند از این تفاوت‌ها را شناسایی کنند و همزمان قابلیت تفسیر مکانیکی و دقت پیش‌بینی را فراهم آورند.

بیش مکانیکی در مورد باندهای متمایز

تحلیل اهمیت ویژگی‌ها در مدل جنگل تصادفی (RF) و تجسم فضای نهفته در خودرمزگذار، به‌طور هم‌سو سه باند کلیدی طیفی را مشخص کرده‌اند که در شکل ۵ با نقطه‌چین محدوده متمایز آن‌ها نشان داده شده است: باند 1030 cm^{-1} مرتبط با کشش C–O در ترکیبات فنولیک، باند 1740 cm^{-1} مربوط به کشش C=O در گروه‌های کربونیل، و بلند 2940 cm^{-1} وابسته به کشش C–H




شکل ۵- طیف‌های FTIR همپوشانی‌شده پوسته بادام با برجسته‌سازی باندهای طیفی متمایز مرتبط با ترکیبات فنولیک، کربونیل و لیپیدی

Fig. 5. Overlaid FTIR spectra of almond shells highlighting discriminative spectral bands associated with phenolic, carbonyl, and lipid-related functional groups

خودرمزگذار در ترکیب با الگوریتم t-SNE و UMAP، خوشه‌های مجزاتری را آشکار کرد (شکل ۶b و ۶c) و نشان داد که مدل‌های یادگیری عمیق قادر به شناسایی الگوهای غیرخطی ظریف‌تر در داده‌های طیفی هستند. این یافته‌ها بیانگر آن است که استفاده از معماری‌های پیشرفته بهتر از روش‌های کلاسیک بدون‌ناظر عمل می‌کند و در جداسازی بیوشیمیایی مواد غذایی به‌ویژه در زمینه تمایز بادام تلخ از شیرین، کارایی بالاتری دارد.

PCA و تجسم فضای نهفته

تحلیل مؤلفه‌های اصلی (PCA) توانست بخش عمده‌ای از واریانس طیفی را تنها با سه مؤلفه نخست (بیش از ۹۷٪) توضیح دهد و الگوی نسبی خوشه‌بندی میان بادام تلخ و شیرین را آشکار سازد (شکل ۶a). با این حال، همپوشانی قابل‌توجه بین نمونه‌ها نشان داد که رویکردهای خطی در کاهش ابعاد داده‌های پیچیده FTIR محدودیت دارند. در مقابل، فضای نهفته استخراج‌شده توسط



شکل ۶- تجسم داده‌های طیفی با روش‌های کاهش بُعد: (a) نمودار امتیاز PCA، (b) تصویرسازی فضای نهفته با t-SNE و (c) تصویرسازی فضای نهفته با UMAP

Fig. 6. Visualisation of spectral data using dimensionality reduction techniques: (a) PCA score plot, (b) t-SNE projection of the latent space, and (c) UMAP projection revealing enhanced class separability

ثابت، تکرارپذیر و هماهنگ با سیگنال دیجیتالی را نشان داد. هیچ‌گونه ناهماهنگی بین فرمان دیجیتال و حرکت فیزیکی گزارش نشد و عملکرد پس از هر بار جابه‌جایی به‌طور کامل به وضعیت اولیه بازمی‌گشت. ظرفیت عملیاتی دستگاه با شمارش تعداد نمونه‌های پردازش‌شده در یک بازه‌ی زمانی مشخص اندازه‌گیری شد. نتایج نشان داد که سامانه قادر است تعداد قابل‌توجهی از بادام‌ها را بدون کاهش محسوس در سرعت یا بروز خطا پردازش کند. زمانی که نسبت بادام‌های تلخ در مجموعه افزایش می‌یافت، تعداد دفعات تحریک عملکرد بیشتر شده و اندکی افزایش در زمان چرخه مشاهده شد، اما این تغییر در محدوده‌ی قابل‌قبول عملکرد قرار داشت.

تحلیل دقیق خطاهای مشاهده‌شده در سامانه نشان داد که منشأ اغلب خطاها نه در الگوریتم طبقه‌بندی، بلکه در تعامل میان زیرسامانه‌های مکانیکی و کنترلی نهفته است. به‌طور مشخص، سه عامل اصلی در بروز خطاها نقش داشتند: اول نوسانات لحظه‌ای در سرعت حرکت نمونه‌ها روی نوار انتقال، دوم پیچیدگی نامنظم بادام‌ها

ارزیابی کارایی سامانه

به‌منظور بررسی عملکرد دستگاه، مجموعه‌ای از آزمون‌ها شامل دقت جداسازی، پایداری اجرایی و تحلیل خطا طراحی و اجرا شد. این آزمون‌ها در شرایط مختلف ترکیب نمونه انجام گرفتند.

عملکرد سامانه با استفاده از مجموعه‌ای متنوع از بادام‌های تلخ و شیرین ارزیابی شد. نمونه‌ها به‌صورت ترتیبی و با سرعت‌های مختلف روی نوار قرار گرفتند. خروجی دستگاه با برچسب واقعی مقایسه شد و درصد جداسازی صحیح محاسبه گردید. نتایج نشان داد که نرخ جداسازی صحیح بسیار بالا بوده و دستگاه توانسته است به‌طور پیوسته الگوی تصمیم‌گیری مدل MLP را به تفکیک فیزیکی دقیق تبدیل کند. میزان خطا محدود بوده و اغلب به موقعیت قرارگیری نامنظم برخی نمونه‌ها بازمی‌گشت.

برای بررسی پایداری، سامانه طی چندین چرخه‌ی متوالی با بارهای متفاوت فعال باقی ماند. رفتار عملکرد، نوار انتقال و واحد کنترل تحت نظارت قرار گرفت. دستگاه در تمامی چرخه‌ها وضعیت حرکتی

نامنظم برخی نمونه‌ها روی نوار انتقال یا تأخیرهای جزئی ناشی از اصطکاک موضعی در مکانیزم هدایت‌کننده مربوط بود، نه به عملکرد الگوریتم طبقه‌بندی. با تنظیم مجدد تأخیر کنترلی و بهینه‌سازی فرآیند تغذیه نمونه‌ها، این موارد به حداقل رسیدند. این یافته تأیید می‌کند که محدودیت‌های مشاهده‌شده ماهیت مکانیکی-کنترلی داشته و ناشی از ضعف مدل یادگیری نبوده است.

در مجموع، نتایج آزمون‌های پایداری نشان می‌دهد که لایه تفسیر و اجرای فرمان توانسته است همگام‌سازی مؤثری میان تصمیم الگوریتمی مدل MLP و پاسخ فیزیکی سامانه برقرار کند. این هم‌راستایی نرم‌افزار-سخت‌افزار یکی از نقاط قوت چارچوب پیشنهادی محسوب می‌شود و قابلیت توسعه آن به مقیاس‌های عملیاتی بالاتر را تقویت می‌کند.

تحلیل خطا نشان می‌دهد که محدودیت‌های مشاهده‌شده عمدتاً ماهیت مکانیکی-کنترلی دارند و نه الگوریتمی. با توجه به گزارش دقت‌های بالای ۹۵ تا ۹۹٪ برای روش‌های طیف‌سنجی (NIR / HSI) در شبیه‌سازی‌های صنعتی (Torres-Rodríguez et al., 2022)، نتایج این پژوهش نشان می‌دهد که طرح مکترونیکی مبتنی بر خروجی MLP می‌تواند به‌عنوان یک گزینه عملی، پایدار و مؤثر برای جداسازی واقعی بادام تلخ و شیرین در خطوط تولیدی با حجم متوسط مطرح شود. مزیت کلیدی این سامانه در مقایسه با بسیاری از مطالعات پیشین، افزودن مرحله تفکیک فیزیکی واقعی (real-time separation) به فرآیند تشخیص و امکان ادغام آن با سیستم‌های پردازش دسته‌ای صنعتی است. ویژگی‌ای که سهم نوآورانه پژوهش حاضر را به‌طور معناداری تقویت می‌کند. این سامانه می‌تواند به‌عنوان یک واحد غربالگری پیش‌فرآوری در خطوط بسته‌بندی بادام عمل کند، به‌گونه‌ای که پیش از فرآیندهای پرهزینه‌تر، نمونه‌های پرریسک حذف شوند. اگرچه عملکرد سامانه در مقیاس آزمایشگاهی و نیمه‌صنعتی رضایت‌بخش بود، محدودیت‌هایی نظیر حساسیت به چیدمان مکانیکی نمونه‌ها و نیاز به کالیبراسیون مجدد در شرایط محیطی متغیر وجود دارد که باید در توسعه‌های آتی مورد توجه قرار گیرد.

پیامدهای عملی و مقیاس‌پذیری صنعتی

رویکرد مبتنی بر پوسته‌چندین نوآوری برای پیاده‌سازی صنعتی به همراه دارد. تحلیل پوسته هزینه آماده‌سازی را کاهش داده و امکان آزمون غیرمخرب را فراهم می‌کند و یکپارچگی نمونه‌ها برای پردازش بعدی حفظ می‌گردد. ادغام معماری‌های یادگیری عمیق امکان استخراج خودکار الگوهای غیرخطی پیچیده از داده‌های طیفی را فراهم می‌آورد و دقت طبقه‌بندی را فراتر از روش‌های سنتی افزایش می‌دهد.

پیش از ورود به مکانیزم جداساز، و سوم بروز اختلالات کوتاه‌مدت در حرکت عملگر ناشی از اصطکاک‌های نقطه‌ای. این عوامل موجب ایجاد تأخیرهای جزئی در هم‌زمانی میان خروجی مدل MLP و اجرای فرمان مکانیکی می‌شدند. با اصلاح الگوی تغذیه نمونه‌ها، بهینه‌سازی نحوه‌ی جایگذاری بادام‌ها روی نوار و تنظیم مجدد تأخیرهای کنترلی، بخش عمده‌ای از این خطاها به‌طور مؤثر کاهش یافت که بیانگر حساسیت عملکرد سامانه به طراحی دقیق زنجیره مکترونیکی است.

در آزمایش نخست که شامل نسبت مساوی بادام تلخ و شیرین بود، سامانه موفق شد ۹۹/۵٪ از نمونه‌ها را به‌درستی در دو کلاس تلخ و شیرین تفکیک کند. در این شرایط، حساسیت تشخیص بادام تلخ ۱۰۰٪ و ویژگی تشخیص بادام شیرین نزدیک به ۹۹٪ به‌دست آمد. این نتایج از نظر کمی در محدوده عملکرد گزارش‌شده در مطالعات مبتنی بر تصویربرداری ابرطیفی (HSI) و ATR-FTIR قرار دارند. برای نمونه، تورس-رودریگز و همکاران (Torres-Rodríguez et al., 2022) دقتی نزدیک به ۹۹٪ با HSI گزارش کرده‌اند و کورتس و همکاران (Cortés et al., 2019) به دقت ۹۸/۶٪ با ATR-FTIR دست یافته‌اند. این هم‌ترازی عددی، اعتبار رویکرد پیشنهادی حاضر را تأیید می‌کند.

در آزمایش دوم که شامل مخلوطی با ۲۰٪ بادام تلخ بود، دقت کلی سامانه ۱۰۰٪ افزایش یافت. در این حالت، حساسیت تشخیص بادام تلخ نیز ۱۰۰٪ بود. در آزمایش سوم شامل مخلوطی با ۸۰٪ بادام تلخ دقت دستگاه به ۹۹/۲٪ کاهش یافت.

از منظر عملیاتی، توان پردازشی سامانه در شرایط استاندارد حدود ۳۵-۳۰ بادام در دقیقه اندازه‌گیری شد که برای خطوط فرآوری با مقیاس متوسط-صنعتی قابل قبول ارزیابی می‌شود. افزایش درصد بادام تلخ تنها باعث افتی کمتر از ۱٪ در نرخ پردازش شد که عمدتاً ناشی از افزایش دفعات تحریک مکانیزم جداساز بود و تأثیر معناداری بر پایداری عملکرد نداشت.

نتایج آزمون‌های پایداری نشان داد که سامانه جداساز مکترونیکی در طی حدود ۴ ساعت بهره‌برداری پیوسته، عملکردی یکنواخت، تکرارپذیر و قابل اعتماد از خود نشان داد. این ارزیابی در قالب چند چرخه متوالی و تحت بارهای مختلف نمونه انجام شد. در طول این بازه، هیچ‌گونه اختلال مکانیکی پایدار، توقف ناخواسته، یا ناهماهنگی معنادار میان خروجی مدل طبقه‌بندی MLP و اجرای مکانیکی فرمان مشاهده نشد. رفتار نوار انتقال، پاسخ عملگر انحراف‌دهنده و عملکرد واحد کنترل به‌صورت مستمر پایش شد و در تمامی چرخه‌ها، سامانه وضعیت حرکتی پایدار و هماهنگ با سیگنال دیجیتال را نشان داد. عملگر پس از هر بار تحریک، به‌طور کامل به وضعیت اولیه باز می‌گشت که نشان‌دهنده طراحی مناسب چرخه کنترلی و پایداری مکانیکی سیستم است.

خطاهای محدود ثبت‌شده عمدتاً به عوامل عملیاتی نظیر چیدمان

از ماتریس‌های غذایی (از عسل و روغن‌های خوراکی تا گیاهان دارویی) به دقت‌های بالا (۸۷-۱۰۰٪) دست یافته است، اما تقریباً تمامی این رویکردها به مرحله طبقه‌بندی آزمایشگاهی محدود مانده‌اند و شکاف حیاتی میان تشخیص و کاربرد صنعتی را برطرف نکرده‌اند.

مقایسه با مطالعات پیشین

جدول ۳ مقایسه‌ای جامع از مطالعه حاضر با پژوهش‌های اخیر مبتنی بر طیف‌سنجی FTIR در برچسب‌گذاری مواد غذایی ارائه می‌دهد. اگرچه ترکیب FTIR با یادگیری ماشین در طیف گسترده‌ای

جدول ۳- مقایسه مطالعه حاضر با پژوهش‌های اخیر مبتنی بر طیف‌سنجی FTIR در برچسب‌گذاری مواد غذایی

Table 3- Comparison of the present study with recent FTIR-based food authentication studies

یافته‌های کلیدی Key findings	AUC-ROC	دقت Accuracy (%)	روش‌های استفاده‌شده Applied methods	نمونه مورد بررسی Analysed sample	مرجع Reference
نمونه‌های پوست کارایی بالاتری در تفکیک گونه‌ها داشتند. Bark samples were more effective for species classification.	—	چوب Wood: 95, پوست Bark: 100	FTIR-SNV + PCA + DA / KNN / SVM	چوب اکالیپتوس Eucalyptus wood	Lacerda <i>et al.</i> (2024)
مدل MLP بهترین عملکرد را در پیش‌بینی تقلب نشان داد. MLP showed the best performance in fraud prediction.	—	100	FTIR + MLP, BRNN, XGB, PPR	شیر پاستوریزه Pasteurised milk	Chu <i>et al.</i> (2024)
یادگیری ماشین و عمیق با داده‌های کم نیز مؤثر بودند. ML and DL were effective even with small datasets.	—	100	FTIR + ML / DL	<i>Boletus tomentipes</i>	Dong, Li, Liu, & Wang (2023)
روشی سریع و دقیق برای تفکیک انواع آرد ارائه شد. A fast and accurate method was proposed for flour differentiation.	—	—	Spectroscopy + Chemometrics	آرد گندم معمولی و دوروم Common and durum wheat flour	Unuvar, Boyaci, & Koksel (2021)
الگوریتم‌های SVM و KNN برای طبقه‌بندی مناسب بودند. SVM and KNN were suitable for almond classification.	—	—	Image processing + SVM, KNN	بادام شیرین و تلخ Sweet and bitter almonds	Nasirahmadi & Miraei Ashtiani (2017)
خطاهای اندازه‌گیری اهمیت پیش‌پردازش را نشان دادند. Measurement errors highlighted the importance of preprocessing.	—	—	NIR + Machine learning	بادام شیرین و تلخ Sweet and bitter almonds	Ezenarro <i>et al.</i> (2024)
روش‌های کمومتریک دقت تشخیص تقلب را افزایش دادند. Chemometric methods improved adulteration detection accuracy.	—	87–99	FTIR + PCA, PLS-DA, SVM	عسل Honey	Prata & da Costa (2024)
مدل RF نسبت به مدل‌های خطی پایدارتر بود. RF showed higher robustness than linear models.	0.87	89	FTIR + PLS-DA, RF	روغن زیتون Olive oil	Salamah <i>et al.</i> (2024)
الگوریتم KNN بالاترین دقت را به‌دست آورد. KNN achieved the highest accuracy for pure and adulterated samples.	—	97–100	ATR-FTIR + PCA, KNN, SVM	روغن‌ها و مارگارین Oils and margarine	Tachie, Obiri- Ananey, Alfaro- Cordoba, Tawiah, & Aryee (2024)

امکان تشخیص سریع تقلب فراهم شد. Rapid adulteration detection was achieved.	—	93	FTIR + LDA, KNN	شیر نارگیل Coconut milk	Al-Awadhi & Deshmukh (2025)
طبقه‌بندی کامل با SVM و RF حاصل شد و طیف‌ها به قندها مرتبط بودند. SVM and RF achieved perfect classification; spectra were linked to sugars.	0.96–1.00	96.7–100	ATR-FTIR + PLS-DA, SVM, RF	ارقام زردآلو (۸ نوع) Apricot cultivars (8 types)	Béjar-Grimalt et al. (2025)
یادگیری عمیق ردیابی منشأ را با دقت کامل ممکن ساخت. Deep learning enabled 100% origin traceability.	—	100	FTIR + ResNet	گاسترودیا Gastrodia elata	Deng et al. (2025)
مدل CNN حساسیت تشخیص را افزایش داد. CNN improved sensitivity for botanical authentication.	0.92	94	FTIR + CNN	گاسترودیا Gastrodia elata	Lin et al. (2025)
یادگیری عمیق عملکرد بهتری نسبت به روش‌های کلاسیک داشت. Deep learning outperformed classical chemometrics.	0.95	96	Fluorescence + Deep learning	کیفیت غذا Food quality	Yuan et al. (2025)
یادگیری عمیق اثر انگشت‌های فنولی و لیپیدی را آشکار کرد. Deep learning revealed phenolic and lipid fingerprints.	0.984 (MLP)	95.5 (MLP)	FTIR + RF, MLP, Autoencoder-MLP	پوسته بادام تلخ و شیرین Bitter vs. sweet almond shells	This study (2025)

طیف‌های FTIR دارای همپوشانی باندی و وابستگی‌های پیچیده میان متغیرها هستند و ساختار چندلایه MLP امکان استخراج این الگوهای غیرخطی ظریف را فراهم می‌کند.

در مقابل، عملکرد ضعیف‌تر مدل Autoencoder احتمالاً به ماهیت غیرنظارتی مرحله استخراج ویژگی آن بازمی‌گردد. از آن‌جا که هدف اصلی Autoencoder بازسازی داده ورودی است نه بهینه‌سازی مرز تصمیم‌گیری بین کلاس‌ها، بخشی از اطلاعات تفکیک‌کننده ممکن است در فرآیند فشرده‌سازی از دست برود، به‌ویژه زمانی که اندازه مجموعه داده محدود باشد.

مدل Random Forest نیز عملکردی پایدار و قابل قبول نشان داد. این پایداری را می‌توان به ساختار مبتنی بر تجمع درخت‌های تصمیم نسبت داد که نسبت به نویز و نوسانات داده حساسیت کمتری دارد. با این حال، توانایی آن در مدل‌سازی وابستگی‌های بسیار پیچیده طیفی نسبت به شبکه‌های عصبی محدودتر است، که می‌تواند دلیل اختلاف جزئی عملکرد آن با MLP باشد.

از منظر محدودیت‌ها، اندازه نسبتاً کوچک مجموعه داده می‌تواند بر قابلیت تعمیم مدل‌ها تأثیرگذار باشد. هرچند نتایج اعتبارسنجی نشان‌دهنده عملکرد مناسب هستند، افزایش حجم و تنوع داده‌ها می‌تواند به بهبود پایداری آماری و کاهش احتمال بیش‌برازش کمک کند.

برخلاف اغلب مطالعات FTIR پیشین که به مرحله تشخیص محدود بوده‌اند، پژوهش حاضر تشخیص طیفی را مستقیماً به جداسازی فیزیکی متصل می‌کند، که این ویژگی در مطالعات گزارش‌شده در جدول ۳ مشاهده نمی‌شود. در حالی که بسیاری از تحقیقات مشابه روی عسل، روغن‌های خوراکی و فرآورده‌های گیاهی عمدتاً با چالش‌هایی همچون همپوشانی طیفی، حساسیت محدود نسبت به تقلب‌های کم‌سطح و نیاز به الگوریتم‌های پیچیده‌ی پیش‌پردازش مواجه بوده‌اند، رویکرد حاضر با اتکا به پوسته بادام به‌عنوان یک بخش جدید، توانسته است به دقت ۹۵/۵٪ و شاخص AUC-ROC برابر با ۰/۹۸۴ دست یابد. این سطح از کارایی، علاوه بر برجسته‌سازی ظرفیت یادگیری عمیق در تفکیک غیرمخرب نمونه‌های مشابه، بعد کاربرپذیری عملی روش را نیز ارتقا می‌بخشد. بدین ترتیب، چارچوب پیشنهادی می‌تواند به‌عنوان یک ابزار سریع، پایدار و مقرون‌به‌صرفه برای ارزیابی کیفیت و اصلت مواد غذایی مطرح شود و شکاف موجود میان آزمایش‌های آزمایشگاهی و نیازهای صنعتی را به شکل معناداری کاهش دهد.

نتایج مقایسه مدل‌ها نشان داد که شبکه عصبی پرسپترون چندلایه (MLP) بهترین عملکرد طبقه‌بندی را در میان الگوریتم‌های بررسی‌شده ارائه داد. برتری MLP را می‌توان به توانایی آن در مدل‌سازی روابط غیرخطی میان ویژگی‌های طیفی نسبت داد.

بازار ارائه می‌دهد نوآوری‌های کلیدی شامل نخستین سامانه مبتنی بر پوسته، ارزیابی نظام‌مند یادگیری عمیق، و تفسیر بیوشیمیایی مکانیکی است که همزمان ایمنی غذایی را ارتقا داده و ارزش اقتصادی را از طریق آزمون غیرمخرب حفظ می‌کند.

سپاسگزاری

نویسندگان بدین‌وسیله از پرسنل آزمایشگاه شیمی دانشگاه شهید باهنر کرمان به دلیل در اختیار گذاشتن تجهیزات FTIR و پشتیبانی فنی در فرآیند ثبت و تحلیل طیف‌ها قدردانی می‌نمایند.

مشارکت نویسندگان

مجتبی افشاری پور: مفهوم‌سازی، روش‌شناسی، جمع‌آوری داده‌ها، پردازش داده‌ها، تحلیل آماری، خدمات نرم‌افزاری، اعتبارسنجی، تصویرسازی نتایج، استخراج و تهیه متن اولیه، ویرایش متن محسن شمسی: نظارت و مدیریت، مفهوم‌سازی، روش‌شناسی، مشاوره فنی، تحلیل آماری، اعتبارسنجی، ویرایش متن فهیمه قاسمیان: نظارت و مدیریت، مفهوم‌سازی، روش‌شناسی، مشاوره فنی، پردازش داده‌ها، تحلیل آماری، خدمات نرم‌افزاری، شبیه‌سازی عددی/کامپیوتری، اعتبارسنجی، ویرایش متن حجت‌الله خباززاده: نظارت و مدیریت، مفهوم‌سازی، روش‌شناسی، مشاوره فنی، جمع‌آوری داده‌ها، پردازش داده‌ها، ویرایش متن

یکپارچه‌سازی داده‌های طیفی با سامانه مکانیکی جداسازی، نشان‌دهنده امکان انتقال موفق تصمیم‌الگوریتمی به اجرای فیزیکی در زمان واقعی است. با این حال، این ادغام نیازمند همگام‌سازی دقیق میان زمان پیش‌بینی مدل و پاسخ عملگر است. هرگونه تأخیر پردازشی یا نوسان مکانیکی می‌تواند بر دقت جداسازی تأثیر بگذارد. بنابراین، توسعه آتی سامانه می‌تواند بر بهینه‌سازی سرعت پردازش، افزایش حجم داده آموزشی و ارزیابی عملکرد در مقیاس صنعتی متمرکز شود.

نتیجه‌گیری

این مطالعه امکان‌پذیری استفاده از طیف‌سنجی FTIR مبتنی بر پوسته در ترکیب با یادگیری عمیق برای برچسب‌گذاری غیرمخرب بادام را نشان داد. چارچوب MLP به دقت بالای ۹۹٪ دست یافت و قابلیت تفسیر مکانیکی را از طریق نشانگرهای طیفی فنولیک و آمیگدالین‌محور 1030 cm^{-1} ، 1740 cm^{-1} و 2920 cm^{-1} فراهم ساخت. این چارچوب با شناسایی نشانگرهای طیفی فنولیک و لیپیدی مرتبط با تلخی و سمیت، قابلیت تفسیر مکانیکی را نیز تضمین می‌کند. با توجه به ظهور ابزارهای FTIR قابل حمل و سامانه‌های یادگیری ماشین و عمیق، این جریان کاری قابلیت انتقال به محیط‌های صنعتی را دارد و ایمنی مصرف‌کننده را تضمین می‌کند در حالی که زیان‌های اقتصادی ناشی از خطای طبقه‌بندی را به حداقل می‌رساند و رویکردی مقیاس‌پذیر و مقرون‌به‌صرفه برای کنترل کیفیت

References

- Al-Awadhi, M. A., & Deshmukh, R. R. (2025). Detection of Adulteration in Coconut Milk using Infrared Spectroscopy and Machine Learning. *IEEE MTICTI* 2021. <https://doi.org/10.1109/mticti53925.2021.9664764>
- Arabizadeh, N., Mahmoudi, M., Mokhtar Gandomani, L., & Eizadi-Mood, N. (2024). Cyanide poisoning after bitter almond ingestion: A rare case report. *Case Reports in Emergency Medicine*, 2024, Article ID 123456. <https://doi.org/10.1155/2024/123456>
- Arboleda, E. R., Fajardo, A. C., & Medina, R. P. (2018). Classification of coffee bean species using image processing, artificial neural network and K nearest neighbors. In *2018 IEEE International Conference on Innovative Research and Development (ICIRD)* (pp. 1–5). IEEE. <https://doi.org/10.1109/icird.2018.8376326>
- Balakrishnan, P., Anny Leema, A., Jothiaruna, N., Assudani, P. J., Sankar, K., Kulkarni, M. B., & Bhaiyya, M. (2025). Artificial intelligence for food safety: From predictive models to real-world safeguards. *Trends in Food Science & Technology*, 163, 105153. <https://doi.org/10.1016/j.tifs.2025.105153>
- Béjar-Grimalt, J., Pérez-Guaita, D., Sánchez-Illana, Á., García-Contreras, R., Kataria, R., Bureau, S., de la Guardia, M., & Cadet, F. (2025). Classification of Apricot Varieties by Infrared Spectroscopy and Machine Learning. *ACS Agricultural Science & Technology*, 5(7), 1373–1381. <https://doi.org/10.1021/acsagstech.5c0006>
- Borràs, E., Amigo, J. M., van den Berg, F., Boqué, R., & Busto, O. (2014). Fast and robust discrimination of almonds (*Prunus amygdalus*) with respect to their bitterness by using near infrared and partial least squares-discriminant analysis. In *Food Chemistry* (Vol. 153, pp. 15–19). Elsevier BV. <https://doi.org/10.1016/j.foodchem.2013.12.032>
- Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/a:1010933404324>
- Chu, C., Wang, H., Luo, X., Fan, Y., Nan, L., Du, C., Gao, D., Wen, P., Wang, D., Yang, Z., Yang, G., Liu, L., Li, Y., Hu, B., Zunongjiang, A., & Zhang, S. (2024). Rapid detection and quantification of melamine, urea, sucrose, water, and milk powder adulteration in pasteurized milk using Fourier transform infrared (FTIR) spectroscopy coupled with modern statistical machine learning algorithms. *Heliyon*, 10(12), e32720. <https://doi.org/10.1016/j.heliyon.2024.e32720>

9. Cochran, W. G. (1977). *Sampling Techniques* (3rd ed.). John Wiley & Sons.
10. Cortés, V., Talens, P., Barat, J. M., & Lerma-García, M. J. (2019). Discrimination of intact almonds according to their bitterness and prediction of amygdalin concentration by Fourier transform infrared spectroscopy. *Postharvest Biology and Technology*, 148, 236-241. <https://doi.org/10.1016/j.postharvbio.2018.05.006>
11. Das, M., Yeo, W. S., & Saptoro, A. (2025). A review of machine learning in hyperspectral imaging for food safety. *Vibrational Spectroscopy*, 139, 103828. <https://doi.org/10.1016/j.vibspec.2025.103828>
12. Deng, Z., Wang, T., Zheng, Y., Zhang, W., & Yun, Y. H. (2024). Deep learning in food authenticity: Recent advances and future trends. *Trends in Food Science & Technology*, 144, 104344. <https://doi.org/10.1016/j.tifs.2024.104344>
13. Dimakopoulou-Papazoglou, D., Serrano, S., Rodríguez, I., Ploskas, N., Koutsoumanis, K., & Katsanidis, E. (2025). FTIR spectroscopy combined with machine learning for the classification of Mediterranean honey based on origin. *Journal of Food Composition and Analysis*, 144, 107778. <https://doi.org/10.1016/j.jfca.2025.107778>
14. Dong, J. E., Li, J., Liu, H., & Wang, Y. Z. (2023). Machine learning and deep learning based on the small FT-MIR dataset for fine-grained sampling site recognition of boletus tomentipes. *Food Research International*, 167, 112679. <https://doi.org/10.1016/j.foodres.2023.112679>
15. Durak, T., & Depciuch, J. (2020). Effect of plant sample preparation and measuring methods on ATR-FTIR spectra results. *Environmental and Experimental Botany*, 169, 103915. <https://doi.org/10.1016/j.envexpbot.2019.103915>
16. Ezenarro, J., Riu, J., Ahmed, H. J., Busto, O., Giussani, B., & Boqué, R. (2024). Measurement errors and implications for preprocessing in miniaturised near-infrared spectrometers: Classification of sweet and bitter almonds as a case of study. *Talanta*, 276, 126271. <https://doi.org/10.1016/j.talanta.2024.126271>
17. Gökalp, Ç., & Mübarek Mazhar, Ç. (2024). An improved pistachio detection approach using YOLO-v8 Deep Learning Models. *BIO Web of Conferences*, 85, 01013. <https://doi.org/10.1051/bioconf/20248501013>
18. Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
19. Hong, Y., Birse, N., Quinn, B., Li, Y., Jia, W., McCarron, P., Wu, D., da Silva, G. R., Vanhaecke, L., van Ruth, S., & Elliott, C. T. (2023). Data fusion and multivariate analysis for food authenticity analysis. *Nature Communications*, 14(1), 7738. <https://doi.org/10.1038/s41467-023-38382-z>
20. Hou, L., Liu, Z., You, J., Liu, Y., Xiang, J., Zhou, J., & Pan, Y. (2024). Tomato Sorting System Based on Machine Vision. *Electronics*, 13(11), 2114. <https://doi.org/10.3390/electronics13112114>
21. International Organization for Standardization. (2002). Sensory analysis Methodology General guidance for measuring odour, flavour and taste detection thresholds by a 3-AFC procedure (ISO 13301:2002). <https://www.iso.org/standard/36791.html>
22. Jahnke, S., Roussel, J., Hombach, T., Kochs, J., Fischbach, A., Huber, G., & Scharr, H. (2016). phenoSeeder - A Robot System for Automated Handling and Phenotyping of Individual Seeds. *Plant Physiology*, 172(3), 1358-1370. <https://doi.org/10.1104/pp.16.01122>
23. Lacerda, M., Franca, T., Calvani, C., Marangoni, B., Teodoro, P., Campos, C. N. S., Baio, F. H. R., Azevedo, G. B., & Cena, C. (2024). A simple method for Eucalyptus species discrimination: FTIR spectroscopy and machine learning. *Results in Chemistry*, 7, 101233. <https://doi.org/10.1016/j.rechem.2023.101233>
24. Lawless, H. T., & Heymann, H. (1999). Principles of Good Practice. In Food science text series (pp. 83-115). Springer US. https://doi.org/10.1007/978-1-4419-7452-5_3
25. LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444. <https://doi.org/10.1038/nature14539>
26. Lin, S., Liu, Z., Qin, H., Jiang, L., Zhao, D., Li, Q., & Ou, Q. (2025). Developing a fast Fourier transform infrared spectroscopy system for precise and reliable grade differentiation of Gastrodia elata. *Vibrational Spectroscopy*, 136, 103769. <https://doi.org/10.1016/j.vibspec.2025.103769>
27. Mekonnen, K. D. (2023). Fourier transform infrared spectroscopy as a tool for identifying the unique characteristic bands of lipid in oilseed components: Confirmed via Ethiopian indigenous desert date fruit. *Heliyon*, 9(4), e14699. <https://doi.org/10.1016/j.heliyon.2023.e14699>
28. Mustafa, G., Wang, H., Liu, Y., Wang, L., Ali, M., Yao, Z., Quan, H., & He, K. (2025). Recent Advances in Spectroscopy and Machine Learning for Non-Destructive and Real-Time Detection of Mycotoxins in Cereals. *Trends in Food Science & Technology*, 157, 105246. <https://doi.org/10.1016/j.tifs.2025.105246>
29. Naes, T., Isaksson, T., Fearn, T., & Davies, T. (2002). *A user-friendly guide to multivariate calibration and classification*. NIR Publications.
30. Nasirahmadi, A., & Miraei Ashtiani, S. H. (2017). Bag-of-Feature model for sweet and bitter almond classification. *Biosystems Engineering*, 156, 51-60. <https://doi.org/10.1016/j.biosystemseng.2017.01.008>
31. Park, H., Chung, H., Choi, S., Bahn, Y. S., & Son, J. (2024). Evaluation of exposure to cyanogenic glycosides and potential hydrogen cyanide release in commercially available foods among the Korean population. *Food Chemistry*, 456, 139872. <https://doi.org/10.1016/j.foodchem.2024.139872>
32. Prata, J. C., & da Costa, P. M. (2024). Fourier Transform Infrared Spectroscopy Use in Honey Characterization and Authentication: A systematic review. *ACS Food Science & Technology*, 4(8), 1817-1828.

- <https://doi.org/10.1021/acsfoodscitech.4c00377>
33. Rahimzadeh, M., & Attar, A. (2020). Detecting and Counting Pistachios based on Deep Learning. arXiv. <https://doi.org/10.48550/ARXIV.2005.03990>
 34. Romano, R., Vestergaard, J. S., Kompany-Zareh, M., & Bredie, W. L. P. (2010). Monitoring Panel Performance Within and Between Sensory Experiments by Multi-Way Analysis. In *Studies in Classification, Data Analysis, and Knowledge Organization* (pp. 335–342). Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-642-13312-1_35
 35. Rong, D., Wang, H., Ying, Y., Zhang, Z., & Zhang, Y. (2020). Peach variety detection using VIS-NIR spectroscopy and deep learning. *Computers and Electronics in Agriculture*, 175, 105553. <https://doi.org/10.1016/j.compag.2020.105553>
 36. Salamah, N., Cantika, C. D., Nurani, L. H., & Guntarti, A. (2024). Authentication of citrus peel oils from different species and commercial products using FTIR Spectroscopy combined with chemometrics. *Pharmacia*, 71, 1-7. <https://doi.org/10.3897/pharmacia.71.e118789>
 37. Sheahata, D., ElGamal, R., Radwan, S., & Elmasry, G. (2025). Detection of impurities on faba bean (*Vicia faba* L.) by NIR spectroscopy. *Journal of Plant Production Sciences*, 14(1), 43-53. <https://doi.org/10.21608/jpps.2025.390691.1013>
 38. 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 Reviews in Food Science and Food Safety*, 23(6), e13785. <https://doi.org/10.1111/1541-4337.70054>
 39. Sipos, L., Nyitrai, Á., Hitka, G., Friedrich, L. F., & Kókai, Z. (2021). Sensory Panel Performance Evaluation Comprehensive Review of Practical Approaches. *Applied Sciences*, 11(24), 11977. <https://doi.org/10.3390/app112411977>
 40. Sluijterman, L., Cator, E., & Heskes, T. (2025). Likelihood-ratio-based confidence intervals for neural networks. *Machine Learning*, 114(4), 2319-2347. <https://doi.org/10.1007/s10994-024-06639-3>
 41. Syafri, S., Jaswir, I., Yusof, F., Rohman, A., & Hamidi, D. (2022). The use of GC-MS and FTIR spectroscopy coupled with multivariate analysis for the detection of red ginger oil adulteration. *Rasayan Journal of Chemistry*, 15(4), 2231-2236. <https://doi.org/10.31788/rjc.2022.1547039>
 42. Tachie, C. Y. E., Obiri-Ananey, D., Alfaro-Cordoba, M., Tawiah, N. A., & Aryee, A. N. A. (2024). Classification of oils and margarines by FTIR spectroscopy in tandem with machine learning. *Food Chemistry*, 431, 137077. <https://doi.org/10.1016/j.foodchem.2023.137077>
 43. Taş, N. G., & Gökmen, V. (2017). Phenolic compounds in natural and roasted nuts and their skins: a brief review. *Current Opinion in Food Science*, 14, 103-109. <https://doi.org/10.1016/j.cofs.2017.03.001>
 44. Torres-Rodríguez, I., Sánchez, M. T., Entrenas, J. A., Vega-Castellote, M., Garrido-Varo, A., & Pérez-Marín, D. (2022). Hyperspectral Imaging for the Detection of Bitter Almonds in Sweet Almond Batches. *Applied Sciences*, 12(10), 4842. <https://doi.org/10.3390/app12104842>
 45. Unuvar, A., Boyaci, I. H., & Koksels, H. (2021). A novel approach for rapid discrimination of common and durum wheat flours using spectroscopic analyses combined with chemometrics. *Journal of Cereal Science*, 100, 103269. <https://doi.org/10.1016/j.jcs.2021.103269>
 46. Uzer, M. S. (2025). Deep Learning-Based Classification Consisting of Pre-Trained Models and Proposed Model Using K-Fold Cross-Validation for Pistachio Species. *Applied Sciences*, 15(8), 4516. <https://doi.org/10.3390/app15084516>
 47. Yuan, Y., Ji, Z., Fan, Y., Xu, Q., Shi, C., Lyu, J., & Ertbjerg, P. (2025). Deep learning-assisted fluorescence spectroscopy for food quality and safety analysis. *Trends in Food Science & Technology*, 156, 104821. <https://doi.org/10.1016/j.tifs.2024.104821>
 48. Zahedi, A., Shafei, A. M., & Shamsi, M. (2023). Application of hybrid robotic systems in crop harvesting: Kinematic and dynamic analysis. *Computers and Electronics in Agriculture*, 107724. <https://doi.org/10.1016/j.compag.2023.107724>
 49. Zhang, L., Boom, R. M., & Ma, Y. (2025). Machine Learning in Automated Food Processing: A Mini Review. *Annual Review of Food Science and Technology*, 16(1), 25-37. <https://doi.org/10.1146/annurev-food-111523-122039>
 50. Zhou, Y., Chen, X., & Wu, Y. (2021). Oblique and rotation double random forest: Enhancing model diversity in ensemble learning. *IEEE Transactions on Neural Networks and Learning Systems*, 32(10), 4495-4505. <https://doi.org/10.1109/TNNLS.2020.3048732>
 51. Ziani, I., Bouakline, H., El Guerraf, A., El Bachiri, A., Marie-Laure Fauconnier, & Sher, F. (2025). Integrating AI and advanced spectroscopic techniques for precision food safety and quality control. *Trends in Food Science & Technology*, 156, 104850. <https://doi.org/10.1016/j.tifs.2024.104850>