انجمن مهندسان مکانیک ایران

نشریه علمی
ماشین های کشاورزی

دانشگاه فردوسی مشهد

جلد ۱۶ شماره ۴

سال ۱۴۰۵

(شماره پیاپی: ۴۲)

شاپا: ۶۸۲۹-۲۲۲۸

عنوان مقالات

مقالات پژوهشی

راهبرد نوین طبقه‌بندی کود پتاسیم بر مبنای میزان pH با استفاده از تصویربرداری فراطیفی مرئی-فروسرخ نزدیک و یادگیری ماشینی ۶۲۷

محمدحسین نرگسی، کامران خیرعلی‌پور، فاطمه ولی‌زاده کاخکی، زهرا مرادی

بهینه‌سازی فراسنجه‌های انرژی و حرارتی در فرآیند خشک‌کردن نشاسته اصلاح‌شده با پیش‌تیمار پلاسمای سرد ۶۴۱

علی تقوی، آزاده رنجبر ندامانی، علی متولی، سید جعفر هاشمی

بررسی خواص فیزیکی- شیمیایی و کیفیت اسانس غنچه گل محمدی در روش‌های مختلف خشک‌کردن ۶۵۵

امیدرضا روستاپور، فاطمه سفیدکن، ابوالفضل گلشن تفتی، حمیدرضا گازر

پیش‌بینی غیرمخرب pH آلو خرمایی و خونی با به‌کارگیری سامانه تصویربرداری فراطیفی و روش‌های یادگیری ماشین ۶۷۱

میثم لطیفی عموقین، یوسف عباس‌پور گیلانده

برآورد کاهش انتشار گازهای گلخانه‌ای، هزینه اجتماعی آلاینده‌ها و ارتقای کارایی مصرف انرژی در کشت گندم در مدیریت مکان محور نهاده‌های شیمیایی ۶۹۵

اشکان جلیلیان، محمد مهدی قاسمی، حسن قاسمی مبتکر، علی کعب

طراحی و توسعه سیستم هوشمند درجه‌بندی کشمش طلایی مبتنی بر شبکه عصبی کانولوشن عمیق ۷۱۳

حامد میرخراسانی، مهدی عباسقلی پور، بهزاد محمدی الستی

بررسی اثر هندسه محفظه حسگرها و نوع سیال بر جریان سیال در سامانه بینی الکترونیکی با استفاده از شبیه‌سازی دینامیک سیالات محاسباتی ۷۳۳

عارفه الطافی، سید سعید محتسبی، علی جعفری، مهدی قاسمی ورنامخواستی

سامانه‌ی یکپارچه جداساز مکاترونیکی مبتنی بر FTIR پوسته سخت بادام تلخ و شیرین بر پایه شبکه عصبی MLP ۷۵۳

مجتبی افشاری‌پور، محسن شمسی، فهیمه قاسمیان، حجت الله خبازاده

بهبود تخمیر بی‌هوازی ضایعات کشاورزی با استفاده از پیش‌تیمار فراصوت به‌منظور افزایش تولید بیوهیدروژن: مطالعه مسیر متابولیکی واکنش‌ها ۷۷۱

محمود محمودی اشکفتکی، امین لطفعلیان دهکردی، حمید خفاجه، سیده حدیثه بهرام شابهرامی

نشریه ماشین های کشاورزی

با شماره پروانه ۸۹/۱۲۶۳۹ **و درجه علمی – پژوهشی شماره** ۳/۱۱/۳۷۸۱ **از وزارت علوم، تحقیقات و فناوری**

۸۹/۶/۱۳ **۸۹/۳/۱۷**

"بر اساس مصوبه وزارت عتف از سال ۱۳۹۸، کلیه نشریات دارای درجه "علمی-پژوهشی" به نشریه "علمی" تغییر نام یافتند."

جلد ۱۶ شماره ۴ زمستان ۱۴۰۵

صاحب امتیاز: دانشگاه فردوسی مشهد

مدیر مسئول: سید محمدرضا مدرس رضوی — استاد- گروه مکانیک دانشکده مهندسی (دانشگاه فردوسی مشهد)

سردبیر: محمدحسین عباسپور فرد — استاد- گروه مهندسی مکانیک بیوسیستم (دانشگاه فردوسی مشهد)

اعضای هیئت تحریریه:

آق خانی، محمدحسین	گروه مهندسی بیوسیستم، دانشکده کشاورزی، دانشگاه فردوسی مشهد، مشهد، ایران
آغباشلو، مرتضی	گروه مهندسی ماشین‌های کشاورزی، دانشگاه تهران، پردیس کرج، ایران
ابونجمی، محمد	گروه فنی کشاورزی، پردیس ابوریحان دانشگاه تهران، ایران
خوش تقاضا، محمدهادی	گروه مهندسی مکانیک بیوسیستم، دانشگاه تربیت مدرس، تهران، ایران
راجی، عبدالغنی	گروه مهندسی کشاورزی و محیط زیست، دانشکده فنی، دانشگاه ایبادان، نیجریه
روحانی، عباس	گروه مهندسی بیوسیستم، دانشکده کشاورزی، دانشگاه فردوسی مشهد، مشهد، ایران
سعیدی راد، محمدحسین	مرکز تحقیقات کشاورزی و منابع طبیعی خراسان رضوی، بخش تحقیقات فنی و منهدسی، مشهد، ایران
سوپاکیت، سایاسونترن	دانشکده کشاورزی، دانشگاه کاستسارت، تایلند
عباسپور فرد، محمدحسین	گروه مهندسی بیوسیستم، دانشکده کشاورزی، دانشگاه فردوسی مشهد، مشهد، ایران
علیمردانی، رضا	گروه مهندسی ماشین‌های کشاورزی، دانشگاه تهران، پردیس کرج، ایران
عمادی، باقر	گروه مهندسی شیمی و بیولوژیک، دانشگاه ساسکاچوان، ساسکاتون، کانادا
غضنفری مقدم، احمد	گروه مهندسی مکانیک بیوسیستم، دانشگاه شهید باهنر کرمان، کرمان، ایران
کدخدایان، مهران	گروه مهندسی مکانیک، دانشکده مهندسی، دانشگاه فردوسی مشهد، مشهد، ایران
لغوی، محمد	گروه مهندسی بیوسیستم، دانشگاه شیراز، ایران
محتسبی، سید سعید	گروه مهندسی ماشین‌های کشاورزی، دانشگاه تهران، پردیس کرج، ایران
مدرس رضوی، محمدرضا	گروه مهندسی مکانیک، دانشکده مهندسی، دانشگاه فردوسی مشهد، مشهد، ایران
نصیراحمدی، ابوذر	گروه مهندسی کشاورزی، دانشگاه کاسل، آلمان

ناشر: دانشگاه فردوسی مشهد

مقالات این نشریه در پایگاه‌های معتبر زیر نمایه می‌شود:

AGRIS، Scopus، Web of Science: Emerging Sources Citation Index™ (ESCI)، CABI، DOAJ، EBSCO، Google scholar، Internet Archive، پایگاه استنادی جهان اسلام (ISC)**، سامانه نشریات علمی ایران و پایگاه اطلاعات علمی جهاد دانشگاهی** (SID)

پست الکترونیک: jame@um.ac.ir

مقالات این شماره در سایت http://jame.um.ac.ir **به‌صورت مقاله کامل نمایه شده است.**

این نشریه به تعداد ۴ شماره در سال و به‌صورت آنلاین منتشر می‌شود.

مندرجات

مقالات پژوهشی

راهبرد نوین طبقه‌بندی کود پتاسیم بر مبنای میزان pH با استفاده از تصویربرداری فراطیفی مرئی-فروسرخ نزدیک و یادگیری ماشینی ۶۲۷

محمدحسین نرگسی، کامران خیرعلی‌پور، فاطمه ولی‌زاده کاخکی، زهرا مرادی

بهینه‌سازی فراسنجه‌های انرژی و حرارتی در فرآیند خشک‌کردن نشاسته اصلاح‌شده با پیش‌تیمار پلاسمای سرد ۶۴۱

علی تقوی، آزاده رنجبر ندامانی، علی متولی، سید جعفر هاشمی

بررسی خواص فیزیکی- شیمیایی و کیفیت اسانس غنچه گل محمدی در روش‌های مختلف خشک‌کردن ۶۵۵

امیدرضا روستاپور، فاطمه سفیدکن، ابوالفضل گلشن تفتی، حمیدرضا گازر

پیش‌بینی غیرمخرب pH آلو خرمایی و خونی با به‌کارگیری سامانه تصویربرداری فراطیفی و روش‌های یادگیری ماشین ۶۷۱

میثم لطیفی عموقین، یوسف عباس‌پور گیلانده

برآورد کاهش انتشار گازهای گلخانه‌ای، هزینه اجتماعی آلاینده‌ها و ارتقای کارایی مصرف انرژی در کشت گندم در مدیریت مکان محور نهاده‌های شیمیایی ۶۹۵

اشکان جلیلیان، محمد مهدی قاسمی، حسن قاسمی مبتکر، علی کعب

طراحی و توسعه سیستم هوشمند درجه‌بندی کشمش طلایی مبتنی بر شبکه عصبی کانولوشن عمیق ۷۱۳

حامد میرخراسانی، مهدی عباسقلی پور، بهزاد محمدی الستی

بررسی اثر هندسه محفظه حسگرها و نوع سیال بر جریان سیال در سامانه بینی الکترونیکی با استفاده از شبیه‌سازی دینامیک سیالات محاسباتی ۷۳۳

عارفه الطافی، سید سعید محتسبی، علی جعفری، مهدی قاسمی ورنامخواستی

سامانه‌ی یکپارچه جداساز مکاترونیکی مبتنی بر FTIR پوسته سخت بادام تلخ و شیرین بر پایه شبکه عصبی MLP ۷۵۳

مجتبی افشاری‌پور، محسن شمسی، فهیمه قاسمیان، حجت الله خباززاده

بهبود تخمیر بی‌هوازی ضایعات کشاورزی با استفاده از پیش‌تیمار فراصوت به‌منظور افزایش تولید بیوهیدروژن: مطالعه مسیر متابولیکی واکنش‌ها ۷۷۱

محمود محمودی اشکفتکی، امین لطفعلیان دهکردی، حمید خفاجه، سیده حدیثه بهرام شابهرامی

Journal of Agricultural Machinery

Homepage: https://jame.um.ac.ir

Research Article
Vol. 16, No. 4, 2026, p. 625-638

A Novel Strategy for Classifying Potassium Fertilizer Based on pH Level Using Visible-Near-Infrared Hyperspectral Imaging and Machine Learning

M. H. Nargesi[1*], K. Kheiralipour[1], F. Valizadeh Kakhki[2], Z. Moradi[3]

1- Mechanical Engineering of Biosystems Department, Ilam University, Ilam, Iran
2- Ph.D. in Environmental Science, Specialization in Environmental Pollutions, Ilam, Iran
3- Department of Chemistry, Faculty of Science, Ilam University, Ilam, Iran
(*- Corresponding Author Email: mohamadhossein.73@gmail.com)

Received: 09 June 2025
Revised: 30 July 2025
Accepted: 26 August 2025
Available Online: 27 September 2025

How to cite this article:
Nargesi, M. H., Kheiralipour, K., Valizadeh Kakhki, F., & Moradi, Z. (2026). A Novel Strategy for Classifying Potassium Fertilizer Based on pH Level Using Visible-Near-Infrared Hyperspectral Imaging and Machine Learning. *Journal of Agricultural Machinery, 16*(4), 625-638. [in Persian]. https://doi.org/10.22067/jam.2025.93983.1394

Introduction

Paying attention to the technical aspects of production plays a crucial role in increasing yield and ensuring sustainable agriculture. Organic fertilizers, such as poultry manure, contribute to plant growth by providing essential nutrients and improving soil quality. However, they alone cannot fully meet the nutritional needs of plants. The combination of organic and chemical fertilizers is an effective approach to enhancing soil fertility and boosting crop performance, ultimately leading to sustainable agricultural development. Integrated nutrient management also helps reduce the use of chemical fertilizers while minimizing their harmful effects on the environment. Potassium is an essential element in plant nutrition, playing a key role in processes such as photosynthesis, growth, chlorophyll production, and transpiration regulation. Additionally, under stress conditions, potassium enhances water uptake and regulates osmotic pressure, helping to maintain plant health. Potassium fertilizers are classified into two categories: chloride-based and chloride-free. Potassium sulfate, due to its lack of chloride, is a suitable option for chloride-sensitive crops such as tea, potatoes, and sugar beets. Meanwhile, hyperspectral imaging has emerged as an innovative technique with broad applications in detecting chemical parameters, assessing quality, and analyzing the purity of agricultural and food products. This study utilizes hyperspectral image processing technology to determine the pH level of potassium sulfate.

Materials and Methods

The present study was conducted in the Image Processing Laboratory at the Ilam University, Iran. To determine the pH level of potassium sulfate, four different levels of 2.5, 2.6, 2.8, and 2.9 were considered. The pH measurement was performed in the laboratory using a flame photometer. The required images were obtained through hyperspectral imaging using the line-scan method. For each pH level, three samples were obtained and six hyperspectral images were captured for each sample, resulting in 18 images per pH level and a total of 72 hyperspectral images for each pH level. MATLAB software was used for the analysis and processing of these images. The image processing stage included wavelength selection, feature extraction, and feature selection. Finally, the selected features were classified using an artificial neural network.

Results and Discussion

Principal Component Analysis performed on the hyperspectral image channels of potassium sulfate revealed significant variations in the principal component values across different pH levels. This finding indicates that pH

Authors retain the copyright. This is an open access article distributed under Creative Commons Attribution 4.0 International License (CC BY 4.0).

https://doi.org/10.22067/jam.2025.93983.1394

conditions exert a considerable influence on the spectral response of the samples. Based on the prominent peaks obtained from the analysis, the most relevant channels were identified, and their corresponding wavelengths were determined as the optimal spectral bands. The selected channels for the four pH levels were 65, 327, 334, 482, 510, 607, and 644, with their corresponding effective wavelengths being 453.32, 669.95, 675.74, 798.11, 821.26, 901.47, and 932.06 nm, respectively. To extract discriminative spectral information, six features were computed from each of the selected wavelengths. Consequently, a total of 42 features were obtained, which were subsequently employed in the classification process of different pH levels. The confusion matrices of the classification model based on the artificial neural network were obtained to evaluate the model's accuracy. The classification accuracy for detecting the pH level of potassium sulfate was 98.6% with effective features and 97.2% without them.

Conclusion

The results of this study demonstrated the high potential of hyperspectral imaging technology combined with the artificial neural network classification method, using strategies with and without effective feature selection, in detecting the pH level of potassium sulfate. The proposed method offers several advantages over laboratory-based approaches, such as being non-destructive, having high speed, and being cost-effective. It is suggested to explore other methods for classifying hyperspectral images for determining the pH level of potassium sulfate. The proposed method in this study could also be applied in the future to identify various chemical elements in potassium sulfate.

Keywords: Artificial neural network, Chemical fertilizer, Hyperspectral imaging, Image processing, Machine learning

نشریه ماشین‌های کشاورزی
https://jame.um.ac.ir

مقاله پژوهشی
جلد ۱۶، شماره ٤، زمستان ۱٤۰۵، ص ٦۳۸-٦۲۵

راهبرد نوین طبقه‌بندی کود پتاسیم بر مبنای میزان pH با استفاده از تصویربرداری فراطیفی مرئی-فروسرخ نزدیک و یادگیری ماشینی

محمدحسین نرگسی[۱*]، کامران خیرعلی‌پور[۱]، فاطمه ولی‌زاده کاخکی[۲]، زهرا مرادی[۳]

تاریخ دریافت: ۱۴۰۴/۰۳/۱۹
تاریخ پذیرش: ۱۴۰۴/۰۶/۰۴

چکیده

در حوزه کشاورزی، علاوه بر کودهای آلی، انواع مختلفی از کودهای شیمیایی به منظور افزایش حاصلخیزی خاک و ارتقای عملکرد گیاهان مورد استفاده قرار می‌گیرند. پتاسیم به‌عنوان یکی از عناصر ضروری برای رشد گیاه، نقش کلیدی در فرآیندهایی نظیر فتوسنتز، سنتز کلروفیل و افزایش مقاومت گیاه در برابر تنش‌های محیطی ایفا می‌کند. یکی از شاخص‌های مهم در بررسی کیفیت کودهای پتاس، میزان اسیدیته آن‌هاست که تأثیر مستقیمی بر قابلیت جذب عناصر غذایی و اثربخشی کود دارد. در این پژوهش، با هدف توسعه روشی غیرمخرب و دقیق برای ارزیابی خصوصیات شیمیایی کود پتاسیم، از تصویربرداری فراطیفی در بازه طول موجی ۴۰۰ تا ۹۵۰ نانومتر استفاده شد. تصاویر چهار نمونه کود پتاسیم با سطوح متفاوت pH ثبت گردید و پس از پردازش اولیه، طول موج‌های مؤثر شامل ۴۵۳/۳۲، ۶۶۹/۹۵، ۷۹۸/۱۱، ۸۲۱/۲۶، ۹۰۱/۴۷ و ۹۳۲/۰۶ نانومتر انتخاب شدند. از کانال‌های تصویری متناظر با این طول موج‌ها، مجموعه‌ای از ویژگی‌های طیفی و آماری استخراج شد. به‌منظور طبقه‌بندی سطوح مختلف pH، با استفاده از یادگیری ماشینی، از شبکه عصبی مصنوعی بهره گرفته شد. نتایج نشان داد مدل بهینه در حالت استفاده از تمامی ویژگی‌ها دارای ساختار ۴۲-۶-۴ و در حالت استفاده از ویژگی‌های منتخب، دارای ساختار ۷-۴-۴ است. دقت طبقه‌بندی این دو مدل به‌ترتیب برابر با ۹۸/۶ و ۹۷/۲ درصد به‌دست آمد. یافته‌های این مطالعه بیانگر آن است که ترکیب تصویربرداری فراطیفی و الگوریتم‌های یادگیری ماشینی، روشی کارآمد، سریع، غیرمخرب و مقرون به‌صرفه برای پایش کیفیت شیمیایی کودهای پتاس ارائه می‌دهد و می‌تواند جایگزین مناسبی برای روش‌های آزمایشگاهی مرسوم باشد.

واژه‌های کلیدی: پردازش تصویر، تصویربرداری فراطیفی، شبکه عصبی مصنوعی، کود شیمیایی، یادگیری ماشینی

مقدمه

توجه به جنبه‌های فنی تولید به‌منظور افزایش کمیت محصول، از الزامات اساسی در راستای تحقق کشاورزی پایدار به‌شمار می‌رود (Kheiralipour, 2022). در این میان، کودهای آلی با فراهم کردن عناصر غذایی مورد نیاز گیاه، بهبود کیفیت خاک و افزایش عملکرد محصولات، نقش قابل‌توجهی در کشاورزی ایفا می‌کنند (Perramon, Bosch-Serra, Domingo, & Boixadera, 2016). مصرف کودهای آلی به‌تنهایی قادر به تأمین کامل نیازهای تغذیه‌ای گیاهان نیست (Pandey & Patra, 2015; Siadat & Moradi-Telavat, 2018). ازاین‌رو، ترکیب کودهای آلی و شیمیایی به‌عنوان رویکردی مؤثر برای افزایش حاصلخیزی خاک و بهبود عملکرد گیاه، گزینه‌ای امیدبخش برای کشاورزی پایدار محسوب می‌شود (Allahvirdizadeh & Nazari Deljou, 2014; Chen, 2006; Zhao *et al.*, 2016). یافته‌های پژوهشی نشان می‌دهد که این رویکرد نه‌تنها موجب افزایش بهره‌وری محصولات می‌گردد، بلکه گامی مؤثر در جهت توسعه کشاورزی ارگانیک و پایدار نیز به‌شمار می‌آید (Griffe, Metha, & Shankar, 2003). در کشاورزی مدرن، کودهای شیمیایی به‌عنوان یکی از مهم‌ترین نهاده‌ها شناخته می‌شوند و استفاده از آن‌ها برای افزایش عملکرد محصولات، به‌ویژه در کشورهای توسعه‌یافته و در حال توسعه، رایج و موفقیت‌آمیز بوده است (Al-Taai, 2021; Scharf *et al.*, 2005). بدون تغذیه مناسب و

۱- گروه مهندسی مکانیک بیوسیستم، دانشکده کشاورزی، دانشگاه ایلام، ایلام، ایران
۲- دکتری محیط‌زیست گرایش آلودگی‌های محیطی، ایلام، ایران
۳- گروه شیمی، دانشکده علوم پایه، دانشگاه ایلام، ایلام، ایران
(*- نویسنده مسئول: Email: mohamadhossein.73@gmail.com)
https://doi.org/10.22067/jam.2025.93983.1394

متعادل، دستیابی به عملکرد بالا امکان‌پذیر نخواهد بود.

پتاسیم یکی از عناصر اساسی و پرمصرف در تغذیه گیاهان است که نقش مهمی در فرآیندهای فیزیولوژیکی مرتبط با رشد، سلامت و مقاومت گیاه در برابر تنش‌های زیستی و غیرزیستی ایفا می‌کند. هنگامی که گیاه با کمبود عناصر غذایی مواجه می‌شود، علائم تنش از مهم‌ترین نشانه‌ها در تشخیص تغذیه هستند (Sun, Tong, He, Wang, & Chen, 2018). اما ظهور این علائم زمان‌بر است و به همین دلیل تشخیص را با محدودیت زمانی مواجه می‌سازد. بر اساس سازوکار رشد گیاه، اثرات کمبود NPK بر رشد برگ‌ها به‌صورت بروز علائم تنش و پویایی زمانی این علائم (یعنی شکل‌گیری و گسترش آن‌ها) ظاهر می‌شود (Qi, Wang, & Guo, 2017). این عنصر در افزایش میزان فتوسنتز، رشد رویشی، شاخص سطح برگ، تقویت سنتز ATP و NADPH، افزایش ساخت کلروفیل a و b، بهبود انتقال مواد نیتروژنه به دانه‌ها، افزایش سنتز پروتئین‌ها و ترکیبات پلیمری، تنظیم باز و بسته شدن روزنه‌ها، افزایش تعداد روزنه‌ها و کاهش تعرق تأثیرگذار است. همچنین در شرایط تنش، پتاسیم با بهبود جذب آب و تنظیم فشار اسمزی، شرایط داخلی مناسبی برای گیاه فراهم می‌کند (Sakinejad, 2003). به‌عنوان نمونه، در پژوهشی مشخص شد که در گیاه شنبلیله، مصرف ۴۰۰ میلی‌گرم پتاسیم در ۱۰۰ لیتر آب، بیشترین میزان رشد و عملکرد را به همراه داشت؛ به‌طوری‌که ارتفاع گیاه به ۵۸/۳۵ سانتی‌متر، تعداد شاخه‌ها به ۶۶/۵ عدد در هر گیاه، تعداد غلاف‌ها به ۱۶/۱۲ عدد، تعداد دانه در هر غلاف به ۵۰/۱۱ دانه و عملکرد کل به ۵۰/۳۰۵ کیلوگرم در هکتار رسید (Naser, 2017).

کودهای پتاسیمی به‌طور کلی به دو گروه اصلی تقسیم می‌شوند: کودهای حاوی کلر (مانند کلرید پتاسیم) و کودهای بدون کلر (مانند سولفات پتاسیم). کلرید پتاسیم (KCl) به دلیل داشتن یون کلر، ممکن است برای برخی محصولات زراعی مضر باشد؛ چرا که موجب افزایش شوری و pH خاک می‌شود. در مقابل، سولفات پتاسیم (K_2SO_4) که فاقد کلر است، گزینه‌ای مناسب برای گیاهان حساس به کلر به‌شمار می‌آید و به‌ویژه برای محصولاتی مانند تنباکو، چای، سیب‌زمینی، هندوانه و چغندرقند مفید بوده و در بهبود رشد و کیفیت آن‌ها نقش دارد (Ahmad, Anjum, Waraich, Ayub, & Ahmad, 2018; Shabbir Dar *et al.*, 2021).

آزمایش‌های شیمیایی رایج برای اندازه‌گیری pH کودهای پتاسیمی، اسیدی یا بازی بودن محلول کود را مشخص می‌کنند و تأثیر آن بر خصوصیات خاک را مورد ارزیابی قرار می‌دهند. فرآیند اندازه‌گیری pH با استفاده از pHمتر نیازمند نمونه‌گیری است و به‌صورت آنلاین قابل‌انجام نمی‌باشد. در این راستا، توسعه ابزارهایی که امکان به‌کارگیری آنلاین دارند دارای اهمیت بالایی است. بنابراین، هدف اصلی این پژوهش، طراحی و معرفی روشی سریع، برای طبقه‌بندی میزان pH در کود پتاسیم است. در سال‌های اخیر، روش‌های مختلف تصویربرداری برای بررسی کیفیت و ایمنی مواد به‌کار گرفته شده‌اند (Marzbani & Kheiralipour, 2016; Nargesi & Kheiralipour, 2024; Salam, Kheiralipour, & Jian, 2022). تصویربرداری فراطیفی (HSI) به‌عنوان یکی از جدیدترین روش‌ها، قادر است به‌طور هم‌زمان اطلاعات مکانی و طیفی را ثبت کند (Aviara, Liberty, Olatunbosun, Shoyombo, & Oyeniyi, 2022; Gowen, O'Donnell, Cullen, Downey, & Frias, 2007; Kheiralipour, 2012; Kheiralipour, 2024). این روش از حساسیت بالایی نسبت به ساختار و ترکیب مواد برخوردار است (Gowen *et al.*, 2007; Soni, Dixit, Reis, Brightwell, 2022) و به همین دلیل، در مطالعات گوناگونی همچون شناسایی ناخالصی‌ها (Khan *et al.*, 2020; Saha & Manickavasagan, 2021; Wu, Zhu, Huang, & Xu, 2017) و ویژگی‌های کیفی محصولات کشاورزی به‌کار رفته است (Kheiralipour *et al.*, 2014).

ترکیب تصویربرداری فراطیفی با الگوریتم‌های یادگیری ماشینی، امکان تحلیل دقیق‌تر و کاربردهای گسترده‌تری را فراهم ساخته است؛ از جمله: ارزیابی کیفیت محصولات کشاورزی (Kheiralipour, Sajadipour, & Nargesi, 2025; Nashmil, Mardani, Hosainpour, & Golanbari, 2024; Sharma *et al.*, 2023)، شناسایی مواد تقلبی (Nargesi, Amiriparian, Bagherpour, Kheiralipour, 2024b; Park *et al.*, 2023; Yang *et al.*, 2023)، تعیین کمی ترکیبات غذایی (Li *et al.*, 2023) و تشخیص انواع آرد (Nargesi, Kheiralipour, & Jayas, 2024c).

در روش تصویربرداری فراطیفی داده‌های زیادی ثبت می‌شود که تحلیل آن‌ها پیچیده است. در این راستا، یادگیری ماشینی به دلیل توانایی‌های خودکار و سازگاری پویا، به‌عنوان ابزاری مؤثر برای تحلیل داده‌ای پیچیده در نظر گرفته می‌شود (Kheiralipour, Ahmadi, Rajabipour, & Rafiee, 2018; Kheiralipour, Sajadipour, & Nargesi, 2025; Lin, Ma, Wang, & Sun, 2023). در تحقیقی شوئه و همکاران (Xue *et al.*, 2025) به بررسی تشخیص غیرمخرب مقدار pH در طول تخمیر ثانویه سیلاژ ذرت با استفاده از آرایه حسگر رنگ‌سنجی ترکیب‌شده با فناوری تصویربرداری فراطیفی پرداخته است. همچنین با وجود پیشرفت‌های صورت‌گرفته، تاکنون مطالعه‌ای به‌طور خاص به بررسی تشخیص میزان PH در کود پتاسیم با استفاده از HSI و یادگیری ماشینی صورت نگرفته است. بنابراین، تحقیق حاضر با هدف توسعه یک مدل طبقه‌بندی مبتنی بر شبکه عصبی مصنوعی انجام شده است که قادر به شناسایی میزان PH در کود پتاسیم بر اساس طیف‌های HSI باشد.

مواد و روش‌ها

آماده‌سازی نمونه‌های کود پتاسیم

مراحل مختلف تحقیق حاضر، شامل تعیین مقادیر pH نمونه‌های پتاسیم به‌صورت آزمایشگاهی، تهیه تصاویر فراطیفی از نمونه‌ها و فرآیند تجزیه و تحلیل داده‌ها در شکل ۱ نشان داده شده است.

نمونه‌های کود پتاسیم از شرکت مجتمع صنایع شیمیایی ایران، ایلام، ایران تامین گردید. سپس، برای انجام مراحل بعدی آزمایش، ۵۰ گرم از نمونه‌های آماده‌شده در کیسه‌های زیپ‌دار قرار داده شد تا در مرحله تصویربرداری فراطیفی مورد استفاده قرار گیرند. بدین منظور، مقدار ۵۰ گرم از هر نمونه بر روی ظرف مخصوص قرار داده شد و سطح آن به‌طور یکنواخت صاف گردید. سپس تصویربرداری از نمونه با استفاده از دوربین فراطیفی انجام و داده‌های تصویری به‌صورت مستقیم در رایانه شخصی ذخیره شد.

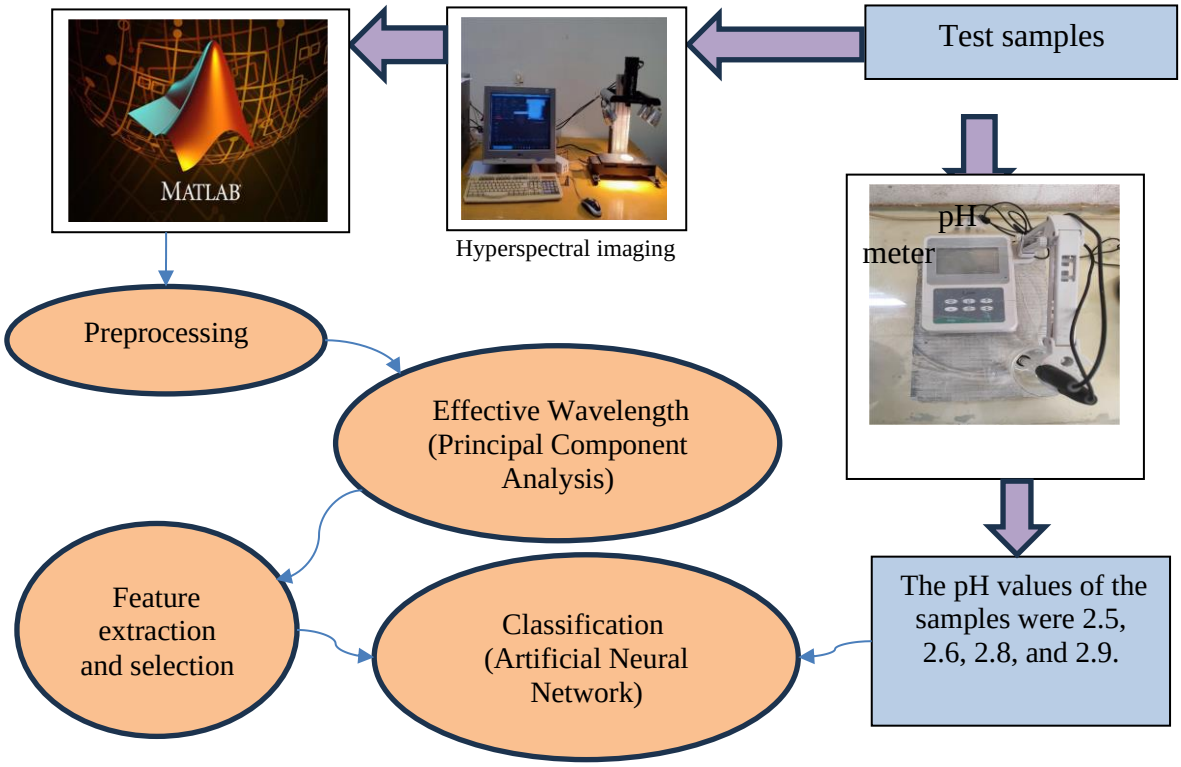

شکل ۱- مراحل پژوهش

Fig. 1. Research steps

تصویربرداری فراطیفی مرئی-فروسرخ نزدیک

یک سامانه تصویربرداری فراطیفی معمولا شامل یک دوربین فراطیفی، اجزای نوری، منبع نور و یک رایانه مجهز به نرم‌افزار برای کنترل فرآیند تصویربرداری و پردازش‌های بعدی مانند دیجیتالی‌سازی، ذخیره‌سازی، مدل‌سازی، و تصمیم‌گیری است (Ismail, Yim, Kim, & Jo, 2023; Kheiralipour, Chelladurai, & Jayas, 2023; Kheiralipour & Jaya, 2023; Min *et al.*, 2023). اجزای نوری این سامانه شامل لنز، طیف‌سنج (یا واحد پراکندگی طیفی)، فیلترهای نوری و عناصر کالیبراسیون می‌شود. انتخاب مناسب این اجزا نقش مهمی در بهبود عملکرد سامانه HSI و ثبت تصاویر ابرطیفی باکیفیت و دقیق ایفا می‌کند. انتخاب دقیق طیف نوری، شدت، پایداری، و ویژگی‌های منبع نور بر اساس نیازهای خاص هر کاربرد ضروری است (Kheiralipour & Jayas, 2024; Ahmed, Khaliduzzaman, Emmert, & Kamruzzaman, 2025).

در این پژوهش، برای ثبت تصاویر فراطیفی نمونه‌ها، از یک سامانه تصویربرداری فراطیفی مرئی-فروسرخ نزدیک (مدل Specam، شرکت پرتو صنعت، زنجان، ایران) با محدوده طول موج ۴۰۰ تا ۹۵۰ نانومتر در آزمایشگاه پردازش تصویر دانشگاه ایلام، ایلام، ایران، استفاده شد (شکل ۱). بخش نورپردازی سامانه تصویربرداری دارای چهار لامپ ال‌ای‌دی با توان ۲۵ وات می‌باشد. لامپ‌ها در بالا نمونه و با زاویه ۴۵ درجه قرار گرفتند. این سامانه به موتوری مجهز

بود که امکان اسکن خطی با حرکت خطی نمونه را فراهم می‌کرد. این قابلیت اجازه می‌دهد نمونه‌ها نسبت به حسگر حرکت کرده و بخش‌های مختلف آن‌ها را اسکن کند.

برای هر سطح pH، سه نمونه و از هر نمونه شش تصویر فراطیفی (فرامکعب) به‌دست آمد به‌طوری‌که از هر سطح تعداد ۱۸ تصویر فراطیفی ثبت شد. در مجموع ۷۲ تصویر فراطیفی کسب شد.

پیش‌پردازش

برای پردازش تصاویر فراطیفی، یک الگوریتم اختصاصی در محیط نرم‌افزار MATLAB نسخه ۲۰۱۶ (شرکت متورکس، کارلس‌بد، کالیفرنیا، آمریکا) طراحی و پیاده‌سازی شد. این الگوریتم ابتدا فرآیند پیش‌پردازش را بر روی تصاویر فراطیفی انجام می‌دهد. به همین منظور، ناحیه مرکزی تصاویر به ابعاد ۴۰×۲۰ پیکسل را برش داده و آن‌ها را برای مراحل بعدی پردازش آماده می‌کند (شکل ۲). با توجه به تعداد بالای متغیرهای ورودی، کاهش ابعاد داده‌ها به‌منظور بهبود عملکرد طبقه‌بندی از اهمیت بالایی برخوردار است. از این‌رو، در این مطالعه ابتدا طول‌موج‌های مؤثر شناسایی شده و سپس ویژگی‌های مؤثر استخراج‌شده از این طول‌موج‌ها انتخاب گردید. ویژگی‌های غیرضروری حذف شده تا مدل طبقه‌بندی با داده‌های بهینه‌تری آموزش داده شود. برای بهبود دقت طبقه‌بندی و کاهش پیچیدگی محاسباتی، کاهش حجم داده‌های ورودی ضروری بود. بنابراین، در مرحله بعد، موثرترین طول‌موج‌ها از تصاویر انتخاب شدند تا داده‌های کلیدی برای تحلیل نهایی مورد استفاده قرار گیرند (Arif Chaudhry, Bane, McAllister, Paliwal, & Narváez-Bravo, 2025; Kheiralipour *et al.*, 2021; Nargesi, Heidarbeigi, Moradi, & Abdolahi, 2024a).

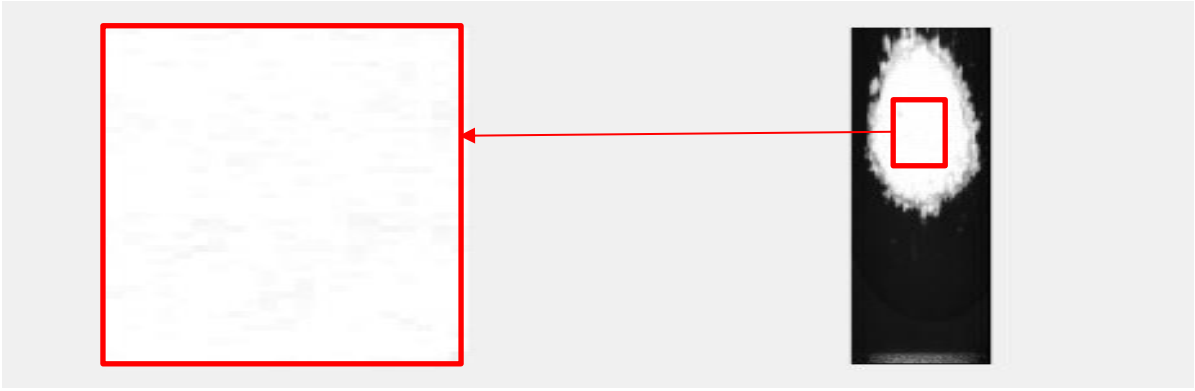

شکل ۲– قسمت برش‌خورده یک تصویر نمونه در طول موج ۶۴۷/۶۳ نانومتر

Fig. 2. Cropped section of a sample image at 647.63 nm wavelength

شناسایی طول موج‌های موثر و استخراج ویژگی

پس از انجام مرحله پیش‌پردازش تصاویر، فرآیند انتخاب طول‌موج‌های مؤثر انجام شد. برای این منظور، از روش تحلیل مؤلفه‌های اصلی[1] (PCA) برای شناسایی طول موج‌های کلیدی استفاده گردید. انتخاب این طول موج‌ها بر اساس محاسبه میانگین دو مؤلفه اصلی اول (PC1) و دوم (PC2) صورت گرفت، به‌طوری‌که طول موج‌های مهم تصاویر با توجه به نقاط اوج (پیک) منحنی‌های PC1 و PC2 تعیین شدند (Fernandez, Allende-Prieto, & Peon, 2019; Hasan *et al.*, 2022; Kheiralipour *et al.*, 2016).

پس از انتخاب طول‌موج‌های مناسب، ویژگی‌های مختلفی از کانال‌های مربوط به این طول‌موج‌ها استخراج شد. این ویژگی‌ها شامل میانگین، حداقل، حداکثر، میانه، واریانس، و انحراف معیار طول موج‌های نمونه‌ها بودند (Kheiralipour *et al.*, 2014; Nargesi, 2024).

انتخاب ویژگی‌های کارا

از آنجایی که برای هر کانال تصویر شش ویژگی استخراج شد، طبقه‌بندی این ویژگی‌ها کاری زمان‌بر است و ممکن است منجر به کاهش دقت آن شود. در میان آن‌ها، چند ویژگی به‌عنوان ویژگی‌های کارآمد انتخاب شدند. برای انتخاب ویژگی‌های کارآمد، از روش انتخاب ویژگی متوالی (Sequential Feature Selection) استفاده شد. این روش، ویژگی‌های کارآمد را بر اساس معیار انحراف برازش (تعمیم مجموع مربعات باقیمانده) پیدا می‌کند. برای این منظور، الگوریتمی در نرم‌افزار MATLAB طراحی و برنامه‌نویسی شد. در الگوریتم توسعه‌یافته، داده‌های ورودی، ویژگی‌های استخراج‌شده و هدف، کلاس‌های مورد مطالعه بودند. خروجی الگوریتم پس از اجرا،

1- Principal Component Analysis

مجموعه‌ای از ویژگی‌های کارآمد بود (Bagherpour, Fatehi, Shojaeian, & Bagherpour, 2025; Hosainpour, Kheiralipour, Nadimi, & Paliwal, 2022; Khazaee, Kheiralipour, Hosainpour, Javadikia, & Paliwal, 2022; Kheiralipour, 2022). این روش بر پایه معیار انحراف برازش عمل می‌کند که با محاسبه مجموع تعمیم‌یافته مجذور باقیمانده‌ها، ویژگی‌های مؤثر را تعیین می‌کند (Kheiralipour *et al.*, 2021; Kheiralipour *et al.*, 2023; Nargesi & Kheiralipour, 2024).

طبقه‌بندی

در این تحقیق، تشخیص میزان pH کود پتاسیم با استفاده از روش شبکه عصبی مصنوعی مورد بررسی و ارزیابی قرار گرفت. در روش شبکه عصبی مصنوعی، داده‌های ورودی شامل ویژگی‌های تصاویر (طبقه‌بندی داده‌های تصاویر فراطیفی با دو راهبرد با و بدون انتخاب ویژگی کارآمد صورت گرفت: یک بار بر اساس ویژگی‌های کارا و یک بار تمامی ویژگی‌های استخراج‌شده) و داده‌های خروجی مربوط به طبقه‌ها (سطوح مختلف pH) بودند. توابع فعال‌سازی لایه پنهان و لایه خروجی به‌ترتیب tensing و purelin بودند. الگوریتم آموزش Levenberg-Marquardt به دلیل سرعت بالا و جلوگیری از آموزش بیش از حد شبکه برای جلوگیری از یادگیری نامناسب مدل استفاده شد (Kheiralipour, Ahmadi, Rajabipour, Rafiee, & Javan-Nikkhah, 2015; Salam *et al.*, 2022). این داده‌ها به‌طور تصادفی به سه مجموعه (۶۰، ۲۰، و ۲۰ درصد) به‌ترتیب برای آموزش، اعتبارسنجی و آزمون تقسیم شدند (Khazaee *et al.*, 2022; Nargesi & Kheiralipour, 2024; Nargesi *et al.*, 2024c).

نتایج و بحث

میزان pH نمونه‌ها

میزان pH چهار نمونه کود پتاسیم با استفاده از روش آزمایشگاهی اشاره‌شده در بخش مواد و روش‌ها اندازه‌گیری شد. محدوده اندازه‌گیری‌شده pH نمونه‌ها ۲/۵، ۲/۶، ۲/۸، و ۲/۹ بود (Pahalvi, Rafiya, Rashid, Nisar, & Kamili, 2021). بر این اساس، نمونه‌ها برای تصویربرداری آماده شدند (شکل ۳). نمونه‌ها با چهار میزان متفاوت pH شامل (۲/۵، ۲/۶، ۲/۸، و ۲/۹) تهیه و در کیسه‌های جداگانه بسته‌بندی شدند. پس از آماده‌سازی نمونه‌ها، میزان pH کود پتاسیم با استفاده pHمتر مدل 500 PH، ساخت شرکت کلین، چین، اندازه‌گیری شد. به این صورت که مقدار معینی از نمونه کود جامد (معمولاً ۱۰ گرم) با دقت وزن شده و در حجم مشخصی از آب دیونیزه (حدود ۱۰۰ میلی‌لیتر) حل شد. محلول حاصل به مدت ۳۰ دقیقه توسط همزن مغناطیسی هم‌زده شد تا یون‌های موجود به‌طور کامل آزاد شوند و مقدار pH به حالت تعادل برسد. پس از صاف‌سازی محلول، الکترود pHمتر درون آن قرار گرفت و پس از پایدار شدن عدد نمایشگر، مقدار pH اندازه‌گیری و ثبت شد (Ding, Zhang, Ahmed, Liu, & Qin, 2019; Noshirvani & Mohebbi, 2023).

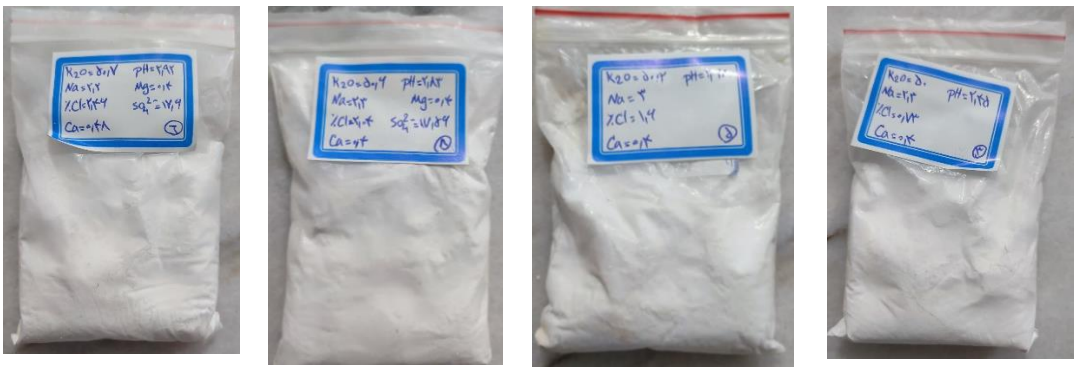

شکل ۳– آماده‌سازی نمونه‌های آزمایش

Fig. 3. Preparation of test samples

طول موج‌های موثر

نمودارهای مربوط به دو مؤلفه اصلی اول حاصل از تحلیل مؤلفه‌های اصلی (PCA) برای کانال‌های تصویر فراطیفی سولفات پتاسیم (شامل ۶۶۵ کانال) در شکل ۴ نمایش داده شده‌اند. همان‌طور که در این نمودار قابل‌مشاهده است، مقادیر مؤلفه‌های اصلی در سطوح مختلف pH تفاوت قابل‌توجهی دارند که نشان‌دهنده تأثیر شرایط pH بر اطلاعات طیفی است. بر اساس پیک‌های برجسته موجود در این نمودارها، کانال‌های مؤثر تصویر شناسایی و انتخاب

شدند. سپس با استفاده از این کانال‌ها، طول‌موج‌های متناظر و بهینه در تصاویر فراطیفی تعیین گردیدند. کانال‌های انتخاب‌شده برای چهار سطح مختلف pH عبارتند از: ۶۵، ۳۲۷، ۳۳۴، ۴۸۲، ۵۱۰، ۶۰۷ و ۶۴۴، که در شکل ۴ به‌طور مشخص قابل‌مشاهده‌اند. طول‌موج‌های مؤثر متناظر با این کانال‌ها به‌ترتیب برابر با ۴۵۳/۳۲، ۶۶۹/۹۵، ۶۷۵/۷۴، ۷۹۸/۱۱، ۸۲۱/۲۶، ۹۰۱/۴۷ و ۹۳۲/۰۶ نانومتر بودند. برای استخراج ویژگی‌های مؤثر از این طول‌موج‌های منتخب، از هر طول‌موج شش ویژگی استخراج شد. در نتیجه، در مجموع ۴۲ ویژگی حاصل گردید که در فرآیند طبقه‌بندی سطوح مختلف pH مورد استفاده قرار گرفتند.

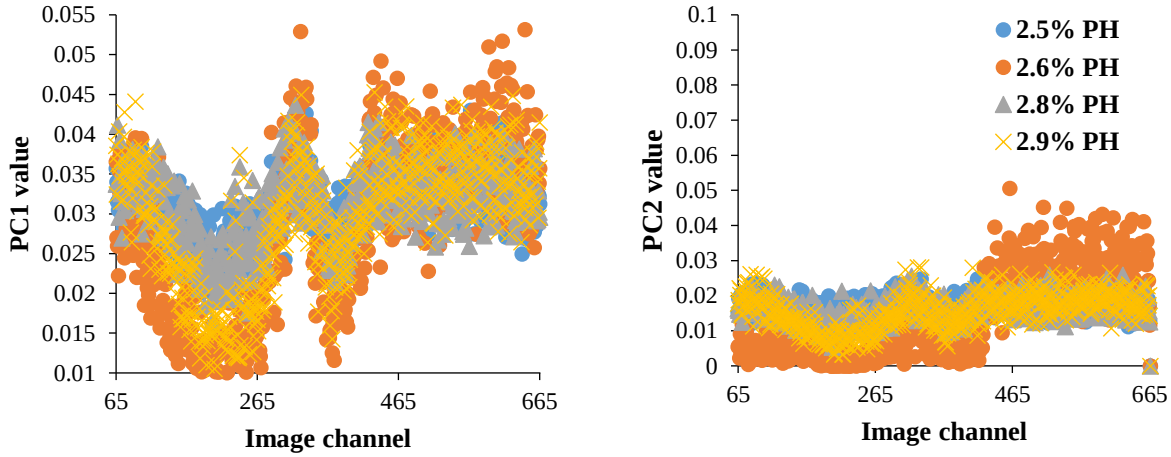

شکل ٤– نمودارهای تحلیل مولفه‌های اصلی PC1 و PC2 برای داده‌های pH کود پتاسیم

Fig. 4. PC1 and PC2 principal component analysis plots for potassium fertilizer pH data

طبقه‌بندی بدون انتخاب ویژگی

نتایج طبقه‌بندی با استفاده از روش ANN بر اساس تمام ویژگی‌های استخراج‌شده در شکل ۷ نمایش داده شده است. سطوح مختلف pH طبقه‌بندی شدند. در این مدل طبقه‌بندی، شبکه بهینه دارای ساختار ۴-۶-۴۲ بود، یعنی تعداد نورون‌ها در لایه ورودی شبکه بهینه ۴۲ (تعداد ویژگی‌های مؤثر) و تعداد نورون‌ها در لایه خروجی یک (پیش‌بینی سطوح مختلف pH) و تعداد نورون‌ها در لایه پنهان شش به‌دست آمد (شکل ۵-الف). بهترین عملکرد اعتبارسنجی شبکه در دور شماره ۱۳ با مقدار ۰/۰۳۱۴ مشاهده گردید (شکل ۵-ب). ضرایب همبستگی طبقه‌بندی شبکه عصبی مصنوعی برای داده‌های آموزش، اعتبارسنجی، آزمون، و تمام داده‌ها به‌ترتیب ۱۰۰، ۹۱/۲۳، ۹۹/۴۰ و ۹۸/۲۳ بود (شکل ۵-ج). با استفاده از این مدل، ۷۱ نمونه از ۷۲ نمونه به‌درستی شناسایی شدند (شکل ۵-د). نرخ طبقه‌بندی صحیح مدل بهینه برای طبقه‌بندی میزان pH بر اساس تمام ویژگی‌های کارآمد برابر با ۹۸/۶ درصد بود.

طبقه‌بندی با انتخاب ویژگی

از بین تمام طول موج‌ها، هفت طول موج به‌عنوان طول موج‌های کارا انتخاب و بقیه از فرآیند حذف شدند. برای هر یک از این طول موج‌ها، شش ویژگی شامل میانگین، حداقل، حداکثر، واریانس، میانه و انحراف معیار از طول موج کارای تصاویر فراطیفی استخراج گردید. در مجموع ۴۲ ویژگی مختلف استخراج شد. مقادیر متوسط هر یک از ویژگی‌های انتخابی در جدول ۱ آورده شده است.

طبق جدول ۱، میانگین مقادیر ویژگی میانگین در طول موج ۷۹۸/۱۱ نانومتر برای تمامی سطوح pH در بازه $۹۷/۷\times۱۰^{-۳}$ تا $۹۹/۵\times۱۰^{-۳}$ قرار داشت که کمترین و بیشترین مقادیر آن به‌ترتیب مربوط به سطوح ۲/۶ و pH ۲/۹ بودند. میانگین مقادیر ویژگی حداقل برای سطوح ۲/۵، ۲/۶، ۲/۸ و pH ۲/۹ در طول موج ۸۲۱/۲۶ نانومتر به‌ترتیب $۸۳/۱\times۱۰^{-۳}$، $۹۳/۱\times۱۰^{-۳}$، $۸۶/۵\times۱۰^{-۳}$ و $۹۰/۷\times۱۰^{-۳}$ بود. همچنین در همین طول موج، کمترین مقدار میانگین ویژگی میانگین معادل $۹۶/۵\times۱۰^{-۳}$ برای pH برابر با ۲/۸ و بیشترین مقدار معادل $۹۹/۰۰\times۱۰^{-۳}$ برای pH برابر با ۲/۶ بود. در طول موج ۹۰۱/۴۷ نانومتر، برای ویژگی حداقل، کمترین مقدار به سطح pH ۲/۵ و بیشترین مقدار به سطح pH ۲/۶ اختصاص داشت. همچنین در همان طول موج، میانگین مقادیر ویژگی برای سطوح ۲/۵، ۲/۶، ۲/۸ و pH ۲/۹ به‌ترتیب $۹۶/۹\times۱۰^{-۳}$، $۹۶/۶\times۱۰^{-۳}$، $۹۷/۳\times۱۰^{-۳}$ و $۹۸/۴\times۱۰^{-۳}$ بود. برای ویژگی واریانس نیز مقادیر به‌ترتیب $۳/۹\times۱۰^{-۳}$،

$۱۰/۱\times۱۰^{-۳}$، $۲/۸\times۱۰^{-۳}$ و $۲/۳\times۱۰^{-۳}$ مشاهده شد. در طول موج ۹۳۲/۰۶ نانومتر، میانگین ویژگی در محدوده $۹۵/۳\times۱۰^{-۳}$ تا $۹۸/۶\times۱۰^{-۳}$ بود و همان‌طور که نتایج نشان می‌دهد، کمترین مقدار این ویژگی مربوط به pH ۲/۵ و ۲/۸ و بیشترین مقدار آن مربوط به pH ۲/۶ در کود پتاسیم بود.

ویژگی کارای انتخاب‌شده برای طبقه‌بندی توسط روش شبکه عصبی مصنوعی مورد استفاده قرار گرفتند. ساختار مدل بهینه در این راهبرد به صورت ۴-۴-۷ بود که در آن تعداد نورون‌ها در لایه پنهان برابر با ۴ تعیین شد (شکل ۶-الف). عملکرد شبکه در مرحله اعتبارسنجی در شکل ۶-ب نمایش داده شده است. کمترین خطای اعتبارسنجی در دور ۲۱ با مقدار ۰/۳۵ به‌دست آمد. ضرایب همبستگی شبکه عصبی مصنوعی بهینه برای داده‌های آموزش، اعتبارسنجی، آزمون، و تمام داده‌ها در شکل ۶-ج نشان داده شده است. ضریب همبستگی شبکه بهینه برای داده‌ها به‌ترتیب ۹۹/۵۲، ۹۰/۲۵، ۹۲/۲۵، و ۹۶/۳۰ بود. در ماتریس اغتشاش (شکل ۶-د)، طبقات شماره ۱، ۲، ۳ و ۴ به‌ترتیب مربوط به سطوح pH برابر ۲/۵، ۲/۶، ۲/۸، و ۲/۹ هستند. ماتریس اغتشاش میزان مختلف pH نشان داد که طبقه‌بند بهینه توانسته است ۷۰ نمونه از ۷۲ نمونه را به‌درستی شناسایی کند. بنابراین، میانگین دقت طبقه‌بندی شبکه عصبی مصنوعی بر اساس تمامی ویژگی‌های استخراج‌شده ۹۷/۲ درصد بود.

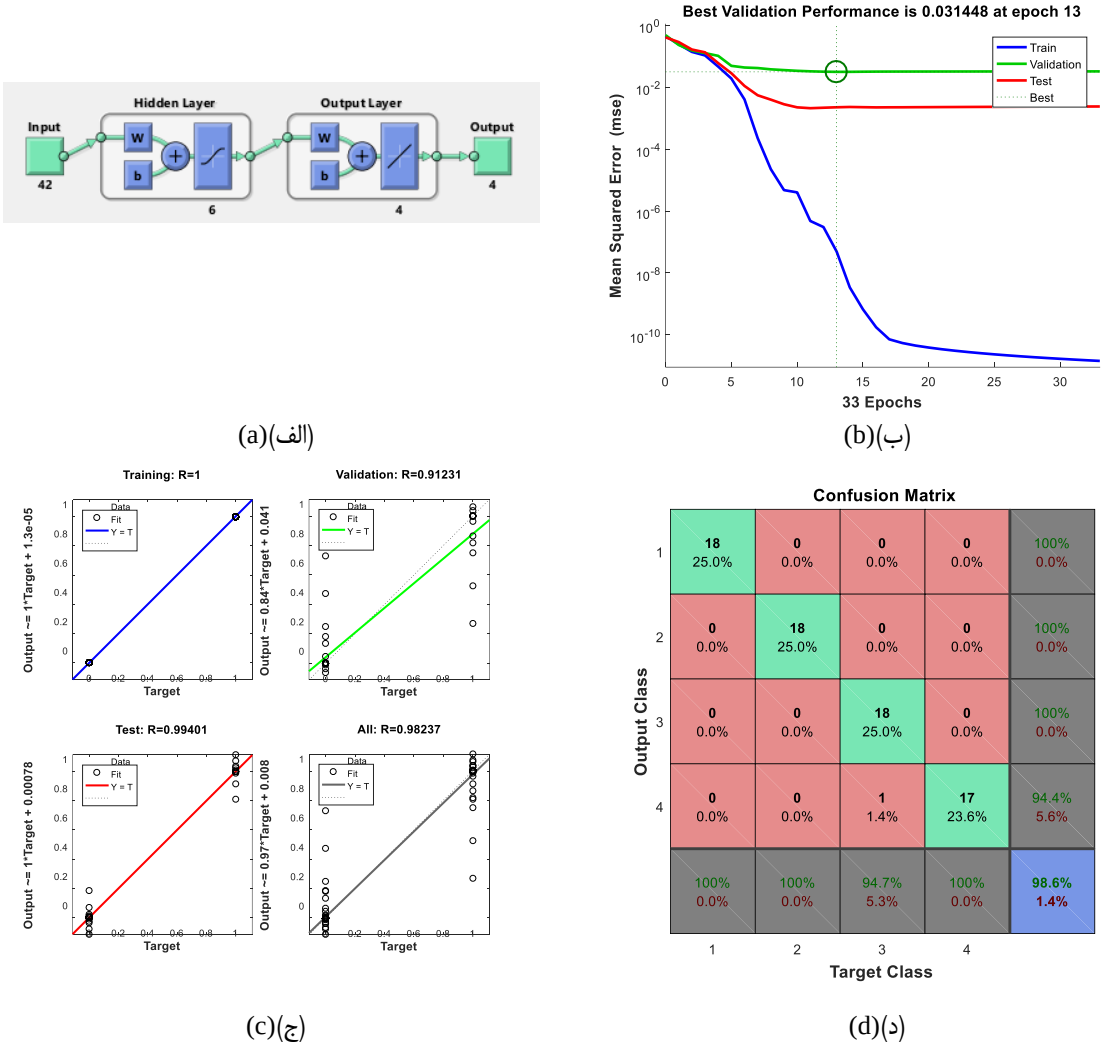

(a)(الف) (b)(ب)

(c)(ج) (d)(د)

شکل ۵– ساختار بهینه شبکه عصبی مصنوعی بر اساس تمام ویژگی‌های استخراج‌شده الف) ساختار بهینه، ب) عملکرد اعتبارسنجی، ج) ضرایب همبستگی و د) ماتریس اغتشاش

Fig. 5. Optimal structure of the artificial neural network based on all extracted features: (a) optimal structure, (b) validation performance, (c) correlation coefficients, and (d) confusion matrix

جدول ۱– مقادیر میانگین ویژگی‌های انتخاب‌شده از تصاویر فراطیفی برای طبقه‌بندی کود پتاسیم

Table 1- Average values of selected features from hyperspectral images to classify potassium fertilizer

میزان pH pH level		2.5		2.6		2.8		2.9	
ویژگی Feature	طول موج (نانومتر) Wavelength (nanometers)	میانگین Mean	انحراف معیار Standard deviation	میانگین Mean	انحراف معیار Standard deviation	میانگین Mean	انحراف معیار Standard deviation	میانگین Mean	انحراف معیار Standard deviation
میانگین Mean	798.11	13.8×10^{-4}	13.8×10^{-4}	99.5×10^{-3}	0.8×10^{-4}	97.7×10^{-3}	2.3×10^{-4}	99.03×10^{-3}	1.2×10^{-4}
حداقل Minimum	821.26	83.1×10^{-3}	12.1×10^{-4}	93.1×10^{-3}	2.6×10^{-4}	86.5×10^{-3}	6.9×10^{-4}	90.7×10^{-3}	3.8×10^{-4}
میانگین Mean	821.26	97.9×10^{-3}	13.1×10^{-4}	99×10^{-3}	1.2×10^{-4}	96.5×10^{-3}	2.04×10^{-4}	98.4×10^{-3}	1.6×10^{-4}
حداقل Minimum	901.47	77×10^{-3}	14.7×10^{-4}	90.9×10^{-3}	2.8×10^{-4}	82.71×10^{-3}	7.4×10^{-4}	85.4×10^{-3}	5×10^{-4}
میانگین Mean	901.47	96.9×10^{-3}	2.2×10^{-4}	99.6×10^{-3}	0.4×10^{-4}	97.3×10^{-3}	2.9×10^{-4}	98.4×10^{-3}	1.2×10^{-4}
واریانس Variance	901.47	3.9×10^{-3}	3×10^{-4}	10.1×10^{-3}	0.6×10^{-4}	2.8×10^{-3}	1.5×10^{-4}	2.3×10^{-3}	0.9×10^{-4}
میانگین Mean	932.06	95.3×10^{-3}	2.1×10^{-4}	98.6×10^{-3}	0.9×10^{-4}	95.3×10^{-3}	3.08×10^{-4}	96.8×10^{-3}	1.6×10^{-4}

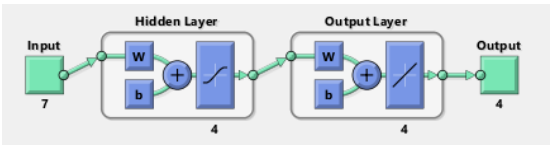

(a)(الف)

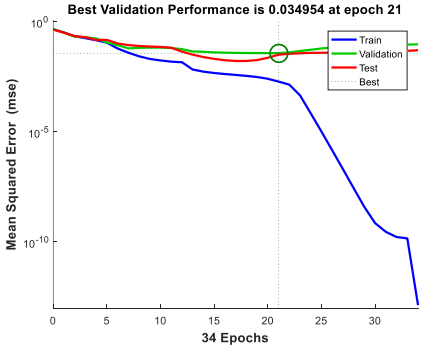

(b)(ب)

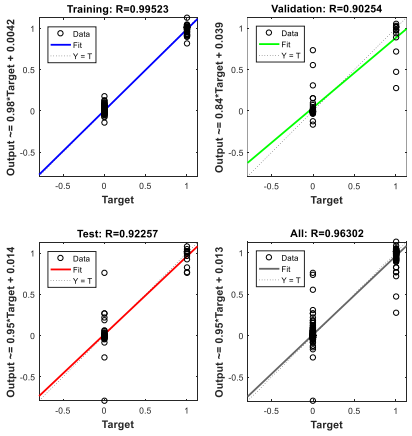

(c)(ج)

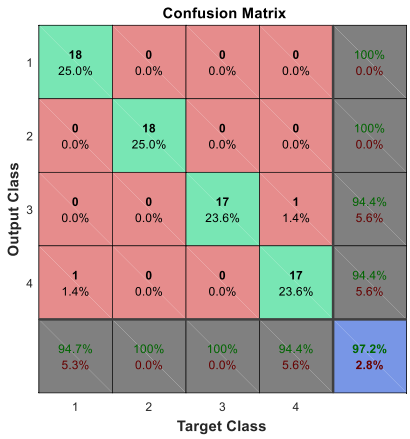

(d)(د)

شکل ٦– ساختار بهینه شبکه عصبی مصنوعی بر اساس ویژگی‌های کارا الف) ساختار بهینه، ب) عملکرد اعتبارسنجی، ج) ضرایب همبستگی و د) ماتریس اغتشاش

Fig. 6. Optimal structure of artificial neural network based on the efficient features: (a) optimal structure, (b) validation performance, (c) correlation coefficients, and (d) confusion matrix

بالاترین دقت در تشخیص درصدهای مختلف pH با استفاده از روش ANN بر اساس تمام ویژگی‌های استخراج‌شده، برابر ۹۸/۶ درصد بود. این نتیجه نسبت به گزارش پاتیل و لَد (Patil & Lad, 2021) که دقت ۹۳ درصد را برای تشخیص بیماری برگ گیاه فلفل با استفاده از روش ANN گزارش کرده بودند، عملکرد بهتری نشان می‌دهد. علاوه بر این، دقت به‌دست‌آمده در این پژوهش با استفاده از روش ANN نسبت به تحقیق‌های گزارش‌شده برای سایر محصولات کشاورزی و غذایی بالاتر است (Vadivambal & Jayas, 2016).

نتیجه‌گیری

توسعه ابزارهای دقیق، سریع و مقرون به‌صرفه برای اندازه‌گیری pH کود پتاسیم اهمیت زیادی دارد؛ زیرا به کشاورزان کمک می‌کند تا از اثرات منفی آن بر رشد گیاهان جلوگیری کند. در این پژوهش، چهار نمونه کود پتاسیم با سطوح مختلف pH با استفاده از روش تصویربرداری فراطیفی تشخیص داده شدند. طول موج‌های موثر شامل ۴۵۳/۳۲، ۶۶۹/۹۵، ۷۹۸/۱۱، ۸۲۱/۲۶، ۹۰۱/۴۷ و ۹۳۲/۰۶ بودند. پس از استخراج و انتخاب ویژگی از کانال‌های متناظر با آن‌ها، سطوح مختلف pH نمونه‌ها با استفاده از روش شبکه عصبی مصنوعی و بر اساس همه ویژگی‌های استخراج‌شده و ویژگی‌های کارای انتخاب‌شده طبقه‌بندی شدند. مدل بهینه برای شناسایی میزان سطوح مختلف pH کود پتاسیم دارای ساختار ۴-۶-۴۲ هنگام استفاده از تمامی ویژگی‌ها و ۴-۴-۷ هنگام استفاده از ویژگی‌های کارا بود. نتایج نشان داد که دقت طبقه‌بندی مدل بهینه بر اساس همه ویژگی‌های استخراج بالاتر (۹۸/۶ درصد) بود. این سطح بالای دقت طبقه‌بندی، پتانسیل توسعه یک سیستم بلادرنگ برای طبقه‌بندی آنلاین پارامتر شیمیایی pH در کود پتاسیم را برجسته می‌کند. چنین سیستمی می‌تواند زمان و هزینه ارزیابی را به‌طور قابل‌توجهی کاهش دهد و در عین حال کاربردهای کارآمدتری را در محیط‌های صنعتی فراهم کند.

سپاسگزاری

از دانشگاه ایلام به‌خاطر حمایت از پژوهش حاضر سپاسگزاری می‌شود. همچنین از شرکت مجتمع صنایع شیمیایی ایران به‌خاطر فراهم کردن شرایط لازم اجرای این پژوهش قدردانی می‌شود.

تعارض منافع

هیچ‌گونه تعارض منافعی توسط نویسندگان بیان نشده است.

مشارکت نویسندگان

محمدحسین نرگسی: جمع‌آوری داده‌ها، پردازش داده‌ها، شبیه‌سازی عددی/کامپیوتری، استخراج تهیه متن اولیه، پردازش داده‌ها، تحلیل آماری و خدمات نرم‌افزاری.

کامران خیرعلی‌پور: نظارت و مدیریت، روش‌شناسی، مشاوره فنی، ویرایش متن و خدمات نرم‌افزاری.

فاطمه ولی‌زاده کاخکی: مشاوره فنی، ویرایش متن و خدمات نرم‌افزاری.

زهرا مرادی: استخراج تهیه متن اولیه، ویرایش متن و خدمات نرم‌افزاری.

References

1. Ahmad, Z., Anjum, S., Waraich, E. A., Ayub, M. A., & Ahmad, T. (2018). Growth, physiology, and biochemical activities of plant responses with foliar potassium application under drought stress–a review, *Journal of Plant Nutrition 41*, 1734-1743. https://doi.org/10.1080/01904167.2018.1459688
2. Ahmed, W., Khaliduzzaman, A., Emmert, J. L., & Kamruzzaman, M. (2025). An overview of recent advancements in hyperspectral imaging in the egg and hatchery industry. *Computers and Electronics in Agriculture, 230*, 109847. https://doi.org/10.1016/j.compag.2024.109847
3. Allahvirdizadeh, N., & Nazari Deljou, M. J. (2014). Effect of humic acid on morph-physiological traits, nutrients uptake and postharvest vase life of pot marigold cut flower (*Calendula officinalis* cv. Crysantha) in hydroponic system. *Journal of Science Technology of Greenhouse Culture, 5*(18), 133-143. (in Persian with English abstract).
4. Al-Taai, S. H. H. (2021). The effect of fertilizer uses on environmental pollution: A review. *Review of International Geographical Education Online, 11*(5), 3620-3529.
5. Arif Chaudhry, M. M., Bane, M., McAllister, T., Paliwal, J., & Narváez-Bravo, C. (2025). Identification and Classification of Multi-Species Biofilms on Polymeric Surfaces Using Hyperspectral Imaging. *Journal of Food Safety, 45*, e70008. https://doi.org/10.1111/jfs.70008
6. Aviara, N. A., Liberty, J. T., Olatunbosun, O. S., Shoyombo, H. A., & Oyeniyi, S. K. (2022). Potential application of hyperspectral imaging in food grain quality inspection, evaluation and control during bulk storage. *Journal of Agriculture and Food Research, 8*, 100288. https://doi.org/10.1016/j.jafr.2022.100288

7. Bagherpour, H., Fatehi, F., Shojaeian, A., & Bagherpour, R. (2025). Hyperparameter Optimization of ANN, SVM, and KNN Models for Classification of Hazelnuts Images Based on Shell Cracks and Feature Selection Method. *Journal of Agricultural Machinery*, *15*(1), 129-144. https://doi.org/10.22067/jam.2024.87830.1244
8. Chen, J. H. (2006). The combined use of chemical and organic fertilizers and/or biofertilizer for crop growth and soil fertility. Paper presented at the international workshop on sustained management of the soil-rhizosphere system for efficient crop production and fertilizer use.
9. Ding, J., Zhang, R., Ahmed, S., Liu, Y., & Qin, W. (2019). Effect of sonication duration in the performance of polyvinyl alcohol/chitosan bilayer films and their effect on strawberry preservation. *Molecules*, *24*(7), 1408. https://doi.org/10.3390/molecules24071408
10. Fernandez, L. C., Allende-Prieto, J., & Peon, E. (2019). Preliminary Assessment of Visible, Near-Infrared, and Short-Wavelength–Infrared Spectroscopy with a Portable Instrument for the Detection of Staphylococcus aureus Biofilms on Surfaces. *Journal of Food Protection*, *82*(8), 1314-1319. https://doi.org/10.4315/0362-028X.JFP-18-567
11. Gowen, A. A., O'Donnell, C. P., Cullen, P. J., Downey, G., & Frias, J. M. (2007). Hyperspectral imaging–an emerging process analytical tool for food quality and safety control. *Trends in Food Science & Technology*, *18*, 590-598. https://doi.org/10.1016/j.tifs.2007.06.001
12. Griffe, P., Metha, S., & Shankar, D. (2003). Organic production of medicinal, aromatic and dye yielding plants (MADPs): forward, preface and introduction. *Food Agriculture Organization*, *2*, 52-63.
13. Hasan, M. M., Chaudhry, M. M. A., Erkinbaev, C., Paliwal, J., Suman, S. P., & Rodas- Gonzalez, A. (2022). Application of Vis-NIR and SWIR Spectroscopy for the Segregation of Bison Muscles Based on Their Color Stability. *Meat Science*, *188*, 108774. https://doi.org/10.1016/j.meatsci.2022.108774
14. Hosainpour, A., Kheiralipour, K., Nadimi, M., & Paliwal, J. (2022). Quality assessment of dried white mulberry (*Morus alba* L.) using machine vision. *Horticulturae*, *8*(11), 1011. https://doi.org/10.3390/horticulturae8111011
15. Ismail, A., Yim, D.-G., Kim, G., & Jo, C. (2023). Hyperspectral imaging coupled with multivariate analyses for efficient prediction of chemical, biological and physical properties of seafood products. *Food Engineering Reviews*, *15*, 41-55. https://doi.org/10.1007/s12393-022-09327-x
16. Khan, M. H., Saleem, Z., Ahmad, M., Sohaib, A., Ayaz, H., & Mazzara, M. (2020). Hyperspectral imaging for color adulteration detection in red chili. *Applied Sciences*, *10*, 5955. https://doi.org/10.3390/app10175955
17. Khazaee, Y., Kheiralipour, K., Hosainpour, A., Javadikia, H., & Paliwal, J. (2022). Development of a novel image analysis and classification algorithms to separate tubers from clods and stones. *Potato Research*, *65*, 1-22. https://doi.org/10.1007/s11540-021-09528-7
18. Kheiralipour, K. (2024). *The future of imaging technology*. Nova Science Publishers, Hauppauge, New York, USA. ISBN 979-8-89530-078-7.
19. Kheiralipour, K. (2022). *Sustainable production: Definitions, aspects, and elements*. (1st ed.), Nova Science Publishers, Hauppauge, New York, USA. ISBN 979-8-88697-208-5.
20. Kheiralipour, K. (2012). Implementation and construction of a system for detecting fungal infection in pistachio kernel based on thermal imaging (TI) and image processing technology. Ph.D. Dissertation, University of Tehran, Karaj, Iran.
21. Kheiralipour, K., Ahmadi, H., Rajabipour, A., & Rafiee, S. (2018). Thermal imaging, principles, methods and applications. Ilam University Publication. Ilam, IR Iran.
22. Kheiralipour, K., Ahmadi, H., Rajabipour, A., Rafiee, S., & Javan-Nikkhah. M. (2015). Classifying healthy and fungal infected-pistachio kernel by thermal imaging technology. *International Journal of Food Properties*, *18*(1), 93-99. https://doi.org/10.1080/10942912.2012.717155
23. Kheiralipour, K., Ahmadi, H., Rajabipour, A., Rafiee, S., Javan-Nikkhah, M., & Jayas, D. S. (2014). Detection of healthy and fungal-infected pistachios based on hyperspectral image processing. 8th Iranian national congress of agricultural machinery engineering (biosystems) and mechanization, 29-31 January, Mashahd, Iran.
24. Kheiralipour, K., Ahmadi, H., Rajabipour, A., Rafiee, S., Javan-Nikkhah, M., Jayas, D. S., & Siliveru, K. (2016). Detection of fungal infection in pistachio kernel by long-wave near-infrared hyperspectral imaging technique. *Quality Assurance and Safety of Crops & Foods*, *8*(1), 129-135. https://doi.org/10.3920/QAS2015.0606
25. Kheiralipour, K., Ahmadi, H., Rajabipour, A., Rafiee, S., Javan-Nikkhah, M., Jayas, D. S., Siliveru, K., & Malihipour, A. (2021). Processing the hyperspectral images for detecting infection of pistachio kernel by R5 and KK11 isolates of Aspergillus flavus fungus. *Iranian Journal of Biosystems Engineering*, *52*(1), 13-25. https://doi.org/10.22059/ijbse.2020.299712.665293
26. Kheiralipour, K., Chelladurai, V., & Jayas, D. S. (2023). *Imaging Systems and Image Processing Techniques*. In Image Processing: Advances in Applications and Research. Edited by Jayas, D.S. New York, USA: Nova Science Publishers.
27. Kheiralipour, K., & Marzbani, F. (2016). Pomegranate quality sorting by image processing and artificial neural network. 10th Iranian national congress on agricultural machinery (biosystems) and mechanization, 29-31 August, Mashhad, Iran.

28. Kheiralipour, K., Sajadipour, F., & Nargesi, M. H. (2025). Applications of spectral imaging in Biosystems engineering in Iran, A review. Recent Progress in Science, Accepted manuscript. https://doi.org/10.70462/rps.2025.2.007
29. Kheiralipour, K., & Jayas, D. S. (2024). Current and future applications of hyperspectral imaging in agriculture, nature and food. *Trends in Technical & Scientific Research, 7*(2), 1-9.
30. Kheiralipour, K., & Jayas, D. S. (2023). Applications of near infrared hyperspectral imaging in agriculture, natural resources, and food in Iran. 15th national and 1st international congress of mechanics of biosystems engineering and agricultural mechanization, Karaj, Iran.
31. Li, C., He, M., Cai, Z., Qi, H., Zhang, J., & Zhang, C. (2023). Hyperspectral imaging with machine learning approaches for assessing soluble solids content of tribute citru. *Foods, 12*, 247. https://doi.org/10.3390/foods12020247.
32. Lin, Y., Ma, J., Wang, Q., & Sun, D.-W. (2023). Applications of machine learning techniques for enhancing nondestructive food quality and safety detection. *Critical Reviews in Food Science and Nutrition, 63*, 1649-1669. https://doi.org/10.1080/10408398.2022.2131725
33. Min, D., Zhao, J., Bodner, G., Ali, M., Li, F., Zhang, X., & Rewald, B., (2023). Early decay detection in fruit by hyperspectral imaging–Principles and application potential. *Food Control, 152*, 109830. https://doi.org/10.1016/j.foodcont.2023.109830
34. Nargesi, M. H., Amiriparian, j., Bagherpour, H., & Kheiralipour, K. (2024b). Detection of different adulteration in cinnamon powder using hyperspectral imaging and artificial neural network method. *Results in Chemistry, 9*, 101644. https://doi.org/10.1016/j.rechem.2024.101644
35. Nargesi, M. H., & Kheiralipour, K. (2024). Visible feature engineering to detect fraud in black and red peppers. *Scientific Reports, 14*, 25417. https://doi.org/10.1038/s41598-024-76617-1
36. Nargesi, M. H., Kheiralipour, K., & Jayas, D. S. (2024c). Classification of different wheat flour types using hyperspectral imaging and machine learning techniques. *Infrared Physics & Technology, 142*, 105520. https://doi.org/10.1016/j.infrared.2024.105520
37. Nargesi, M. H. (2024). Detection of fraud in black pepper, red pepper, and cinnamon powder using hyperspectral imaging and artificial neural network. Ph.D. Dissertation, University of Bu-Ali Sina. Pages 11-130.
38. Nargesi, M. H., Heidarbeigi, K., Moradi, Z., & Abdolahi, S. (2024a). Detection of chlorine in potassium chloride and potassium sulfate using chemical imaging and artificial neural network. Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy. 326, Pages, 125253. https://doi.org/10.1016/j.saa.2024.125253
39. Naser, A. A. (2017). Study of response Trigonella foenum-graecum to spraying with high potassium (Miller) and high phosphor (Agroleaf). *Tikrit Journal of Pure Science, 22*(9), 6-10. https://doi.org/10.25130/tjps.v22i9.866
40. Nashmil, F., Mardani, A., Hosainpour, A., & Golanbari, B. (2025). Prediction of Rut Depth in Soil Caused by Wheels Using Artificial Neural Networks. *Journal of Agricultural Machinery, 15*(2), 263-274. (in Persian with English abstract). https://doi.org/10.22067/jam.2024.90273.1295
41. Noshirvani, N., & Mohebi, A. (2023). Investigation of chemical and microbial properties of date syrup during production stages (from raw material to final product). *Iranian Journal of Food Science and Industry, 20*(139). (in Persian). https://doi.org/10.22034/FSCT.20.139.110
42. Pahalvi, H. N., Rafiya, L., Rashid, S., Nisar, B., & Kamili, A. N. (2021). Chemical Fertilizers and Their Impact on Soil Health. In: Dar, G.H., Bhat, R.A., Mehmood, M.A., Hakeem, K.R. (eds) Microbiota and Biofertilizers, Vol 2. Springer, Cham. https://doi.org/10.1007/978-3-030-61010-4_1
43. Pandey, V., & Patra, D. (2015). Crop productivity, aroma profile and antioxidant activity in Pelargonium graveolens L'Hér. under integrated supply of various organic and chemical fertilizers. *Industrial Crops Products, 67*, 257-263. https://doi.org/10.1016/j.indcrop.2015.01.042
44. Park, J.-J., Cho, J.-S., Lee, G., Yun, D.-Y., Park, S.-K., Park, K.-J., & Lim, J.-H. (2023). Detection of Red Pepper Powder Adulteration with Allura Red and Red Pepper Seeds Using Hyperspectral Imaging. *Foods, 12*, 3471. https://doi.org/10.3390/foods12183471
45. Patil, A., & Lad, K. (2021). Chili Plant Leaf Disease Detection Using SVM and KNN Classification. Springer Nature Singapore Pte Ltd. 2021 V. S. Rathore et al. (eds.), Rising Threats in Expert Applications and Solutions, Advances in Intelligent Systems and Computing 1187. https://doi.org/10.1007/978-981-15-6014-9_26
46. Perramon, B., Bosch-Serra, A., Domingo, F., & Boixadera, J. (2016). Organic and mineral fertilization management improvements to a double-annual cropping system under humid Mediterranean conditions. *European Journal of Agronomy, 76*, 28-40. https://doi.org/10.1016/j.eja.2016.01.014
47. Qi, W., Wang, C., & Guo, X. (2017). Study on plant behavior perception based on computer vision: A review. *Jiangsu Journal of Agricultural Sciences, 45*, 20-26.
48. Saha, D., & Manickavasagan, A. (2021). Machine learning techniques for analysis of hyperspectral images to determine quality of food products: A review. *Current Research in Food Science, 4*, 28-44. https://doi.org/10.1016/j.crfs.2021.01.002
49. Salam, S., Kheiralipour, K., & Jian, F. (2022). Detection of unripe kernels and foreign materials in chickpea

mixtures using image processing. *Agriculture*, *12*(7), 995. https://doi.org/10.3390/agriculture12070995
50. Sakinejad, T. (2003). Study of effect of water deficit on the trend of uptake of N, P, K and Na at different growth stages considering the morphological and physiological traits of maize in Ahvaz climate. Ph.D. Dissertation on Crop Physiology, Science and Research Branch, Ahvaz, Iran.
51. Scharf, P. C., Kitchen, N. R., Sudduth, K. A., Davis, J. G., Hubbard, V. C., & Lory, J. A. (2005). Field-scale variability in optimal nitrogen fertilizer rate for corn. *Agronomy Journal*, *97*(2), 452-461. https://doi.org/10.2134/agronj2005.0452
52. Shabbir Dar, J., Akhtar Cheema, M., Ishaq Asif Rehmani, M., Khuhro, S., Rajput, S., Latif Virk, A., Hussain, S., Amjad Bashir, M., Suliman, M., Al-Zuaibr, M., Javed Ansari, M., & Hessini, K. (2021). Potassium fertilization improves growth, yield and seed quality of sunflower (*Helianthus annuus* L.) under drought stress at different growth stages. *PLoS ONE*, *16*(9), e0256075. https://doi.org/10.1371/journal.pone.0256075
53. Sharma, S., Sirisomboon, P., Sumesh, K., Terdwongworakul, A., Phetpan, K., Kshetri, T. B., & Sangwanangkul, P. (2023). Near-infrared hyperspectral imaging combined with machine learning for physicochemical-based quality evaluation of durian pulp. *Postharvest Biology and Technology*, *200*, 112334. https://doi.org/10.1016/j.postharvbio.2023.112334
54. Siadat, S. A., & Moradi-Telavat, M. R. (2018). Practical Aspects of Organic Farming. Tehran: Agricultural Education and Extension Press, 500 p. (in Persian).
55. Soni, A., Dixit, Y., Reis, M. M., & Brightwell, G. (2022). Hyperspectral imaging and machine learning in food microbiology: Developments and challenges in detection of bacterial, fungal, and viral contaminants. *Comprehensive Reviews in Food Science and Food Safety*, *21*, 3717-3745. https://doi.org/10.1111/1541-4337.12983
56. Sun, Y., Tong. Ch., He, Sh., Wang, K., & Chen, L. (2018). Identification of Nitrogen, Phosphorus, and Potassium Deficiencies Based on Temporal Dynamics of Leaf Morphology and Color. *Sustainability*, *10*, 762. https://doi.org/10.3390/su10030762
57. Vadivambal, R., & Jayas, D. S. (2016). Bio-Imaging: Principles, Techniques, and Applications. CRC Press, Taylor and Francis Group, New York, NY, US.
58. Wu, X. Y., Zhu, S. P., Huang, H., & Xu, D. (2017). Quantitative identification of adulterated sichuan pepper powder by near-infrared spectroscopy coupled with chemometrics. *Journal of Food Quality*, 5019816. https://doi.org/10.1155/2017/5019816
59. Xue, X., Tian, H., Zhao, K., Yu, Y., Zhuo, C., Xiao, Z., & Wan, D. (2025). Non-Destructive Detection of pH Value During Secondary Fermentation of Maize Silage Using Colorimetric Sensor Array Combined with Hyperspectral Imaging Technology. *Agronomy*, *15*, 285. https://doi.org/10.3390/agronomy15020285
60. Yang, F., Sun, J., Cheng, J., Fu, L., Wang, S., & Xu, M. (2023). Detection of starch in minced chicken meat based on hyperspectral imaging technique and transfer learning. *Journal of Food Process Engineering*, *46*, e14304. https://doi.org/10.1111/jfpe.14304
61. Zhao, J., Ni, T., Li, J., Lu, Q., Fang, Z., Huang, Q., Zhang, R., Li, R., Shen, B., & Shen, Q. (2016). Effects of organic–inorganic compound fertilizer with reduced chemical fertilizer application on crop yields, soil biological activity and bacterial community structure in a rice–wheat cropping system. *Applied Soil Ecology*, *99*, 1-12. https://doi.org/10.1016/j.apsoil.2015.11.006

Journal of Agricultural Machinery

Homepage: https://jame.um.ac.ir

Research Article
Vol. 16, No. 4, 2026, p. 639-652

Optimisation of Energy and Thermal Parameters in the Drying Process of Modified Starch with Cold Plasma Pretreatment

A. Taghavi[1], A. Ranjbar Nedamani[1*], A. Motevali[1], S. J. Hashemi[1]

1- Department of Mechanical Engineering of Biosystems, Sari Agricultural Sciences and Natural Resources University, Iran
(*- Corresponding Author Email: a.ranjbar@sanru.ac.ir)

Received: 30 June 2025
Revised: 16 August 2025
Accepted: 30 August 2025
Available Online: 03 December 2025

How to cite this article:
Taghavi, A., Ranjbar Nedamani, A., Motevali, A., & Hashemi, S. J. (2026). Optimisation of Energy and Thermal Parameters in the Drying Process of Modified Starch with Cold Plasma Pretreatment. *Journal of Agricultural Machinery, 16*(4), 639-652. [in Persian]. https://doi.org/10.22067/jam.2025.94207.1405

Introduction

Drying is one of the important steps in starch modification, after applying the modification treatments. Starch is obtained from the seeds and fruits of various plants and used in a dried state to achieve a longer shelf life, potentially saving on transportation and storage costs for commercial purposes. Drying is the final necessary step in starch modification, often performed using a conventional oven, a freeze dryer, or an organic solvent (typically ethanol or acetone). In food drying processes, energy consumption is considered a key parameter. The method used to dry pre-gelatinised starch is crucial, as drying is one of the most important steps in the production of modified starch powder. On the other hand, considering the global tendency to use renewable energies, especially in food drying, to reduce thermal damage, energy consumption and drying time, it is of great importance to investigate drying with reflectance window systems, which are environmentally friendly, have high efficiency and cause less damage to the food product components. The effect of drying modified starch with cold plasma by a reflectance window system at a temperature of 50 °C was investigated, and its results were compared with data from the traditional oven drying system.

Materials and Methods

Potato starch powder was obtained from Zamen Food Products Manufacturing Company, located in Mashhad Industrial City, Iran, in plastic packs. A laboratory-scale cold plasma generator device available at the Sari University of Agricultural Sciences and Natural Resources Growth Centre was used. This device consists of two main parts: the cold plasma generation section and the sample storage section. The device generated cold plasma through direct contact of the sample with the resulting ionised air. Cold plasma was applied to the sample produced by a plasma reactor with copper and steel electrodes at a voltage of 20 kV, a current of 3 mA, and a frequency of 50 Hz, using atmospheric air. A randomised complete factorial design was implemented with the factors of pre-gelatinisation temperature (55 and 60 °C), cold plasma treatment time (0, 15, and 30 min), and starch drying temperature in the oven (60, 70, and 80 °C). To prepare pre-gelatinised samples, 10 g of starch was dissolved in 90 g of distilled water to prepare a 10% (w/w) solution. The energy analysis included calculations of drying efficiency, energy efficiency, thermal efficiency, and specific heat consumption. The resulting data were optimized using Design-Expert software.

Results and Discussion

The results showed that the pre-gelatinisation temperature had a significant effect on all the studied parameters (energy, drying, and temperature efficiency), with a confidence level of $p < 0.05$. Drying temperature did not significantly affect energy efficiency, but it had a significant impact on both drying efficiency and

Authors retain the copyright. This is an open access article distributed under Creative Commons Attribution 4.0 International License (CC BY 4.0).

https://doi.org/10.22067/jam.2025.94207.1405

temperature efficiency. Plasma treatment had a substantial effect on energy efficiency and drying efficiency, but no significant effect was observed on temperature efficiency. Based on regression models, the linear model has the best fit to the experimental data and was able to accurately predict the responses, which indicates the importance of the factors under study in process optimisation. Based on optimisation analysis, the optimal conditions indicate a temperature of 60 ℃ for pre-gelatinisation, 70 ℃ for oven-drying, and 30 min for cold plasma treatment time. This combination results in maximum efficiency and reduced energy consumption.

Conclusion

This analysis shows that the studied temperature changes and different treatments have distinct effects on drying processes and energy consumption, which can be considered in optimising these processes. The results of this research can help improve starch production processes and increase their efficiency in related industries. This research simultaneously investigates two new methods for modifying and drying starch, which can result in practical improvements to starch quality.

Funding Sources: This research was funded by the Sari Agricultural Sciences and Natural Resources University in the form of a Master's thesis with registration number 6490/1403/D and registration date 16/9/2024 from the research budget related to the thesis grant.

Conflict of Interest: No conflict of interest has been declared by the authors.

Acknowledgements: We would like to thank Sari Agricultural Sciences and Natural Resources University for their financial and moral support in conducting this research.

Keywords: Cold Plasma, Drying, Energy Consumption, Starch Modification

نشریه ماشین‌های کشاورزی
https://jame.um.ac.ir

مقاله پژوهشی
جلد ۱۶، شماره ٤، زمستان ۱٤۰۵، ص ٦٥۲-٦۳۹

بهینه‌سازی فراسنجه‌های انرژی و حرارتی در فرآیند خشک‌کردن نشاسته اصلاح‌شده با پیش‌تیمار پلاسمای سرد

علی تقوی[۱]، آزاده رنجبر ندامانی[۱*]، علی متولی[۱]، سید جعفر هاشمی[۱]

تاریخ دریافت: ۱۴۰۴/۰۴/۰۹
تاریخ پذیرش: ۱۴۰۴/۰۶/۰۸

چکیده

یکی از مراحل مهم اصلاح نشاسته، بعد از اعمال تیمارهای اصلاحی، خشک‌کردن آن است. در فرآیندهای خشک‌کردن مواد غذایی، مصرف انرژی به‌عنوان یکی از فراسنجه‌های کلیدی و مهم موردتوجه قرار می‌گیرند. در این مطالعه اثر تیمارهای مختلف اصلاح نشاسته بر فراسنجه‌های انرژی و حرارتی فرآیند خشک‌کردن آن بررسی شد. پلاسمای سرد با استفاده از یک راکتور پلاسما با الکترودهایی از جنس مس و فولاد، در ولتاژ ۲۰ کیلوولت، جریان ۳ میلی‌آمپر و بسامد ۵۰ هرتز و با بهره‌گیری از هوای اتمسفر تولیدشده و بر روی نمونه اعمال شد. در تهیه نمونه‌های نشاسته، آزمایش چندعامله در قالب طرح کاملاً تصادفی با عوامل دمای پیش ژلاتینه (۵۵ و ۶۰ درجه سانتی‌گراد)، زمان تیمار با پلاسمای سرد (۳۰، ۱۵ و ۰ دقیقه)، و دمای خشک‌کردن نشاسته در آون (۸۰، ۷۰ و ۶۰ درجه سانتی‌گراد) اجرا شد. محاسبهٔ فراسنجه‌های انرژی و حرارتی در خشک‌کن جریان هوای گرم، بازده خشک‌شدن و انرژی حرارتی و گرمای مخصوص مصرفی به‌عنوان پاسخ‌ها محاسبه و بهینه‌سازی نتایج توسط نرم‌افزار دیزاین اکسپرت انجام شد. نتایج نشان داد دمای پیش ژلاتینه با سطح اطمینان ($p<۰/۰۵$) تأثیر قابل‌توجهی بر تمامی فراسنجه‌های موردنظر، یعنی بازده انرژی، بازده خشک‌کردن و بازده حرارتی داشت. در مقابل، دمای خشک‌کردن تأثیر معناداری بر بازده انرژی نشان نداد؛ اما اثرات آن بر بازده خشک‌کردن و حرارتی معنادار ارزیابی شد. از سوی دیگر، تیمار پلاسما اثر کاملاً معناداری بر بازده انرژی و خشک‌کردن داشت؛ اما در مورد بازده حرارتی تأثیر قابل‌توجهی مشاهده نشد. این تحلیل نشان می‌دهد که تغییرات دمایی و تیمارهای مختلف بر فرآیندهای خشک‌کردن و مصرف انرژی اثرات تفکیک‌شده‌ای دارند که می‌توانند در بهینه‌سازی این فرآیندها موردتوجه قرار گیرد.

واژه‌های کلیدی: اصلاح نشاسته، پلاسمای سرد، خشک‌کردن، مصرف انرژی

مقدمه

نشاسته‌ی طبیعی به دلیل ویژگی‌های فیزیکوشیمیایی خاص خود، از جمله گرانروی بالا در شرایط حرارت‌دهی، پایداری محدود در برابر حرارت، تنش مکانیکی و محیط‌های اسیدی، و همچنین حساسیت زیاد به فرآیندهای برگشت نشاسته[۲] و پس دادن آب[۳]، کاربردهای صنعتی محدودی دارد. این خواص چالش‌هایی را در استفاده از نشاسته در فرآیندهای مختلف ایجاد کرده و نیاز به اصلاح آن را برای بهبود عملکرد در صنایع غذایی و غیرغذایی برجسته کرده است. با بهره‌گیری از روش‌های اصلاح فیزیکی، شیمیایی، آنزیمی و ژنتیکی، می‌توان ویژگی‌های مطلوب نشاسته را تقویت کرده و محدودیت‌های آن را کاهش داد که این امر نقش مهمی در گسترش کاربردهای صنعتی آن دارد (Huber & BeMiller, 2010; Singh, Kaur, & McCarthy, 2007). با تغییر ساختار فیزیکوشیمیایی پلیمرهای آمیلوز و آمیلوپکتین، اصلاح نشاسته موجب بهبود ویژگی‌های عملکردی آن می‌شود. این تغییرات نه‌تنها خواص مطلوب را افزایش می‌دهند، بلکه محدودیت‌های ذاتی نشاسته‌ی طبیعی را کاهش داده و امکان استفاده‌ی گسترده‌تر از آن را در صنایع غذایی و غیرغذایی فراهم می‌آورند (Ashogbon & Akintayo, 2014; Huber & BeMiller, 2010; Kaur, Ariffin, Bhat, & Karim, 2012). در صنعت غذا، نشاسته‌ی اصلاح‌شده نقش کلیدی در بهبود کیفیت و عملکرد محصولات ایفا می‌کند. این نوع نشاسته با ایجاد بافت مطلوب و افزایش غلظت، موجب ارتقای ساختار مواد غذایی می‌شود. همچنین،

۱- گروه مهندسی بیوسیستم، دانشگاه علوم کشاورزی و منابع طبیعی ساری، ساری، ایران
(*- نویسنده مسئول: Email: a.ranjbar@sanru.ac.ir)
https://doi.org/10.22067/jam.2025.94207.1405
2- Retrogradation
3- Syneresis

حفظ استحکام و شفافیت ژل، تولید پوشش‌های خوراکی، کاهش برگشت نشاسته و تثبیت امولسیون‌ها از دیگر کاربردهای آن است. علاوه بر این، نشاسته‌ی اصلاح‌شده قابلیت بهبود پایداری در فرآیندهای انجماد–ذوب، جایگزینی چربی، کپسوله‌سازی ترکیبات آروماتیک و افزایش مقدار نشاسته‌ی مقاوم را دارا می‌باشد که این ویژگی‌ها نقش مهمی در افزایش کیفیت و پایداری مواد غذایی ایفا می‌کنند (Almaei, Nassiri, Nematollahi, Zare, & Khorram, 2024; Belitz, Grosch, & Schieberle, 2009; Bertolini, 2009).

یکی از مراحل مهم اصلاح نشاسته، بعد از تیمارهای اصلاحی، خشک‌کردن آن است. نشاسته از دانه‌ها و میوه‌های متفاوت گیاهان به‌دست می‌آید و برای ماندگاری طولانی‌تر و صرفه‌جویی بالقوه در هزینه‌های حمل و نقل و ذخیره‌سازی تجاری، به حالت خشک مورداستفاده قرار می‌گیرد. خشک‌کردن آخرین مرحله ضروری در طول اصلاح نشاسته است که اغلب با استفاده از آون معمولی، خشک‌کن انجمادی و حلال آلی (اغلب اتانول یا استون) انجام می‌شود. گزارش شده است که روش‌های خشک‌کردن می‌تواند ساختار نشاسته را تغییر دهد، مانند آسیب به ساختار سطحی و داخلی گرانول‌های نشاسته که به نوبه خود بر خواص عملکردی و واکنش شیمیایی نشاسته تأثیر می‌گذارد (Apinan *et al.*, 2007).

نتایج پژوهش‌های متولی و همکاران (Motevali, Minaei, Banakar, Ghobadian, & Khoshtaghaza, 2014; Motevali, Minaei, & Khoshtagaza, 2011) در خشک‌کردن محصولات مختلف کشاورزی با استفاده از فناوری‌های مختلف خشک‌کردن (جریان هوای گرم، مایکروویو، مایکروویو–جریان هوای گرم، فروسرخ، فروسرخ–جریان هوای گرم، تحت خلا، مایکروویو–تحت خلا) نشان داد که استفاده از خشک‌کردن جریان هوای گرم بالاترین مصرف انرژی در بین تمامی روش‌های خشک‌کردن را دارد با این حال، همان‌گونه که ذکر شد، خشک‌کردن با هوای گرم یک عملیات پرمصرف از نظر انرژی است که منجر به تغییرات شیمیایی و فیزیکی نامطلوب در ماده غذایی نیز می‌شود. بنابراین، بهبود کارایی خشک‌کردن و حفظ کیفیت محصول از نتایج اصلی تحقیقات در زمینه خشک‌کردن مواد غذایی است (Misra & Martynenko, 2021; Ranjbar Nedamani & Hashemi, 2021). در فرآیند خشک‌کردن با هوای گرم، ضریب انتقال حرارت پایین مواد غذایی و وجود یک لایه بر سطح محصولات کشاورزی، مانع حذف رطوبت شده و در نتیجه زمان خشک‌شدن طولانی‌تر شده و کیفیت کلی محصول کاهش می‌یابد (Ashtiani *et al.*, 2020; Zhou *et al.*, 2020) بنابراین، برای رفع این نقص، روش‌های تیمار کمکی برای خشک‌کردن با هوای گرم، مانند بلانچینگ با آب داغ و بخار، تیمار اسیدی یا قلیایی، مورد مطالعه قرار گرفته‌اند. اگرچه این روش‌ها تأثیر مثبتی بر فرآیند خشک‌کردن دارند؛ اما همچنان ممکن است با مشکلاتی مانند جذب شیمیایی، کاهش کیفیت، بازآب‌پذیری ضعیف، فروپاشی ساختاری، از دست رفتن مواد مغذی و مصرف بالای انرژی مواجه شوند (Bassey, Cheng, & Sun, 2021). برای ارتقای بیشتر عملکرد خشک‌کردن مواد غذایی، لازم است کاربرد فناوری‌های نوین در فرآیند خشک‌کردن مورد بررسی قرار گیرد (Bassey *et al.*, 2021). به‌عنوان یک فناوری نوظهور در فرآیندهای خشک‌کردن، پلاسمای سرد[1] (CP) به‌طور گسترده در کاربردهای ضدباکتریایی (Zhou *et al.*, 2020)، اصلاح ترکیب‌بندی مواد غذایی و فیلم‌های بسته‌بندی (Bahrami *et al.*, 2022; Taghavi, Nedamani, Motevali, & Hashemi, 2025; K. Zhang *et al.*, 2019)، تیمار آلاینده‌های غذایی (Wu, Cheng, & Sun, 2021)، ضدعفونی (Katsigiannis, Bayliss, & Walsh, 2022) و موارد دیگر مورداستفاده قرار گرفته است. همچنین گزارش‌های اخیر نشان می‌دهند که تیمار پلاسمای سرد بر روی محصولات غذایی قبل یا حین فرآیند خشک‌کردن، قابلیت قابل‌توجهی برای بهبود کارایی خشک‌کردن و ارتقای کیفیت دارد (Du, Yang, Yu, Xie, & Yao, 2022). پیش‌تیمار خشک‌کردن با پلاسمای سرد یک روش بسیار کارآمد از نظر مصرف انرژی است؛ زیرا با کاهش نیاز به انرژی، موجب صرفه‌جویی قابل‌توجهی در فرآیند خشک‌کردن می‌شود. علاوه بر این، این روش جایگزین پاک‌تر و مؤثرتری نسبت به پیش‌تیمارهای شیمیایی مانند استفاده از اسید و قلیا است. پلاسمای سرد معمولاً تنها به هوای محیط متکی است و نیازی به مواد شیمیایی یا آب اضافی ندارد که این ویژگی آن را به یک راهکار پایدار و دوستدار محیط‌زیست تبدیل می‌کند (Thirumdas, Sarangapani, & Annapure, 2015). این فناوری با سایر روش‌های خشک‌کردن، به‌ویژه سامانه‌های صنعتی، کاملاً سازگار است (Gavahian & Khaneghah, 2020). همچنین مشخص شده است فرآیند تیمار با پلاسمای سرد می‌تواند اصلاحاتی در ساختار نشاسته ایجاد کند که بر ویژگی‌های عملکردی آن تأثیر بگذارد. این تغییرات موجب بهبود کارایی نشاسته در نقش یک افزودنی غذایی شده و امکان استفاده بهینه‌تر از آن را در مراحل مختلف آماده‌سازی غذا فراهم می‌آورد (Thirumdas, Kadam, & Annapure, 2017). پیش‌تیمار پلاسمای سرد به‌طورقابل‌توجهی زمان خشک‌کردن را کاهش داده و بازده فرآیند خشک‌کردن را بهبود می‌بخشد (Li *et al.*, 2019; Ranjbar Nedamani & Hashemi, 2022). مطالعات اخیر نشان داده‌اند که تیمار پلاسمای سرد قبل یا در حین خشک‌کردن مواد غذایی، قابلیت بالایی در بهبود کارایی خشک‌کردن و کیفیت دارد؛ به‌عنوان مثال ژو و همکاران (Zhou *et al.*, 2020) گوجی بری را به

1- Cold Plasma

مدت ۳۰ ثانیه با پلاسمای سرد تیمار کردند که منجر به کاهش ۵۰٪ در زمان خشک‌کردن شد. آشتیانی و همکاران (Ashtiani *et al.*, 2020) با کمک تیمار پلاسمای سرد، زمان خشک‌کردن و مصرف انرژی را به‌ترتیب ۲۶/۲۷٪ و ۲۶/۳۰٪ کاهش دادند. این کار سبب حفظ ترکیبات فنولی و ویتامین C نیز شد. گوپتا و همکاران (Gupta, Guha, & Srivastav, 2023) به بررسی اثر پلاسمای سرد دی‌الکتریک (BDB) بر نشاسته تارو پرداختند و نتایج نشان داد که پلاسما شفافیت خمیر، حلالیت، پایداری انجماد–ذوب (درصد پس دادن آب)، خواص رنگی، شاخص سفیدی و قابلیت هضم آزمایشگاه را تغییر می‌دهد بنابراین نشاسته تارو تیمارشده با پلاسمای سرد می‌تواند در زمینه مواد بسته‌بندی مواد غذایی، محصولات غذایی کاربردی و دارویی مورداستفاده قرار گیرد.

باتوجه‌به توضیحات ذکرشده، نحوه خشک‌کردن نشاسته پیش‌ژلاتینه بسیار مهم بوده و خشک‌کردن یکی از مراحل بسیار مهم در تولید پودر نشاسته اصلاح‌شده است. هدف اصلی از این تحقیق، بررسی و بهینه‌سازی فراسنجه‌های انرژی و حرارتی در فرآیند خشک‌کردن نشاسته اصلاح‌شده با پیش‌تیمارهای ژلاتینه شدن و پلاسمای سرد است. این مطالعه به دنبال یافتن شرایط بهینه‌ای است که منجر به کاهش مصرف انرژی و افزایش کارایی فرآیند خشک‌کردن در اثر تیمار پلاسمای سرد شود. به‌این‌ترتیب می‌توان خشک‌کردن نشاسته اصلاح‌شده را به‌گونه‌ای بهبود بخشید که هم مصرف انرژی کمتر و هم بهره‌وری حرارتی بهتری داشته باشد.

مواد و روش‌ها

پودر نشاسته سیب‌زمینی از شرکت تولیدی محصولات غذایی ضامن واقع در شهرک صنعتی مشهد، ایران، در بسته‌بندی پلاستیکی بدون آن‌که با هوای بیرون در تماس باشد، تهیه شد.

تیمار با پلاسمای سرد

برای انجام تیمار پلاسمای سرد بر روی نشاسته، از یک مولد پلاسمای سرد دست‌ساز (شکل ۱) در مرکز رشد دانشگاه علوم کشاورزی و منابع طبیعی ساری، استفاده شد. این وسیله از دو بخش اصلی تشکیل شده است: بخش تولید پلاسمای سرد (نوع تخلیه الکتریکی با مانع[1] (DBD)) و بخش نگهداری نمونه. طراحی این وسیله به‌گونه‌ای است که امکان تولید پلاسمای سرد و تماس مستقیم نمونه با هوای یونیزه‌شده حاصل از آن را فراهم می‌آورد. پلاسمای سرد با استفاده از یک راکتور پلاسما با الکترودهایی از جنس مس و فولاد، در ولتاژ ۲۰ کیلوولت، جریان ۳ میلی‌آمپر و بسامد ۵۰ هرتز و با بهره‌گیری از هوای اتمسفر تولیدشده و بر روی نمونه اعمال شد.

آماده‌سازی نمونه‌ها

در تهیه نمونه‌های نشاسته، آزمایش چندعامله در قالب طرح کاملاً تصادفی با عوامل دمای پیش‌ژلاتینه (۶۰ و ۵۵ درجه سانتی‌گراد)، زمان تیمار با پلاسمای سرد (۳۰، ۱۵ و ۰ دقیقه)، و دمای خشک‌کردن نشاسته (۸۰، ۷۰ و ۶۰ درجه سانتی‌گراد) در یک آون جریان هوای گرم اجرا شد. برای تهیه نمونه‌های پیش‌ژلاتینه‌شده، مقدار ۱۰ گرم نشاسته در ۹۰ گرم آب مقطر ریخته و یک محلول ۱۰٪ (w/w) تهیه شد. نمونه‌هایی که باید تیمار پیش‌ژلاتینه شدن دریافت می‌کردند، تا دمای موردنظر گرمادهی شده و بعد از تغییر رنگ و گرانروی، برای انجام تیمار پلاسمای سرد در وسیله قرار داده شدند. در نهایت تمام نمونه‌ها در دمای مورد آون هوای گرم افجی فن‌دار مدل BM55E تا رسیدن به وزن ثابت خشک شدند. در طول آزمایش‌های خشک‌کردن، محدودهٔ میانگین تغییرات دمای محیط ۲۵°C و رطوبت نسبی هوا ۳۵٪ بود و فرآیند خشک‌کردن در سرعت جریان هوای ثابت ۰/۵ متر بر ثانیه انجام شد. یک نمونه نشاسته بدون تیمار پیش‌ژلاتینه و بدون تیمار با پلاسما نیز به‌عنوان شاهد تهیه و جهت مقایسه نتایج مورداستفاده قرار گرفت.

محاسبهٔ فراسنجه‌های انرژی در خشک‌کن جریان هوای گرم

انرژی مصرفی توسط خشک‌کن جریان هوای گرم برای خشک‌کردن در دماهای مختلف و سرعت جریان هوای ثابت با استفاده از رابطهٔ (۱) به‌دست آمد (Aghbashlo & Samimi-Akhijahani, 2008; Motevali, Minaei, Khoshtaghaza, & Amirnejat, 2011)

$$E_{ter} = A\,\upsilon\,\rho_a\,C_a\Delta T t \qquad (۱)$$

E_{ter} نمایانگر مقدار کل انرژی حرارتی مصرفی در یک دوره خشک‌شدن (kWh)، A بیانگر مساحت ظرفی که نمونه آزمایش در آن قرار می‌گیرد (m^2)، υ نشان‌دهندهٔ سرعت باد ($m\ s^{-1}$)، ρa چگالی هوا ($kg\ m^{-3}$)، t مجموع زمان لازم برای خشک‌شدن هر نمونه (h)، ΔT اختلاف دما (°C) و Ca گرمای ویژه هوا ($kJ\ kg^{-1}°C^{-1}$) هستند.

انرژی مکانیکی مصرفی توسط دمنده در خشک‌کن در طول فرآیند خشک‌کردن از رابطهٔ (۲) به‌دست می‌آید:

$$E_{mec} = \Delta P.w_{air}.t \qquad (۲)$$

E_{mec} کل انرژی مکانیکی در هر دوره (kJ)، ΔP افت فشار (Pa)، جریان هوا ($m\ s^{-1}$)، t زمان خشک‌شدن (h) است (Motevali, Hashemi, & Keyani, 2023).

انرژی مخصوص موردنیاز به‌ازای خروج یک کیلوگرم رطوبت از محصول در حال خشک‌شدن با استفاده از رابطهٔ (۳) به‌دست می‌آید:

1- Dielectric Barrier Discharge

$$S.E.C = \frac{Eu_{(total)}}{M_w} = \frac{Eu_{(Per+mec+ter)}}{M_w} \quad (۳)$$

S.E.C انرژی مخصوص مورد نیاز ($kWh\ kg^{-1}$)، $E.U_{total}$ مقدار کل انرژی مصرفی در طول فرآیند خشک‌شدن (kwh) و Mw میزان رطوبت حذف‌شده از محصول (kg) و Epr میزان انرژی مصرفی پیش‌تیمار هستند (Motevali *et al.*, 2023).



شکل ۱- مولد پلاسمای سرد

Fig. 1. The cold plasma generator device

بازده خشک‌شدن

بازده فرآیند خشک‌شدن از طریق نسبت مجموع انرژی موردنیاز برای گرم‌کردن محصول و انرژی لازم جهت تبخیر رطوبت، به کل انرژی مصرف‌شده طی فرآیند خشک‌کردن تعیین می‌شود. این معیار نشان‌دهنده کارایی انرژی طی این فرآیند است (رابطه(۴)) (Vieira, Estrella, & Rocha, 2007).

$$Drying\ Efficiency = \frac{E_{Heating+evaporation}}{E_{total}} \quad (۴)$$

دراین‌رابطه، Drying efficiency بازده خشک‌شدن (٪)، $E_{Heating}$ انرژی لازم برای افزایش دمای محصول در حال خشک‌شدن (kJ)، $E_{eveporation}$ انرژی لازم برای تبخیر رطوبت (kJ) و E_{total} کل انرژی مصرفی (kJ) است.

انرژی مصرفی برای تبخیر رطوبت در مواد و محصولات دارای رطوبت زیاد از رابطه (۵) محاسبه می‌گردد (Vieira *et al.*, 2007).

$$E_{evaporation} = h_{fg}.M_w \quad (۵)$$

در رابطه (۵) h_{fg} از رابطه‌های (۶) و (۷) به‌دست می‌آید.

$$h_{fg} = 2.503\times10^6 - 2.386\times10^3(T - 273.16) \qquad 273.16 \le T(K) \le 338.72 \quad (۶)$$

$$h_{fg} = (7.33\times10^{12} - 1.60\times10^7 T^2)^{0.5} \qquad 338.72 \le T(K) \le 533.16 \quad (۷)$$

همچنین $E_{heating}$ مقدار انرژی لازم برای بالا بردن دمای محصول در حال خشک‌شدن می‌باشد و مقدار آن از طریق رابطه (۸) محاسبه می‌گردد.

$$E_{heating} = W_d c_m (T_{m2} - T_{m1}) \quad (۸)$$

مقدار انرژی لازم برای افزایش دمای نمونه‌ها به شدت تحت تأثیر c_m (گرمای ویژه محصول) می‌باشد. گرمای ویژه محصولات کشاورزی که رابطه عمیقی با میزان رطوبت اولیه آن‌ها دارد از طریق رابطه (۹ و ۱۰) به‌دست می‌آید (Motevali *et al.*, 2014).

$$c_m = 1465.0 + 3560.0\left(\frac{M_p}{1+M_p}\right) \quad (۹)$$

$$M_p = \left(\frac{W_w - W_d}{W_d}\right) \quad (۱۰)$$

در روابط بالا c_m انرژی لازم برای افزایش دمای محصول (کیلوژول)، W_d وزن ماده خشک (کیلوگرم)، C_m گرمای ویژه محصول (کیلوژول بر کیلوگرم درجه کلوین)، T_{m1} دمای اولیه محصول (کلوین)، T_{m2} دمای نهایی محصول (کلوین)، M_p محتوای رطوبتی محصول بر پایه خشک (کیلوگرم آب بر کیلوگرم ماده جامد)، W_w وزن اولیه محصول (کیلوگرم) می‌باشد.

بازده انرژی

بازده انرژی از تقسیم انرژی لازم برای تبخیر رطوبت از محصول در حال خشک‌شدن، به کل انرژی مصرفی در طول فرآیند خشک‌شدن طبق رابطه (۱۱) به‌دست می‌آید (Motevali *et al.*, 2023):

$$Energy\ Efficiency = \frac{E_{evaporation}}{E_{total}} \quad (۱۱)$$

دراین‌رابطه، Energy efficiency بازده انرژی، $E_{evaporation}$ انرژی لازم برای تبخیر رطوبت (kJ) و E_{total} کل انرژی مصرفی (kJ) است.

بازده حرارتی

بازده حرارتی عبارت است از تقسیم میزان رطوبت تبخیرشده از محصول به میزان گرمای مصرفی که از رابطهٔ (۱۲) به‌دست می‌آید (Motevali *et al.*, 2023):

$$Thermal\ Efficiency = \frac{M_{evaporation}}{H_{total}} \quad (۱۲)$$

دراین‌رابطه، Thermal efficiency بازده حرارتی ($kg\ kJ^{-1}$)، $M_{evaporation}$ وزن رطوبت تبخیرشده از محصول (kg)، H_{total} کل گرمای مصرفی (kJ) است.

گرمای مخصوص مصرفی

گرمای مصرفی مخصوص عبارت است از تقسیم کل گرمای مصرفی در طول فرآیند خشک‌شدن به وزن کل رطوبت خارج‌شده از محصول که عکس بازده حرارتی است و از رابطه (۱۳) به‌دست می‌آید (Motevali *et al.*, 2023).

$$Specific\ Heat\ Consumption = \frac{H_{total}}{M_{evaporation}} \quad (۱۳)$$

دراین‌رابطه، Specific heat consumption گرمای مصرفی مخصوص ($kJ\ kg^{-1}$)، $M_{evaporation}$ وزن رطوبت تبخیرشده از محصول (kg)، H_{total} کل گرمای مصرفی (kJ) است.

تحلیل آماری و بهینه‌سازی مدل

در این پژوهش، فرآیند طراحی تیمارها با استفاده از نرم‌افزار Design Expert نسخه ۱۲ انجام شد. بهینه‌سازی شرایط تیمار در سطح اطمینان ($p<۰/۰۵$) صورت گرفت. نمودارهای مرتبط توسط نرم‌افزار Excel ترسیم و تمامی آزمون‌ها در دو تکرار اجرا شدند. جهت انتخاب مدل برتر، معیارهایی نظیر بالاترین ضریب تبیین (R^2) و کمترین مقدار جذر میانگین مربعات خطا (RMSE) مدنظر قرار گرفتند. جهت پیش‌بینی رفتار فراسنجه‌های انرژی، از جعبه پیش‌بینی نرم‌افزار Design Expert نسخه ۱۲ استفاده شد.

نتایج و بحث

بازده خشک‌کردن و بازده حرارتی

مطابق شکل ۲، بالاترین بازده حرارتی و خشک‌کردن در دمای ۸۰°C با دمای پیش‌ژلاتینه ۶۰°C و زمان پلاسمای ۳۰ دقیقه که ۶/۰۷٪ می‌باشد اتفاق افتاد. در مقابل، کمترین میزان بازده حرارتی و خشک‌کردن در دمای ۸۰°C و دمای پیش‌ژلاتینه ۵۵°C و ۱۵ دقیقه پیش‌تیمار با پلاسمای سرد و ۲/۷۵٪ بود و اختلاف این دو ۳/۳۲٪ می‌باشد. این امر نشان‌دهنده آن است که با افزایش تیمار پلاسما، دمای خشک و دمای پیش‌ژلاتینه شدن میزان بازده حرارتی و بازده خشک‌کردن افزایش می‌یابد. به‌طور کل افزایش زمان پلاسما و دمای پیش‌ژلاتینه به کاهش زمان خشک‌کردن نمونه‌ها کمک می‌کند بررسی‌ها نشان داد که با افزایش دمای خشک‌کردن از ۶۰°C به ۹۰°C، بازده حرارتی و خشک‌کردن روند صعودی داشت. همچنین مقایسه میزان اثرگذاری پیش‌تیمارهای مختلف نشان داد که استفاده از پیش‌تیمار پلاسمای سرد با مدت‌زمان ۳۰ دقیقه و پیش‌ژلاتینه با دمای ۶۰°C، توانست بهترین عملکرد را در بین تمامی پیش‌تیمارها و همچنین در تمامی دماهای خشک‌کردن داشته باشد. یکی از دلایل نتایج به‌دست‌آمده این بود که وقتی نشاسته تحت پیش‌ژلاتینه ۶۰°C و تیمار پلاسمایی به مدت ۳۰ دقیقه قرار می‌گیرد، ساختار مولکولی آن دست‌خوش تغییر شده و زنجیره‌های آن شکسته می‌شوند. این امر منجر به افزایش سرعت خشک‌شدن ماده می‌گردد. همان‌طور که ژانگ و همکاران (X. Zhang *et al.*, 2019) اشاره کرده‌اند، تیمار پلاسما تأثیر چشمگیری بر میزان رطوبت دارد، به‌گونه‌ای که رطوبت موجود در نشاسته نقشی تعیین‌کننده در فرآیند دپلیمریزاسیون ایفا می‌کند. در این فرآیند، الکترون‌های ثانویه با مولکول‌های آب واکنش داده و موجب تشکیل رادیکال‌های هیدروکسیل فعال و الکترون‌های آزاد می‌شوند. این واکنش‌ها در نهایت موجب تخریب ساختار پلی‌ساکاریدی نشاسته می‌گردد (Phillips, 1962; Sokhey & Hanna, 1993). تیمار پلاسما موجب ایجاد اچینگ (حکاکی) در سطح ماده می‌شود. این فرآیند می‌تواند دیواره‌های نمونه را تخریب کرده، آب‌دوستی آن را افزایش داده و باعث ایجاد ترک‌هایی شود. در نهایت، این تغییرات منجر به تسریع خروج آب و در نتیجه فرآیند خشک‌شدن می‌شوند (X. Zhang *et al.*, 2019) و به دنبال آن میزان انرژی کم‌تری در فرآیند خشک‌کردن مصرف می‌شود (Du *et al.*, 2022). در پژوهشی که میسرا و مارتینکو (Misra & Martynenko, 2021) انجام دادند، مشخص شد که انرژی مصرفی در فرآیند تیمار پلاسما در مقایسه با کل انرژی مورد نیاز برای فرآیند خشک‌کردن، مقدار ناچیزی است. با این حال، استفاده از تیمار پلاسما می‌تواند به طورقابل‌توجهی هزینه‌های مربوط به انرژی در فرآیند خشک‌کردن را کاهش دهد.

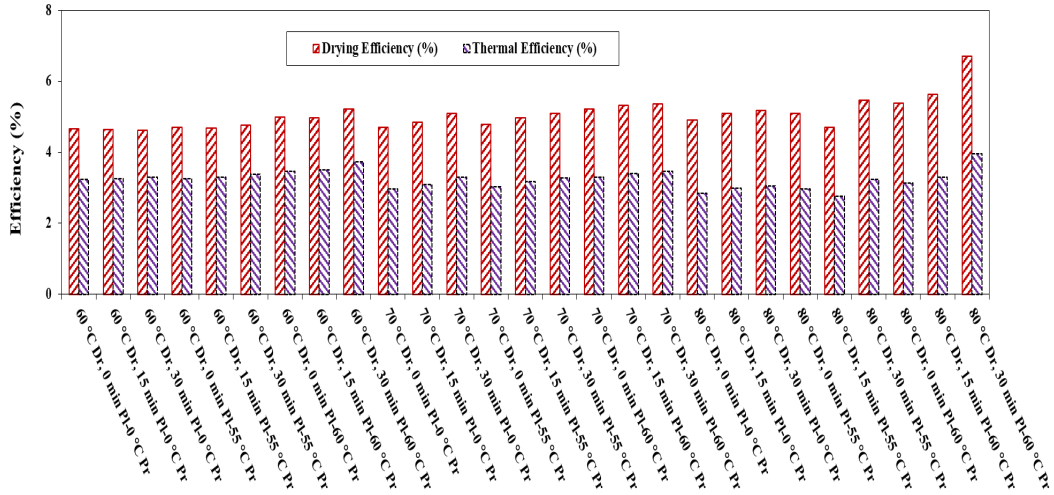

شکل ۲– روند تغییرات بازده انرژی و خشک‌شدن با تغییرات دما و پیش‌تیمار خشک‌شدن (Dr نماد دمای خشک‌کردن، Pl نماد زمان پیش‌تیمار با پلاسمای سرد، و Pr نماد دمای پیش‌ژلاتینه)

Fig. 2. Energy efficiency and drying efficiency changes with temperature and drying pretreatment (*Dr* is the symbol of Drying temperature, *Pl* is the symbol of cold plasma pretreatment, and *Pr* is the symbol of pregelatinisation temperature)

بازده انرژی

همان‌طور که در شکل ۳ نشان داده شده است، با افزایش مدت‌زمان اعمال پلاسما و بالا رفتن دمای پیش‌ژلاتینه، میزان انرژی مخصوص و گرمای مصرفی نسبت به نمونه شاهد افزایش می‌یابد. نکته قابل‌توجه این است که انرژی مخصوص با بالا رفتن دما از ۶۰°C و دمای پیش‌ژلاتینه ۶۰°C و زمان پیش‌تیمار پلاسمای سرد ۳۰ دقیقه، به دمای ۷۰°C با همین شرایط افزایش پیدا می‌کند؛ اما با افزایش دما از ۷۰°C به ۸۰°C، انرژی مخصوص کاهش می‌یابد. همچنین، گرمای مصرفی با افزایش دما از ۶۰°C به ۷۰°C کاهش پیدا کرده و با رسیدن دما به ۸۰°C افزایش می‌یابد. کم‌ترین مقدار انرژی مخصوص مصرفی در دمای خشک‌کردن ۸۰°C، دمای پیش‌ژلاتینه ۵۵°C، پیش‌تیمار ۱۵ دقیقه پلاسمای سرد و ۲/۷۱٪ مشاهده شده، در حالی‌که بیشترین مقدار مربوط به دمای خشک‌کردن ۸۰°C، دمای پیش‌ژلاتینه ۶۰°C، ۳۰ دقیقه پیش‌تیمار با پلاسمای سرد و ۳/۶۶٪ است که اختلاف کم‌ترین و بیشترین گرمای مصرفی برابر است با ۰/۹۵ از سوی دیگر، کم‌ترین میزان گرمای مخصوص دمای خشک‌کردن ۸۰°C، دمای پیش‌ژلاتینه ۶۰°C، ۳۰ دقیقه پلاسما و ۳/۶۶٪ و بیشترین میزان گرمای مخصوص در دمای خشک‌کردن ۸۰°C، دمای پیش‌ژلاتینه ۵۵°C، ۱۵ دقیقه پیش‌تیمار پلاسمای سرد و ۲/۷۱٪ مشاهده شده است که این امر نشان‌دهنده آن است که هرچه میزان دمای پیش‌ژلاتینه و زمان پلاسما بالاتر رود سرعت خشک‌کردن و همچنین میزان انرژی مصرفی کاهش پیدا می‌کند و به‌طور کلی باعث کاهش میزان مصرف انرژی می‌شود.

این افزایش سرعت خشک‌شدن می‌تواند ناشی از تشکیل منافذ میکروسکوپی طی تیمار پلاسمایی باشد که انتقال آب در طول فرآیند خشک‌شدن را تسهیل می‌کند. افزایش مدت مواجهه با پلاسما موجب کاهش تدریجی زمان خشک‌شدن شد که احتمالاً به دلیل افزایش اندازه منافذ میکروسکوپی است (Ashtiani *et al.*, 2020). نتایج نشان می‌دهد که استفاده‌ی مناسب از پیش‌تیمار پلاسما در خشک‌کردن همرفتی می‌تواند کاهش چشمگیری در مصرف انرژی ایجاد کند. این یافته‌ها نقش مؤثر پلاسما را در بهبود کارایی خشک‌کردن و کاهش هزینه‌های انرژی برجسته می‌کنند که با تحقیق مورد مطالعه آشتیانی و همکاران (Ashtiani *et al.*, 2020) که در مورد تأثیر پیش‌تیمار پلاسما و خشک‌کردن بر روی انگور بوده است مطابقت دارد که در این تحقیق تیمار پلاسما باعث کاهش مصرف انرژی و افزایش سرعت خشک‌شدن انگور شده است.

مدل‌سازی و بهینه‌سازی بازده انرژی، بازده خشک‌کردن و بازده دمایی

در تحلیل اثرات متغیرهای مختلف بر بازده‌های انرژی، خشک‌کردن و دمایی، بررسی نتایج جدول ۱، شکل ۴ و معادله خطی مرتبط نشان می‌دهد که دمای پیش‌ژلاتینه با سطح اطمینان ($p<۰/۰۵$) تأثیر قابل‌توجهی بر تمامی فراسنجه‌های موردنظر، یعنی بازده انرژی، بازده خشک‌کردن و بازده دمایی، داشته است. در مقابل،

دمای خشک‌کردن تأثیر معناداری بر بازده انرژی نشان نداده؛ اما اثرات آن بر بازده خشک‌کردن و بازده دمایی معنادار ارزیابی شده‌اند. از سوی دیگر، تیمار پلاسما اثر کاملاً معناداری بر بازده انرژی و بازده خشک‌کردن داشته؛ اما در مورد بازده دمایی تأثیر قابل‌توجهی مشاهده نشده است. این تحلیل نشان می‌دهد که تغییرات دمایی و تیمارهای مختلف بر فرآیندهای خشک‌کردن و مصرف انرژی اثرات تفکیک‌شده‌ای دارند که می‌توانند در بهینه‌سازی این فرآیندها موردتوجه قرار گیرد.

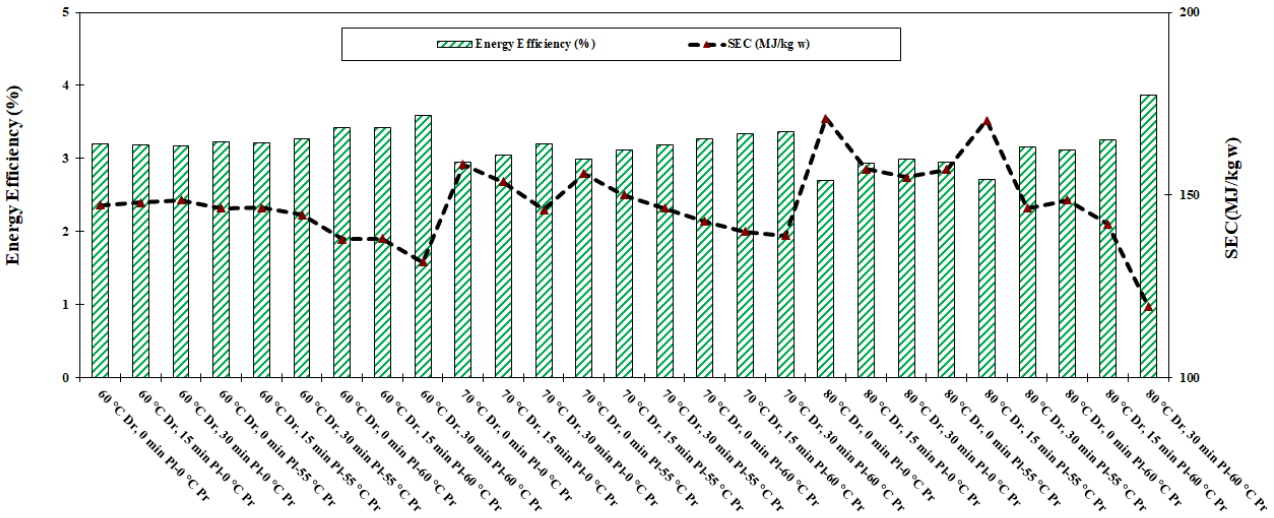

شکل ۳– روند تغییرات انرژی مخصوص و گرمای مخصوص نسبت به تغیرات دما و پیش‌تیمار در خشک‌کردن نشاسته (Dr نماد دمای خشک‌کردن، Pl نماد زمان پیش‌تیمار با پلاسمای سرد و Pr نماد دمای پیش‌ژلاتینه)

Fig. 3. Specific energy and specific heat changes with respect to changes in temperature and pretreatment in starch drying (*Dr* is the symbol of Drying temperature, *Pl* is the symbol of cold plasma pretreatment, and Pr is the symbol of pregelatinisation temperature)

جدول ۱ معناداری فاکتورهای مورد مطالعه بر پاسخ‌های مورد بررسی در این تحقیق و همچنین معناداری مدل رگرسیونی پیش‌بینی‌شده برای داده‌های تجربی را نشان می‌دهد. مطابق با این جدول، هر سه فاکتور دمای پیش‌ژلاتینه کردن، دمای خشک‌شدن و زمان تیمار پلاسما بر بازده انرژی، بازده خشک‌کردن و بازده دمایی اثر معنادار داشتند. همچنین برازش داده‌های آزمایشگاهی نشان داد بهترین مدل رگرسیونی برای هر سه پاسخ، مدل خطی بوده و این مدل‌ها قادرند با ضریب تبیین بیش از ۰/۸۶ در تمامی شاخص‌ها (جدول ۱ و شکل ۳) پاسخ‌های موردنظر را پیش‌بینی کنند.

در مورد بازده انرژی، مدل رگرسیونی نشان داد که اثر دمای پیش‌ژلاتینه کردن بیش‌ترین میزان تغییرات آن را توجیه می‌کند به‌طوری‌که هر واحد افزایش در این فاکتور، باعث افزایش تقریباً ۰/۱۳ واحدی در میزان بازده انرژی می‌شود. از طرفی، دمای خشک‌کردن و مدت‌زمان تیمار با پلاسمای سرد نیز به‌ترتیب اثرات مثبت و منفی بر بازده انرژی داشته و نشان‌دهنده نقش متقابل دما و زمان در تنظیم مصرف انرژی است.

در بررسی بازده خشک‌کردن نشاسته اصلاح‌شده، اثر فاکتورها از نظر آماری بسیار قوی‌تر بوده هر سه عامل اثر معنادار بر پاسخ داشتند. به‌طوری‌که دمای خشک‌کردن ضریب تأثیر تقریباً ۰/۳ از خود نشان داد. یعنی افزایش این فاکتور باعث افزایش قابل‌توجه در مقدار بازده خشک‌کردن خواهد شد. این نشان می‌دهد کنترل دقیق دمای خشک کردن نشاسته اصلاح‌شده، نقش مهمی در بهبود کارایی خشک‌کردن آن و در نتیجه کاهش اتلاف انرژی و کوتاه کردن زمان خشک‌کردن خواهد شد.

در بررسی بازده دمایی نیز اثر هر سه فاکتور معنادار بود. با این تفاوت که اثرات آن‌ها کمی کمتر از شاخص‌های دیگر است؛ اما ضریب معناداری و مقدار p کم نشان‌دهنده توانایی مدل در توضیح و پیش‌بینی فرآیند است. این نتیجه نشان می‌دهد کنترل بهینه دما و زمان تیمار با پلاسمای سرد، باعث بهبود بازده دمایی خواهد شد.

جدول ۱– اثر پاسخ فاکتورهای دمای پیش‌ژلاتینه کردن، دمای خشک‌شدن و زمان تیمار پلاسما بر بازده انرژی، بازده خشک‌کردن و بازده دمایی

Table 1- Effect of response factors of pregelatinisation temperature, drying temperature, and plasma treatment time on energy efficiency, drying efficiency, and temperature efficiency

Energy Efficiency							
Source	**Sum of Squares**	**df**	**Mean Square**	**F-value**	**p- value**	**R^2**	**Adjusted R^2**
Model	0.2555	3	0.0852	27.75	< 0.0001	0.86	0.83
A-PregelTemp	0.1317	1	0.1317	42.91	< 0.0001		
B-Drying Temp	0.0794	1	0.0794	25.86	0.0002		
C-CPtime	0.0444	1	0.0444	14.46	0.0022		
Residual	0.0399	13	0.0031				
Lack of Fit	0.0399	9	0.0044				
Pure Error	0.0000	4	0.0000				
Cor Total	0.2955	16					
Linear Model	Coefficient						
Intercept	3.16						
A-PregelTemp	0.1283						
B-Drying Temp	-0.0996						
C-CPtime	0.0745						
Drying Efficiency							
Source	**Sum of Squares**	**df**	**Mean Square**	**F-value**	**p-value**	**R^2**	**Adjusted R^2**
Model	1.08	3	0.3603	42.80	< 0.0001	0.90	0.88
A-PregelTemp	0.3397	1	0.3397	40.36	< 0.0001		
B-Drying Temp	0.6227	1	0.6227	73.97	< 0.0001		
C-CPtime	0.1185	1	0.1185	14.08	0.0024		
Residual	0.1094	13	0.0084				
Lack of Fit	0.1094	9	0.0122				
Pure Error	0.0000	4	0.0000				
Cor Total	1.19	16					
Linear Model	Coefficient						
Intercept	5.03						
A-PregelTemp	0.2061						
B-Drying Temp	0.2790						
C-CPtime	0.1217						
Thermal Efficiency							
Source	Sum of Squares	df	Mean Square	F-value	p-value	R^2	Adjusted R^2
Model	0.3446	3	0.1149	37.55	< 0.0001	0.89	0.87
A-PregelTemp	0.1414	1	0.1414	46.21	< 0.0001		
B-Drying Temp	0.1070	1	0.1070	34.99	< 0.0001		
C-CPtime	0.0962	1	0.0962	31.44	< 0.0001		
Residual	0.0398	13	0.0031				
Lack of Fit	0.0398	9	0.0044				
Pure Error	0.0000	4	0.0000				
Cor Total	0.3844	16					
Linear Model	Coefficient						
Intercept	3.22						
A-PregelTemp	0.1329						
B-Drying Temp	-0.1157						
C-CPtime	0.1096						

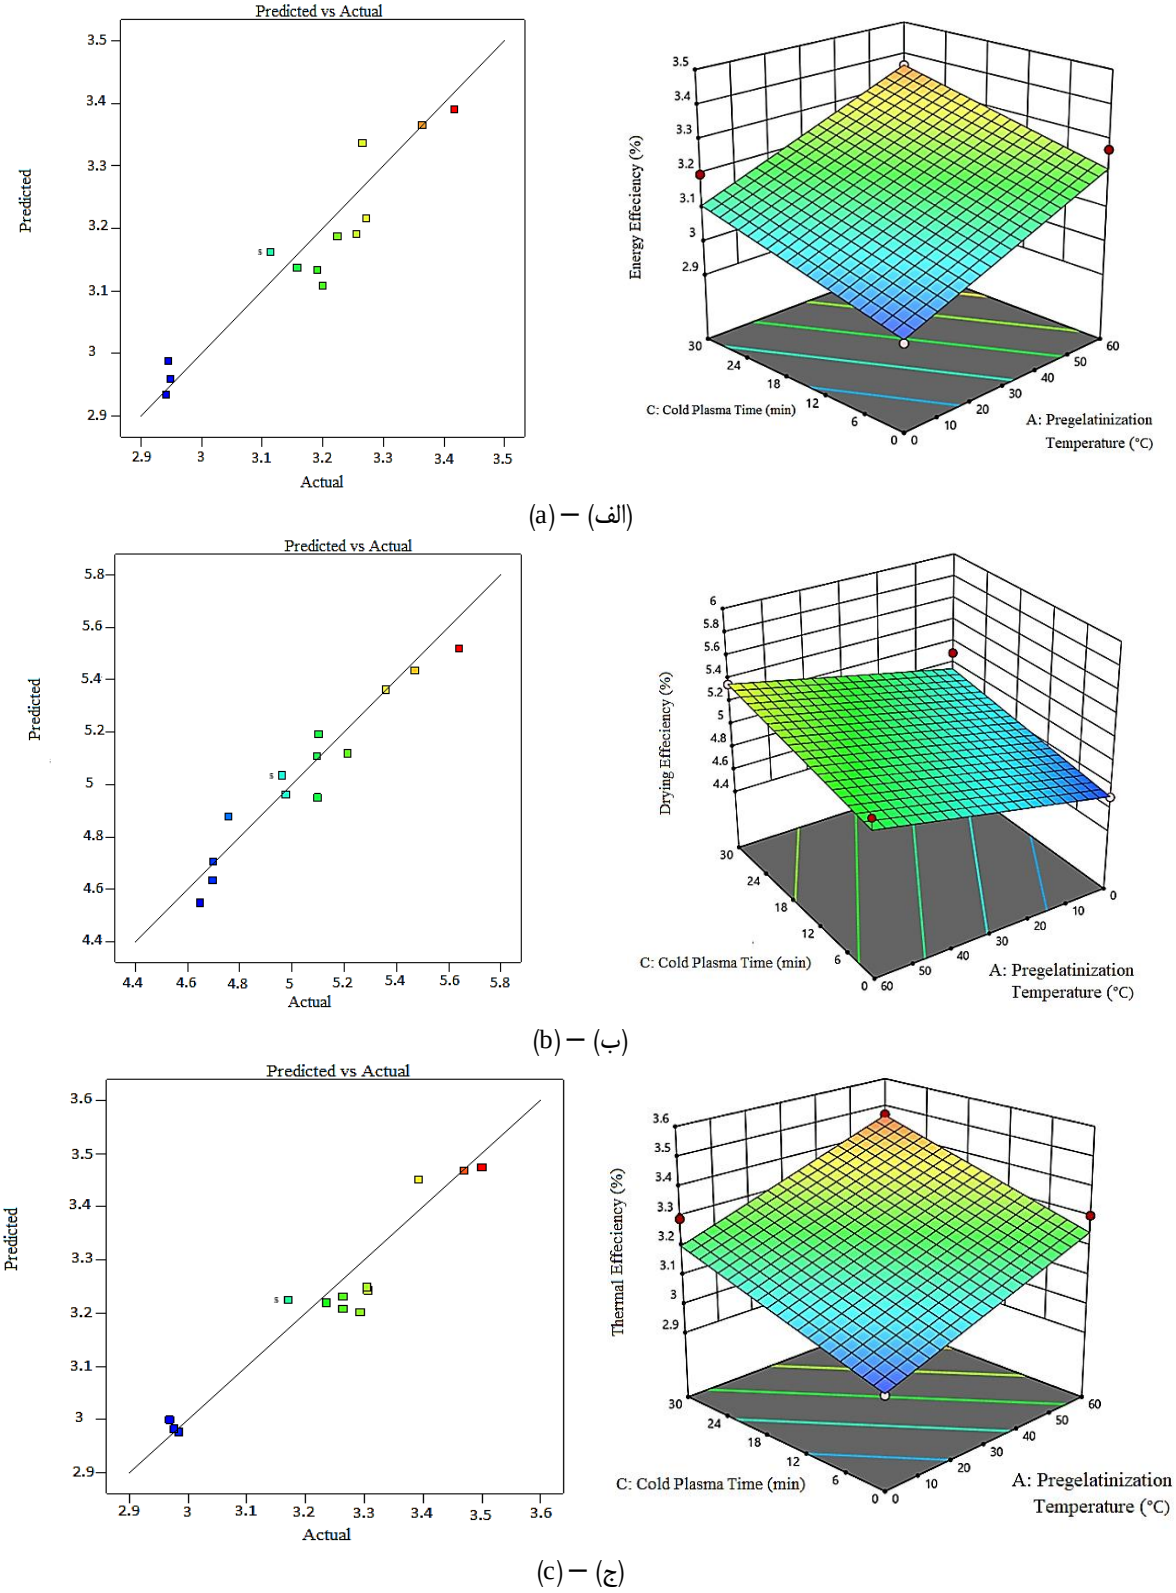

شکل ۳- اثر پاسخ فاکتورهای مورد مطالعه بر (الف) بازده انرژی، (ب) بازده خشک‌کردن و (ج) بازده دمایی

Fig. 3. Effect of the response of the studied factors on (a) energy efficiency, (b) drying efficiency, (c) and temperature efficiency

باتوجه‌به تأثیر متغیرهای مختلف بر میزان مصرف انرژی، تعیین شرایط بهینه برای ارزیابی این اثرات چندگانه ضروری است. در این راستا، فراسنجه‌های مرتبط با انرژی، گرما و دما مورد بهینه‌سازی قرار گرفته‌اند تا شرایط مطلوب برای کاهش یا افزایش مصرف انرژی مشخص شود. نتایج حاصل از این بهینه‌سازی عددی در شکل ۴ ارائه شده‌اند که نشان می‌دهد دمای پیش‌تیمار ۶۰°C، دمای خشک‌کردن ۷۰°C و زمان اعمال پلاسما ۳۰ دقیقه بهینه‌ترین شرایط را برای نمونه فراهم می‌کنند. بنابراین، جهت دستیابی به بهترین عملکرد در این فرآیند، توصیه می‌شود از ترکیب دمای ۶۰°C برای پیش‌ژلاتینه کردن، دمای ۶۷/۲°C برای خشک‌کردن و مدت‌زمان ۳۰ دقیقه برای تیمار با پلاسمای سرد استفاده شود که موجب افزایش کارایی و بهینه‌سازی انرژی خواهد شد.

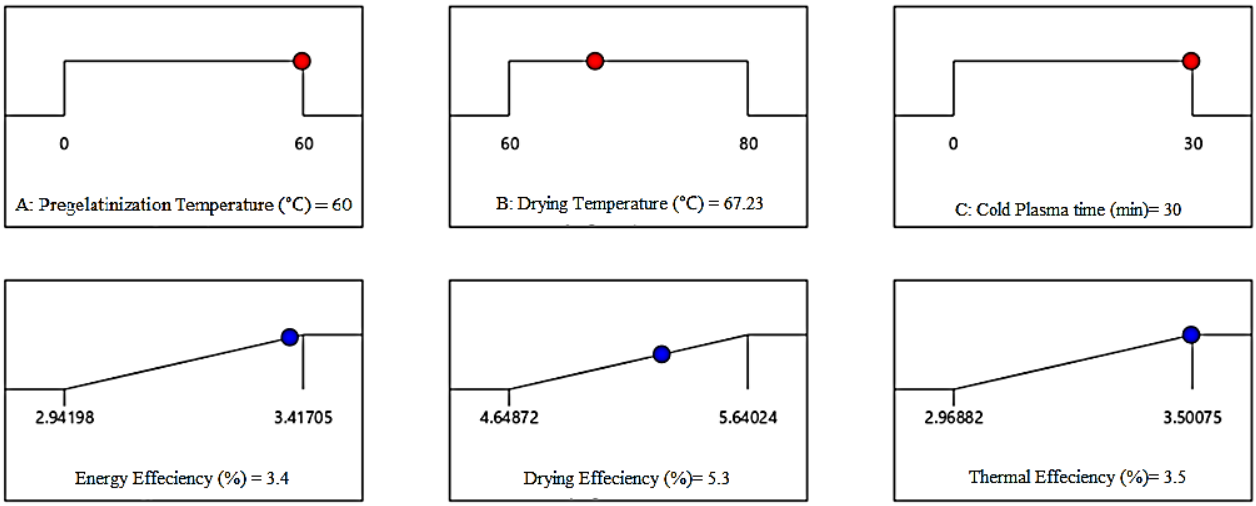

شکل ٤– شرایط بهینه‌سازی اندیس بازده‌های انرژی، گرما و دما در دیسپرسیون[1] نشاسته اصلاح‌شده با تیمارهای موردمطالعه

Fig. 4. Optimisation conditions for the energy, heat, and temperature efficiency indices in modified starch dispersion with the studied treatments

نتیجه‌گیری

یکی از روش‌های غیرحرارتی و نوین که تأثیر قابل‌توجهی دارد، استفاده از پلاسمای سرد به‌عنوان پیش‌تیمار در فرآیند خشک‌کردن است. این تکنیک نه‌تنها سرعت خشک‌کردن را افزایش داده و کیفیت محصول نهایی را بهبود می‌بخشد، بلکه موجب کاهش مصرف انرژی و جلوگیری از افت کیفیت می‌شود. در این مطالعه، نتایج نشان داد که تغییرات دمای خشک‌کردن و نوع پیش‌تیمارها اثرات متفاوتی بر فراسنجه‌های کارایی انرژی، حرارتی و خشک‌کردن داشتند. نتایج این تحقیق نشان می‌دهد که با افزایش زمان تیمار پلاسما، دمای پیش‌ژلاتینه و دمای خشک‌کردن، میزان انرژی مصرفی کاهش‌یافته و در نتیجه سرعت خشک‌شدن افزایش پیدا می‌کند که کارایی بالای این روش را در بهینه‌سازی فرآیند خشک‌کردن اثبات می‌کند. به‌طوری‌که بیش‌ترین بهره‌وری و کم‌ترین مصرف انرژی در شرایط بهینه دمای ۶۰°C برای پیش‌ژلاتینه کردن، دمای ۶۷/۲°C برای خشک‌کردن و مدت‌زمان ۳۰ دقیقه برای تیمار با پلاسمای سرد حاصل شد. این یافته‌ها می‌توانند در بهبود فرآیندهای تولید نشاسته اصلاح‌شده در صنایع تبدیلی مورداستفاده قرار گیرند و منجر به توسعه روش‌های پایدارتر تولید نشاسته شوند.

1- Dispersion

منابع تأمین مالی

بودجه این پژوهش توسط دانشگاه علوم کشاورزی و منابع طبیعی ساری در قالب پایان‌نامه دانشجوی کارشناسی ارشد به شماره ثبت ۱۴۰۳/۶۴۹۰/د و تاریخ ثبت ۱۴۰۳/۶/۲۶ از بودجه پژوهشی مربوط به گرنت پایان‌نامه‌ها تأمین شده است.

تعارض منافع

هیچ‌گونه تعارض منافع توسط نویسندگان بیان نشده است.

سپاسگزاری

از دانشگاه علوم کشاورزی و منابع طبیعی ساری بابت حمایت مادی و معنوی از انجام این پژوهش سپاسگزاری می‌شود.

مشارکت نویسندگان

علی تقوی: مفهوم‌سازی، مدیریت داده‌ها، تحلیل رسمی، تحقیق و بررسی، روش‌شناسی، منابع، نرم‌افزار، اعتبارسنجی، نوشتن– بررسی و ویرایش

آزاده رنجبر ندامانی: مفهوم‌سازی، مدیریت داده‌ها، تحلیل رسمی، تأمین مالی، تحقیق و بررسی، روش‌شناسی، مدیریت پروژه، منابع، نرم‌افزار، نظارت، اعتبارسنجی، تجسم، نوشتن– پیش‌نویس اصلی، نوشتن– بررسی و ویرایش

علی متولی: مفهوم‌سازی، تحقیق و بررسی، روش‌شناسی، مدیریت پروژه، منابع، نظارت

سیدجعفر هاشمی: مفهوم‌سازی، مدیریت داده‌ها، تحلیل رسمی، روش‌شناسی، مدیریت پروژه، نظارت

References

1. Aghbashlo, M., & Samimi-Akhijahani, H. (2008). Influence of drying conditions on the effective moisture diffusivity, energy of activation and energy consumption during the thin-layer drying of berberis fruit (Berberidaceae). *Energy Conversion and Management, 49*(10), 2865-2871. https://doi.org/10.1016/j.enconman.2008.03.009
2. Almaei, M., Nassiri, S. M., Nematollahi, M. A., Zare, D., & Khorram, M. (2024). Study on Drying Process of Farmed Shrimp Meat in a Hot Air Convective Dryer and Variation of Some Related Parameters. *Journal of Agricultural Machinery, 14*(3), 253-269. (in Persian with English abstract). https://doi.org/10.22067/jam.2023.80905.1145
3. Apinan, S., Yujiro, I., Hidefumi, Y., Takeshi, F., Myllärinen, P., Forssell, P., & Poutanen, K. (2007). Visual observation of hydrolyzed potato starch granules by α-amylase with confocal laser scanning microscopy. *Starch-Stärke, 59*(11), 543-548. https://doi.org/10.1002/star.200700630
4. Ashogbon, A. O., & Akintayo, E. T. (2014). Recent trend in the physical and chemical modification of starches from different botanical sources: A review. *Starch-Stärke, 66*(1-2), 41-57. https://doi.org/10.1002/star.201300106
5. Ashtiani, S. H. M., Rafiee, M., Morad, M. M., Khojastehpour, M., Khani, M. R., Rohani, A., ..., & Martynenko, A. (2020). Impact of gliding arc plasma pretreatment on drying efficiency and physicochemical properties of grape. *Innovative Food Science & Emerging Technologies, 63*, 102381. https://doi.org/10.1016/j.ifset.2020.102381
6. Bahrami, R., Zibaei, R., Hashami, Z., Hasanvand, S., Garavand, F., Rouhi, M., ..., & Mohammadi, R. (2022). Modification and improvement of biodegradable packaging films by cold plasma; a critical review. *Critical Reviews in Food Science and Nutrition*. 62 (7), 1936- 1950. https://doi.org/10.1080/10408398.2020.1848790
7. Bassey, E. J., Cheng, J. H., & Sun, D. W. (2021). Novel nonthermal and thermal pretreatments for enhancing drying performance and improving quality of fruits and vegetables. *Trends in Food Science & Technology, 112*, 137-148. https://doi.org/10.1016/j.tifs.2021.03.045
8. Belitz, H. D., Grosch, W., & Schieberle, P. (2009). Coffee, tea, cocoa. *Food Chemistry*, 938-970.
9. Bertolini, A. (2009). *Starches: characterization, properties, and applications*: CRC Press.
10. Du, Y., Yang, F., Yu, H., Xie, Y., & Yao, W. (2022). Improving food drying performance by cold plasma pretreatment: A systematic review. *Comprehensive Reviews in Food Science and Food Safety, 21*(5), 4402-4421. https://doi.org/10.1111/1541-4337.13027
11. Gavahian, M., & Khaneghah, A. M. (2020). Cold plasma as a tool for the elimination of food contaminants: Recent advances and future trends. *Critical Reviews in Food Science and Nutrition, 60*(9), 1581-1592. https://doi.org/10.1080/10408398.2019.1584600
12. Gupta, R. K., Guha, P., & Srivastav, P. P. (2023). Effect of high voltage dielectric barrier discharge (DBD) atmospheric cold plasma treatment on physicochemical and functional properties of taro (*Colocasia esculenta*) starch. *International Journal of Biological Macromolecules, 253*, 126772. https://doi.org/10.1016/j.ijbiomac.2023.126772
13. Huber, K., & BeMiller, J. (2010). *Modified starch: Chemistry and properties. En: Starches: characterization, properties and applications*, (AC Bertolini ed.) Pp 145-204. In: CRC Press, Boca Raton, Fl.
14. Katsigiannis, A. S., Bayliss, D. L., & Walsh, J. L. (2022). Cold plasma for the disinfection of industrial food-contact surfaces: An overview of current status and opportunities. *Comprehensive Reviews in Food Science and Food Safety, 21*(2), 1086-1124. https://doi.org/10.1111/1541-4337.12885
15. Kaur, B., Ariffin, F., Bhat, R., & Karim, A. A. (2012). Progress in starch modification in the last decade. *Food Hydrocolloids, 26*(2), 398-404. https://doi.org/10.1016/j.foodhyd.2011.02.016
16. Li, S., Chen, S., Han, F., Xv, Y., Sun, H ,.Ma, Z., ..., & Wu, W. (2019). Development and optimization of cold plasma pretreatment for drying on corn kernels. *Journal of Food Science, 84*(8), 2181-2189. https://doi.org/10.1111/1750-3841.14708
17. Misra, N., & Martynenko, A. (2021). Multipin dielectric barrier discharge for drying of foods and biomaterials. *Innovative Food Science & Emerging Technologies, 70*, 102672. https://doi.org/10.1016/j.ifset.2021.102672
18. Motevali, A., Hashemi, S. J., & Keyani, R. (2023). Investigation of Thermodynamic Parameters and Essentioan

Oil Content in Drying of Rosemary by Applying a Microwave Pulsed Pretreatment. *Energy Engineering and Management*, *7*(2), 42-51. Retrieved from https://energy.kashanu.ac.ir/article_113413_49278afa381bdf6ff048e6d6c0b46d2a.pdf
19. Motevali, A., Minaei, S., Banakar, A., Ghobadian, B., & Khoshtaghaza, M. H. (2014). Comparison of energy parameters in various dryers. *Energy Conversion and Management*, *87*, 711-725. https://doi.org/10.1016/j.enconman.2014.07.012
20. Motevali, A., Minaei, S., & Khoshtagaza, M. H. (2011). Evaluation of energy consumption in different drying methods. *Energy Conversion and Management*, *52*(2), 1192-1199. https://doi.org/10.1016/j.enconman.2010.09.014
21. Motevali, A., Minaei, S., Khoshtaghaza, M. H., & Amirnejat, H. (2011). Comparison of energy consumption and specific energy requirements of different methods for drying mushroom slices. *Energy*, *36*(11), 6433-6441. https://doi.org/10.1016/j.energy.2011.09.024
22. Phillips, G. O. (1962). Radiation chemistry of carbohydrates. In *Advances in Carbohydrate Chemistry* (Vol. 16, pp. 13-58): Elsevier .https://doi.org/10.1016/S0096-5332(08)60258-1
23. Ranjbar Nedamani, A., & Hashemi, S. J. (2021). RSM-CFD modeling for optimizing the apricot water evaporation. *Journal of Food and Bioprocess Engineering*, *4*(2), 112-119. https://doi.org/10.22059/jfabe.2021.320809.1088
24. Ranjbar Nedamani, A., & Hashemi, S. J. (2022). Energy consumption computing of cold plasma-assisted drying of apple slices (Yellow Delicious) by numerical simulation. *Journal of Food Process Engineering*, *45*(5), e14019. https://doi.org/10.1111/jfpe.14019
25. Singh, J., Kaur, L., & McCarthy, O. (2007). Factors influencing the physico-chemical, morphological, thermal and rheological properties of some chemically modified starches for food applications—A review. *Food Hydrocolloids*, *21*(1), 1-22. https://doi.org/10.1016/j.foodhyd.2006.02.006
26. Sokhey, A., & Hanna, M. (1993). Properties of irradiated starches. *Food Structure*, *12*(4), 2.
27. Taghavi, A., Nedamani, A. R., Motevali, A., & Hashemi, S. J. (2025). Expanding the Application of Potato Starch in Diverse Food Products by Modifying Its Water Absorption, Swelling, and Solubility Through Pregelatinization–Cold Plasma Treatments. *Journal of Food Biochemistry*, *2025*(1), 6809100. https://doi.org/10.1155/jfbc/6809100
28. Thirumdas, R., Kadam, D., & Annapure, U. (2017). Cold plasma: An alternative technology for the starch modification. *Food Biophysics*, *12*, 129-139. https://doi.org/10.1007/s11483-017-9468-5
29. Thirumdas, R., Sarangapani, C., & Annapure, U. S. (2015). Cold plasma: a novel non-thermal technology for food processing. *Food Biophysics*, *10*, 1-11. https://doi.org/10.1007/s11483-014-9382-z
30. Vieira, M., Estrella, L., & Rocha, S. (2007). Energy efficiency and drying kinetics of recycled paper pulp. *Drying Technology*, *25*(10), 1639-1648. https://doi.org/10.1080/07373930701590806
31. Wu, Y., Cheng, J. H., & Sun, D. W. (2021). Blocking and degradation of aflatoxins by cold plasma treatments: Applications and mechanisms. *Trends in Food Science & Technology*, *109*, 647-661. https://doi.org/10.1016/j.tifs.2021.01.053
32. Zhang, K., Perussello, C. A., Milosavljević, V., Cullen, P., Sun, D.-W., & Tiwari, B. K. (2019). Diagnostics of plasma reactive species and induced chemistry of plasma treated foods. *Critical reviews in food science and nutrition*, *59*(5), 812-825. https://doi.org/10.1080/10408398.2018.1564731
33. Zhang, X.-L., Zhong, C.-S., Mujumdar, A. S., Yang, X.-H., Deng, L.-Z., Wang, J., & Xiao, H.-W. (2019). Cold plasma pretreatment enhances drying kinetics and quality attributes of chili pepper (*Capsicum annuum* L.). *Journal of Food Engineering*, *241*, 51-57. https://doi.org/10.1016/j.jfoodeng.2018.08.002
34. Zhou, Y.-H., Vidyarthi, S. K., Zhong, C.-S., Zheng, Z.-A., An, Y., Wang, J., ..., & Xiao, H.-W. (2020). Cold plasma enhances drying and color, rehydration ratio and polyphenols of wolfberry via microstructure and ultrastructure alteration. *Lwt*, *134*, 110173. https://doi.org/10.1016/j.lwt.2020.110173

Journal of Agricultural Machinery

Homepage: https://jame.um.ac.ir

Research Article
Vol. 16, No. 4, 2026, p. 653-668

Investigation of the Physicochemical Properties and Essential Oil Quality of Rosa Flower Buds under Different Drying Methods

O. R. Roustapour[1*], F. Sefidkon[2], A. Golshan Tafti[1], H. R. Gazor[1]

1- Agricultural Engineering Research Institute, Agricultural Research, Education and Extension Organization (AREEO), Karaj, Iran
2- Research Institute of Forests and Rangelands, Agricultural Research, Education and Extension Organization (AREEO), Tehran, Iran
(*- Corresponding Author Email: o.roostapour@areo.ir)

Received: 22 August 2025
Revised: 21 November 2025
Accepted: 07 January 2026
Available Online: 24 February 2026

How to cite this article:
Roustapour, O. R., Sefidkon, F., Golshan Tafti, A., & Gazor, H. R. (2026). Investigation of the Physicochemical Properties and Essential Oil Quality of Rosa Flower Buds under Different Drying Methods. *Journal of Agricultural Machinery*, *16*(4), 653-668. [in Persian]. https://doi.org/10.22067/jam.2026.94774.1418

Introduction

Rosa damascena Mill is a valuable cultivated plant, and for many years, essential oil has been produced from its flowers in Iran. The flower buds are generally dried by spreading them out in the shade or in the sun. Shade drying can lead to prolonged drying times, while sun drying may reduce product quality, affecting colour and essential oil. Therefore, in the current study, Rosa flower buds were dried using different drying processes and periods, and their physicochemical properties and essential oil quality were determined.

Materials and Methods

Rosa flower buds were collected from a farm located in Markazi province, Iran, in late May, 2024. Buds were dried using shade, a cabinet dryer (30 and 40 °C), an indirect solar dryer, a freeze-dryer, and a vacuum-dryer. Colour specifications (*Lab*) of the inner and outer petals of dried buds were measured by a colorimeter. Titratable acidity was determined by the titration method using 0.1 normal sodium hydroxide solution. Ascorbic acid was also measured by the titration method with 2 and 6 dichlorophenol indophenol. Experiments were carried out in three replications using a completely randomised design, and data were analysed using one-way ANOVA. Afterwards, the means of the data were compared using the Duncan test. The extraction of essential oil was applied by the water distillation method. After determining the essential oil yield, the compounds' percentages were identified using GC and GC-MS devices.

Results and Discussion

The results revealed that drying in shade took too long (more than 12 days), and the shortest drying time happened in the vacuum-dryer (18 hours). The maximum colour index (L^*) in the outer and inner petals of dried buds was observed in the freeze-dryer as 49.42 and 44.94, respectively. The maximum value of the a^* index of 25.61 was acquired in the outer petal buds, which were dried at 50 °C in the cabinet dryer. After the fresh buds, the a^* index of the inner petal buds was highest in the vacuum dryer at 16.62. The b^* index of the outer and inner petal buds dried in the cabinet dryer, solar dryer, shade, and vacuum dryer did not have any significant differences. The maximum titratable acidity value was related to buds dried in the solar dryer (2.3%), and the minimum was observed in the vacuum dryer (1.23%). In the cabinet dryer (40 and 50 °C), ascorbic acid of dried buds had the highest values (1.57 and 1.49 mg per 100 g wet matter) in comparison with the other treatments. The quality of the essential oil extracted from dried buds in shade was similar to that of fresh buds. After the shade drying method, the best quality of essential oil was observed in buds dried in the cabinet dryer at 40 °C

Authors retain the copyright. This is an open access article distributed under Creative Commons Attribution 4.0 International License (CC BY 4.0).

https://doi.org/10.22067/jam.2026.94774.1418

(30.4%).

Conclusion

Based on the results, applying vacuum-drying considerably shortened the drying period in comparison with shade drying. Lightness (*L*) is the most important specification that had the maximum value in outer and inner petals of buds dried in the freeze-dryer, and the least in the solar dryer. There were no significant differences between the lightness of inner petals of buds dried in shade and the two treatments of the cabinet dryer. Drying caused an increase in titratable acidity and a decrease in ascorbic acid of the flower buds. The maximum titratable acidity was depicted in buds dried by an indirect solar dryer, and the minimum was in the vacuum dryer. The flower buds dried in the cabinet dryer contained significantly higher levels of ascorbic acid compared to other drying methods. Cabinet drying at 50 °C yielded the highest amount of essential oil. The most aroma compounds and the lowest waxy compounds were observed in fresh buds, buds dried in shade, and buds which dried at 40 °C in the cabinet dryer, respectively.

Keywords: Chemical properties, Drying, Essential oil quality, Physical properties, Rosa flower bud

نشریه ماشین‌های کشاورزی
https://jame.um.ac.ir

مقاله پژوهشی
جلد ۱۶، شماره ٤، زمستان ۱٤۰۵، ص ٦٦۸-٦۵۳

بررسی خواص فیزیکی- شیمیایی و کیفیت اسانس غنچه گل محمدی در روش‌های مختلف خشک‌کردن

امیدرضا روستاپور[1*]، فاطمه سفیدکن[2]، ابوالفضل گلشن تفتی[1]، حمیدرضا گازر[1]

تاریخ دریافت: ۱۴۰۴/۰۵/۳۱
تاریخ پذیرش: ۱۴۰۴/۰۱/۱۷

چکیده

غنچه خشک گل محمدی فرآورده‌ای است که علاوه‌بر مصارف خوراکی برای گلاب‌گیری و تهیه اسانس استفاده می‌شود. به‌منظور دستیابی به روش مناسب خشک‌کردن غنچه، شش روش سایه خشک، خشک‌کن‌های خورشیدی غیرمستقیم، کابینتی (۴۰ و ۵۰ درجه سلسیوس)، انجمادی و تحت خلاء مورد ارزیابی قرار گرفتند. خواص فیزیکی و شیمیایی غنچه شامل رنگ، اسیدیته قابل‌تیتراسیون و ویتامین ث اندازه‌گیری شدند. اسانس‌گیری به‌روش تقطیر با آب و جداسازی و شناسایی ترکیب‌های اسانس پس از تعیین بازده انجام شد. با دستگاه‌های کروماتوگرافی گازی و متصل به طیف‌سنج جرمی، نوع و درصد اجزای اسانس‌ها تعیین شد. طبق نتایج، بیشترین شدت خشک شدن در خورشیدی غیرمستقیم و کمترین در روش سایه خشک می‌باشد. بیشترین مقدار ویتامین ث، در غنچه خشک‌شده در کابینتی (۴۰ و ۵۰) و کمترین در انجمادی و تحت خلاء بود. اسیدیته قابل‌تیتراسیون در غنچه خشک‌شده در خورشیدی غیرمستقیم دارای بیشترین و در تحت خلاء دارای کمترین مقدار بود. غنچه‌های خشک‌شده در سایه و کابینتی (۴۰ و ۵۰) بیشترین فنل کل را دارند. کمترین فنل به‌ترتیب در تحت خلاء، انجمادی و خورشیدی غیرمستقیم به‌دست آمد. بالاترین L^* گلبرگ‌های بیرونی و درونی، در روش‌های انجمادی و سپس تحت خلاء می‌باشد. بیشترین a^* در گلبرگ‌های بیرونی تحت روش کابینتی (۵۰) به‌دست آمد. این شاخص در گلبرگ‌های درونی غنچه‌ها تحت روش خلاء، بعد از غنچه تازه دارای بیشترین مقدار بود. کیفیت اسانس غنچه‌های سایه خشک تفاوت چندانی با غنچه‌های تازه نداشت. همچنین خشک‌کن کابینتی (۴۰) بعد از سایه خشک بهترین شرایط در کیفیت اسانس غنچه خشک ایجاد کرد.

واژه‌های کلیدی: خشک‌کردن، خواص شیمیایی، خواص فیزیکی، غنچه گل محمدی، کیفیت اسانس

مقدمه

گل محمدی (*Rosa damascene* Mill.)، گیاهی درختچه‌ای دائمی و متعلق به تیره رزاسیا[3] است. این گیاه یکی از پنج پایه اصلی رز در جهان است و سازگاری خوبی نسبت به شرایط محیطی به‌ویژه خشکی دارد. گل محمدی یک گیاه ارزشمند باغبانی است و از آن برای تولید گلاب و اسانس در ایران استفاده می‌شود. این گل علاوه بر ایران در کشورهای بلغارستان، سوریه، ترکیه، فرانسه، مراکش، تونس، ژاپن، اوکراین، هند، آمریکا و کانادا نیز کشت می‌شود. تاکنون ۵۶ گونه گل محمدی در ایران شناسایی شده است. در کشورهای تولیدکننده گل محمدی، سه گونه دامسنا، سِنتیفولیا و گالیسا برای استفاده از مواد مؤثره‌شان در صنایع غذایی و آرایشی و بهداشتی استفاده می‌شود (Mir, 2019; Yousefi, Tabaie Aghdaei, & Amiri, 2021).

فرآیند خشک کردن بعد از برداشت غنچه به‌منظور کاهش درصد رطوبت به زیر ۱۰ درصد به‌منظور فراهم آوردن شرایط ذخیره محصول، به‌کار گرفته می‌شود. خشک کردن بایستی در کمترین زمان به‌منظور جلوگیری از فساد غنچه گل محمدی و حفظ انرژی برای اهداف تجاری انجام شود (Brennan, 2003).

در حال حاضر درصد زیادی از غنچه‌های گل محمدی به

۱- موسسه تحقیقات فنی و مهندسی کشاورزی، سازمان تحقیقات، آموزش و ترویج کشاورزی، کرج، ایران
۲- موسسه تحقیقات جنگل‌ها و مراتع کشور، سازمان تحقیقات، آموزش و ترویج کشاورزی، تهران، ایران
(*- نویسنده مسئول: (Email: o.roostapour@areo.ir
https://doi.org/10.22067/jam.2026.94774.1418
3- Rosaceae

روش‌های مرسوم با پهن کردن در برابر آفتاب و یا پهن کردن در سایه خشک می‌شوند. خشک کردن در هوای آزاد باعث کاهش کیفیت محصول به علت نشست گرد و غبار و تردد جانوران و حشرات و نیز عدم دست‌یابی به استانداردهای ثابت کیفیت می‌شود (Khorramdel, Shabahang, & Asadi, 2013). با توجه به این‌که درصد رطوبت اولیه غنچه گل حدود ۷۵ درصد (بر پایه تر) می‌باشد و رطوبت نهایی غنچه حدود ۱۰ درصد است (Ebrahimi & Sharifzadeghan, 2016) لذا از هر یک تن غنچه تر حدود ۲۸۰ کیلوگرم غنچه خشک به‌دست آمده و ایجاد درآمد ناخالص بالا به‌ازای هر هکتار برای کشاورز می‌نماید. افزایش کیفیت غنچه خشک‌شده باعث افزایش قیمت غنچه ایران در بازار جهانی و بازار داخل و به تبع ارزش افزوده بالاتر خواهد شد. استفاده از روش‌های صحیح و مکانیزه خشک‌کردن، علاوه‌بر کاهش زمان خشک‌شدن، افزایش سطح کیفی محصول در راستای اهداف امنیت غذایی کشور را به دنبال خواهد داشت.

ترکیب اسانس گل محمدی تقطیرشده در فشارها و دماهای متفاوت در سطح نیمه‌صنعتی مورد مطالعه قرار گرفته است و اسانس حاصل از گل‌های تازه به‌وسیله GC-FID مورد تجزیه قرار گرفت. نتایج نشان داده که به‌طور کلی، درصد الکل‌ها (۸۳/۴۱– ۵۵/۲۵) در اسانس گل محمدی با افزایش فشار و دمای تقطیر افزایش پیدا می‌کند. اجزای اصلی اسانس گل محمدی از عصاره دی‌کلرومتانی و تقطیر مجدد گلاب در فشار اتمسفر و فشار بالاتر مورد بررسی قرار گرفت و از کاهش درصد الکل خالص نتیجه گرفته شد که تقطیر انجام‌شده در فشار بالاتر، اسانسی با کیفیت مناسب حاصل نمی‌کند اما اسانس استخراج‌شده با دی‌کلرو متان از گلاب، حاوی مقادیر بیشتری از ۲– فنیل اتیل الکل است (Babu, Singh, Joshi, & Singh, 2002).

مقایسه نمونه آزمایشگاهی و صنعتی اسانس گل محمدی از لحاظ کمیت وکیفیت ترکیب‌های عمده از منطقه کاشان نشان داد که ترکیب‌های عمده در اسانس صنعتی شامل فیتول (۳۹/۳ ٪)، هنی‌کوزان (۱۶/۵ ٪)، هگزادکان (۱۲/۵ ٪)، هپتادکان (۵/۹ ٪) و سیترونلول(۴/۱ ٪) می‌باشد. درحالی‌که ترکیب‌های عمده نمونه اسانس آزمایشگاهی نونادکان (۲۱ ٪)، سیترونلول (۲۰/۳ ٪)، ژرانیول (۱۹ ٪) و فنیل اتیل الکل (۱۸/۹ ٪) بودند (Rezaee, Jaimand, Tabaei- Aghdaei, & Barazandeh, 2003).

در یک تحقیق، اثر روش‌های مختلف خشک‌کردن آفتاب، سایه و آون ۳۰ و ۴۰ درجه سلسیوس بر کمیت و کیفیت اسانس گلبرگ‌های سه ژنوتیپ گل محمدی بررسی و اسانس کلیه نمونه‌ها به روش تقطیر با آب و استخراج به‌وسیله دستگاه‌های GC-MS و GC تجزیه و شناسایی شد. نتایج نشان داد که اسانس گلبرگ‌های تازه دارای بالاترین کیفیت (درصد بالای ژرانیول و سیترونلول و کمترین میزان ترکیبات مومی) است. همچنین اسانس حاصل از گلبرگ‌های خشک‌شده در سایه نسبت به اسانس حاصل از روش‌های دیگر از لحاظ میزان اسانس دارای تفاوت معنی‌داری نبوده ولی از لحاظ کیفیت دارای تفاوت چشمگیری است. بنابراین بهترین روش خشک‌کردن گل محمدی برای حفظ مقادیر بالاتری از اسانس و اجزای معطر، خشک کردن در سایه توصیه شد (Ahmadi, Sefidkon, & Assareh, 2008).

بیار و همکاران (Boyar, Bayhan, & Dikmen, 2013) ویژگی‌ها و رفتار خشک‌شدن گل محمدی در سایه را مورد بررسی قرار دادند. میانگین رطوبت اولیه گل‌ها ۷۹/۶ درصد (بر پایه تر) بود که پس از خشک‌شدن به ۷/۱۱ درصد (بر پایه تر) رسید. زمان خشک‌شدن گل محمدی بسته به شرایط آب و هوایی در محدوده ۷۲–۱۶۲ ساعت بود. طبق گزارش این پژوهشگران، در طی فرآیند خشک‌کردن گل محمدی در سایه، ویژگی‌های هیگروسکوپی گل محمدی مشاهده شد.گل محمدی به شدت تحت تأثیر دما و رطوبت هوا در طی فرآیند خشک‌کردن در سایه قرار داشت.

رائول و همکاران (Raol, Kumpavat, & Vyas, 2013) از خشک‌کن کابینتی با دماهای ۴۰، ۵۰ و ۶۰ درجه سلسیوس، مایکروویو با سلیکاژل در دمای ۵۰ درجه سلسیوس، خشک‌کن تحت خلاء در دمای ۴۰ درجه سلسیوس و فشار ۷۶۰ میلی‌متر جیوه، خشک‌کردن در سایه و در آفتاب برای خشک‌کردن غنچه کامل گل محمدی استفاده کردند. بیشترین زمان خشک‌کردن برای روش سایه (۵ روز) و کمترین زمان خشک‌کردن در روش مایکروویو (۱۳ دقیقه) حاصل شد. روش مایکروویو و سپس روش تحت خلاء بهترین روش‌های خشک‌کردن غنچه گل محمدی گزارش شدند. در خشک‌کن کابینتی ۴۰ درجه سلسیوس در طی مدت ۵ ساعت مقدار رطوبت از ۸۰ درصد (بر پایه تر) به ۲۹ درصد (بر پایه تر) کاهش یافت.

هنین و همکاران (Henin, Zhang, Ju, & Wang, 2021) گل سرخ خوراکی را با خشک‌کن هیبریدی مادون قرمز– تصعیدی طی شرایط مجهز به سامانه توزیع گاز ضربانی و بدون در نظرگرفتن این سامانه در سه سطح دمای ۵۰، ۶۰ و ۷۰ درجه سلسیوس خشک کردند. خشک‌کن هیبریدی مجهز به سامانه توزیع گاز باعث کاهش زمان خشک‌کردن (۳۰–۸ درصد) و انرژی مصرفی (۳۶–۱۵ درصد) نسبت به خشک‌کن تصعیدی (شاهد) شد. محصول نهایی خروجی از خشک‌کن تصعیدی دارای بیشترین روشنایی (L) و کمترین قرمزی (a) بود و شرایط بهتری را نسبت به خشک‌کن هیبریدی داشت.

در فرآیند خشک کردن غنچه گل محمدی حفظ عطر و بو، اسانس، کیفیت ظاهری و رنگ مخصوصاً رنگ غنچه در هسته مرکزی به‌منظور تولید محصول با ارزش افزوده بالا، بازارپسندی و صادرات ضروری است. غنچه گل محمدی با خشک‌کن‌های مختلف

شامل کابینتی در دماهای ۴۰ و ۵۰ درجه سلسیوس، خورشیدی غیرمستقیم، تحت خلاء و انجمادی و با پهن کردن در سایه خشک شدند و مدت زمان خشک شدن، خواص فیزیکی- شیمیایی و کیفیت اسانس مورد بررسی قرار گرفتند.

مواد و روش‌ها

غنچه‌های گل محمدی (*Rosa damascene* Mill.) از اواخر اردیبهشت ماه تا اواسط خرداد ماه ۱۴۰۳ از مزرعه گل محمدی واقع در استان مرکزی، بخش خرقان، روستای منجیقان به مختصات جغرافیایی ۳۵ درجه و ۲۱ دقیقه و ۴۷ ثانیه شمالی و ۴۹ درجه و ۵۰ دقیقه و ۲۰ ثانیه شرقی، در ساعات اولیه صبح از زیر نهنج جدا شده و بلافاصله به آزمایشگاه منتقل شدند. در آزمایشگاه، غنچه‌های سالم، عاری از هرگونه آفت و بدون علائم آسیب‌دیدگی و کبودی، برای خشک‌کردن با روش‌های مختلف انتخاب شدند (شکل ۱). رطوبت اولیه غنچه‌ها با قرار دادن نمونه‌ها در آون اتمسفریک در دمای ۷۰ درجه سلسیوس و به مدت ۲۴ ساعت حدود ۷۰ درصد بر پایه تر به‌دست آمد (Anon, 1990).



شکل ۱- غنچه‌های گل محمدی جمع‌آوری‌شده

Fig.1. Collected Rosa flower buds

روش‌های خشک کردن غنچه گل محمدی

در این تحقیق شش تیمار خشک‌کردن شامل خشک کردن در سایه، خشک‌کن خورشیدی غیرمستقیم، خشک‌کن کابینتی با جریان هوای اجباری در دماهای ۴۰ و ۵۰ درجه سلسیوس، خشک‌کن تحت خلاء و خشک‌کن تصعیدی برای خشک‌کردن غنچه گل محمدی در شهرستان کرج مورد استفاده و بررسی قرار گرفت. انتخاب دما در خشک‌کردن غنچه گل محمدی که دارای بافت حساسی می باشد بسیار مهم است. دمای بالا باعث تخریب بافت غنچه، تغییر رنگ شدید هسته مرکزی و از بین رفتن ترکیبات مفید اسانس خواهد شد. از طرفی دمای کم هم باعث طولانی‌شدن فرآیند و آسیب به ترکیبات فنلی و آنتوسیانین خواهد شد لذا انتخاب مناسب دما و زمان در فرآیند خشک‌کردن غنچه ضروری است. در یک پروژه تحقیقاتی سه سطح دمایی ۴۰، ۵۰ و ۶۰ درجه سلسیوس برای خشک کن کابینتی در نظر گرفته شده است (Roustapour *et al.*, 2024)، منتهی در دمای ۶۰ درجه سلسیوس ترکیبات فنلی و همچنین ترکیبات مفید اسانس به شدت کاهش یافته است. بنابراین کاربرد دماهای بالای ۵۰ درجه سلسیوس در خشک‌کن کابینتی برای خشک‌کردن غنچه گل محمدی مناسب نیست. ترکیب مناسب دما و زمان خشک‌شدن در حفظ ترکیبات فنلی و اسانس ضروری است لذا برای دستیابی به بهترین شرایط فرآیند، دو سطح دمایی یادشده انتخاب گردید. (Bhardwaj, Chauhan, Kumar, & Sethi, 2017; Henin *et al.*, 2021; Zheng, Xia, & Lu, 2015).

لازم به‌ذکر است برای تمام روش‌های آزمایش عملیات خشک کردن غنچه تا محدوده رطوبتی ۱۲ تا ۱۴درصد بر پایه انجام شد (Ebrahimi & Sharifzadeghan, 2016). سپس با در نظر گرفتن زمان استراحت و هم‌دمایی نمونه‌ها با محیط پارامترهای کیفی بررسی و اندازه‌گیری شد.

در روش سایه خشک، غنچه‌های گل روی یک سطح پارچه‌ایی گسترده در محیط باز (سایه) با متوسط دمای ۲۲ درجه سلسیوس پهن و فرآیند خشک کردن آن طی ۳ تکرار انجام شد. مدت زمان خشک شدن غنچه ۲۹۸ ساعت بود.

خشک‌کن خورشیدی غیرمستقیم[1] دارای یک واحد جمع‌کننده[2] مشتمل بر یک صفحه جاذب به رنگ سیاه بوده که تابش آفتاب را دریافت و گرم می‌شود. هوای گرم توسط یک فن مکنده به داخل

1- Indirect solar dryer
2- Collector

محفظه شامل سینی‌هایی که غنچه‌های گل محمدی بر روی آن‌ها پهن شده‌اند، جریان می‌یابد. خشک‌کن خورشیدی مورد استفاده توسط روستاپور و همکاران (Roustapour *et al.*, 2016) در مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی فارس طراحی و ساخته شده است. در این خشک‌کن عبور جریان هوای گرم از زیر سینی‌ها، باعث تبخیر رطوبت و خشک‌شدن محصول می‌شود. متوسط دمای هوای محیط اطراف خشک‌کن ۲۵ درجه سلسیوس به‌دست آمد. مدت زمان خشک شدن غنچه‌ها در این خشک‌کن ۴۸ ساعت بود.

خشک‌کن کابینتی مورداستفاده از نوع جریان متقاطع با منبع تامین حرارت گرم‌کن برقی و جریان هوای اجباری توسط فن دمنده می‌باشد. سرعت جریان خروجی هوا از خشک‌کن ۱ متر بر ثانیه در نظر گرفته شد. مدت زمان خشک کردن غنچه‌ها در خشک‌کن کابینتی در دو سطح دمایی ۴۰ و ۵۰ درجه سلسیوس به‌ترتیب ۵۴ و ۳۸ ساعت بود. خشک‌کن انجمادی[1] استفاده شده مدل FD-8505/FD-5005-HS-BT ساخت شرکت دنا با حجم ۵ لیتر و دارای پمپ خلاء با فشار خلاء ۰/۰۰۰۵ میلی‌متر جیوه بود. نمونه‌های غنچه گل محمدی ابتدا به‌منظور انجماد عمیق[2] به مدت ۲ ساعت در فریزر با دمای ۷۰- درجه سلسیوس قرار داده شدند. در ادامه، نمونه‌ها سریعاً به خشک‌کن تصعیدی انتقال یافته و تحت فرآیند تصعید در دمای ۵۰ درجه سلسیوس و خلاء کمتر از ۴/۵۸ میلی‌متر جیوه قرار گرفتند. در این دستگاه ابتدا آب درون ماده یخزده در دمای صفر درجه سلسیوس شروع به تصعید نمود. سپس به‌تدریج با تجمع بخار، فشار از ۴/۵۸ میلی‌متر جیوه افزایش یافت و نمونه‌های غنچه در مدت زمان ۶۴ ساعت خشک شدند. خشک‌کن تحت خلاء استفاده شده ساخت بخش بیوسیستم دانشگاه فردوسی مشهد و دارای پمپ خلاء با توان ۰/۵۵ کیلووات و با مکش ۵- میلی‌بار بود. نمونه غنچه‌های گل محمدی بر روی سینی خشک‌کن پهن شده و در دمای ورودی ۵۰ درجه سلسیوس تحت فرآیند خشک‌شدن قرار گرفتند. فرآیند خشک کردن غنچه‌ها در مدت زمان ۱۸ ساعت انجام شد. برای بررسی تغییرات رطوبت محصول در تمامی روش‌های خشک شدن، توزین نمونه‌ها هر ۳ ساعت یکبار توسط ترازوی دیجیتال AND ژاپن با دقت ۰/۰۱ گرم انجام شد.

تعیین خواص کیفی غنچه گل محمدی قبل و پس از خشک‌کردن

تغییر رنگ غنچه خشک‌شده در سطح رویه و لایه داخلی به‌عنوان یکی از خواص فیزیکی در سیستم CIE Lab تعیین خواهد شد. رنگ با ۳ ویژگی روشنایی (L)، میزان قرمزی (a) و زردی (b) بیان می‌شود. میزان روشنایی بین صفر تا ۱۰۰ متغیر است که عدد صفر معرف تاریکی و ۱۰۰ معرف روشنایی است. میزان قرمزی بین a^- تا a^+ متغیر بوده که a^+ نشانگر قرمزی و a^- نشانگر سبزی است. زردی با b^+ و رنگ آبی با b^- مشخص می‌شود (Yam & Papadakis, 2004).

رنگ گلبرگ‌های درونی و بیرونی غنچه گل محمدی با دستگاه رنگ‌سنج (مدل DP- 25– 9000 ساخت شرکت Hunterlab آمریکا) قبل و بعد از فرآیند خشک‌کردن اندازه‌گیری شد. همچنین تغییرات رنگ کلی که نشان‌دهنده تغییرات رنگ گلبرگ‌های بیرونی و درونی غنچه گل بعد از خشک‌کردن به روش‌های مختلف نسبت به غنچه تازه است، طبق رابطه (۱) محاسبه و مورد بررسی قرار گرفت (Santos-Sa´nchez *et al.*, 2012).

$$\sqrt{(L_0 - L_t)^2 + (a_0 - a_t)^2 + (b_0 - b_t)^2} \quad (۱)$$

اسیدیته قابل‌تیتراسیون (بر حسب اسید سیتریک) با روش تیتراسیون و استفاده محلول سود ۰/۱ نرمال اندازه‌گیری شد. نتایج بر حسب درصد سیتریک اسید محاسبه و گزارش شد. مقدار ویتامین ث (اسید آسکوربیک) با روش تیتراسیون با ۲ و ۶ دی‌کلروفنل ایندوفنل اندازه‌گیری و مقدار آن بر حسب میلی‌گرم در صد گرم ماده تر بیان شد (Mabellinia *et al.*, 2011).

استخراج، جداسازی و شناسایی ترکیب‌های اسانس

برای هر اسانس‌گیری، ابتدا درصد رطوبت نمونه‌های خشک‌شده با قرار دادن در آون تعیین شد. سپس ۲۰۰ تا ۳۰۰ گرم غنچه تازه و ۸۰ تا ۱۰۰ گرم غنچه خشک به‌دست‌آمده از هر تیمار به مدت ۲ ساعت به روش تقطیر با آب اسانس‌گیری شد. اسانس‌گیری از هر تیمار، در ۳ تکرار صورت گرفت. ضمن تعیین بازده اسانس و به‌عبارتی میزان اسانس بر حسب گرم در ۱۰۰ گرم گیاه، نمونه‌هایی از مخلوط تکرارها برای هر تیمار جهت شناسایی ترکیبات آن‌ها برای آنالیز دستگاهی انتخاب شدند. تعیین ترکیبات اسانس با دستگاه GC-MS و GC صورت گرفت. پس از تزریق نمونه‌های اسانس به دستگاه گاز کروماتوگراف (GC) و یافتن مناسب‌ترین برنامه‌ریزی حرارتی ستون جهت دستیابی به بهترین جداسازی، اسانس‌های حاصله با دی‌کلرومتان رقیق شد و به دستگاه گازکروماتوگراف متصل شده با طیف‌سنج جرمی (GC-MS) تزریق و طیف‌های جرمی و کروماتوگرام‌های مربوطه به‌دست آمد. سپس با استفاده از زمان بازداری، شاخص بازداری کواتس، مطالعه طیف‌های جرمی و مقایسه با ترکیب‌های استاندارد و استفاده از اطلاعات موجود در نرم‌افزار SATURN، ترکیب‌های تشکیل‌دهنده اسانس‌ها مورد شناسایی کمی و کیفی قرار گرفت (Shahverdi, Sefidkon, Jamzad, & Nejhadsattari, 2012). دستگاه کروماتوگرافی گازی فوق سریع دارای ستون H-۵ (به طول ۱۰ متر، قطر داخلی ۰/۱ میلی‌متر و

1- Freeze dryer
2- Deep freezing

ضخامت فاز ساکن ۰/۴ میکرومتر) بود. دمای اولیه، ۶۰ درجه سلسیوس (با زمان نگهداری ۳ دقیقه) و در نهایت با افزایش ۸۰ درجه سلسیوس دما در هر دقیقه به دمای نهایی ۲۸۰ درجه سلسیوس رسید. از گاز حامل هلیوم با درجه خلوص ۹۹/۹۹۹ با حرکت در طول ستون با سرعت ۳۲ سانتی‌متر بر ثانیه استفاده شد. گاز کروماتوگراف متصل به طیف‌سنج جرمی مجهز به ستون DB-۵ به طول ۳۰ متر و قطر ۰/۲۵ میلی‌متر و ضخامت لایه فاز ساکن در آن ۰/۲۵ میکرومتر بود. برنامه‌ریزی حرارتی ستون GC-MS از ۲۴۰-۴۰ درجه سلسیوس با سرعت افزایش دمای ۳ درجه سلسیوس در دقیقه بود. دمای محفظه تزریق ۱۰ درجه بیشتر از دمای نهایی ستون تنظیم شد و گاز حامل، هلیوم با سرعت ۳۱/۵ سانتی‌متر بر ثانیه در طول ستون حرکت می‌کرد. زمان اسکن برابر یک ثانیه، انرژی یونیزاسیون ۷۰ الکترون ولت و ناحیه جرمی از ۴۰ تا ۳۴۰ بود.

تجزیه و تحلیل آماری

آزمایش‌ها در قالب طرح کاملاً تصادفی با ۳ تکرار اجرا شد. داده‌ها با نرم‌افزار SPSS مورد تجزیه واریانس یک‌طرفه قرار گرفتند و میانگین داده‌ها با آزمون چند دامنه‌ای دانکن در سطح اطمینان ۹۵ درصد با هم مقایسه شدند.

نتایج و بحث

خشک کردن غنچه گل محمدی

همان‌طور که بیان شد خشک‌کردن غنچه طی شش تیمار سایه-خشک، خشک‌کن خورشیدی غیرمستقیم، خشک‌کن کابینتی در دو سطح دمایی ۴۰ و ۵۰ درجه سلسیوس، خشک‌کن انجمادی و خشک‌کن تحت خلاء تا رسیدن رطوبت نمونه‌ها از رطوبت اولیه حدود ۷۳ درصد بر پایه تر به رطوبت نهایی ۱۲ تا ۱۴ درصد بر پایه تر انجام شد. بر اساس نتایج، بیشترین زمان فرآیند در روش مرسوم سایه خشک معادل ۱۲ روز و ۱۰ ساعت حاصل شد. همچنین در روش‌های مکانیزه خشک‌کردن، بیشترین زمان فرآیند در خشک‌کن انجمادی (۶۴ ساعت) و کمترین زمان در خشک‌کن تحت‌خلاء (۱۸ ساعت) به‌دست آمد (شکل ۲). استفاده از فشار منفی هوا باعث خروج سریع‌تر رطوبت از محصول خواهد شد لذا زمان خشک شدن در خشک‌کن تحت خلاء از بقیه روش‌ها کمتر است. در خشک‌کن خورشیدی غیرمستقیم با توجه به این‌که دما در سطح محصول در حداکثر دمای هوای محیط تا ۵۷ درجه سلسیوس می‌رسد و متوسط دمای هوا در این خشک‌کن ۴۴ درجه سلسیوس بوده است لذا زمان خشک‌شدن محصول نسبت به خشک‌کن کابینتی در دمای ۴۰ درجه سلسیوس کمتر شده است (۳۷/۵ درجه سلسیوس)، در حالی‌که زمان خشک شدن محصول نسبت به خشک‌کن کابینتی در دمای ۵۰ درجه سلسیوس بیشتر است. در خشک‌کن تصعیدی با توجه به این‌که ابتدا بایستی یخ موجود در محصول تبخیر شود و فرآیند خشک کردن شامل دو مرحله ثابت و نزولی می‌باشد لذا زمان فرآیند نسبت به دیگر روش‌ها بیشتر بوده است (Roustapour *et al.*, 2024).

خصوصیات فیزیکی و شیمیایی غنچه تازه گل محمدی

میانگین خصوصیات فیزیکی غنچه تازه گل محمدی در جدول ۱ آورده شده است. مابلینی و همکاران (Mabellinia *et al.*, 2011)، وزن گل محمدی در دو منطقه از ترکیه را به‌ترتیب ۱/۵۸ و ۱ گرم و در سه منطقه از آرژانتین، به‌ترتیب ۱/۱۰، ۱/۹۴ و ۲/۱۱ گرم گزارش کردند.

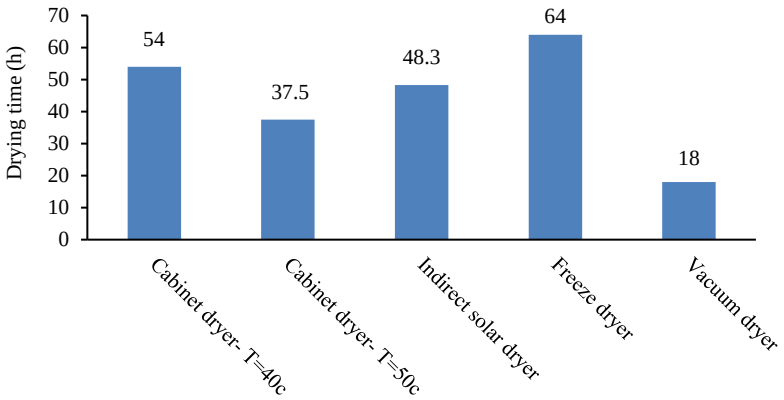

شکل ۲- زمان خشک‌شدن غنچه‌های گل محمدی در روش‌های مختلف خشک کردن

Fig.2. Drying time of flower buds using different drying methods

ویژگی‌های کیفی غنچه تازه گل محمدی، در جدول ۲ نشان داده شده است. به‌هرحال، گونه‌های گل رز منبع خوبی از ویتامین ث، اسانس‌های روغنی، کارتنوئیدها و ترکیبات آنتی‌اکسیدانی هستند که مقدار آن‌ها در هر گونه به عواملی از جمله زمان برداشت، درجه رسیدگی و شرایط آب و هوایی منطقه رشد بستگی دارد.

جدول ۱- میانگین صفات فیزیکی غنچه‌های تازه گل

Table 1- Mean physical properties of fresh flower buds

وزن Weight (g)	طول Length (mm)	قطر Diameter (mm)	رنگ Colour		
			*b**	*a**	*L**
1.18	21.82	12.43	-4.69	41.44	43.93

جدول ۲- میانگین ترکیب شیمیایی غنچه‌های تازه گل

Table 2- Mean chemical components of fresh flower buds

رطوبت (بر پایه تر) Moisture (w.b.) (%)	pH	ویتامین ث Vitamin C (mg/100g wet matter)	اسیدیته قابل‌تیتراسیون Titratable acidity
70	5.58	2.02	0.67

تأثیر روش‌های خشک‌کردن بر خصوصیات فیزیکی و شیمیایی غنچه گل محمدی

نتایج تجزیه واریانس اثر روش‌های خشک‌کردن بر خواص فیزیکی (رنگ) غنچه گل محمدی در جدول ۳ آورده شده است. روش‌های مختلف خشک‌کردن، اثر معنی‌داری بر تغییرات رنگ غنچه گل محمدی در سطح احتمال یک‌دهم درصد داشتند.

جدول ۳- تجزیه واریانس اثر روش‌های خشک‌کردن بر شاخص‌های رنگ گلبرگ‌های تازه و خشک بیرونی و درونی غنچه‌های گل

Table 3- Analysis of Variance of the effect of drying methods on the colour indices of the inner and outer petals of fresh and dried flower buds

منابع تغییر Source of variation	df	میانگین مربعات Mean squares					
		شاخص‌های رنگ گلبرگ‌های درونی Colour indices of inner petals			شاخص‌های رنگ گلبرگ‌های بیرونی Colour indices of outer petals		
		*b**	*a**	*L**	*b**	*a**	*L**
روش خشک‌کردن Drying method	5	190.731**	236.246**	24.512**	36.543**	187.084**	46.826**
خطا Error	18	7.044	3.621	3.013	8.080	5.213	2.253

**: اختلاف معنی‌دار در سطح احتمال یک درصد

** Significant difference at 1% level

در جدول ۴ مقادیر شاخص‌های رنگ در گلبرگ‌های بیرونی و درونی غنچه گل محمدی تازه و خشک‌شده طی فرآیندهای مختلف نشان داده شده است. بالاترین میزان شاخص *L در گلبرگ‌های بیرونی مربوط به غنچه‌های خشک‌شده با روش انجمادی معادل با ۴۹/۴۲ است که با غنچهٔ تازه و دیگر نمونه‌ها اختلاف معنی‌داری دارد. این شاخص در گلبرگ‌های درونی غنچه‌های خشک‌شده با روش انجمادی معادل با ۴۴/۹۴ و نسبت به دیگر روش‌های خشک‌کردن بالاتر است ولی با غنچه تازه (۴۴/۰۵) اختلاف معنی‌داری ندارد. این شاخص در گلبرگ‌های درونی غنچه‌های خشک‌شده با دیگر روش‌ها (به‌جز انجمادی) اختلاف معنی‌داری نشان نمی‌دهد. شاخص *a در گلبرگ‌های بیرونی غنچه تازه برابر ۴۱/۴۴ است. بیشترین میزان این شاخص پس از غنچه‌های تازه در گلبرگ‌های بیرونی غنچه‌های خشک‌شده با روش هوای گرم ۵۰ درجه سلسیوس (۲۵/۶۱) مشاهده شده است. این شاخص در گلبرگ‌های درونی غنچه‌های خشک‌شده با روش‌های تحت خلاء (۱۶/۶۲)، سایه (۱۵/۹۰)، هوای گرم ۵۰ درجه سلسیوس (۱۵/۴۸) و هوای گرم ۴۰ درجه سلسیوس (۱۴/۴۰) بعد از

غنچهٔ تازه بیشترین است و اختلاف معنی‌داری در این روش‌ها نشان نمی‌دهد. احتمالاً زمان خشک‌شدن طولانی در روش انجمادی در کاهش شاخص a* (قرمزی) در گلبرگ‌های بیرونی و درونی غنچه‌های خشک‌شده مؤثر بوده است. شاخص b* در گلبرگ‌های بیرونی غنچه تازه گل محمدی برابر ۴/۷۰- است که به‌طور معنی‌داری کمتر از غنچه‌های خشک‌شده با روش‌های مختلف خشک‌کردن است. کمترین مقدار شاخص b* در غنچه‌های خشک (۱/۰۸-)، مربوط به نمونه‌های خشک‌شده با روش هوای گرم ۵۰ درجه سلسیوس است که نشان‌دهنده رنگ زرد کمتر این غنچه‌های خشک است. به‌طورکلی، کاهش شاخص L* بیانگر تیره‌شدن رنگ نمونه‌های خشک است. افزایش ضخامت لایهٔ محصول در خشک‌کن، دمای بالا و طولانی بودن زمان خشک‌شدن در کاهش این شاخص مؤثر است (Roozdar, Azizi, Ghani, & Davarynejad, 2014). در پژوهشی دیگر گزارش شده است گلبرگ‌های خشک‌شده گل محمدی در خشک‌کن هوای گرم با دمای ۵۵ درجه سلسیوس، نسبت به نمونه‌های خشک‌شده در دمای ۲۵ درجه سلسیوس، دارای رنگ روشن‌تری هستند و با افزایش زمان خشک‌شدن، رنگ گلبرگ‌های گل محمدی تیره‌تر می‌شود (Ziolhagh, Babakhanzadeh Sajirani, & Hosseini, 2022).

جدول ٤- مقایسه میانگین اثر روش خشک‌کردن بر شاخص‌های رنگ و تغییرات کلی رنگ گلبرگ‌های غنچه گل

Table 4- Mean comparison of the effect of various drying methods on the colour indices of the flower bud petals

تیمار Treatment	شاخص رنگ Colour specification							
	گلبرگ‌های درونی Inner petals				گلبرگ‌های بیرونی Outer petals			
	ΔE	b*	a*	L*	ΔE	b*	a*	L*
غنچه تازه Fresh bud	-	-2.45 ^{d}	38.30 ^{a}	44.05 ^{ab}	-	-4.7 ^{c}	41.44 ^{a}	43.93^{b}
غنچه خشک- سایه خشک Dried bud- Shade drying	26.76	2.76 ^{c}	15.90 ^{b}	41.02 ^{bc}	24.20	0.31 ^{bc}	18.32 ^{de}	38.82^{cd}
غنچه خشک- خشک‌کن انجمادی Dried bud- Freeze dryer	37.55	17.0 ^{a}	10.80 ^{c}	44.94 ^{a}	26.71	2.76 ^{ab}	16.38 ^{e}	49.42 ^{a}
غنچه خشک- خشک‌کن تحت خلاء Dried bud- Vacuum dryer	25.91	2.74^{c}	16.62^{b}	44.08^{ab}	21.30	0.92^{b}	21.06^{cd}	41.32^{c}
غنچه خشک- خشک‌کن کابینتی ۴۰ درجه سلسیوس Dried bud- Cabinet dryer at 40 °C	31.51	10.76 ^{b}	14.40 ^{b}	39.14 ^{c}	28.27	7.57 ^{a}	16.43 ^{e}	39.05^{cd}
غنچه خشک- خشک‌کن کابینتی ۵۰ درجه سلسیوس Dried bud- Cabinet dryer at 50 °C	29.07	7.64 ^{b}	15.48 ^{b}	39.57 ^{c}	17.80	-1.08 ^{bc}	25.61 ^{b}	36.64 ^{d}
غنچه خشک- خشک‌کن خورشیدی غیرمستقیم Dried bud- Indirect solar dryer	39.53	17.89 ^{a}	9.95 ^{c}	36.12 ^{d}	18.33	0.21 ^{cb}	24.64 ^{bc}	38.47 ^{d}

در هر ستون، میانگین‌ها با حروف مشابه اختلاف معنی‌داری با یکدیگر ندارند (α=٪۵)

In every column, there is no significant difference between mean data with similar alphabet letters (α = 5%)

جدول ۵- تجزیه واریانس اثر روش‌های خشک‌کردن بر خواص شیمیایی گلبرگ‌های تازه و خشک غنچه گل

Table 5- Analysis of Variance of the effect of drying methods on the chemical properties of the fresh and dried flower bud petals

منابع تغییر Source of variation	df	میانگین مربعات Mean squares	
		ویتامین ث Vitamin C	اسیدیته قابل‌تیتراسیون Titratable acidity
روش خشک‌کردن Drying method	5	0.402**	0.633**
خطا Error	18	0.006	0.024

**: اختلاف معنی‌دار در سطح احتمال یک درصد

** Significant difference at 1% level

نتایج تجزیه واریانس اثر روش‌های خشک‌کردن بر خواص شیمیایی غنچه گل محمدی شامل اسیدیته قابل‌تیتراسیون و ویتامین ث در جدول ۵ آورده شده است.

کمترین مقدار اسیدیته قابل‌تیتراسیون به‌ترتیب در روش‌های خشک‌کردن تحت خلاء (۱/۲۳ درصد)، خشک‌کن هوای گرم با دمای ۴۰ درجه سلسیوس (۱/۳۸ درصد)، سایه (۱/۴۲ درصد) و خشک‌کن هوای گرم با دمای ۵۰ درجه سلسیوس (۱/۴۳ درصد) مشاهده شد که البته اختلاف معنی‌داری با یکدیگر نداشتند. بیشترین اسیدیته قابل‌تیتراسیون (۲/۳) در نمونه‌های خشک‌شده در خشک‌کن خورشیدی غیرمستقیم به‌دست آمد (شکل ۳). کلیه روش‌های خشک‌کردن، مقدار ویتامین ث را در غنچه‌های گل محمدی به‌طور معنی‌داری کاهش دادند. غنچه‌های خشک‌شده در خشک‌کن کابینتی با دماهای ۴۰ و ۵۰ درجه سلسیوس به‌ترتیب با مقادیر ۱/۵۷ و ۱/۴۹ میلی‌گرم در صد گرم ماده تر به‌طور معنی‌داری مقدار ویتامین ث بیشتری را دارا بودند (شکل ۴). روش خشک‌کردن در سایه و روش خورشیدی غیرمستقیم به‌ترتیب با مقدار ویتامین ث ۱/۲۴ و ۱/۱۴ میلی‌گرم در صد گرم ماده تر در رتبه‌های بعدی قرار داشتند. دما و زمان خشک‌کردن بر مقدار ویتامین ث در نمونه‌های گل محمدی تأثیر دارند (Mabellinia *et al.*, 2011). زمان طولانی خشک‌کردن در خشک‌کن انجمادی (۶۴ ساعت) سبب کاهش معنی‌دار ویتامین ث در نمونه‌های خشک گل محمدی شده است. در دمای پایین خشک‌کردن در خشک‌کن تحت خلاء، نیز احتمالاً تجزیه آنزیمی ویتامین ث در کاهش مقدار آن در نمونه‌های خشک گل محمدی مؤثر بوده است.

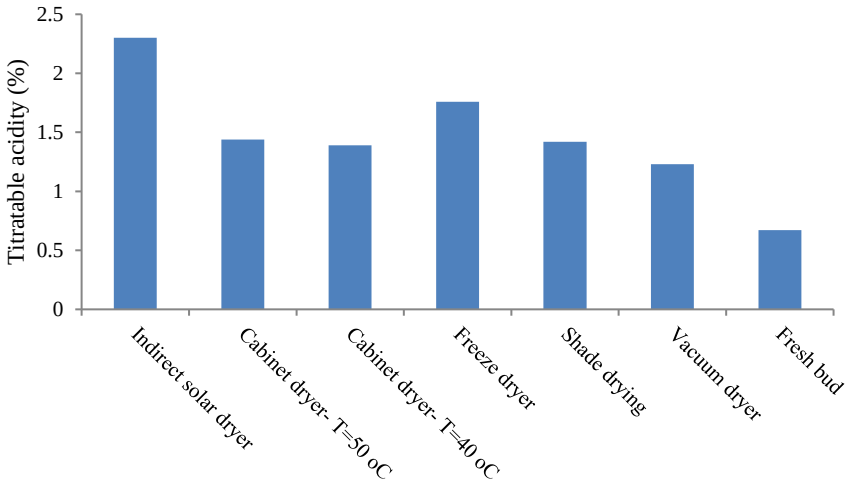

شکل ۳- اثر روش‌های خشک‌کردن بر مقدار اسیدیته قابل‌تیتراسیون گلبرگ‌های غنچه گل محمدی

Fig.3. Effect of drying methods on titratable acidity of the flower bud petals

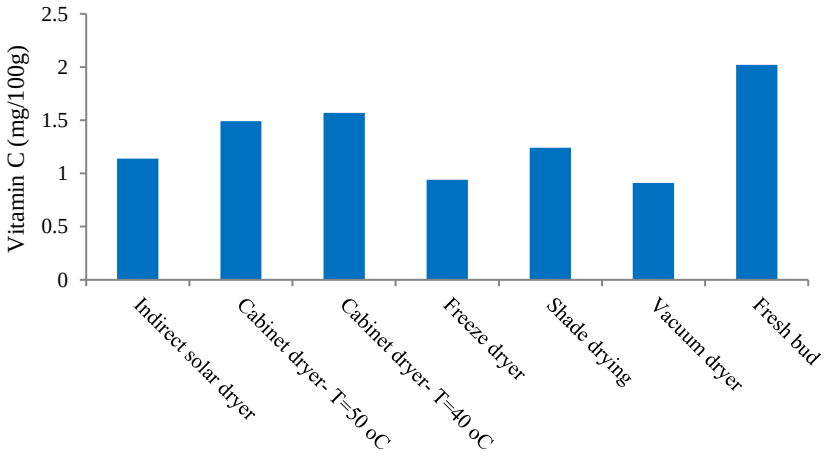

شکل ٤- اثر روش‌های خشک‌کردن بر مقدار ویتامین ث گلبرگ‌های غنچه گل محمدی

Fig. 4. Effect of drying methods on vitamin C of the flower bud petals

آنالیز و تعیین بازده اسانس

بازده اسانس نمونه‌های غنچه تازه و خشک‌شده گل محمدی طی شش تیمار روش خشک کردن در جدول ۶ نشان داده شده است. میانگین بازده اسانس غنچه‌های خشک گل محمدی در روش‌های مختلف خشک‌کردن بین ۰/۰۱۷ تا ۰/۰۳۴ درصد متغیر است. بازده اسانس غنچه تازه نیز ۰/۰۲۲ درصد است بالاترین بازده اسانس متعلق به غنچه‌هایی است که در خشک‌کن کابینتی در دمای ۵۰ درجه خشک شده‌اند و کمترین بازده اسانس مربوط به خشک‌کردن نمونه در خشک‌کن انجمادی است.

جدول ٦- بازده اسانس نمونه‌های غنچه گل محمدی

Table 6- Essential oil yield of Rosa flower bud samples

تیمار Treatment	وزن نمونه Sample weight (g)	بازده اسانس Essential oil yield (g/100g wet matter)
غنچه تازه Fresh bud	492	0.022
غنچه خشک- سایه خشک Dried bud- Shade drying	230	0.028
غنچه خشک- خشک‌کن کابینتی ۴۰ درجه سلسیوس Dried bud- Cabinet dryer at 40 °C	170	0.027
غنچه خشک- خشک‌کن کابینتی ۵۰ درجه سلسیوس Dried bud- Cabinet dryer at 50 °C	175	0.034
غنچه خشک- خشک‌کن تحت خلاء Dried bud- Vacuum dryer	157	0.026
غنچه خشک- خشک‌کن انجمادی Dried bud- Freeze dryer	213	0.017
غنچه خشک- خشک‌کن خورشیدی غیرمستقیم Dried bud- Indirect solar dryer	206	0.022

جداسازی و شناسایی ترکیب‌های تشکیل‌دهنده عصاره‌های مطلق

نتایج به‌دست‌آمده از تجزیه و شناسایی ترکیب‌های تشکیل‌دهنده اسانس در هر یک از نمونه‌های مورد بررسی به‌وسیله دستگاه‌های GC و GC-MS در جداول ۷ الی ۹ مشاهده می‌شود. شناسایی کیفی با استفاده از طیف‌های جرمی به‌دست‌آمده از دستگاه GC-MS و مقایسه این طیف‌ها با طیف‌های موجود در کتابخانه کامپیوتری و با کمک گرفتن از شاخص بازداری محاسبه‌شده از طیف‌های GC به‌دست آمده و مقایسه آن با شاخص‌های موجود در کتب مرجع و مقالات صورت گرفت. نتایج حاصل از هر نمونه اسانس ارائه شده است.

در اسانس حاصل از غنچه‌های تازه گل محمدی، ۱۷ ترکیب شناسایی شد که از بین آن‌ها سیترونلول (۳۱/۸ درصد) و ژرانیول (۹/۹ درصد) به‌عنوان دو ترکیب مهم معطر اسانس گل محمدی به‌همراه فنیل اتیل الکل، ژرانیال، نرال و لینالول به‌عنوان سایر ترکیبات معطر و خوشبوی گل محمدی در مجموع ۴۴ درصد اسانس را تشکیل می‌دادند. در حالی‌که نونادکان (۲۱/۹ درصد)، هنی‌کوزان (۶/۸ درصد)، نوناندسن (۶ درصد) و هپتادکان (۵/۱ درصد) به‌همراه تری‌کوزان، پنتاکوزان و ای‌کوزان به‌عنوان بخش استئاروپتنی و مومی اسانس در مجموع ۴۴/۶ درصد اسانس را تشکیل می‌دهند. در اسانس حاصل از غنچه‌های گل محمدی خشک‌شده در سایه، ۱۴ ترکیب شناسایی شد که از بین آن‌ها سیترونلول (۳۱/۳ درصد) و ژرانیول (۵/۷ درصد) به‌عنوان دو ترکیب مهم معطر اسانس گل محمدی به‌همراه فنیل اتیل الکل و لینالول به‌عنوان سایر ترکیبات معطر و خوشبوی گل محمدی در مجموع ۳۸/۳ درصد اسانس را تشکیل می‌دادند. نرال و ژرانیال در این اسانس وجود نداشتند. در حالی‌که نونادکان (۲۳/۴ درصد)، هنی‌کوزان (۶/۷ درصد)، نوناندسن (۴/۸ درصد) و هپتادکان (۴/۸ درصد) به همراه تری‌کوزان، پنتاکوزان، و ای‌کوزان به‌عنوان بخش استئاروپتنی و مومی اسانس در مجموع ۴۳ درصد اسانس را تشکیل می‌دهند. در اسانس حاصل از غنچه‌های گل محمدی خشک‌شده در خشک‌کن خورشیدی غیرمستقیم، در مجموع ۱۱ ترکیب شناسایی شد. سیترونلول به میزان ۱۱/۶ درصد در اسانس غنچه خشک‌شده در خشک‌کن خورشیدی غیرمستقیم وجود داشت. ژرانیول به مقدار بسیار کم (۰/۵ درصد) در اسانس حاصله وجود داشت. نونادکان به میزان

۳۷/۶ درصد در اسانس غنچه خشک‌شده در این خشک‌کن به‌دست آمد. همچنین هنی‌کوزان نیز به میزان ۱۵/۶ درصد در اسانس غنچه خشک یافت شد. مقایسه کیفیت اسانس نمونه‌های غنچه گل محمدی تازه، خشک‌شده در سایه و خشک شده توسط خشک‌کن خورشیدی غیرمستقیم نشان می‌دهد که مقدار سیترونلول به‌عنوان یکی از ترکیب‌های مهم عطر گل محمدی در غنچه تازه و سایه خشک تغییر چندانی نداشته ولی در خشک‌کن خورشیدی کاهش یافته است. اما مقدار ژرانیول به‌عنوان دومین ترکیب عمده معطر و خوشبوی اسانس گل محمدی، در اثر روش سایه خشک حدود ۴۰ درصد و در خشک‌کن خورشیدی حدود ۹۰ درصد نسبت به غنچه تر کاهش یافته است. از بخش استئاروپتنی اسانس که ترکیبات سنگین و غیرمطلوب اسانس گل محمدی هستند مقدار نونادکان در نمونه خشک‌شده در سایه اندکی (حدود ۷ درصد) و در خشک‌کن خورشیدی حدود ۷۲ درصد افزایش یافته است. مقدار هنی‌کوزان در غنچه سایه خشک نسبت به غنچه تر تغییر چندانی نکرده و تقریبا ثابت مانده است در حالی‌که در غنچه خشک‌شده در خشک‌کن خورشیدی به بیش از دو برابر رسیده است. سایر ترکیبات جزئی‌تر مثل لینالول و فنیل اتیل الکل (از دسته ترکیبات معطر) در غنچه تازه و خشک‌شده در سایه تغییر فاحشی نداشته است در صورتی‌که لینالول در غنچه خشک‌شده در خشک‌کن خورشیدی یافت نشده و فنیل اتیل الکل نسبت به غنچه تازه تا ۶۰ درصد کاهش یافته است. هپتادکان در غنچه تازه، غنچه خشک‌شده در سایه و در خشک‌کن خورشیدی تغییر فاحشی نداشته است (جدول ۷).

جدول ۷- ترکیبات اسانس غنچه گل محمدی تازه و خشک‌شده در سایه

Table 7- Essential oil compounds of fresh buds and buds dried in the shade

ترکیبات Compounds (%)	غنچه تازه Fresh bud	غنچه خشک- سایه خشک Dried bud- Shade drying	غنچه خشک- خشک‌کن خورشیدی غیرمستقیم Dried bud- Indirect solar dryer	شاخص بازداری Retention index
Linalool	0.6	0.8	-	1101
Phenyl ethyl alcohol	0.7	0.5	0.3	1117
Citronellol	31.8	31.3	11.6	1235
Neral	0.4	-	-	1245
Geraniol	9.9	5.7	0.5	1257
Geranial	0.6	-	-	1266
Eugenol	1.1	0.4	0.4	1348
Geranyl acetate	0.3	-	-	1364
E-caryophyllene	0.3	0.6	-	1427
Germacrene D	0.8	1.1	-	1488
Heptadecane	5.1	4.8	5.1	1698
Nonadecene	6	4.8	6.1	1878
Nonadecane	21.9	23.4	37.6	1900
Eiecosane	1.6	1.8	3.5	1988
Heneicosane	6.8	6.7	15.6	2102
Tricosane	1.6	1.1	3.4	2300
Pentacosane	0.8	0.4		2500

در اسانس حاصل از غنچه‌های گل محمدی خشک‌شده در خشک کن کابینتی، در مجموع ۱۳ ترکیب شناسایی شد. سیترونلول به میزان ۲۳/۷ و ۱۱/۸ درصد به‌ترتیب در اسانس غنچه خشک‌شده در دماهای ۴۰ و ۵۰ درجه سلسیوس وجود داشت. ژرانیول (۵/۷ درصد) به مقدار ۵ و ۲/۴ درصد به‌ترتیب در اسانس غنچه خشک‌شده در دماهای ۴۰ و ۵۰ درجه سلسیوس وجود داشت. ژرانیال فقط در اسانس نمونه‌های خشک‌شده در ۴۰ درجه سلسیوس وجود داشت. نونادکان به میزان ۲۸/۵ و ۳۶/۱ درصد به‌ترتیب در اسانس غنچه خشک‌شده در دماهای ۴۰ و ۵۰ درجه سلسیوس شناسایی شد. هنی‌کوزان نیز به میزان ۸/۷ و ۱۱/۴ درصد به‌ترتیب در اسانس غنچه خشک‌شده در دماهای ۴۰ و ۵۰ درجه سلسیوس وجود داشت. مقایسه کیفیت اسانس دو نمونه غنچه گل خشک‌شده در خشک‌کن کابینتی در ۲ دمای مختلف ۴۰ و ۵۰ درجه سلسیوس نشان می‌دهد که بالا رفتن دما از ۴۰ درجه به ۵۰ درجه سلسیوس، باعث کاهش مقدار ترکیبات معطر سیترونلول و ژرانیول و افزایش مقدار ترکیبات سنگین نونادکان و هنی‌کوزان شده است (جدول ۸).

جدول ۸- آنالیز اسانس غنچه گل محمدی خشک‌شده در خشک‌کن کابینتی با دماهای مختلف

Table 8- Essential oil compounds of dried buds in cabinet dryer with various temperatures

ترکیبات Compounds (%)	خشک‌کن کابینتی ۴۰ درجه سلسیوس Cabinet dryer at 40 °C	خشک‌کن کابینتی ۵۰ درجه سلسیوس Cabinet dryer at 50 °C	شاخص بازداری Retention index
Linalool	1	0.4	1101
Phenyl ethyl alcohol	0.3	0.2	1117
Citronellol	23.7	11.8	1235
Geraniol	5	2.4	1257
Geranial	0.4	-	1266
Eugenol	0.7	0.5	1348
Heptadecane	5.9	6.7	1698
Nonadecene	7.8	8.8	1878
Nonadecane	28.5	36.1	1900
Eiecosane	2	2.6	1988
Heneicosane	8.7	11.4	2102
Tricosane	2	2.4	2300
Pentacosane	0.7	1	2500

در اسانس حاصل از غنچه‌های گل محمدی خشک‌شده در خشک‌کن‌های تحت خلاء و انجمادی، در مجموع ۱۲ ترکیب شناسایی شد. در هیچ‌یک از این نمونه‌ها فنیل اتیل الکل یافت نشد. کمترین مقدار سیترونلول (به‌ترتیب ۱/۲ درصد در خشک‌کن تحت خلاء و ۷/۳ درصد در خشک‌کن انجمادی) و ژرانیول (به‌ترتیب ۱/۱ درصد در خشک‌کن تحت خلاء و ۲/۹ درصد در خشک‌کن تصعیدی) در اسانس این دو نمونه وجود داشت. همچنین بیشترین مقدار ترکیبات غیرمطلوب نونادکان (به‌ترتیب ۳۷/۹ درصد در خشک‌کن تحت خلاء و ۳۱/۹ درصد در خشک‌کن انجمادی)، هنی‌کوزان (به‌ترتیب ۱۹ درصد در خشک‌کن تحت خلاء و ۱۴/۲ درصد در خشک‌کن انجمادی) و نونادکن (به‌ترتیب ۹/۴ درصد در خشک‌کن تحت خلاء و ۸/۳ درصد در خشک‌کن تصعیدی) و سایر ترکیبات سنگین در این نمونه‌ها نیز یافت شد. اسانس غنچه‌های خشک‌شده در خشک‌کن تصعیدی و خشک‌کن تحت خلاء، نسبت به سایر روش‌های خشک کردن، دارای کمترین مقدار ترکیبات معطر و در نتیجه پایین‌ترین کیفیت اسانس به‌علت خلاء موجود در حین فرآیند خشک شدن بودند. مکش باعث خروج ترکیبات مفید اسانس از غنچه می‌شود. ترکیب سیترونلول به‌عنوان مهم‌ترین ترکیب معطر اسانس گل محمدی در نمونه خشک‌شده در خشک‌کن انجمادی فقط ۷/۳ درصد اسانس و در شرایط تحت خلاء از آن هم کمتر در حد ۱/۲ درصد وجود داشت. بنابراین خلاء به‌کار رفته‌شده تقریباً کل ترکیبات معطر را از غنچه‌ها خارج کرده است. مقدار ژرانیول هم در هر دو نمونه بسیار پایین (۲/۹ درصد در شرایط خشک‌کن تصعیدی و ۱/۱ درصد در خشک‌کن تحت خلاء) بود. در عوض ترکیبات مومی و غیرمطلوب، بخش عمده اسانس غنچه گل محمدی خشک‌شده در خشک‌کن انجمادی (۷۷/۵ درصد) و در خشک‌کن تحت خلاء (۷۰/۹ درصد) را تشکیل دادند (جدول ۹).

جدول ۹- آنالیز اسانس غنچه گل محمدی خشک‌شده در خشک‌کن‌های انجمادی و تحت خلاء

Table 9- Essential oil compounds of buds dried in freeze and vacuum dryers

ترکیبات Compounds (%)	خشک‌کن انجمادی Freeze dryer	خشک‌کن تحت خلاء Vacuum dryer	شاخص بازداری Retention index
Linalool	0.8	-	1101
Phenyl ethyl alcohol	-	-	1117
Citronellol	7.3	1.2	1235
Geraniol	2.9	1.1	1257
Geranial	4.9	-	1266
Eugenol	1.1	-	1348
Heptadecane	7.8	3.8	1698
nonadecene	8.3	9.4	1878
Nonadecane	31.9	37.9	1900
Eiecosane	3.5	0.2	1988
Heneicosane	14.2	19.0	2102
Tricosane	3.6	5.2	2300
Pentacosane	1.6	2	2500

مقایسه اثر روش های خشک‌کردن بر روی میـزان ترکیبـات معطر و مومی اسانس غنچه گل محمدی

میزان ترکیبات معطر اسـانس غنچـه‌های تـازه و خشک‌شـده بـه روش‌هـای مختلـف در شـکل‌های ۵ و ۶ نشـان داده شـده اسـت. همان‌گونه که در شکل ۵ ملاحظه می‌شود، بیشترین ترکیبـات معطـر ابتدا در نمونه‌های تازه و سپس در نمونه‌های سایه خشک و پس از آن نیز در خشک‌کن کابینتی در دمای ۴۰ درجه سلسیوس به‌دسـت آمـده است. در مقابل کمتـرین مقـدار ترکیبـات سـنگین و مـومی اسـانس به‌ترتیب در تمونـه‌های تـازه، سـایه خشـک و پـس از آن خشـک‌کن خورشیدی مستقیم دیده شـده اسـت (شـکل ۶). بـا توجـه بـه زمـان طولانی مورد نیاز برای خشک‌کردن غنچه‌های گل محمدی در سـایه (۲۹۸ ساعت)، می‌توان روش خشـک‌کردن در خشـک‌کن کـابینتی در دمای ۴۰ درجه سلسیوس را پیشنهاد داد.

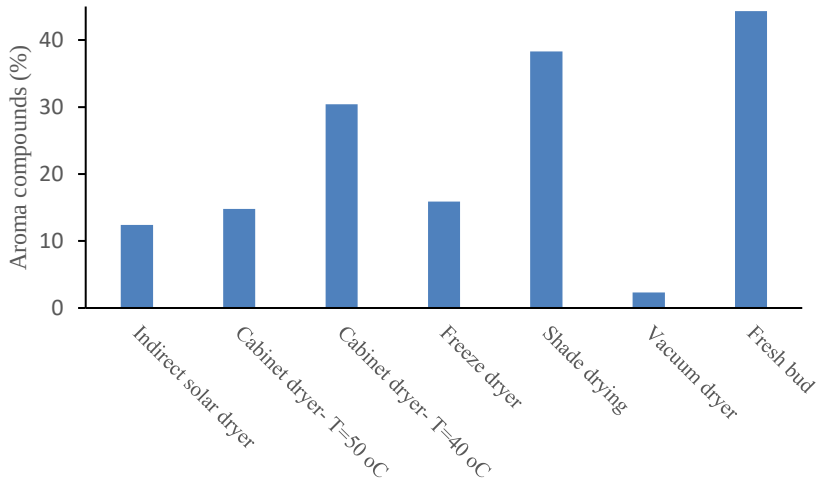

شکل ۵- مقایسه میزان ترکیب‌های معطر در اسانس نمونه‌های مختلف غنچه‌های گل محمدی

Fig.5. Comparison of aroma compounds in essential oil samples of Rosa flower buds

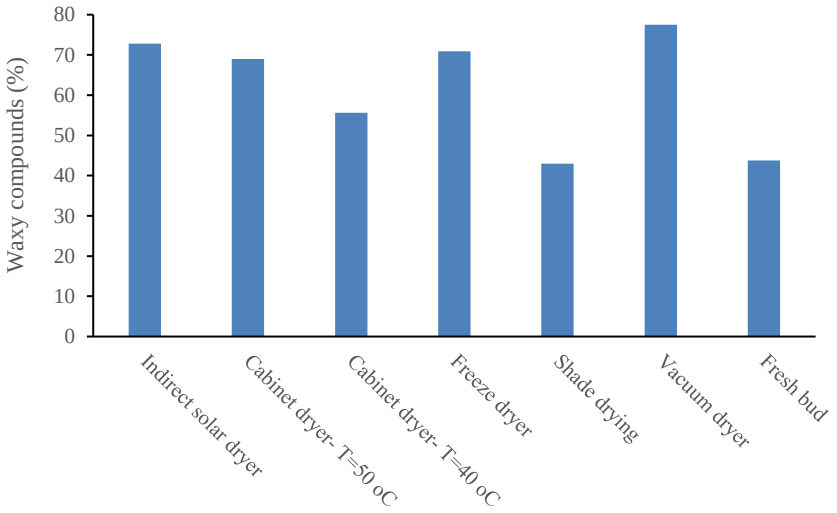

شکل ٦- مقایسه میزان ترکیب‌های مومی در اسانس نمونه‌های مختلف از غنچه‌های گل محمدی

Fig.6. Comparison of waxy compounds in essential oil samples of Rosa flower buds

نتیجه‌گیری

در فرآیند خشک‌شدن غنچه گل محمدی؛ رایحه، اسانس و رنگ گلبرگ‌های غنچه خصوصاً گلبرگ‌های درونی از مسائل بسیار مهم در تولید غنچه خشک با کیفیت مناسب است. فرآیند خشک‌کردن غنچه گل محمدی نشان داد که بیشترین زمان خشک‌کردن به روش‌های سایه‌خشک و انجمادی و کمترین زمان خشک‌کردن به روش تحت خلاء اختصاص داشت. براساس نتایج مقایسه رنگ غنچه‌های خشک‌شده به روش‌های مختلف، شاخص روشنایی (L^*)، در گلبرگ‌های درونی غنچه‌های خشک‌شده به روش سایه‌خشک و کابینتی در دو سطح دمای هوا اختلاف معنی‌داری نداشت و در مقایسه با روش خورشیدی غیرمستقیم دارای شاخص روشنایی بالاتری بودند. بیشترین میزان شاخص a^* پس از غنچه‌های تازه، در گلبرگ‌های بیرونی غنچه‌های خشک‌شده با روش هوای گرم ۵۰ درجه سلسیوس (۲۵/۶۱) مشاهده شد. این شاخص در گلبرگ‌های درونی غنچه‌های خشک‌شده با روش‌های سایه (۱۵/۹۰)، هوای گرم ۵۰ درجه سلسیوس (۱۵/۴۸) و هوای گرم ۴۰ درجه سلسیوس (۱۴/۴۰) بعد از غنچه تازه بیشترین بود و اختلاف معنی‌داری را در این روش‌ها نشان نداد. فرآیند خشک‌کردن، مقدار ویتامین ث را در غنچه‌های گل محمدی به‌طور معنی‌داری کاهش داد. غنچه‌های خشک‌شده با خشک‌کن کابینتی در دو سطح دمایی ۴۰ و ۵۰ درجه سلسیوس به‌ترتیب با مقدار ۱/۵۷ و ۱/۴۹ میلی‌گرم در صد گرم ماده تر به‌طور معنی‌داری مقدار ویتامین ث بیشتری را دارا بودند.

بازده اسانس در غنچه تازه گل محمدی ۰/۰۲۲ درصد و در غنچه خشک‌شده در خشک‌کن کابینتی با دمای ۵۰ درجه سلسیوس دارای بیشترین مقدار برابر با ۰/۰۳۴ درصد بود. کمترین مقدار بازده اسانس در خشک‌کن انجمادی (۰/۰۱۷ درصد) به‌دست آمد. در اسانس حاصل از غنچه‌های تازه گل محمدی، ۱۷ ترکیب شناسایی شد که از بین آن‌ها سیترونلول (۳۱/۸ درصد) و ژرانیول (۹/۹ درصد) به عنوان دو ترکیب مهم معطر اسانس گل محمدی به‌همراه فنیل اتیل الکل، ژرانیال، نرال و لینالول به‌عنوان سایر ترکیبات معطر و خوشبوی گل محمدی در مجموع ۴۴ درصد اسانس را تشکیل داده‌اند. بالا رفتن دما از ۴۰ درجه به ۵۰ درجه سلسیوس در خشک‌کن کابینتی، باعث کاهش مقدار ترکیبات معطر سیترونلول و ژرانیول و افزایش مقدار ترکیبات سنگین نوادکان و هنی‌کوزان شده است. خلاء به‌کاررفته در خشک‌کن‌های تحت خلاء و انجمادی تقریباً کل ترکیبات معطر را از غنچه‌ها خارج کرده است. مقدار ژرانیول هم در هر دو نمونه بسیار پایین (۲/۹ درصد در شرایط خشک‌کن انجمادی و ۱/۱ درصد در خشک‌کن تحت خلاء) بود. بیشترین ترکیبات معطر و کمترین ترکیبات مومی ابتدا در نمونه‌های تازه و سپس در نمونه‌های سایه خشک و پس از آن نیز در غنچه‌های خشک‌شده در خشک‌کن کابینتی با دمای ۴۰ درجه سلسیوس به‌دست آمد. با توجه به زمان طولانی مورد نیاز برای خشک‌کردن غنچه‌های گل محمدی در سایه و خواص کیفی و ترکیبات معطر غنچه خشک‌شده در شرایط مختلف، روش مکانیزه خشک‌کردن در خشک‌کن کابینتی با دمای۴۰ درجه سلسیوس پیشنهاد می‌شود.

تعارض منافع

هیچ‌گونه تعارض منافع توسط نویسندگان بیان نشده است.

مشارکت نویسندگان

امیدرضا روستاپور: نظارت و مدیریت، روش‌شناسی، مشاوره فنی، جمع‌آوری داده‌ها، خدمات نرم‌افزاری، اعتبارسنجی، تصویرسازی نتایج، استخراج و تهیه متن اولیه، ویرایش متن

فاطمه سفیدکن: روش‌شناسی، جمع‌آوری داده‌ها، تحلیل آماری، اعتبارسنجی، تصویرسازی نتایج، استخراج و تهیه متن اولیه

ابوالفضل گلشن تفتی: روش‌شناسی، جمع‌آوری داده‌ها، تحلیل آماری، اعتبارسنجی، تصویرسازی نتایج، استخراج و تهیه متن اولیه، ویرایش

حمیدرضا گازر: روش‌شناسی، جمع‌آوری داده‌ها، تصویرسازی نتایج

References

1. Ahmadi, K., Sefidkon, F., & Assareh, M. H. (2008). The Effects of Different Drying Methods on Essential Oil Content and Composition of Three Genotypes of *Rosa Damascena* Mill. *Iranian Journal of Medicinal and Aromatic Plants, 24*(2), 162-176. (in Persian with English abstract).
2. Anon. (1990). *AOAC Standard. Official Methods of Analysis (15th Edn)*. Association of Official Analytical Chemists, Washington DC, USA.
3. Babu, K. G. D, Singh, B., Joshi, V. P., & Singh, V. (2002). Essential Oil Composition of Damask Rose (*Rosa Damascene* Mill.) Distilled under Different Pressures and Temperatures. *Flavour and Fragrance Journal, 17*, 136-140. https://doi.org/10.1002/ffj.1052
4. Bhardwaj, A. K., Chauhan, R., Kumar, R., & Sethi, M. (2017). Experimental Investigation of An Indirect Solar Dryer Integrated with Phase Change Material for Drying Valeriana Jatamansi (Medicinal Herb). *Case Studies in*

Thermal Engineering, 10, 302-314. https://doi.org/10.1016/j.csite.2017.07.009
5. Boyar, S., Bayhan, A. K., & Dikmen, E. (2013). Investigation on Drying Behavior of Isparta Rose Flowers (Rosa Damascene Mill.) Under Natural Shade Conditions. *Bulgarian Journal of Agricultural Science, 19*(2), 361-374.
6. Brennan, J. G. (2003). *Drying Theory of Air Drying.* PP. 1913-1917 in B. Caballero, L. C. Trugo and P. M. Finglas eds. Encyclopedia of Food Sciences and Nutrition. Academic Press, Elsevier Sci Ltd., Oxford, UK. https://doi.org/10.1016/b0-12-227055-x/00368-0
7. Ebrahimi, M., & Sharifzadeghan, H. (2016). *Knowing about the principles of Rosa damascene planting.* Extension magazine. Research Institute of Forests and Rangelands, Agricultural Research, Education & Extension Organization, Tehran, Iran. (in Persian with English abstract).
8. Henin, K. K., Zhang, M., Ju, R., & Wang, B. (2021). A Novel Infrared Pulse-Spouted Freeze Drying on the Drying Kinetics, Energy Consumption and Quality of Edible Rose Flowers. *LWT- Food Science and Technology*, 136, 110318. https://doi.org/10.1016/j.lwt.2020.110318
9. Khorramdel, S., Shabahang, J., & Asadi, G.A. (2013). Effect of Drying Methods on Drying Time, Essential Oil Quantitative and Qualitative of Some of Medicinal Plants. *Eco- phytochemical Journal of Medical Plants, 1*(1), 36-48. (in Persian with English abstract).
10. Mabellinia, A., Ohaco, E., Ochoa, M. R., Kesselera, A. G., Marqueza, C. A., & De Michelis, A. (2011). Chemical and Physical Characteristics of Several Wild Rose Species Used as Food or Food Ingredient. *International Journal of Industrial Chemistry, 2*(3), 158-171.
11. Mir, S. J. (2019). Analysis of Damask Rose Development Policy in Iran. *Agricultural Economics and Development, 27*(3), 181-201. (in Persian). https://doi.org/30490/aead.2019.120758
12. Raol, J. B., Kumpavat, M. T., & Vyas, D. M. (2013). Drying Characteristics of Rose Flowers. *Journal of Agricultural Engineering, 50*(1), 39-46. https://doi.org/10.52151/jae2013501.1503
13. Rezaee, M. B., Jaimand, K., Tabaei- Aghdaei, S. R., & Barazandeh, M. M. (2003). Comparative Study of Laboratory and Industrial Essential Oils Samples of *Rosa Damascena* Mill. for Quantitative and Qualitative Constituents from Kashan. *Iranian Journal of Medicinal and Aromatic Plants Research, 19*(1), 63-72. (in Persian with English abstract).
14. Roozdar, F., Azizi, M., Ghani, A., & Davarynejad, G. (2014). The Effects of Drying Methods on Drying Time and Some Biochemical Characteristics of Mentha piperita L. *Journal of Horticultural Science, 28*(3), 407-415. (in Persian). https://doi.org/10.22067/jhorts4.v0i0.42865
15. Roustapour, O. R., Golshan Tafti, A., Sefidkon, F., Gazor, H. R., Zainali, H., Younesi, A., Mirzaei Bafti, M., Chaji, H., Azimi Atergeleh, R., & PardisKian, S. (2024). *Investigation of different methods of drying Rosa flower bud in order to evaluation of quality parameters.* A Publication of Agricultural Engineering Research Institute, Agricultural Research, Education & Extension Organization, Karaj, Iran. (in Persian with English abstract).
16. Roustapour, O. R., Zomorodian, A., Gazor, H. R., Roushanzadeh, H., Joukar, A., & Joukar, L. (2016). *Design, manufacture and evaluation of mixed solar dryer with variable inclination mechanism in order to dry apple (Golab Variety)*. A Publication of Agricultural Engineering Research Institute, Agricultural Research, Education & Extension Organization, Karaj, Iran. (in Persian with English abstract).
17. Santos-Sa´nchez, N. F., Valadez-Blanco, R., Go´mez-Go´mez, M. S., Pe´rez-Herrera, A., & Salas-Coronado, R. (2012). Effect of Rotating Tray Drying on Antioxidant Components, Color and Rehydration Ratio of Tomato Saladette Slices. *LWT – Food Science and Technology, 46*(1), 298-304. https://doi.org/10.1016/j.lwt.2011.09.015
18. Shahverdi, S., Sefidkon, F., Jamzad, Z., & Nejhadsattari, T. (2012). Essential Oil Composition of *Origanum Strobilaceum* Mobayen & Ghahreman. *Iranian Journal of Medicinal and Aromatic Plants, 28*(3), 465-471. (in Persian with English abstract). https://doi.org/10.22092/ijmapr.2012.2948
19. Yam, K. L., & Papadakis, S. E. (2004). A Simple Digital Imaging Method for Measuring and Analyzing Color of Food Surfaces. *Journal of Food Engineering, 61*(1), 137-142. https://doi.org/10.1016/S0260-8774(03)00195-X
20. Yousefi, B., Tabaie-Aghdaei, S. R., & Amiri, A. (2021). Study on Yield and Flower Yield Components, Essential Oil Percentage and Some Morphological and Phonological Traits in 48 Different Accessions of Damask Rose (*Rosa Damascena* Mill.) in Kermanshah Province. *Iranian Journal of Medicinal and Aromatic Plants Research, 37*(4), 612-627. (in Persian with English abstract). https://doi.org/10.22092/ijmapr.2021.353968.2964
21. Ziolhagh, S. H. R., Babakhanzadeh Sajirani, E., & Hosseini, S. A. (2022). *Investigation the effect of drying temperature on weight loss and color of the petals of Rosa Damascena Mill.* Medicinal Plants: Mechanization and Processing Congress. Imam Khomeini Higher Education Center, Karaj, Iran. (in Persian with English abstract).
22. Zheng, M., Xia, Q., & Lu, S. (2015). Study on Drying Methods and Their Influences on Effective Components of Loquat Flower Tea. *LWT- Food Science and Technology, 63*, 14-20. https://doi.org/10.1016/j.lwt.2015.03.090

Journal of Agricultural Machinery

Homepage: https://jame.um.ac.ir

Research Article
Vol. 16, No. 4, 2026, p. 669-691

Non-Destructive Prediction of pH in Khormai and Khoni Plums Using a Hyperspectral Imaging System and Machine Learning Methods

M. Latifi-Amoghin[1], Y. Abbaspour-Gilandeh[1*]

1- Department of Biosystems Engineering, Faculty of Agriculture and Natural Resources, University of Mohaghegh Ardabili, Ardabil, Iran
(*- Corresponding Author Email: abbaspour@uma.ac.ir)

Received: 10 September 2025
Revised: 10 October 2025
Accepted: 26 October 2025
Available Online: 09 November 2025

How to cite this article:
Latifi-Amoghin, M., & Abbaspour-Gilandeh, Y. (2026). Non-Destructive Prediction of pH in Khormai and Khoni Plums Using a Hyperspectral Imaging System and Machine Learning Methods. *Journal of Agricultural Machinery, 16*(4), 669-691. [in Persian]. https://doi.org/10.22067/jam.2025.95325.1427

Introduction

Traditional methods for evaluating fruit quality, such as pH measurement, are often destructive, time-consuming, and costly, leading to product loss and reduced efficiency in the supply chain. The growing need for rapid, accurate, and non-destructive methods makes the use of technologies like Hyperspectral Imaging (HSI) essential. HSI combines two-dimensional imaging with spectroscopy to simultaneously acquire spatial and spectral information from an object. Numerous studies have shown that this method is capable of accurately estimating internal fruit parameters in a non-destructive manner. The objective of this research was to develop a fast and reliable method for the non-destructive estimation of pH in two plum cultivars using HSI and machine learning algorithms such as Partial Least Squares Regression (PLSR) and Artificial Neural Networks (ANN). This study aims to overcome the limitations of conventional methods by leveraging the power of advanced imaging and computational techniques, providing a sustainable and efficient solution for the fruit industry.

Materials and Methods

In this study, 80 samples from each of the Khormaei and Khoni plum cultivars were used, which were purchased from local orchards. The samples were uniform in size, shape, and colour and were free from any physical damage. Hyperspectral images of the samples were acquired using a rotating hyperspectral imaging system in the range of 418 to 1072 nm. The pH of each fruit juice sample was measured using a digital pH meter. In the analysis of spectral data, the initial part of the spectrum was first removed due to high noise, and then the remaining data were processed with preprocessing methods such as a Gaussian filter and Multiplicative Scatter Correction (MSC). To select effective wavelengths (EWs), a hybrid approach using a Decision Tree (DT) and five metaheuristic algorithms was employed, with the Particle Swarm Optimisation (PSO) algorithm showing the best performance. Finally, pH modelling was performed on the selected wavelengths using PLSR and ANN. This comprehensive methodology ensures that the models are trained on high-quality data and are optimised for maximum accuracy.

Results and Discussion

Spectral analysis showed that the reflectance spectra of the Khoni and Khormaei plums had a high degree of variation, which is related to the differences in their chemical composition and structure. Descriptive statistics indicated that the average pH of Khormaei plum (3.909) was higher than that of Khoni plum (3.7375), and the pH range of Khoni plum (3.15 to 4.44) was wider than that of Khormaei plum (3.6 to 4.2). The results showed

Authors retain the copyright. This is an open access article distributed under Creative Commons Attribution 4.0 International License (CC BY 4.0).

https://doi.org/10.22067/jam.2025.95325.1427

that modelling with ANN on the wavelengths selected by PSO, especially for Khoni plum, significantly increased prediction accuracy. The best ANN model for Khoni plum achieved an R^2 of 0.9834 and an RPD of 8.01, which indicates the outstanding accuracy of this method. For the Khormaei plum, the best ANN model also reached an R^2 of approximately 0.76 and a Ratio of Performance to Deviation (RPD) of 2.12, showing a considerable improvement over the PLSR model. The superior performance of the ANN models can be attributed to their ability to capture complex, non-linear relationships between spectral data and pH values, which linear models like PLSR may miss.

Conclusion

This research successfully demonstrated that hyperspectral imaging, in combination with machine learning algorithms, particularly ANN and PSO, can be an accurate and reliable method for the non-destructive prediction of pH in different plum cultivars. The hybrid approach used in this study, which combined DT for initial feature selection with PSO for optimal wavelength selection, enabled the models to predict pH values with very high accuracy, especially for the Khoni plum cultivar. This method can be used as an efficient tool in post-harvest quality control processes, helping to reduce waste and improve efficiency in the fruit supply chain. This work paves the way for the development of smart grading and sorting systems that can quickly and accurately assess fruit quality, benefiting both producers and consumers.

Keywords: Hyperspectral imaging, Metaheuristic algorithms, Particle Swarm Optimisation, pH, Plum

نشریه ماشین‌های کشاورزی
https://jame.um.ac.ir

مقاله پژوهشی
جلد ۱۶، شماره ٤، زمستان ۱٤۰۵، ص ٦۹۱-٦٦۹

پیش‌بینی غیرمخرب pH آلو خرمایی و خونی با به‌کارگیری سامانه تصویربرداری فراطیفی و روش‌های یادگیری ماشین

میثم لطیفی عموقین[۱]، یوسف عباس‌پور گیلانده[۱*]

تاریخ دریافت: ۱۴۰۴/۰۶/۱۹
تاریخ پذیرش: ۱۴۰۴/۰۸/۰۴

چکیده

این پژوهش با هدف توسعه و ارزیابی یک روش غیرمخرب برای پیش‌بینی pH دو رقم آلو (خرمایی و خونی) با استفاده از سامانه تصویربرداری فراطیفی در حالت بازتابی انجام شد. اثر پیش‌پردازش‌های مختلف طیفی بر عملکرد مدل رگرسیون حداقل مربعات جزئی بر روی طیف کامل داده‌ها بررسی شد. در هر دو رقم، بهترین عملکرد این الگوریتم با فیلتر گوسی در مرحله آزمون با R^2=۰/۸۲۰۳، RMSE=۰/۰۵۹ و RPD=۲/۴۴ برای رقم خرمایی و R^2=۰/۸۸۱۹، RMSE=۰/۱۴۱۱ و RPD=۳/۰۱ برای رقم خونی به ثبت رسید. در ادامه به‌عنوان یک نوآوری از ترکیب الگوریتم درخت تصمیم با پنج الگوریتم فراابتکاری برای کاهش ابعاد داده‌ها استفاده شد که میان آن‌ها الگوریتم بهینه‌سازی ازدحام ذرات عملکرد بهتری در انتخاب ویژگی داشت. درنهایت، مدل‌سازی pH بر روی طول‌موج‌های منتخب با استفاده از مدل‌های رگرسیون حداقل مربعات جزئی و شبکه‌ی عصبی مصنوعی صورت پذیرفت. نتایج نشان داد که شبکه‌ی عصبی مصنوعی بر روی طول‌موج‌های منتخب الگوریتم بهینه‌سازی ازدحام ذرات، به‌ویژه برای آلو خونی، منجر به دقت‌های پیش‌بینی به‌مراتب بالاتری شد؛ به‌طوری‌که بهترین عملکرد این الگوریتم برای آلو خونی (با فیلتر گوسی) در مرحله آزمون به R^2=۰/۹۸۳۴، RMSE=۰/۰۵۱۲ و RPD=۸/۰۱ دست‌یافت، که نشان‌دهنده توانایی قابل‌توجه این‌روش برای اندازه‌گیری کمی دقیق است. برای آلو خرمایی نیز، بهترین عملکرد این الگوریتم (با داده‌های بدون پیش‌پردازش و فیلتر میانه) در مرحله آزمون به R^2=۰/۷۶ و RPD=۲/۱۲ رسید که بهبود قابل‌توجهی نسبت به الگوریتم رگرسیون حداقل مربعات جزئی نشان داد. این نتایج، نشان‌دهنده پتانسیل بالا این روش جهت استقرار در خطوط فرآوری برای کنترل کیفیت میوه‌ها طی عملیات پس از برداشت می‌باشد.

واژه‌های کلیدی: آلو، الگوریتم‌های فراابتکاری، بهینه‌سازی ازدحام ذرات، تصویربرداری فراطیفی، pH

مقدمه

آلو (*Prunus domestica* L.)، گیاهی از تیره گل‌سرخ‌ها (*Rosaceae*) و جنس *Prunus* می‌باشد این درختچه یا درخت کوچک بومی مناطق معتدل آسیا و اروپا می‌باشد و به‌طور گسترده در مناطق معتدل جهان کشت می‌شود در تیره گل‌سرخ‌ها انواع مختلف میوه‌های هسته‌دار ازجمله زردآلو، هلو، شلیل و آلبالو جای دارند و گونه‌های دیگری مانند *P. salicina* (آلوی ژاپنی) و *P. americana* (آلوی آمریکایی) نیز به‌عنوان آلو شناخته می‌شوند (Trendafilova *et al.*, 2022). آلو یک میوه مهم باغبانی است که به‌صورت تازه مصرف می‌شود و بخش عمده‌ای از تولید آن به‌صورت خشک (آلوچه یا prune) و فرآورده‌های جانبی عرضه می‌گردد. برای نمونه، در ایالات متحده گونه‌های اروپایی آلو عمدتاً برای تولید آلوچه به‌کار می‌روند این میوه از نظر تغذیه‌ای دارای ارزش بالایی است همچنین آلو سرشار از ویتامین‌ها و مواد معدنی مفید است به‌طور خاص منبع خوبی از ویتامین‌های A و C و پتاسیم به‌شمار می‌آید (Ayub *et al.*, 2023). یکی از پارامترهای مهم آلو که نقش زیادی در ماندگاری و نگهداری دارد pH یا اسیدیته می‌باشد کاهش اسیدیته می‌تواند علاوه بر تغییر رنگ، روند رشد میکروارگانیسم‌ها را نیز تسریع کند و به همین دلیل کنترل pH در طول نگهداری از اهمیت ویژه‌ای برای حفظ کیفیت و ماندگاری آلو برخوردار است (Majeed & Jawandha, 2016).

pH به‌عنوان تابعی مستقیم از یون‌های هیدروژن آزاد موجود در یک ماده غذایی تعریف می‌شود و معیاری اساسی برای اسیدیته آزاد

۱- گروه مهندسی بیوسیستم، دانشکده کشاورزی و منابع طبیعی، دانشگاه محقق اردبیلی، اردبیل، ایران
(*- نویسنده مسئول: Email: abbaspour@uma.ac.ir)
https://doi.org/10.22067/jam.2025.95325.1427

است. این پارامتر ذاتی، به‌طور قابل‌توجهی بر جنبه‌های مختلف کیفیت میوه، از جمله طعم، بافت، ماندگاری و مناسب بودن برای فرآوری تأثیر می‌گذارد (McGlynn, 2003). این پارامتر ذاتی، یک شاخص کلیدی بلوغ و توسعه طعم است؛ به این صورت که در طول فرآیند رسیدن، pH میوه به‌طور کلی افزایش و اسیدیته کل کاهش می‌یابد، که نشان‌دهنده‌ی تبدیل اسیدهای آلی به قندها و تغییرات در ویژگی‌های حسی می‌باشد. همچنین، pH به‌طور مستقیم بر ماندگاری، بافت و مناسب بودن برای فرآوری تأثیر می‌گذارد، زیرا کاهش اسیدیته می‌تواند روند رشد میکروارگانیسم‌ها و تغییرات رنگ را تسریع کند؛ بنابراین، نظارت بر pH برای کنترل کیفیت مؤثر در سراسر زنجیره تأمین آلو حیاتی است (Majeed & Jawandha, 2016).

روش‌های سنتی برای ارزیابی پارامترهای کیفیت داخلی میوه مانند pH ذاتاً مخرب هستند. این امر معمولاً شامل نفوذ فیزیکی، له کردن یا آب‌گیری میوه است. ماهیت مخرب به این معنی است که هر میوه آزمایش‌شده غیرقابل فروش می‌شود و منجر به از دست دادن مستقیم محصول و افزایش ضایعات در زنجیره تأمین می‌شود. این‌روش‌ها همچنین معمولاً زمان‌بر و کار فشرده هستند و اغلب به پرسنل ماهر نیاز دارند. این امر آن‌ها را برای ارزیابی کیفیت سریع و با توان بالا در خطوط بسته‌بندی تجاری یا در تأسیسات فرآوری در مقیاس بزرگ غیرعملی می‌کند (Hasanzadeh *et al.*, 2022) توصیف مداوم روش‌های سنتی به‌عنوان پرهزینه، زمان‌بر و مخرب نشان می‌دهد که این‌ها نه تنها ناراحتی‌های جزئی، بلکه موانع اقتصادی و عملیاتی قابل‌توجهی هستند. از دست دادن محصول به دلیل تخریب، همراه با تجزیه‌وتحلیل آهسته، مستقیماً بر سودآوری تأثیر می‌گذارد و مانع از مرتب‌سازی و درجه‌بندی کارآمد در زمان واقعی در زنجیره تأمین می‌شود. این امر منجر به استفاده ناکارآمد از منابع و افزایش ضایعات می‌شود. بنابراین، محدودیت‌های ذاتی روش‌های مخرب ارزیابی کیفیت، یک الزام تجاری قوی برای اتخاذ فناوری‌های غیرمخرب ایجاد می‌کند، زیرا آن‌ها پتانسیل کاهش قابل‌توجه ضایعات، بهبود کارایی عملیاتی و افزایش سودآوری کلی در تولید و توزیع میوه در مقیاس بزرگ را ارائه می‌دهند (Liu *et al.*, 2025).

رشد مداوم تجارت جهانی میوه و انتظارات فزاینده مصرف‌کنندگان برای طعم، تازگی و ایمنی، نیاز به تغییر به سمت تکنیک‌های ارزیابی سریع، دقیق و غیرمخرب را ضروری می‌سازد که بتوانند کیفیت میوه را با دقت در هر مرحله، از کشت در باغ تا توزیع در بازار، مدیریت کنند. فراتر از کارایی صنعتی، تغییر به سمت آزمایش غیرمخرب مستقیماً به خواسته‌های مصرف‌کننده برای کیفیت، تازگی و ایمنی پایدار پاسخ می‌دهد. اگر هر میوه بدون آسیب ارزیابی شود، تضمین می‌کند که تنها محصولاتی که معیارهای کیفی خاصی را برآورده می‌کنند به بازار می‌رسند و منجر به تجربه مصرف‌کننده سازگارتر و رضایت‌بخش‌تری می‌شوند (Liu *et al.*, 2025).

در سال‌های اخیر روش‌های طیفی غیرمخرب مانند تصویربرداری فراطیفی[1](HSI)، که تصویربرداری دو بعدی سنتی را با طیف‌سنجی ترکیب می‌کند، به‌طور گسترده‌ای برای بررسی ویژگی‌های داخلی میوه‌ها به‌کار گرفته شده‌اند. استفاده از این‌روش‌ها موجب حفظ یکپارچگی نمونه و جلوگیری از ضایعات محصول می‌شود (Huang, Liu, & Ngadi, 2014).

مطالعات متعددی نشان داده‌اند که HSI قادر به تخمین غیرمخرب پارامترهای داخلی میوه‌ها با دقت بالا است. به‌عنوان نمونه، گل‌محمدی و همکاران (Golmohammadi, Tahmasebi, & Razavi, 2022) با استفاده از HSI بازتابی در محدوده ۱۱۰۰–۴۰۰ نانومتر موفق شدند pH سیب رد دلشیز را طی دوره نگهداری با خطای بسیار کم (RMSE=۰/۰۲) و ضریب تعیین تقریباً ۰/۹۸ مدل‌سازی کنند همچنین لیو و همکاران (Liu *et al.*, 2021) با به‌کارگیری روش تصویربرداری فراطیفی و الگوریتم‌های یادگیری ماشین ضریب همبستگی R=۰/۸۲۹ و RMSE=۰/۱۰۷ را برای پیش‌بینی اسیدیته (pH) آلو سبز گزارش کرده‌اند که نشان‌دهنده توانایی بالای این فناوری در تشخیص غیرمخرب اسیدیته است به‌طور مشابه، وانگ و همکاران (Wang *et al.*, 2022) با استفاده از سیستم HSI فلورسانس، pH میوه کیوی را با مدل SVR چندهسته‌ای پیش‌بینی کردند و R^2 =۰/۸۵۱ را برای مجموعه پیش‌بینی به‌دست آوردند و همچنین به‌طور مختصر می‌توان به تعدادی از پژوهش‌ها که برای تشخیص یا پیش‌بینی pH میوه‌ها با استفاده از تصویربرداری فراطیفی انجام گرفته‌اند اشاره کرد؛ از جمله سیب فوجی (Zhiming, Wenqian, Liping, Yankun, & Xiu, 2014)، انبه (Purwanto *et al.*, 2013)، میوه لیچی (Pu, Liu, Wang, & Sun, 2016)، سیب قرمز و زرد (Hasanzadeh *et al.*, 2022)، گلابی (Zhang *et al.*, 2024)، کیوی (Zhu *et al.*, 2017)، گوجه (Rahman *et al.*, 2017)، انگور قرمز (Gao & Xie, 2024)، توت‌فرنگی (Weng, Yu, Guo, Tang, & Liang, 2020) که قابلیت اتکای این‌روش را در تعیین غیرمخرب pH تایید می‌کنند در کارهای دیگر نیز از تصویربرداری فراطیفی به‌منظور پیش‌بینی میزان جامدات محلول[2](SSC)، سفتی بافت و رطوبت در انواع میوه‌ها (از جمله بلوبری، سیب، هلو، انبه، ملون و گلابی) استفاده شده است (Wang *et al.*, 2022).

با توجه به تحقیقات انجام‌گرفته در این زمینه، هدف این مطالعه، توسعه یک روش سریع و غیرمخرب برای تخمین pH میوه ارقام مختلف آلو با استفاده از تصویربرداری فراطیفی و به‌کارگیری

1- Hyperspectral Imaging
2- Soluble Solids Content

الگوریتم‌های یادگیری ماشین از جمله رگرسیون حداقل مربعات جزئی[1] (PLSR) و شبکه عصبی مصنوعی[2] (ANN) می‌باشد؛ بنابراین، در این پژوهش فرض بر این است که ترکیب الگوریتم بهینه‌سازی ازدحام ذرات[3] (PSO) با مدل شبکه عصبی مصنوعی می‌تواند دقت پیش‌بینی pH را نسبت به روش‌های کلاسیک (PLSR) بهبود دهد تا مدلی دقیق و قابل‌اعتماد برای پیش‌بینی pH ارائه دهد که بتواند در مراحل پس‌ازبرداشت و فرآیندهای کنترل کیفیت میوه مورد استفاده قرار گیرد.

مواد و روش‌ها

انتخاب نمونه‌ها

در این پژوهش، برای دستیابی به درکی عمیق از رفتار pH در آلو، دو گونه محبوب و بومی آلو خرمایی (قره آلو) و آلو خونی (توسرخ یا آلو قرمز) از باغ‌های محلی خریداری شدند. از هر رقم، ۸۰ میوه با دقت انتخاب گردید؛ تنها نمونه‌هایی که از نظر اندازه، شکل و رنگ کاملاً یکنواخت و عاری از هرگونه آسیب فیزیکی یا نشانه‌های پوسیدگی بودند، به مرحله بعد راه یافتند. پیش از آغاز اندازه‌گیری‌های دقیق، تمامی نمونه‌ها به مدت دو ساعت در دمای ۲۵ درجه سلسیوس نگهداری شدند تا دمایشان با محیط آزمایشگاه یکسان شود. پس از اتمام مرحله تصویربرداری فراطیفی (HSI)، بلافاصله وارد فاز اندازه‌گیری مخرب pH شدیم.

آزمون غیرمخرب

تصویربرداری فراطیفی

تصاویر فراطیفی نمونه‌ها با استفاده از سامانه تصویربرداری فراطیفی چرخشی ساخت شرکت فناوران فیزیک ایران تهیه شدند. این سامانه شامل یک موتور دوار افقی، دوربین CCD با لنز مناسب، نرم‌افزار دریافت تصویر و رایانه پردازش‌گر می‌باشد. محدوده طیفی تحت پوشش سیستم از ۴۱۸ تا ۱۰۷۲ نانومتر با گام طیفی ۱/۴۳ نانومتر بوده و هر تصویر شامل ۴۲۰ باند طیفی است. فاصله دوربین از نمونه‌ها ۱۰۰ سانتی‌متر در نظر گرفته شد تا نمونه به‌طور کامل در میدان دید دوربین قرار گیرد. به‌منظور جلوگیری از ایجاد سایه و بهبود یکنواختی نور، دو منبع نور ۷ واتی پایه استارتی برند افراتاب با زاویه تابش ۴۵ درجه نسبت به سطح نمونه‌ها استفاده شد شکل۱ تصویر سامانه تصویربرداری فراطیفی و نحوه قرارگیری بخش‌های مختلف سامانه را نشان می‌دهد (Hasanzadeh *et al.*, 2022).

برای اطمینان از یکنواختی داده‌های طیفی و کاهش خطای موقعیت‌دهی، استانداردسازی موقعیت نمونه‌ها با دقت انجام شد. در تمامی آزمایش‌ها، هر نمونه آلو به گونه‌ای روی صفحه نمونه قرار گرفت که محور طولی آن به‌صورت عمودی باشد و بزرگترین سطح جانبی میوه (پهلو) مستقیماً رو به لنز دوربین قرار گیرد. این روش موقعیت‌دهی ثابت تضمین کرد که بازتاب‌های طیفی از ناحیه استانداردشده و قابل‌تکرار میوه (پهلو) ثبت شوند و تأثیر جهت‌گیری نمونه بر نتایج به حداقل برسد.

آزمون مخرب

pH

به‌منظور اندازه‌گیری pH آب‌میوه، از pHمتر دیجیتالی (Metrohm 827, Switzerland) در دمای محیط استفاده شد. مقداری از آب میوه با استفاده از آب‌میوه‌گیر گرفته شد و در یک فالکون ریخته شد ابتدا pHمتر توسط مایع با pH مشخص کالیبره شد و با قرار دادن الکترود در آب‌میوه، مقدار pH اندازه‌گیری شد (Khodabakhshian & Baghbani, 2026; Latifi Amoghin *et al.*, 2024b).

تجزیه‌وتحلیل داده‌های طیفی

فرآیند تحلیل ویژگی‌های طیفی آلو با گردآوری داده‌های طیفی در بازه ۴۱۸ تا ۱۰۷۲ نانومتر آغاز شد که این محدوده، بخش قابل‌توجهی از ناحیه مرئی (Vis) و مادون‌قرمز نزدیک (NIR) را دربرمی‌گیرد. به‌منظور ارتقای کیفیت داده‌ها و کاهش اثرات نویز شدید، بخش ابتدایی طیف (از ۴۱۸ تا حدود ۴۲۰ نانومتر) به دلیل افت محسوس نسبت سیگنال به نویز از مجموعه داده‌ها حذف شد. این گام، برای هر دو رقم آلو به‌طور یکسان انجام گرفت تا پایایی نتایج آتی تضمین شود. برای اطمینان از شفافیت در روش تحلیل داده‌ها، لازم به ذکر است که مجموعه داده‌های طیفی نهایی مورد استفاده در مدل‌سازی، شامل ۱۶۰ نمونه و ۱۲۶۶ ویژگی (طول موج‌ها) بود. این حجم داده از ترکیب ۸۰ نمونه آلو خرمایی و ۸۰ نمونه آلو خونی به‌دست آمد؛ بنابراین، ماتریس داده‌های طیفی خام نهایی دارای ابعاد [۱۶۰×۱۲۶۶] بود.

در ادامه، داده‌های اصلاح‌شده به نرم‌افزار MATLAB نسخه ۲۰۲۲a منتقل گردیدند تا فرایند مدل‌سازی پیش‌بینی آغاز شود. مدل‌سازی بر مبنای PLSR صورت پذیرفت و حداکثر تعداد ۱۰ مؤلفه در فرایند مدل‌سازی در نظر گرفته شد. انتخاب PLSR با توجه به توانایی بالای آن در مدیریت داده‌های حجیم و استخراج ساختارهای ارتباطی میان متغیرهای مستقل و پاسخ توجیه‌پذیر بود. به‌منظور ارتقای قابلیت‌اعتماد مدل‌ها و کاهش تأثیرات ناشی از تقسیم‌بندی تصادفی داده‌ها، رویکردی مبتنی بر تکرارهای چندباره مورد استفاده قرار گرفت.

1- Partial Least Squares Regression
2- Artificial Neural Network
3- Particle Swarm Optimisation



شکل ۱– تصویر سامانه‌ی تصویربردار فراطیفی و بخش‌های مختلف سامانه

Fig. 1. Image of the hyperspectral imaging system and the different parts of the system

در این‌رویکرد، فرآیند تقسیم تصادفی داده‌ها به سه مجموعه آموزش (۶۰٪)، اعتبارسنجی (۲۰٪) و آزمون (۲۰٪) درمجموع ۲۰۰ بار به‌طور مستقل انجام شد. در هر تکرار، مدل PLSR بدون استفاده از هیچ‌گونه پیش‌پردازش بر داده‌های خام توسعه یافت و شاخص‌های ارزیابی شامل ضریب تعیین[1] (R^2)، ریشه میانگین مربعات خطا[2] (RMSE)و نسبت عملکرد به انحراف[3] (RPD) در هر سه مجموعه محاسبه گردید. از میان ۲۰۰ تکرار، تقسیم‌بندی‌ای که ترکیبی از بهترین مقادیر این شاخص‌ها و تعداد بهینه مؤلفه‌ها را ارائه می‌داد، به‌عنوان تقسیم‌بندی مرجع انتخاب و تثبیت شد.

پس از تعیین ساختار بهینه داده‌ها، این تقسیم‌بندی ثابت نگه داشته شد تا تأثیر هر روش پیش‌پردازش به‌طور مستقل و بدون دخالت عوامل تصادفی مورد بررسی قرار گیرد. در این مرحله، مجموعه‌ای متنوع از تکنیک‌های پیش‌پردازش شامل نرمال‌سازی[4]، متغیر نرمال استاندارد[5] (SNV)، تصحیح پراکندگی چندگانه[6] (MSC)، مشتق اول[7]، مشتق دوم[8]، فیلتر میانگین‌گیری متحرک[9]، فیلتر گوسی[10]، فیلتر میانه[11]، صاف‌سازی Savitzky–Golay، Detrend و میانگین‌مرکزی کردن[12] بر روی داده‌ها اعمال شد. به‌ازای هر روش، مدل PLSR مجدداً آموزش داده شد و عملکرد آن با دقت ارزیابی گردید تا بهترین راهکار پیش‌پردازش برای ارتقای دقت پیش‌بینی شناسایی شود.

برای تضمین قابلیت بازتولید نتایج، پارامترهای فنی روش‌های نیازمند تنظیم به شرح زیر استفاده شدند: صاف‌سازی ساویتزکی–گولای با مرتبه چندجمله‌ای ۲ و اندازه پنجره ۱۱ به‌کار رفت. محاسبه مشتق اول و دوم نیز با استفاده از فیلتر ساویتزکی–گولای انجام شد و برای هر دو، مرتبه چندجمله‌ای ۳ و اندازه پنجره ۱۱ در نظر گرفته شد. سایر فیلترهای صاف‌سازی شامل فیلتر میانگین‌گیری متحرک و فیلتر میانه، هر دو با اندازه پنجره ۵ اعمال شدند. همچنین، فیلتر گوسی با هسته‌ای دارای انحراف معیار ۲ اعمال شد.

ارزیابی عملکرد مدل‌های پیش‌بینی

به‌منظور سنجش دقت و قابلیت‌اعتماد مدل‌های توسعه‌یافته، مجموعه‌ای از شاخص‌های آماری کلیدی شامل R^2، RMSE و RPD در سه مرحله آموزش، اعتبارسنجی و آزمون محاسبه گردید. فرمول محاسبه این مقادیر به‌ترتیب در روابط (۱)، (۲) و (۳) نشان داده شده است. کلیه تحلیل‌ها، شامل اعمال روش‌های پیش‌پردازش و مدل‌سازی، در محیط نرم‌افزاری MATLAB نسخه ۲۰۲۲a انجام شد که یکی از ابزارهای معتبر و پرکاربرد در حوزه پردازش داده‌های طیفی و مدل‌سازی شیمی‌سنجی به‌شمار می‌رود (Latifi Amoghin, Abbaspour-Gilandeh, Tahmasebi, & Arribas, 2024a). شاخص RPD که به‌صورت نسبت انحراف معیار مقادیر اندازه‌گیری‌شده مرجع به ریشه میانگین مربعات خطای مجموعه آزمون تعریف می‌شود، معیاری برای سنجش توانایی مدل در پیش‌بینی خارج از داده‌های آموزشی است. هرچه RPD بالاتر باشد، قدرت پیش‌بینی مدل بیشتر است. تفسیر مقادیر RPD بر مبنای طبقه‌بندی ارائه‌شده توسط چانگ و همکاران (Chang, Laird, Mausbach, & Hurburgh, 2001) صورت گرفت؛ به‌طوری‌که

1- Coefficient of Determination
2- Root Mean Square Error
3- Ratio of Performance to Deviation
4- Normalise
5- Standard Normal Variate
6- Multiplicative Scatter Correction
7- 1st Derivative
8- 2st Derivative
9- Moving Average
10- Gaussian Filter
11- Median Filter
12- Mean Centering

RPD کمتر از ۱ نشان‌دهنده مدلی بسیار ضعیف و فاقد کارایی لازم است، مقادیر بین ۱ تا ۱/۴ معرف مدل ضعیف، بازه ۱/۴ تا ۱/۸ بیانگر مدلی قابل‌قبول برای برآوردهای مقدماتی، محدوده ۱/۸ تا ۲ نمایانگر مدلی خوب با توانایی پیش‌بینی کمی مناسب، مقادیر بین ۲ تا ۲/۵ بیانگر مدلی بسیار خوب و مقادیر بالاتر از ۲/۵ معرف مدلی دقیق و کاملاً قابل‌اعتماد در کاربردهای پیش‌بینی کمی است.

$$R^2 = 1 - \frac{\sum_{i=1}^{N}(p_i - d_i)^2}{\sum_{i=1}^{N}(d_i - \bar{d})^2} \quad (۱)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^{N}(p_i - d_i)^2}{N}} \quad (۲)$$

$$RPD = \frac{SD}{RMSE} \quad (۳)$$

در این‌روابط SD انحراف استاندارد داده‌های پیش‌بینی‌شده و RMSE ریشه میانگین مربعات خطا، di و pi به‌ترتیب مقادیر واقعی و پیش‌بینی‌شده مؤلفه‌های iام هستند، $\bar{d}$ میانگین مقادیر واقعی و N تعداد مؤلفه‌ها است.

انتخاب طول‌موج‌های مؤثر و مدل‌سازی مجدد بر روی داده‌های کاهش‌یافته

برای کاهش ابعاد داده‌های طیفی و شناسایی طول‌موج‌های مؤثر که بیشترین نقش را در پیش‌بینی دقیق دارند، رویکردی ترکیبی به‌کار گرفته شد. این‌رویکرد شامل تلفیق روش درخت تصمیم[1] (DT) با مجموعه‌ای از الگوریتم‌های فراابتکاری[2] بود. این الگوریتم‌ها که به دلیل توانایی‌شان در جستجوی بهینه در فضاهای پیچیده شناخته شده‌اند، شامل الگوریتم مسابقه رقابتی جهانی[3](WCC)، الگوریتم قهرمانی لیگ[4] (LCA)، الگوریتم بهینه‌سازی ازدحام ذرات[5] (PSO)، الگوریتم کلونی مورچه[6] (ACO) و الگوریتم اتوماتای یادگیری[7](LA) بودند (Masoudi-Sobhanzadeh, Motieghader, & Masoudi-Nejad, 2019). مشخصات دقیق پارامترهای هر یک از این الگوریتم‌ها در جدول ۱ ارائه شده است.

الگوریتم WCC بر اساس شبیه‌سازی رقابت‌های جهانی طراحی شده است. در این الگوریتم، ایده رقابت بین تیم‌ها یا کشورها برای بهینه‌سازی یک هدف خاص مورد استفاده قرار می‌گیرد. این روش بیشتر برای مسائل پیچیده و چندهدفه مناسب است و تلاش می‌کند تا از استراتژی‌های متنوع رقبا بهره‌برداری کند (Masoudi-Sobhanzadeh & Motieghader, 2016). الگوریتم LCA از رقابت بین تیم‌های ورزشی در یک لیگ الهام گرفته شده است. تیم‌ها در طول مسابقات بهبود عملکرد خود را به کمک تحلیل نتایج و تنظیم استراتژی دنبال می‌کنند. این الگوریتم تلاش می‌کند تا نقاط قوت و ضعف را شناسایی کرده و از آن‌ها برای بهینه‌سازی استفاده کند (Kashan, 2014). الگوریتم PSO از رفتار اجتماعی گروهی مانند پرندگان یا ماهی‌ها الهام گرفته است. در این روش، هر ذره (فرد) موقعیت خود را بر اساس تجربیات گذشته و اطلاعات به‌دست‌آمده از همسایگانش به‌روز می‌کند این الگوریتم بسیار سریع است و برای مسائل بهینه‌سازی پیوسته مناسب می‌باشد (Alam, Dobbie, Koh, Riddle, & Rehman, 2014). الگوریتم ACO این روش از رفتار مورچه‌ها برای یافتن کوتاه‌ترین مسیر بین غذا و لانه الهام گرفته است و برای حل مسائل گسسته مانند مسئله فروشنده دوره‌گرد استفاده می‌شود (Dorigo, Birattari, & Stutzle, 2006). الگوریتم LA این روش مبتنی بر یادگیری تدریجی و تطبیق با محیط برای انتخاب بهینه است. کاربرد آن بیشتر در مسائل گسسته دیده می‌شود (Narendra & Thathachar, 2012).

در این فرآیند، هر الگوریتم فراابتکاری به‌طور مستقل مجموعه‌ای از طول‌موج‌های بهینه را شناسایی کرد. عملکرد خروجی‌های حاصل از هر الگوریتم با توجه به ضریب تعیین R^2 و RMSE ارزیابی شد. هدف نهایی این مرحله، انتخاب الگوریتمی بود که بالاترین دقت پیش‌بینی و کمترین میزان خطا را ارائه دهد. پس از تعیین طول‌موج‌های مؤثر و در نتیجه کاهش حجم داده‌ها، داده‌های حاصله با استفاده از دو روش قدرتمند PLSR و ANN مدل‌سازی مجدد شدند. برای بخش ANN، از یک شبکه عصبی پرسپترون چندلایه[8] مبتنی بر الگوریتم پس‌انتشار استفاده شد. این شبکه شامل یک لایه ورودی بود که تعداد نورون‌های آن برابر با تعداد طول‌موج‌های مؤثر انتخاب‌شده بود و یک لایه خروجی با تنها یک نورون که مقدار pH را پیش‌بینی می‌کرد. به‌منظور بررسی تأثیر ساختار شبکه بر عملکرد مدل، معماری‌های مختلفی طراحی و ارزیابی شدند. این معماری‌ها شامل یک، دو و سه لایه پنهان با تعداد نورون‌های متفاوت بودند (به‌عنوان مثال: [۵], [۱۰], [۱۵], [۲۰] برای یک لایه؛ [۵ ۵], [۱۰ ۵], [۱۵ ۵], [۲۰ ۵], [۱۰ ۱۰], [۱۵ ۱۵], [۲۰ ۲۰] برای دو لایه؛ و [۱۰ ۱۵ ۲۰] برای سه لایه). جهت تقسیم‌بندی داده‌ها برای آموزش، اعتبارسنجی و آزمون شبکه، به‌ترتیب از نسبت‌های ۶۰٪، ۲۰٪ و ۲۰٪ استفاده شد. پارامترهای آموزشی ثابت برای تضمین باز تولیدپذیری نتایج به شرح زیر تنظیم شدند: از الگوریتم لونبرگ–مارکوارت[9] به دلیل سرعت بالای همگرایی و کارایی در مسائل رگرسیون استفاده شد (Latifi

1- Decision Tree
2- Metaheuristic Algorithms
3- World Competitive Contest
4- League Championship Algorithm
5- Particle Swarm Optimisation
6- Ant Colony Optimisation
7- Learning Automata

8- Multilayer Perceptron
9- Levenberg-Marquardt

Amoghin *et al.*, 2024b). برای لایه‌های پنهان، از تابع فعال‌سازی تانژانت سیگموئید و برای لایه خروجی، از تابع خطی استفاده گردید. به‌منظور کمینه‌سازی خطای مدل، تابع میانگین مربعات خطا (MSE) به‌کار رفت.

جدول ۱- مشخصات الگوریتم‌های فراابتکاری مورد استفاده برای انتخاب طول‌موج‌های مؤثر

Table 1- Parameters of the metaheuristic algorithms used for selecting effective wavelengths

ردیف No	الگوریتم Algorithm	پارامترها Parameters
1	WCC	تعداد تیم‌ها: ۶، تعداد گروه‌ها: ۳، تعداد فصل‌ها: ۱۰، زمان مسابقه: ۲ Teams: 6, Groups: 3, Seasons: 10, Match Time: 2
2	LCA	تعداد تیم‌ها: ۸، تعداد فصل‌ها: ۱۰، زمان مسابقه: ۲ Teams: 8, Seasons: 10, Match Time: 2
3	PSO	تعداد ذرات: ۴۰، تعداد تکرارها (Episodes): ۱۰، تعداد بهترین‌های محلی (P Bests): ۸ Particles: 40, Episodes: 10, P Bests: 8
4	ACO	تعداد مورچه‌ها: ۴۰، تعداد تکرارها: ۱۰، نرخ تبخیر: ۴ Ants: 40, Episodes: 10, Evaporation Rate: 4
5	LA	تعداد نسل‌ها: ۱۰، تعداد تلاش‌ها: ۴۰ Generations: 10, Tries: 40

برای جلوگیری مؤثر از بیش‌برازش، از روش توقف زودهنگام[1] استفاده شد که در آن حداکثر تکرار[2] برابر با ۳۰۰ و معیار عدم بهبود عملکرد در مجموعه اعتبارسنجی برابر با ۱۰ تنظیم گردید. همچنین، مجموعه آموزشی اصلی (۶۰٪ کل داده‌ها) به‌طور داخلی در مرحله آموزش به نسبت ۸۰٪ آموزش، ۱۰٪ اعتبارسنجی و ۱۰٪ تست تقسیم شد تا فرآیند توقف زودهنگام به‌طور مؤثر انجام گیرد.

مشابه مراحل قبلی، برای افزایش اعتبار و پایداری نتایج، فرآیند تقسیم‌بندی تصادفی داده‌ها ۲۰۰ بار تکرار شد. این انتخاب تصادفی تنها بر روی داده‌های خام کاهش‌یافته انجام گرفت. پس از انتخاب بهترین تقسیم‌بندی بر اساس شاخص‌های آماری، تمامی پیش‌پردازش‌های مورد نظر بر روی همان ترتیب ثابت داده‌ها اعمال شدند. این‌رویکرد تضمین کرد که تأثیر واقعی هر روش پیش‌پردازش بر عملکرد مدل، بدون دخالت تغییرات ناشی از تقسیم‌بندی تصادفی، به دقت ارزیابی شود.

نتایج و بحث

تحلیل داده‌های طیفی

در این پژوهش، تحلیل جامع داده‌های طیف بازتابی و مقادیر pH نمونه‌های آلو خرمایی و آلو خونی، اطلاعات ارزشمندی را درخصوص ویژگی‌های شیمیایی و فیزیکی این دو رقم و پتانسیل تصویربرداری فراطیفی برای ارزیابی غیرمخرب آن‌ها فراهم آورد.

شکل۲، طیف‌های بازتابی (Reflectance Spectra) نمونه‌های دو رقم آلو شامل آلو خرمایی (الف) و آلو خونی (ب) را در گستره طول‌موج ۴۲۰ تا ۱۰۷۲ نانومتر به تصویر می‌کشد. همان‌طور که از پراکندگی وسیع طیف‌ها در هر دو نمودار (الف و ب) مشهود است، الگوهای طیفی تنوع قابل‌توجهی را نشان می‌دهند. این تنوع در طیف‌های بازتابی عمدتاً به تفاوت‌های ترکیبات شیمیایی و ساختاری درون هر نمونه آلو، از جمله مراحل مختلف رسیدگی، و همچنین به اختلافات ظریف در رنگدانه و بافت هر میوه نسبت داده می‌شود. با دقت بیشتر به نمودارها، می‌توان الگوهای کلی مشترکی را مشاهده کرد: در هر دو رقم، یک پیک بازتابی در محدوده ۶۱۵ نانومتر (نزدیک به نور سبز) و یک ناحیه جذب قوی‌تر در محدوده ۶۹۰–۶۸۰ نانومتر (نزدیک به نور قرمز) دیده می‌شود که ممکن است به حضور کلروفیل (حتی مقادیر اندک آن در مراحل پایانی رسیدگی) یا سایر رنگدانه‌ها مرتبط باشد. در بخش مادون‌قرمز نزدیک (بالاتر از ۷۵۰ نانومتر)، شدت بازتاب به‌طور کلی کاهش می‌یابد. بااین‌حال، تفاوت‌های محسوسی نیز وجود دارد؛ به‌عنوان مثال، در آلو خونی (ب)، به نظر می‌رسد شدت بازتاب کلی در مقایسه با آلو خرمایی (الف) بالاتر است، که می‌تواند نشان‌دهنده تفاوت در سطح و ساختار پوست یا محتوای آب باشد. این اختلافات طیفی زیربنای شناسایی و کمی‌سازی خواص فیزیکوشیمیایی میوه‌ها با استفاده از روش‌های فراطیفی هستند.

جدول ۲، آماره‌های توصیفی مقدار pH را برای نمونه‌های دو رقم آلو مورد مطالعه، خرمایی و خونی، ارائه می‌دهد. مشاهده می‌شود که هر دو رقم، طیف وسیعی از مقادیر pH را در بر می‌گیرند: برای آلو خرمایی، pH از ۳/۶ تا ۴/۲ متغیر است، در حالی‌که برای آلو خونی این دامنه بین ۳/۱۵ تا ۴/۴۴ قرار دارد. این دامنه وسیع مقادیر pH در هر دو رقم، یک مزیت کلیدی برای توسعه مدل‌های رگرسیونی به‌شمار می‌رود، چرا که به مدل‌ها اجازه می‌دهد تا ارتباط پیچیده بین الگوهای طیف بازتابی و سطوح متنوع pH را به‌طور جامع‌تری بیاموزند

1- Early Stopping
2- Epochs

و در نتیجه، از قوت پیش‌بینی بالاتری برخوردار باشند. با بررسی دقیق‌تر، تفاوت‌های مشخصی در آماره‌های pH بین دو رقم مشاهده می‌شود. آلو خرمایی دارای میانگین pH بالاتری (۳/۹۰۹) نسبت به آلو خونی (۳/۷۳۷۵) است. این اختلاف در میانگین pH می‌تواند به تفاوت‌های فیزیولوژیکی و ترکیبات اسیدی موجود در این دو رقم مرتبط باشد. علاوه بر این، انحراف معیار برای آلو خونی (۰/۴۱۰۲) به مراتب بیشتر از آلو خرمایی (۰/۱۷۶۸) است. این نشان‌دهنده پراکنش (تنوع) بیشتر در مقادیر pH بین نمونه‌های آلو خونی است، در حالی‌که آلو خرمایی همگنی بیشتری در pH خود دارد. این پراکندگی بالاتر در آلو خونی ممکن است به تفاوت‌های بیشتر در مرحله رسیدگی یا عوامل محیطی مختلف در زمان برداشت این رقم بازگردد.

ارتباط میان این تفاوت‌های pH در جدول ۲ و الگوهای طیفی مشاهده‌شده در شکل ۲، قابل‌تأمل است. تفاوت‌های فاحش در ویژگی‌های طیفی (مثلاً در نواحی جذب رنگدانه‌ها یا جذب آب) بین دو رقم آلو، تا حدی می‌تواند ناشی از همین اختلافات در میانگین و پراکندگی pH باشد. اسیدیته میوه (که با pH نشان داده می‌شود) بر ساختار سلولی، فعالیت آنزیمی و در نتیجه بر ویژگی‌های نوری و بازتابی میوه تأثیر می‌گذارد. این همبستگی، اهمیت حیاتی بهره‌گیری از کل بازه طیفی مرئی–مادون‌قرمز نزدیک را برای ساخت مدل‌های پیش‌بینی pH تایید می‌کند.

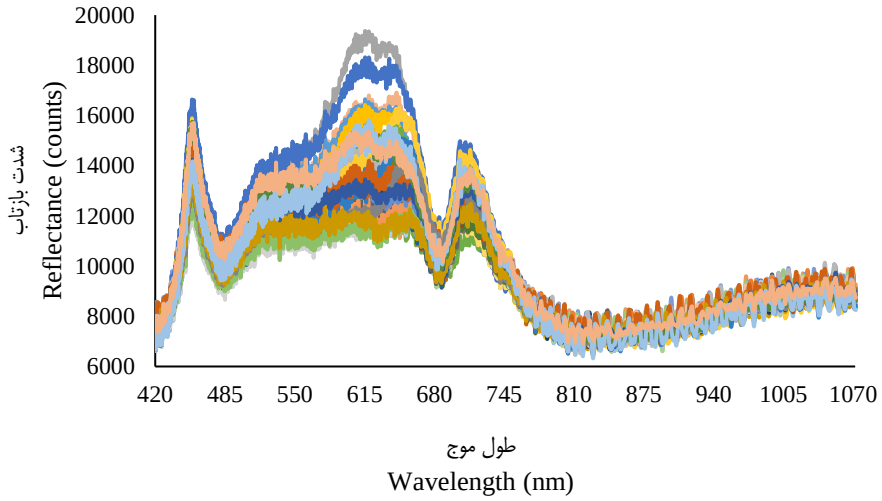

الف (a)

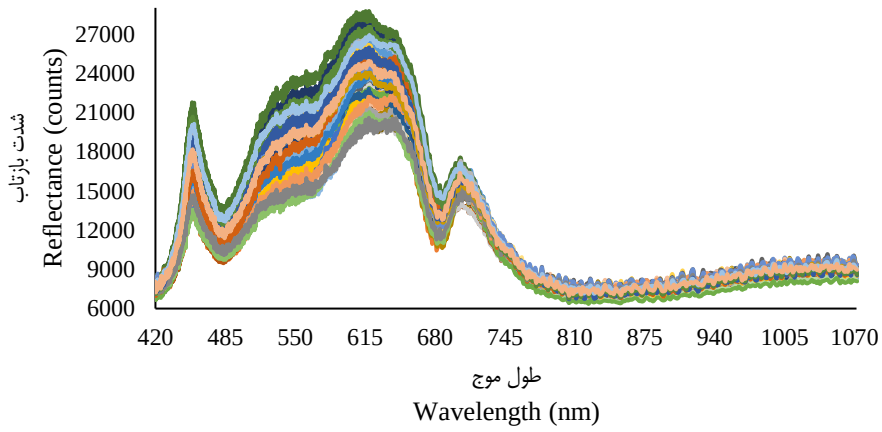

ب (b)

شکل ۲– نمودار طیف‌های بازتابی نمونه‌های (الف) آلو خرمایی و (ب) خونی اندازه‌گیری‌شده با سامانه تصویربرداری فراطیفی

Fig. 2. Reflectance spectra of (a) Khormaei and (b) Khoni plum samples measured by hyperspectral imaging system

جدول ۲- آمار توصیفی مقدار pH در دو رقم آلو

Table 2- Descriptive statistics of pH values in two varieties of plums

رقم Variety	مینیمم Minimum	ماکزیمم Maximum	انحراف معیار Standard deviation	میانگین Mean
خرمایی Khormaei	3.6	4.2	0.1768	3.909
خونی Khoni	3.15	4.44	0.4102	3.7375

استفاده از طیف وسیع داده‌های طیفی، به مدل این قابلیت را می‌دهد که ویژگی‌های شیمیایی و فیزیکی مرتبط با pH را، با وجود تنوع بیولوژیکی، به‌طور مؤثرتری استخراج کرده و در نهایت به ساخت مدل‌های پیش‌بینی قابل‌اعتماد و عمومی‌تر برای هر دو رقم آلو منجر شود.

ارزیابی عملکرد مدل رگرسیون حداقل مربعات جزئی و تأثیر پیش‌پردازش‌های طیفی

پس از تحلیل کیفی طیف‌ها و بررسی توزیع pH، گام بعدی ارزیابی مدل‌های رگرسیونی برای پیش‌بینی کمی این ویژگی می‌باشد به‌منظور بهینه‌سازی دقت مدل‌سازی pH در آلو، تأثیر انواع روش‌های پیش‌پردازش طیفی بر عملکرد مدل PLSR مورد بررسی قرار گرفت. نتایج حاصل برای رقم خرمایی در جدول ۳ و برای رقم خونی در جدول ۴ خلاصه شده‌اند.

جدول ۳ عملکرد مدل PLSR را برای رقم آلو خرمایی با ۹ مؤلفه بهینه، تحت تأثیر پیش‌پردازش‌های مختلف نشان می‌دهد. مشاهده می‌شود که حتی بدون پیش‌پردازش (ردیف ۱)، مدل PLSR توانایی قابل‌قبولی در پیش‌بینی pH رقم خرمایی از خود نشان داده است، به‌طوری‌که در مرحله آزمون به R^2=۰/۷۰۴۵ و RMSE=۰/۰۷۵۶ و RPD=۱/۹ دست‌یافته است. بر اساس سیستم طبقه‌بندی RPD، این مدل در دسته مناسب تا خوب (۱/۸ < RPD < ۲) قرار می‌گیرد که نشان‌دهنده قابلیت استفاده آن برای ارزیابی و پیش‌بینی‌های کمی است.

با اعمال پیش‌پردازش‌های مختلف، بهبودهایی در عملکرد مدل مشاهده می‌شود. به‌عنوان‌مثال، پیش‌پردازش فیلتر میانگین متحرک منجر به بهبود R^2 آزمون به ۰/۷۸۸۳ و کاهش RMSE به ۰/۰۶۴۰ گردیده است، که RPD را به ۲/۲۴ افزایش می‌دهد. این مقدار RPD مدل را در دسته بسیار خوب (۲ < RPD < ۲/۵) قرار می‌دهد. همچنین، فیلتر گوسی با R^2= ۰/۸۲۰۳ و RMSE=۰/۰۵۹۰ و RPD=۲/۴۴، بهترین عملکرد را در مرحله آزمون برای رقم خرمایی به نمایش گذاشته است و آن را در آستانه یک مدل بسیار خوب قرار می‌دهد. این نشان می‌دهد که هموارسازی (smoothing) طیف‌ها می‌تواند به‌طور مؤثری نویز را کاهش داده و اطلاعات مفید مربوط به pH را آشکار سازد. عملکرد بهترین مدل PLSR در مرحله آزمون رقم آلو خرمایی مربوط به فیلتر گوسی به‌عنوان یک معیار پایه برای مقایسه با مدل‌های غیرخطی، در شکل ۳-الف به‌صورت بصری نشان داده شده است.

برخی پیش‌پردازش‌ها مانند SNV، MSC، فیلتر میانه، Savitzky-Golay و Detrend نیز عملکرد مدل را در مرحله آزمون بهبود بخشیده‌اند (با RPD بالای ۲). با این‌حال، پیش‌پردازش‌های مشتق اول و مشتق دوم و مرکزکردن میانگین (Mean Centering) (ردیف‌های ۴، ۵ و ۱۲) عملاً تغییری در نتایج ایجاد نکرده‌اند که احتمالاً به دلیل عدم نیاز به تغییرات شدید در دامنه طیفی یا حذف روند در این مجموعه داده خاص بوده است. همچنین، نرمال‌سازی در مقایسه با سایر روش‌ها عملکرد کمی ضعیف‌تر (RPD=۱/۷۶) را در مرحله آزمون نشان داده است.

جدول ۴، نتایج مدل‌سازی PLSR را برای رقم آلو خونی با ۱۰ مؤلفه بهینه ارائه می‌دهد. مشاهده می‌شود که رقم خونی به‌طور کلی دارای دقت پیش‌بینی بالاتری نسبت به رقم خرمایی است. حتی بدون پیش‌پردازش (ردیف ۱)، مدل PLSR برای آلو خونی به R^2=۰/۸۲۷۶ و RMSE=۰/۱۷۰۵ و RPD=۲/۴۹ در مرحله آزمون دست یافته است. این مقدار RPD مدل را در دسته بسیار خوب قرار می‌دهد.

در میان پیش‌پردازش‌ها، نرمال‌سازی بهترین عملکرد را برای آلو خونی به ارمغان آورده است، با R^2=۰/۸۶۱۲ و RMSE=۰/۱۵۳۰ و RPD=۲/۷۷ در مرحله آزمون. این RPD نشان‌دهنده یک مدل عالی (RPD >۲/۵) است که توانایی بسیار بالایی در پیش‌بینی pH رقم خونی دارد. این نتیجه حاکی از آن است که حذف تأثیرات دامنه یا مقیاس از سیگنال طیفی برای این رقم بسیار مؤثر بوده است.

سایر پیش‌پردازش‌ها مانند میانگین متحرک (RPD =۲/۶۱)، فیلتر گوسی (RPD =۳/۰۱)، فیلتر میانه (RPD =۲/۶۴)، Savitzky-Golay (RPD =۲/۹۶) و Detrend (RPD =۲/۶۶) نیز عملکرد بسیار خوبی را در مرحله آزمون از خود نشان داده‌اند و مدل‌ها را در دسته‌های بسیار خوب تا عالی قرار داده‌اند. در این رقم نیز، پیش‌پردازش‌های مشتق اول، مشتق دوم و مرکز کردن میانگین تأثیر چشمگیری بر نتایج آزمون نداشته‌اند.

جدول ۳- نتایج مدل‌سازی رگرسیون حداقل مربعات جزئی (PLSR) رقم خرمایی با انواع پیش‌پردازش‌های طیفی (۹ مؤلفه)

Table 3- Results of the Partial Least Squares Regression (PLSR) model for the Khormaei plum variety with various spectral preprocessing methods (9 Components)

ردیف No	پیش‌پردازش Preprocessing	آموزش Training			اعتبارسنجی Validation			آزمون Test		
		R^2	RMSE	RPD	R^2	RMSE	RPD	R^2	RMSE	RPD
1	بدون پیش‌پردازش No Preprocessing	0.9769	0.0267	6.65	0.9525	0.0424	4.74	0.7045	0.0756	1.9
2	SNV	0.988	0.0193	9.22	0.8999	0.0616	3.26	0.7591	0.0683	2.1
3	MSC	0.9834	0.0226	7.84	0.8632	0.072	2.79	0.7052	0.0756	1.9
4	مشتق اول First Derivative	0.9769	0.0267	6.65	0.9525	0.0424	4.74	0.7045	0.0756	1.9
5	مشتق دوم Second Derivative	0.9769	0.0267	6.65	0.9525	0.0424	4.74	0.7045	0.0756	1.9
6	نرمال‌سازی Normalisation	0.9826	0.0232	7.67	0.9432	0.0464	4.33	0.6561	0.0816	1.76
7	میانگین متحرک Moving Average	0.9742	0.0282	6.29	0.9084	0.0589	3.41	0.7883	0.064	2.24
8	فیلتر گوسی Gaussian Filter	0.9655	0.0326	5.44	0.8886	0.065	3.09	0.8203	0.059	2.44
9	فیلتر میانه Median Filter	0.9889	0.0185	9.6	0.9152	0.0567	3.55	0.7176	0.074	1.94
10	ساویتزکی-گولای Savitzky-Golay	0.9792	0.0253	7.01	0.9008	0.0613	3.28	0.7716	0.0665	2.16
11	حذف روند Detrending	0.985	0.0215	8.26	0.9419	0.0469	4.28	0.7401	0.0709	2.03
12	مرکز کردن میانگین Mean Centering	0.9769	0.0267	6.65	0.9525	0.0424	4.74	0.7045	0.0756	1.9

نتایج حاصل از جداول ۳ و ۴ به‌وضوح نشان می‌دهند که پیش‌پردازش داده‌های طیفی نقش حیاتی در بهبود دقت مدل‌های پیش‌بینی pH با استفاده از PLSR دارد. انتخاب نوع پیش‌پردازش بهینه، بسته به ویژگی‌های خاص طیف و رقم مورد مطالعه، متفاوت است؛ در حالی‌که میانگین متحرک و فیلتر گوسی برای آلو خرمایی بهترین نتایج را داشت، نرمال‌سازی و فیلتر گوسی بهترین عملکرد را برای آلو خونی نشان دادند. عملکرد بهترین مدل PLSR در مرحله آزمون رقم آلو خونی مربوط به فیلتر گوسی به‌عنوان یک معیار پایه برای مقایسه با مدل‌های غیرخطی، در شکل ۳-ب به‌صورت بصری نشان داده شده است.

به‌طورکلی، مدل‌سازی pH برای آلو خونی (با بهترین RPD حدود ۳/۰۱) نسبت به آلو خرمایی (با بهترین RPD حدود ۲/۴۴) دقت بالاتری را نشان داده است. این تفاوت در دقت می‌تواند به دلیل تفاوت در ویژگی‌های طیفی ذاتی و دامنه pH وسیع‌تر آلو خونی باشد که فرصت بهتری برای مدل جهت یادگیری و تمایز فراهم می‌کند، یا حتی به دلیل تفاوت در پیچیدگی ماتریس شیمیایی هر رقم باشد. توانایی مدل PLSR در دستیابی به RPDهای بالای ۲ در هر دو رقم، بر پتانسیل بالای تکنیک تصویربرداری فراطیفی در ارزیابی غیرمخرب کیفیت داخلی میوه‌های آلو، به‌ویژه pH، تأکید می‌کند. در راستای تایید و گسترش یافته‌های این پژوهش، مقایسه نتایج حاصل با پژوهش‌های مشابه در زمینه ارزیابی غیرمخرب میوه‌ها حائز اهمیت است. به‌عنوان مثال، در مطالعه‌ای دیگر، پتانسیل تصویربرداری فراطیفی در محدوده ۱۰۰۰ تا ۱۵۵۰ نانومتر برای ارزیابی غیرمخرب مؤلفه‌های شیمیایی نظیر رطوبت، pH و مواد جامد محلول (SSC) در گوجه‌فرنگی‌های سالم مورد بررسی قرار گرفت. در آن تحقیق، مدل PLSR مبتنی بر پیش‌پردازش مشتق اول ساویتزکی-گولای بهترین عملکرد را برای pH نشان داد که با ضریب تعیین ۰/۶۹ و ریشه میانگین مربعات خطای پیش‌بینی ۰/۰۶ به‌دست آمد (Rahman *et al.*, 2017). علاوه بر این، در مطالعه‌ای توسط رضوی و همکاران (Razavi, Sharabiani, Tahmasebi, Grassi, & Szymanek, 2025)، پتانسیل طیف‌سنجی Vis-NIR (در محدوده ۵۴۰ تا ۹۶۰ نانومتر) برای ارزیابی پارامترهای کیفی سیب رقم رد دلشیز[1]، ازجمله

1- Red Delicious

pH، TA، اسید اسکوربیک، سفتی، محتوای مواد جامد محلول (SSC) و آنتوسیانین‌ها، با استفاده از روش‌های یادگیری ماشین مورد بررسی قرار گرفت. در آن تحقیق، عملکرد قوی برای تمامی رگرسیون‌های آزمایشی (PLSR, PCR, MLR, SVM-R و ANN) در فازهای اعتبارسنجی متقابل، اعتبارسنجی و آزمون به‌دست آمد. به‌طور خاص، مدل SVM-R در پیش‌بینی pH سیب به R^2=۰/۹۳۵ و RPD=۳/۶۳۶ دست یافت.

این مقایسه‌ها نشان می‌دهد که هر دو تحقیق مورد بررسی، مشابه پژوهش حاضر، بر کارایی بالای طیف‌سنجی در ارزیابی غیرمخرب میوه‌ها تأکید دارند، هرچند در گونه میوه، محدوده طیفی و پارامترهای هدف متفاوت بوده‌اند. RPD حاصل برای pH در مطالعه رضوی بر روی سیب (۳/۶۳۶) و ضریب تعیین ۰/۶۹ برای pH گوجه‌فرنگی در مطالعه دیگر، نشان‌دهنده مدل‌های قوی و قابل‌قبول هستند. در پژوهش حاضر نیز، مدل PLSR برای آلو خونی با بهترین RPD حدود ۳/۰۱ و برای آلو خرمایی با RPD حدود ۲/۴۴، عملکرد بسیار خوبی در پیش‌بینی pH از خود نشان داد. این نتایج در راستای یک روند تحقیقاتی موفق قرار دارد که بر اهمیت انتخاب طول‌موج و استفاده از روش‌های هوشمند برای بهینه‌سازی مدل‌ها و کاربردهای صنعتی تأکید دارد.

کاهش ابعاد داده‌های طیفی و انتخاب طول‌موج‌های مؤثر

تحلیل داده‌های طیفی، که از بازتاب نمونه‌های آلو خرمایی و خونی در محدوده ۴۲۰ تا ۱۰۷۰ نانومتر (مطابق شکل ۲) به‌دست آمده‌اند، حجم وسیعی از اطلاعات را در قالب تعداد زیادی متغیر (طول‌موج) شامل می‌شود. این حجم بالای داده‌ها، چالش‌های مهمی نظیر پیچیدگی محاسباتی و پدیده هم‌خطی شدید را در پی دارد که می‌تواند کارایی و دقت مدل‌های پیش‌بینی را کاهش دهد. از این‌رو، کاهش ابعاد داده‌ها و انتخاب طول‌موج‌های مؤثر، نه تنها برای ساده‌سازی مدل و بهبود دقت پیش‌بینی ضروری است، بلکه با افزایش قابلیت تعمیم‌پذیری و کاهش زمان محاسبات، به پایداری و تفسیرپذیری بهتر مدل نیز کمک شایانی می‌کند. این فرآیند حیاتی، با تمرکز بر استخراج اطلاعات کلیدی از طول‌موج‌هایی که بیشترین ارتباط را با ویژگی‌های هدف (مانند pH) دارند، مسیر را برای مدل‌سازی‌های کارآمد هموار می‌سازد.

جدول ٤- نتایج مدل‌سازی رگرسیون حداقل مربعات جزئی (PLSR) رقم خونی با انواع پیش‌پردازش‌های طیفی (۱۰ مؤلفه)

Table 4- Results of the Partial Least Squares Regression (PLSR) model for the Khoni plum variety with various spectral preprocessing methods (10 components)

ردیف No	پیش‌پردازش Preprocessing	آموزش Training			اعتبارسنجی Validation			آزمون Test		
		R^2	RMSE	RPD	R^2	RMSE	RPD	R^2	RMSE	RPD
1	بدون پیش‌پردازش No Preprocessing	0.9927	0.0342	11.85	0.9787	0.0624	7.07	0.8276	0.1705	2.49
2	SNV	0.9877	0.0445	9.1	0.9108	0.1277	3.46	0.834	0.1673	2.54
3	MSC	0.9878	0.0443	9.13	0.9113	0.1273	3.47	0.8363	0.1661	2.55
4	مشتق اول First Derivative	0.9927	0.0342	11.85	0.9787	0.0624	7.07	0.8276	0.1705	2.49
5	مشتق دوم Second Derivative	0.9927	0.0342	11.85	0.9787	0.0624	7.07	0.8276	0.1705	2.49
6	نرمال‌سازی Normalisation	0.9953	0.0274	14.75	0.9719	0.0717	6.16	0.8612	0.153	2.77
7	میانگین متحرک Moving Average	0.9848	0.0493	8.21	0.9593	0.0862	5.12	0.8435	0.1624	2.61
8	فیلتر گوسی Gaussian Filter	0.9809	0.0554	7.31	0.9238	0.118	3.74	0.8819	0.1411	3.01
9	فیلتر میانه Median Filter	0.9941	0.0307	13.18	0.9648	0.0802	5.5	0.8465	0.1609	2.64
10	ساویتزکی-گولای Savitzky-Golay	0.9864	0.0468	8.65	0.9576	0.088	5.02	0.878	0.1434	2.96
11	حذف روند Detrending	0.9941	0.0308	13.15	0.9727	0.0706	6.25	0.8495	0.1593	2.66
12	مرکز کردن میانگین Mean Centering	0.9927	0.0342	11.85	0.9787	0.0624	7.07	0.8276	0.1705	2.49

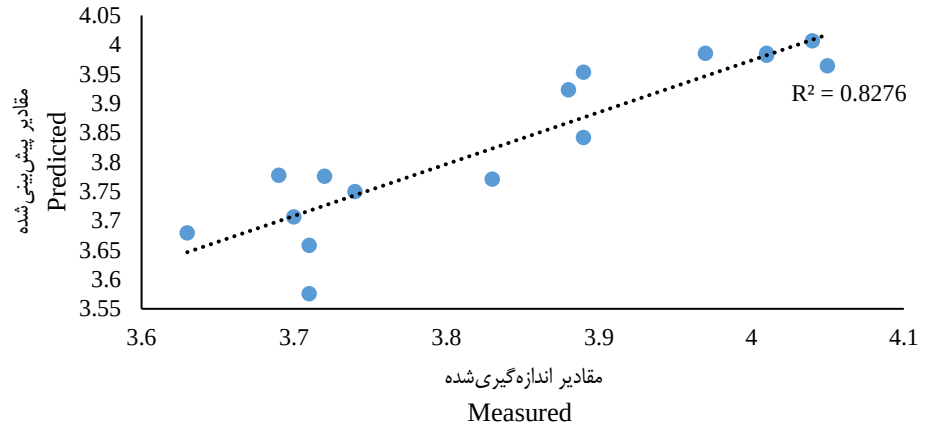

(a) الف

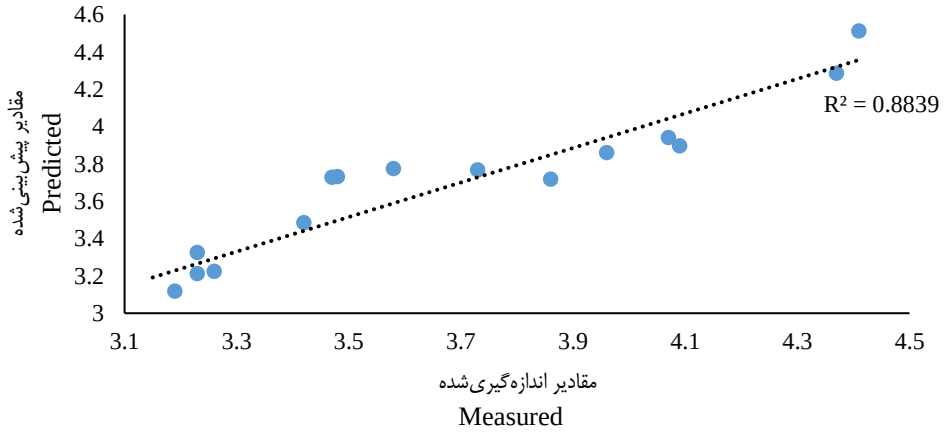

(b) ب

شکل ۳– نمودار پراکنش مقادیر pH اندازه‌گیری‌شده در برابر مقادیر پیش‌بینی‌شده برای بهترین مدل PLSR در محدوده طیف کامل با پیش‌پردازش فیلتر گوسی بر روی مجموعه آزمون ارقام: الف) خرمایی، ب) خونی

Fig. 3. Scatter plot of the measured versus predicted pH values for the best PLSR model on the full spectrum range with Gaussian filter preprocessing on the test set for varieties: (a) Khormaei, (b) Khoni

به‌منظور شناسایی بهینه‌ترین طول‌موج‌ها، پنج الگوریتم فراابتکاری شامل WCC، LCA، PSO، ACO و LA مورد ارزیابی قرار گرفتند. عملکرد این الگوریتم‌ها بر اساس معیارهای میانگین RMSE، میانگین همبستگی و زمان اجرا، برای هر دو نوع آلو تحلیل شد. برای آلو خرمایی، نتایج (مندرج در شکل ۴) نشان دادند که الگوریتم‌های PSO و LA در کاهش خطا و افزایش همبستگی بهترین عملکرد را داشتند؛ PSO با کمترین RMSE نهایی (۷۱/۹۱) و همبستگی بالا (۰/۹۱۵)، و LA با همبستگی نهایی برتر (۰/۹۲۳) و RMSE نزدیک (۷۱/۴۰) برجسته ظاهر شدند. در بعد کارایی محاسباتی، PSO با زمان اجرای تنها ۵/۴۶ ثانیه، برتری قابل‌توجهی نسبت به سایر الگوریتم‌ها نشان داد. این الگو در مورد آلو خونی نیز تکرار شد (شکل ۵)، هرچند الگوریتم ACO با کمترین RMSE (۴۳/۳۲) و بالاترین همبستگی (۰/۹۸۱) و به دنبال آن LCA با عملکردی بسیار نزدیک، دقت بالاتری را به نمایش گذاشتند. بااین‌حال، PSO مجدداً با زمان اجرای ۵/۶۴ ثانیه، سریع‌ترین روش باقی ماند که مزیت آن را در سرعت محاسبات تایید می‌کند. طول‌موج‌های منتخب حاصل از الگوریتم PSO، که بر اساس درجه اهمیت مرتب شده‌اند، در جدول ۵ ارائه شده و در مراحل بعدی مدل‌سازی و تحلیل مورد استفاده قرار گرفته‌اند.

در راستای رویکردهای مشابه در انتخاب طول‌موج‌های مؤثر، پژوهش لطیفی عموقین و همکاران (Latifi Amoghin *et al.*, 2024b) بر روی سه رقم فلفل دلمه‌ای (در محدوده ۱۱۵۰–۳۵۰

نـانومتر) نیـز از ترکیـب ماشـین‌های بـردار پشـتیبان (SVM) بـا الگوریتم‌های ژنتیک (GA)، بهینه‌سازی ازدحام ذرات (PSO)، کلـونی مورچـه (ACO) و الگـوریتم رقابـت امپریالیسـتی (ICA) بـرای بهینه‌سازی انتخاب طول‌موج استفاده کرده‌اند. در آن مطالعـه، SVM-PSO بـه‌عنوان روش بهینـه انتخـاب طول‌مـوج بـر اسـاس RPD، RMSE و مقـادیر همبسـتگی شـناخته شـد و بـه‌طور متوسـط ۱۵ طول‌موج مؤثر شناسایی گردید. این همخـوانی در نتـایج، یعنـی مـؤثر بودن PSO در انتخاب طول‌موج‌های کلیدی، حتی با وجود تفـاوت در مدل پایه ترکیبی (در پژوهش حاضر DT-PSO و در مطالعـه لطیفـی SVM-PSO)، بر توانایی بالای این الگوریتم در کاهش ابعاد داده‌های طیفی و استخراج اطلاعات حیاتی تأکید می‌کند.

با در نظر گرفتن این نتایج جـامع، انتخـاب الگـوریتم برتـر بـرای مدل‌سازی‌های بعدی با شبکه‌های عصـبی مصـنوعی نیازمنـد تـوازن دقیق بین دقت پیش‌بینی و کارایی محاسباتی است. برای آلو خرمایی، الگوریتم PSO به دلیل تعـادل عـالی میـان دقـت (RMSE پـایین و همبستگی بالا) و به‌ویژه زمان اجرای فوق‌العاده پایین، به‌عنوان گزینه برتر برای انتخاب طول‌موج‌ها توصیه می‌شود. اگرچه برای آلو خـونی، ACO و LCA از نظر دقت کمـی بهتـر از PSO عمـل کردنـد، امـا سرعت بالای PSO آن را به گزینه‌ای بسیار جذاب تبدیل می‌کنـد. بـا توجه به این‌که مدل‌های ANN خود نیازمند منابع محاسباتی هسـتند، انتخاب الگوریتمی مانند PSO که عـلاوه بـر دقـت مناسـب، کـارایی محاسباتی بالایی در مرحله انتخاب ویژگی دارد، به بهینه‌سازی زمـان کلی مدل‌سازی کمک شایانی خواهد کرد؛ بنابراین، با در نظـر گـرفتن هر دو فاکتور دقـت و کـارایی محاسـباتی، الگـوریتم PSO بـه‌عنوان روشی بهینه برای استخراج زیرمجموعـه‌ای از طول‌موج‌هـای کلیـدی پیشنهاد می‌گردد.

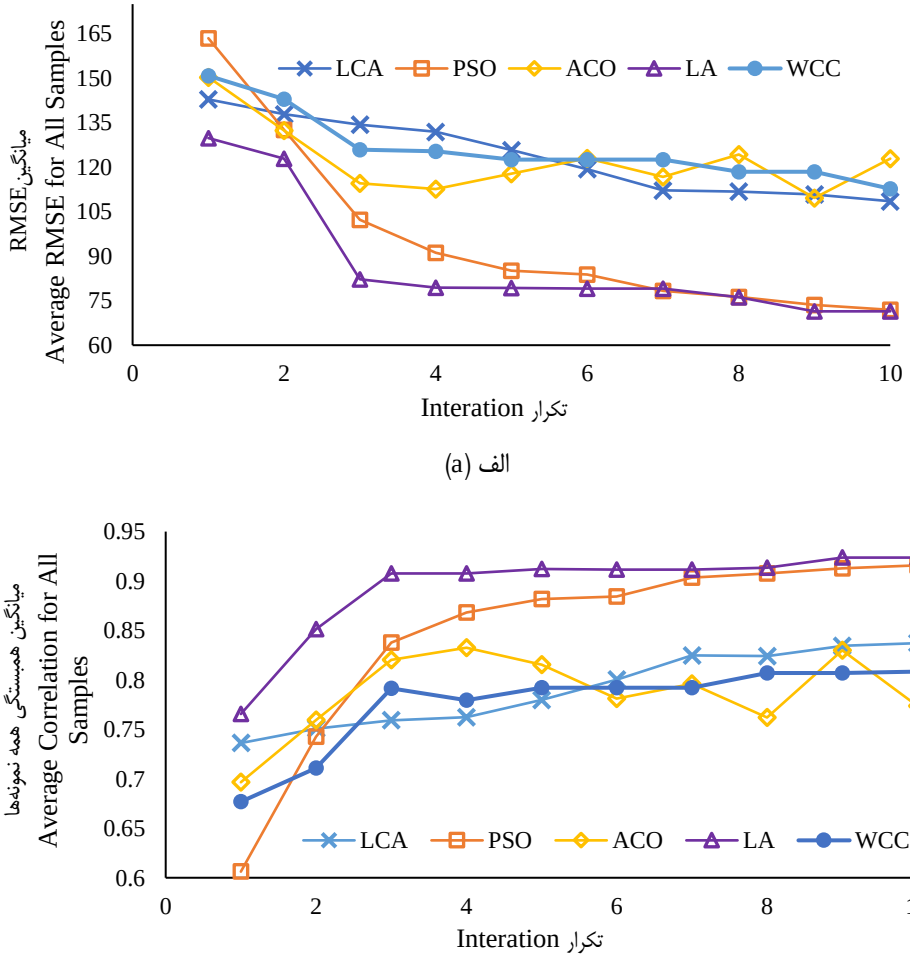

شکل ٤- عملکرد مدل DT همراه با الگوریتم‌های مختلف برای نمونه‌های رقم خرمایی: الف) میانگین RMSE برای همه نمونه‌ها، ب) میانگین همبستگی همه نمونه‌ها

Fig. 4. Performance of the DT model with various algorithms for Khormaei plum samples: (a) Average RMSE for all samples, (b) Average correlation for all samples

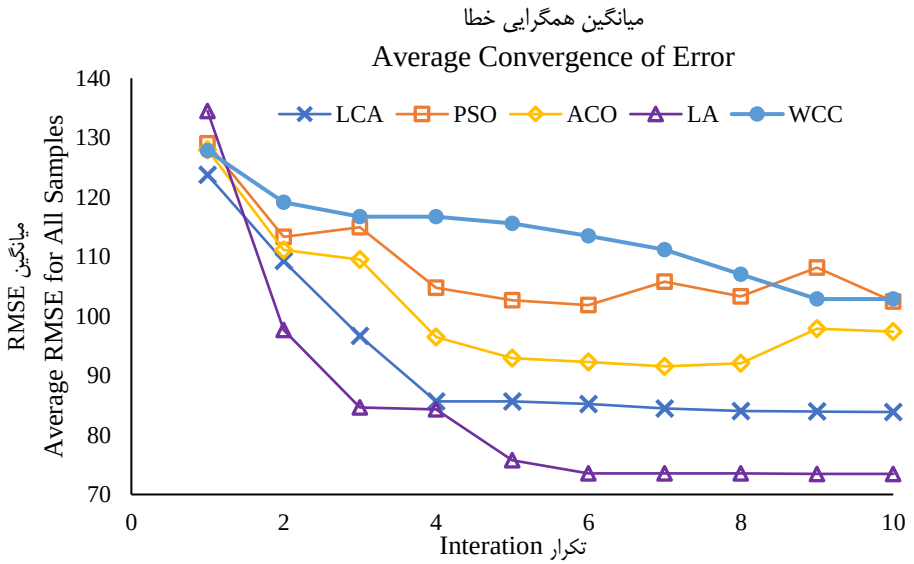

(a) الف

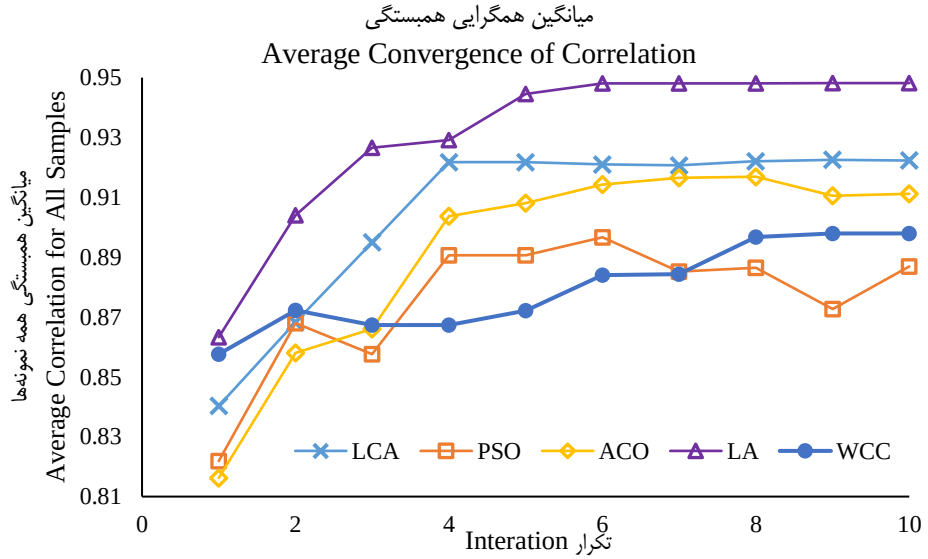

(b) ب

شکل ۵- عملکرد مدل DT همراه با الگوریتم‌های مختلف برای نمونه‌های رقم خونی الف) میانگین RMSE برای همه نمونه‌ها، ب) میانگین همبستگی همه نمونه‌ها

Fig. 5. Performance of the DT model with various algorithms for Khoni plum samples: (a) Average RMSE for all samples, (b) Average correlation for all samples

جدول ۵- طول‌موج‌های منتخب الگوریتم DT-PSO

Table 5- Selected wavelengths by DT-PSO algorithm

رقم **Variety**	**طول‌موج‌های موثر انتخاب‌شده (نانومتر)** **Selected EWs (nm)**
خرمایی Khormaei	519.967, 567.227, 438.989, 471.704, 861.47, 688.055, 571.977, 866.435, 442.203, 746.972, 722.265, 462.389, 507.02, 428.224, 1021.683
خونی Khoni	988.625, 819.5, 432.232, 636.415, 435.922, 630.429, 559.92, 741.437, 527.776, 460.428, 962.516, 950.06, 512.792, 968.704, 794.096

این انتخاب تضمین می‌کند که داده‌ها با حداقل ابعاد ممکن، حاوی اطلاعات کافی برای توسعه مدل‌های ANN دقیق و پایدار باشند و درعین‌حال، فرآیند کلی مدل‌سازی به لحاظ زمانی نیز بهینه گردد.

مدل‌سازی طول‌موج‌های منتخب DT-PSO با استفاده از روش‌های PLSR و ANN

برای شناسایی بهینه‌ترین طول‌موج‌ها و ارزیابی جامع عملکرد مدل‌ها، پنج الگوریتم فراابتکاری به‌کار گرفته شدند. پس از انتخاب طول‌موج‌های مؤثر توسط PSO (جدول ۵)، نتایج مدل‌سازی با استفاده از روش PLSR و ANN بر روی این طول‌موج‌های منتخب مورد تحلیل قرار گرفت. در بررسی رقم آلو خرمایی، نتایج مدل‌سازی PLSR با طول‌موج‌های منتخب PSO (جدول ۶) حاکی از آن بود که رویکردهایی نظیر بدون پیش‌پردازش، مشتق اول و دوم، و مرکز کردن میانگین با مقادیر تقریباً یکسان در محله آزمون R^2=۰/۶۴۰۴ و RPD=۱/۷۲، عملکرد متوسطی را در پیش‌بینی برای داده‌های جدید از خود نشان دادند. این RPD که کمتر از ۲ است، اگرچه برای تخمین اولیه مفید است، اما دقت لازم برای کاربردهای حساس‌تر نظیر غربالگری دقیق یا کنترل کیفیت را ندارد و نشان‌دهنده لزوم بهبود بیشتر مدل است. در مقابل، مدل ANN که قابلیت بالاتری در کشف روابط غیرخطی دارد، برای آلو خرمایی (جدول ۸) با پیش‌پردازش‌های بدون پیش‌پردازش و فیلتر میانه به R^2 آزمون حدود ۰/۷۶ و RPD=۲/۱۲ دست یافت. این بهبود در RPD، قابلیت ANN را برای غربالگری قابل‌قبول نشان می‌دهد و توانایی آن در استخراج اطلاعات از طول‌موج‌های منتخب را برجسته می‌کند. نمودار پراکنش مقادیر اندازه‌گیری‌شده در برابر مقادیر پیش‌بینی‌شده برای این مدل در شکل ۶-الف ارائه شده است. در مورد رقم آلو خونی، مدل‌های PLSR با طول‌موج‌های منتخب PSO (جدول ۷) با پیش‌پردازش‌های ساویتزکی-گولای و فیلتر میانه به‌ترتیب به RPD ۲/۸۵ و ۲/۸۳ در فاز آزمون دست یافتند. این مقادیر RPD که نزدیک به ۳ هستند، دلالت بر عملکرد قوی مدل برای کاربردهای کنترل کیفیت در سطح قابل‌اعتماد دارند. بااین‌حال، اوج عملکرد در مدل‌سازی ANN برای آلو خونی (جدول ۹) حاصل شد؛ جایی‌که پیش‌پردازش فیلتر گوسی با R^2 آزمون ۰/۹۸۳۴ و RPD ۸/۰۱، و بدون پیش‌پردازش با RPD برابر با ۷/۴۵، نتایج قابل‌توجه را به نمایش گذاشتند که به معنی قابلیت این مدل‌ها برای اندازه‌گیری کمی بسیار دقیق و حتی کاربردهای تحقیقاتی پیشرفته است. این نتایج خارق‌العاده به‌صورت بصری در شکل ۶-ب (با تأکید بر مدل فیلتر گوسی) قابل‌مشاهده هستند.

معماری و نقش شبکه عصبی مصنوعی در مدل‌سازی

معماری شبکه عصبی مصنوعی، به‌ویژه تعداد لایه‌های پنهان و تعداد نورون‌ها در هر لایه، نقش تعیین‌کننده‌ای در قابلیت مدل برای یادگیری و استخراج الگوهای پیچیده از داده‌ها دارد. همان‌طور که در ستون بهترین ساختار شبکه جداول ۸ و ۹ مشاهده می‌شود، ساختارهای مختلفی برای هر سناریو بهینه شده‌اند؛ از شبکه‌های ساده تک‌لایه‌ای با تعداد کمی نورون (مانند ۵ یا ۱۰) تا ساختارهای پیچیده‌تر با چندین لایه پنهان و نورون‌های بیشتر (مانند [۵ ۵] یا [۱۰ ۱۵ ۲۰]). انتخاب بهینه این ساختار، نه تنها بر توانایی مدل در برازش دقیق داده‌های آموزشی تأثیر می‌گذارد، بلکه بر قابلیت تعمیم‌پذیری آن به داده‌های جدید نیز اثرگذار است. یک معماری نامناسب (بسیار ساده یا بسیار پیچیده) می‌تواند به‌ترتیب منجر به کم‌برازش[1] یا بیش‌برازش[2] شود. کم‌برازش به معنای عدم توانایی مدل در یادگیری الگوهای موجود در داده است، در حالی‌که بیش‌برازش به معنای یادگیری بیش از حد نویز و جزئیات غیرمفید از داده‌های آموزشی و در نتیجه عملکرد ضعیف بر روی داده‌های آزمون است. نتایج به‌دست‌آمده با ANN در این مطالعه، به‌خصوص برای آلو خونی، به‌خوبی نشان می‌دهد که با وجود کاهش ابعاد داده‌های ورودی، شبکه‌های عصبی با معماری بهینه قادرند روابط غیرخطی پیچیده موجود در طول‌موج‌های منتخب را با دقت فوق‌العاده‌ای استخراج کنند. این توانایی ANN در مدل‌سازی روابط غیرخطی، یک مزیت کلیدی نسبت به روش‌های خطی مانند PLSR است و به همین دلیل در بسیاری از موارد به عملکرد بهتری در فاز آزمون منجر شده است.

در پژوهشی مرتبط با ارزیابی غیرمخرب سیب، قابلیت استفاده از تصویربرداری فراطیفی VIS-NIR با قیمت پایین (در محدوده ۳۸۶–۱۰۲۸ نانومتر) برای پیش‌بینی رطوبت (MC) و pH سیب Pink Lady در سه مرحله رسیدگی مختلف مورد بررسی قرار گرفت. در آن مطالعه، از پنج الگوریتم یادگیری ماشین شامل PLSR, MLR, kNN, DT و ANN برای تحلیل داده‌ها استفاده شد. ویژگی‌های بهینه با استفاده از رویکرد انتخاب ویژگی Bootstrap Random Forest شناسایی شدند. در میان الگوریتم‌های آزمایشی، ANN بهترین عملکرد را برای رطوبت (R=۰/۷۵۶، RMSE=۰/۸۶۸) ارائه داد، اما برای پیش‌بینی pH عملکرد ضعیفی داشت (R=۰/۳۸۳، RMSE=۰/۰۴۴) (Kavuncuoğlu, Çetin, Yildirim, Nadimi, & Paliwal, 2023). این نتیجه در تضاد با یافته‌های برجسته پژوهش حاضر برای pH آلو است؛ جایی‌که ANN بر روی طول‌موج‌های منتخب توانست pH آلو خونی را با R^2=۰/۹۸۳۴ و

1- Underfitting
2- Overfitting

RPD=۸/۰۱ پیش‌بینی کند. این تفاوت فاحش در عملکرد pH نشان می‌دهد که در حالی‌که فناوری VIS-NIR HSI پتانسیل زیادی دارد، کارایی آن در پیش‌بینی pH ممکن است به شدت به گونه میوه، دامنه pH مورد بررسی، و به‌ویژه به روش‌های بهینه‌سازی مدل و انتخاب ویژگی بستگی داشته باشد. موفقیت قابل‌توجه پژوهش حاضر در پیش‌بینی pH آلو با روش ANN، بر ظرفیت بالای این‌رویکرد در مدیریت پیچیدگی‌های بیولوژیکی و طیفی و ارائه دقت بیش از انتظار تأکید می‌کند، حتی در شرایطی که مطالعات دیگر برای پارامتر مشابه در میوه‌های دیگر با چالش مواجه بوده‌اند.

برای ارزیابی تأثیر واقعی کاهش ابعاد، نتایج مدل‌سازی با طول‌موج‌های منتخب PSO با عملکرد مدل‌سازی PLSR بر روی طیف کامل داده‌ها (جداول ۳ و ۴) مقایسه شد. این مقایسه نشان داد که برای رقم آلو خرمایی، بهترین RPD آزمون در مدل PLSR با طیف کامل (جدول ۳) حدود ۲/۴۴ (با پیش‌پردازش میانگین متحرک) بود که اندکی از بهترین RPD در PLSR با طول‌موج‌های منتخب (۱/۷۲) بالاتر است. این تفاوت جزئی، می‌تواند ناشی از دست دادن برخی اطلاعات ریز در فرآیند کاهش ابعاد برای مدل خطی PLSR باشد. بااین‌حال، همان‌طور که قبلاً اشاره شد، مدل ANN با طول‌موج‌های منتخب (جدول ۸، RPD ۲/۱۲) توانست این شکاف را تا حد زیادی جبران کرده و عملکردی رقابتی ارائه دهد. در مورد آلو خونی، نتایج حتی چشم‌گیرتر بود؛ بهترین RPD آزمون در PLSR با طیف کامل (جدول ۴) حدود ۳/۰۱ (با فیلتر گوسی) بود که بسیار نزدیک به بهترین RPD در PLSR با طول‌موج‌های منتخب (۲/۸۵ با Savitzky-Golay) است. این تطابق نزدیک، نشان‌دهنده قابلیت بالای الگوریتم PSO در انتخاب طول‌موج‌هایی است که با وجود کاهش چشمگیر ابعاد داده‌ها، حاوی اطلاعات کافی برای حفظ دقت مدل‌های خطی هستند. از همه مهم‌تر، مدل ANN با طول‌موج‌های منتخب (جدول ۹) برای آلو خونی به RPD قابل‌توجه ۸/۰۱ دست یافت که به‌مراتب از بهترین عملکرد PLSR با طیف کامل فراتر است. این امر، بر توانایی ANN در استخراج روابط پیچیده و غیرخطی از داده‌های کاهش‌یافته طیفی تأکید می‌کند.

این مقایسه‌های دقیق به‌وضوح نشان می‌دهند که الگوریتم PSO یک استراتژی بسیار کارآمد برای کاهش ابعاد داده‌های طیفی است. این‌رویکرد نه‌تنها منجر به کاهش چشمگیر پیچیدگی محاسباتی می‌شود (که در این تحقیق دلیل اصلی عدم استفاده از ANN روی طیف کامل بود)، بلکه امکان بهره‌برداری از مدل‌های قدرتمندتر و زمان‌بر نظیر شبکه‌های عصبی مصنوعی را نیز فراهم می‌آورد.

جدول ٦- نتایج مدل‌سازی PLSR طول‌موج‌های منتخب PSO در رقم خرمایی با انواع پیش‌پردازش‌های طیفی (۷ مؤلفه)

Table 6- Results of the PLSR model on DT-PSO selected wavelengths for the Khormaei plum variety with various spectral preprocessing methods (7 components)

ردیف No	پیش‌پردازش Preprocessing	آموزش Training			اعتبارسنجی Validation			آزمون Test		
		R^2	RMSE	RPD	R^2	RMSE	RPD	R^2	RMSE	RPD
1	بدون پیش‌پردازش No Preprocessing	0.8652	0.0585	2.75	0.9264	0.0534	3.81	0.6404	0.118	1.72
2	SNV	0.7719	0.0761	2.12	0.7365	0.1011	2.01	0.6802	0.1113	1.83
3	MSC	0.7675	0.0768	2.1	0.7088	0.1062	1.91	0.6447	0.1173	1.73
4	مشتق اول First Derivative	0.8652	0.0585	2.75	0.9264	0.0534	3.81	0.6404	0.118	1.72
5	مشتق دوم Second Derivative	0.8652	0.0585	2.75	0.9264	0.0534	3.81	0.6404	0.118	1.72
6	نرمال‌سازی Normalisation	0.8623	0.0591	2.72	0.9294	0.0523	3.89	0.6379	0.1184	1.72
7	میانگین متحرک Moving Average	0.8574	0.0602	2.68	0.9135	0.0579	3.51	0.6208	0.1211	1.68
8	فیلتر گوسی Gaussian Filter	0.7634	0.0775	2.08	0.8338	0.0802	2.53	0.5922	0.1256	1.62
9	فیلتر میانه Median Filter	0.8333	0.065	2.48	0.8613	0.0733	2.77	0.693	0.109	1.86
10	ساویتزکی-گولای Savitzky-Golay	0.7947	0.0722	2.23	0.8869	0.0662	3.07	0.6985	0.108	1.88
11	حذف روند Detrending	0.8616	0.0593	2.72	0.9009	0.062	3.28	0.6251	0.1205	1.69
12	مرکز کردن میانگین Mean Centering	0.8652	0.0585	2.75	0.9264	0.0534	3.81	0.6404	0.118	1.72

جدول ۷- نتایج مدل‌سازی PLSR طول‌موج‌های منتخب PSO در رقم خونی با انواع پیش‌پردازش‌های طیفی (۸ مؤلفه)

Table 7- Results of the PLSR model on DT-PSO selected wavelengths for the Khoni plum variety with various spectral preprocessing methods (8 components)

ردیف No	پیش‌پردازش Preprocessing	آموزش Training			اعتبارسنجی Validation			آزمون Test		
		R^2	RMSE	RPD	R^2	RMSE	RPD	R^2	RMSE	RPD
1	بدون پیش‌پردازش No Preprocessing	0.9711	0.0681	5.95	0.9771	0.0647	6.83	0.8519	0.158	2.68
2	SNV	0.8776	0.1402	2.89	0.9006	0.1348	3.28	0.6474	0.2438	1.74
3	MSC	0.8764	0.1409	2.87	0.8921	0.1405	3.14	0.6734	0.2347	1.81
4	مشتق اول First Derivative	0.9711	0.0681	5.95	0.9771	0.0647	6.83	0.8519	0.158	2.68
5	مشتق دوم Second Derivative	0.9711	0.0681	5.95	0.9771	0.0647	6.83	0.8519	0.158	2.68
6	نرمال‌سازی Normalisation	0.9688	0.0707	5.72	0.9673	0.0773	5.71	0.8041	0.1817	2.33
7	میانگین متحرک Moving Average	0.9663	0.0735	5.51	0.9781	0.0633	6.97	0.8558	0.1559	2.72
8	فیلتر گوسی Gaussian Filter	0.9499	0.0897	4.51	0.9752	0.0673	6.56	0.8592	0.154	2.75
9	فیلتر میانه Median Filter	0.6685	0.2307	1.76	0.7864	0.1976	2.23	0.8665	0.15	2.83
10	ساویتزکی-گولای Savitzky-Golay	0.9529	0.0869	4.66	0.9669	0.0778	5.68	0.8684	0.1489	2.85
11	حذف روند Detrending	0.953	0.0869	4.66	0.9563	0.0894	4.94	0.7655	0.1989	2.13
12	مرکز کردن میانگین Mean Centering	0.9711	0.0681	5.95	0.9771	0.0647	6.83	0.8519	0.158	2.68

همان‌طور که مشاهده شد، ANN با طول‌موج‌های منتخب، به‌ویژه برای رقم آلو خونی، به دقت‌های پیش‌بینی بسیار بالایی دست یافت که دستیابی به آن‌ها با طیف کامل داده‌ها، بدون کاهش ابعاد، به دلیل نیاز به منابع محاسباتی فراوان و زمان‌بر بودن آموزش، عملاً غیرممکن بود. علاوه بر این، انتخاب صحیح روش پیش‌پردازش طیفی نقش حیاتی در بهینه‌سازی عملکرد مدل‌ها ایفا کرد؛ روش‌های هموارسازی مانند Savitzky-Golay و فیلتر گوسی (که به‌ترتیب به کاهش نویز و حذف نویزهای فرکانس بالا کمک می‌کنند) و همچنین روش‌های مبتنی بر مشتق (که به حذف خط پایه و افزایش وضوح پیک‌ها منجر می‌شوند) به‌خصوص در مدل‌سازی آلو خونی نتایج درخشانی داشته‌اند. درمجموع، تلفیق کاهش ابعاد هوشمندانه با PSO و مدل‌سازی پیشرفته با ANN، یک راهکار بهینه و مؤثر برای پیش‌بینی دقیق و کارآمد خواص فیزیکوشیمیایی در نمونه‌های آلو را ارائه می‌دهد که هم از نظر دقت و هم از نظر کارایی محاسباتی برتری چشمگیری دارد.

مقایسه با پژوهش‌های مشابه

به‌منظور تحلیل عمق دستاوردهای مدل‌های توسعه‌یافته در این پژوهش، به‌ویژه عملکرد برجسته مدل ANN بر روی رقم آلو خونی نتایج با تحقیقات پیشین و جدید در حوزه ارزیابی غیرمخرب pH در میوه‌ها مقایسه شده است. این مقایسه برتری‌های روش ترکیبی انتخاب ویژگی (DT-PSO) و قدرت مدل غیرخطی ANN را در مقایسه با روش‌های سنتی‌تر (مانند PLSR) آشکار می‌سازد.

مقایسه با مطالعاتی که از همان پارامتر کیفی (pH) و تکنیک مشابه (HSI) استفاده کرده‌اند، از اهمیت بالایی برخوردار است بنابراین به بررسی نتایج یکسری از پژوهش اخیر در این زمینه پرداخته شد.

جدول ۸- نتایج مدل‌سازی ANN طول‌موج‌های منتخب PSO در رقم خرمایی با انواع پیش‌پردازش‌های طیفی

Table 8- Results of the ANN model on DT-PSO selected wavelengths for the Khormaei plum variety with various spectral preprocessing methods

ردیف No	پیش‌پردازش Preprocessing	بهترین ساختار شبکه Best network topology	آموزش Training			اعتبارسنجی Validation			آزمون Test		
			R^2	RMSE	RPD	R^2	RMSE	RPD	R^2	RMSE	RPD
1	بدون پیش‌پردازش No Preprocessing	10	0.9061	0.0556	3.3	0.77	0.0837	2.15	0.7636	0.0769	2.12
2	SNV	[5 5]	0.6931	0.1005	1.82	0.5664	0.115	1.57	0.7168	0.0842	1.94
3	MSC	[10 15 20]	0.7089	0.0979	1.87	0.6819	0.0985	1.83	0.3934	0.1232	1.33
4	مشتق اول First Derivative	[10 5]	0.8761	0.0639	2.87	0.2986	0.1462	1.23	0.4863	0.1134	1.44
5	مشتق دوم Second Derivative	5	0.8513	0.07	2.62	0.6064	0.1095	1.65	0.5551	0.1055	1.55
6	نرمال‌سازی Normalisation	5	0.5963	0.1153	1.59	0.6315	0.106	1.7	0.548	0.1064	1.54
7	میانگین متحرک Moving Average	[5 5]	0.8585	0.0683	2.69	0.7666	0.0843	2.14	0.698	0.087	1.88
8	فیلتر گوسی Gaussian Filter	[10 10]	0.8972	0.0582	3.15	0.7017	0.0953	1.89	0.5976	0.1004	1.63
9	فیلتر میانه Median Filter	5	0.8412	0.0723	2.54	0.6377	0.1051	1.72	0.7624	0.0771	2.12
10	ساویتزکی-گولای Savitzky-Golay	[15 15]	0.8885	0.0606	3.03	0.56	0.1158	1.56	0.6078	0.0991	1.65
11	حذف روند Detrending	[15 15]	0.9167	0.0524	3.5	0.6407	0.1046	1.72	0.6433	0.0945	1.73
12	مرکز کردن میانگین Mean Centering	[5 5]	0.9089	0.0548	3.35	0.7673	0.0842	2.14	0.7291	0.0823	1.98

پژوهشی توسط گل‌محمدی و همکاران (Golmohammadi *et al.*, 2022) برای تخمین pH سیب رقم Red Delicious در محدوده ۱۱۰۰-۴۰۰ نانومتر انجام شد. این محققان پس از تعیین ۹ طول‌موج مؤثر، از مدل ANN استفاده کردند و بهترین نتایج در مرحله اعتبارسنجی شامل R^2=۰/۹۸ و RMSE=۰/۰۱۸ به‌دست آمد. در حالی‌که R^2 این پژوهش بسیار نزدیک به R^2 آزمون مدل ANN آلو خونی است، اما معیاری که برتری مدل حاضر را به‌وضوح نشان می‌دهد، شاخص RPD است. با دستیابی به RPD=۸/۰۱، مدل ما به یک سطح دقت و قدرت پیش‌بینی رسیده که به مراتب بالاتر از سطح RPD مورد نیاز برای کنترل کیفیت دقیق صنعتی است. این برتری قابل‌ملاحظه، احتمالاً ناشی از کارایی بالاتر روش ترکیبی DT-PSO در انتخاب بهینه‌ترین زیرمجموعه از ویژگی‌های طیفی در مقایسه با روش‌های صرفاً مبتنی بر ضریب رگرسیون است.

ژیمینگ و همکاران (Zhiming *et al.*, 2014) با استفاده از تصویربرداری فراطیفی فروسرخ موج کوتاه، در محدوده ۲۵۰۰-۱۰۰۰ نانومتر برای پیش‌بینی pH سیب فوجی، به بهترین نتیجه با مدل رگرسیون حداقل مربعات جزئی بازه‌های هم‌افزایی[1] (siPLS) شامل R^2=۰/۷۱۸ و RMSEP=۰/۰۳۹۸ دست یافتند. عملکرد ضعیف‌تر مدل siPLS در مقایسه با مدل ANN حاضر، بر اثربخشی بالاتر مدل‌های غیرخطی برای پیش‌بینی پارامترهای شیمیایی پیچیده میوه‌ها تأکید می‌کند. اگرچه محدوده طیفی[2] SWIR (موج بلند) حاوی اطلاعات مهمی درباره پیوندهای O-H و C-H است، اما مدل‌های خطی مانند siPLS و PLSR قادر به درک روابط غیرخطی میان این اطلاعات طیفی و pH میوه با دقت لازم نیستند؛ موضوعی که مدل ANN در پژوهش حاضر با موفقیت آن را مدیریت کرده است.

1- Synergy Interval Partial Least Squares
2- Short-Wave InfraRed

جدول ۹- نتایج مدل‌سازی ANN طول‌موج‌های منتخب PSO در رقم خونی با انواع پیش‌پردازش‌های طیفی

Table 9- Results of the ANN model on DT-PSO selected wavelengths for the Khoni plum variety with various spectral preprocessing methods

ردیف No	پیش‌پردازش Preprocessing	بهترین ساختار شبکه Best network topology	آموزش Training			اعتبارسنجی Validation			آزمون Test		
			R^2	RMSE	RPD	R^2	RMSE	RPD	R^2	RMSE	RPD
1	بدون پیش‌پردازش No Preprocessing	[20 5]	0.9889	0.0444	9.6	0.9674	0.0632	5.72	0.9808	0.0585	7.45
2	SNV	[5 5]	0.9944	0.0316	13.49	0.8877	0.1175	3.08	0.9621	0.082	5.31
3	MSC	[10 10]	0.7944	0.1912	2.23	0.2903	0.2952	1.23	0.7587	0.2071	2.1
4	مشتق اول First Derivative	[15 5]	0.9842	0.053	8.04	0.5508	0.2348	1.54	0.9332	0.109	4
5	مشتق دوم Second Derivative	[20 5]	0.9765	0.0647	6.59	0.8437	0.1385	2.61	0.9157	0.1224	3.56
6	نرمال‌سازی Normalisation	[10 10]	0.8451	0.166	2.57	0.6301	0.2131	1.7	0.8371	0.1701	2.56
7	میانگین متحرک Moving Average	5	0.9762	0.0651	6.55	0.946	0.0814	4.45	0.9804	0.0591	7.37
8	فیلتر گوسی Gaussian Filter	[20 5]	0.9722	0.0702	6.07	0.9012	0.1101	3.29	0.9834	0.0543	8.01
9	فیلتر میانه Median Filter	[10 5]	0.8573	0.1593	2.67	0.1093	0.3307	1.09	0.8395	0.1689	2.58
10	ساویتزکی-گولای Savitzky-Golay	[15 5]	0.9854	0.051	8.36	0.9629	0.0675	5.36	0.9826	0.0555	7.84
11	حذف روند Detrending	[15 5]	0.9861	0.0497	8.58	0.8305	0.1443	2.51	0.9536	0.0908	4.8
12	مرکز کردن میانگین Mean Centering	[10 15 20]	0.9555	0.0889	4.79	0.8349	0.1424	2.54	0.9731	0.0692	6.29

پوروانتو و همکاران (Purwanto *et al.*, 2013) در پژوهش خود، با استفاده از طیف‌سنجی NIR در حالت عبور در بازه ۲۴۰۰-۱۰۰۰ نانومتر و مدل PLS را برای پیش‌بینی pH انبه رقم Gedong Gincu توسعه دادند و به ضریب همبستگی R^2=۰/۸۱۷ دست یافتند. اگرچه این نتیجه برای پیش‌بینی pH انبه، در محدوده مناسب برای غربالگری و سورتینگ مقدماتی قرار می‌گیرد، اما به‌مراتب پایین‌تر از دقت مدل ANN حاضر در مرحله آزمون است. این تفاوت در دقت، نه تنها به ماهیت غیرخطی روابط طیفی pH اشاره دارد، بلکه بر اهمیت حیاتی کاهش دقیق ابعاد تأکید می‌کند. مدل PLS، به‌عنوان یک مدل خطی، نمی‌تواند پیچیدگی سیگنال‌های مربوط به اسیدهای آلی و ساختار قند-اسید (که مستقیماً بر pH تأثیر می‌گذارند) را در محدوده NIR به‌طور کامل درک کند. در مقابل، مدل ما با استفاده از DT-PSO، تنها اطلاعات غیرهم‌خط و پرقدرت را به ANN وارد کرده است، که ANN را قادر می‌سازد تا این روابط پیچیده را با دقت فراتر از مدل‌های خطی، مدل‌سازی کند.

پو و همکاران (Pu *et al.*, 2016) در ارزیابی pH میوه لیچی با استفاده از HSI در محدوده ۲۵۰۰-۱۰۰۰ نانومتر و مدل PLSR، نتایج ضعیف‌تری شامل ضریب همبستگی R^2=۰/۵۵ کسب کردند. عملکرد ضعیف‌تر در پیش‌بینی pH لیچی که حتی به حد قابل‌قبول برای ارزیابی روتین هم نمی‌رسد چالش ذاتی پیش‌بینی pH در میوه‌های گرمسیری یا هسته‌دار (مانند آلو و لیچی) را برجسته می‌سازد. علی‌رغم استفاده از محدوده طیفی طولانی‌تر که اطلاعات غنی‌تری در مورد پیوندهای شیمیایی را در اختیار می‌گذارد، استفاده از مدل PLSR خطی موجب شده است که مدل نتواند واریانس‌های pH را به‌طور مؤثر پوشش دهد. این موضوع قاطعانه تأکید می‌کند که در مواردی که هدف دستیابی به دقت بالا است، لازم است از مدل‌های غیرخطی پیشرفته‌ای مانند ANN در کنار تکنیک‌های دقیق انتخاب ویژگی، نظیر رویکرد DT-PSO در پژوهش حاضر، استفاده شود.

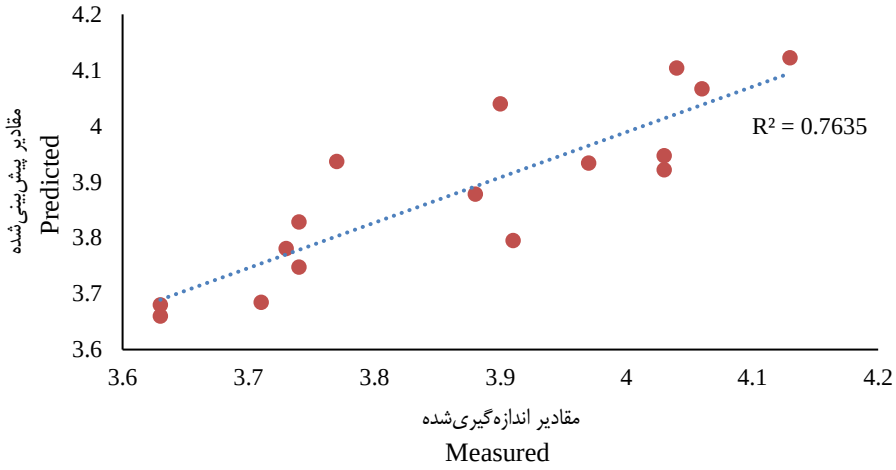

(a) الف

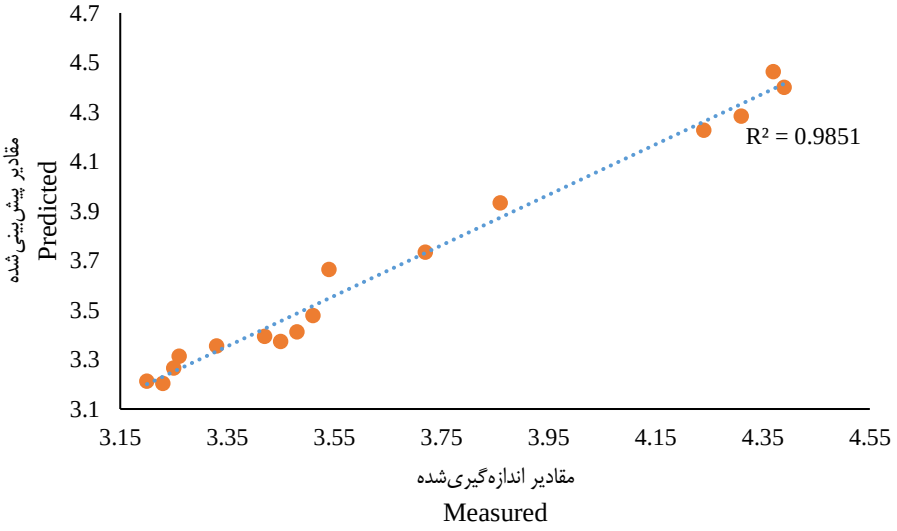

(b) ب

شکل ٦– نمودار پراکنش مقادیر pH اندازه‌گیری‌شده در برابر مقادیر پیش‌بینی‌شده برای بهترین مدل ANN بر روی مجموعه آزمون الف) ساختار معماری شبکه 10 بدون پیش‌پردازش رقم خرمایی ب) ساختار معماری شبکه [20 5] رقم خونی

Fig. 6. Scatter plot of the measured versus predicted pH values for the best ANN model on the test set for: (a) Khormaei variety (network architecture 10, no preprocessing), (b) Khoni variety (network architecture [20 5])

مقایسه با مجموعه‌ای از مطالعات کلیدی در زمینه ارزیابی pH میوه‌ها به‌وضوح نشان داد که دستیابی به دقت بالا در پیش‌بینی pH یک چالش بزرگ در میوه‌شناسی غیرمخرب باقی مانده است. عملکرد مدل ANN در پژوهش حاضر جایگاه متمایزی را برای این تحقیق فراهم می‌آورد. عملکرد مدل ANN، نه‌تنها مدل‌های خطی را پشت سر می‌گذارد، بلکه برتری چشمگیری نسبت به اکثر نتایج گزارش‌شده در ادبیات موضوع برای پارامتر pH در میوه‌های با خواص اسیدی مشابه دارد. این نتیجه، اعتبار روش ترکیبی DT-PSO را در بهینه‌سازی مدل‌های یادگیری ماشین برای اندازه‌گیری کیفی میوه‌ها تأیید می‌کند و نشان می‌دهد که تلفیق مناسب الگوریتم‌های فراابتکاری با قابلیت‌های غیرخطی ANN، راهکار مؤثری برای حل چالش‌های طیف‌سنجی در میوه‌های دارای pH متغیر است.

نتیجه‌گیری

این پژوهش با هدف توسعه و ارزیابی یک روش غیرمخرب و دقیق برای پیش‌بینی pH در دو رقم مهم آلو (خرمایی و خونی) با استفاده از فناوری تصویربرداری فراطیفی در محدوده مرئی–مادون‌قرمز نزدیک (Vis-NIR) به انجام رسید. دستاوردهای این مطالعه به‌وضوح نشان‌دهنده پتانسیل بالای این تکنیک، در کنار کاربرد مؤثر روش‌های پیش‌پردازش طیفی و الگوریتم‌های هوش مصنوعی، برای ارزیابی سریع و کارآمد خواص کیفی میوه‌هاست.

نتایج حاصل از بررسی تأثیر روش‌های مختلف پیش‌پردازش طیفی بر عملکرد مدل‌های رگرسیون حداقل مربعات جزئی (PLSR) به‌وضوح نشان داد که انتخاب بهینه پیش‌پردازش، نقشی حیاتی در بهبود دقت پیش‌بینی ایفا می‌کند. یکی از چالش‌های اصلی در تحلیل داده‌های طیفی، پدیده هم‌خطی و حجم بالای داده‌هاست. این پژوهش با موفقیت از الگوریتم بهینه‌سازی ازدحام ذرات (PSO) در ترکیب با درخت تصمیم (DT-PSO) به‌عنوان یک روش بسیار کارآمد برای کاهش ابعاد داده‌ها و انتخاب طول‌موج‌های مؤثر بهره برد. الگوریتم PSO با وجود کاهش چشمگیر تعداد متغیرها، توانست طول‌موج‌هایی را انتخاب کند که اطلاعات کلیدی را در خود حفظ کرده و به دقت پیش‌بینی بالا در مدل‌های بعدی منجر شدند. در نهایت، مقایسه عملکرد PLSR و شبکه‌های عصبی مصنوعی (ANN) بر روی طول‌موج‌های منتخب، برتری چشمگیر ANN را در مدل‌سازی روابط پیچیده و غیرخطی آشکار ساخت. در حالی‌که مدل‌های PLSR با طول‌موج‌های منتخب عملکرد قابل‌قبولی ارائه دادند، ANN توانست به دقت‌های بسیار بالاتری دست یابد. همچنین، معماری بهینه شبکه عصبی، شامل تعداد لایه‌های پنهان و نورون‌ها، نقشی کلیدی در به حداکثر رساندن دقت این مدل‌ها ایفا کرد. به‌طور خلاصه، این مطالعه با تلفیق نوآورانه تصویربرداری فراطیفی، کاهش ابعاد هوشمندانه با DT-PSO و مدل‌سازی پیشرفته غیرخطی با ANN، یک راهکار دقیق و کارآمد برای ارزیابی غیرمخرب pH ارقام مختلف آلو ارائه می‌دهد.

تعارض منافع

هیچ‌گونه تعارض منافع توسط نویسندگان بیان نشده است.

مشارکت نویسندگان

میثم لطیفی عموقین: مفهوم‌سازی، روش‌شناسی، جمع‌آوری داده، پردازش داده، تصویرسازی نتایج، استخراج و تهیه متن اولیه
یوسف عباس‌پور گیلانده: نظارت و مدیریت، مفهوم‌سازی، مشاوره فنی، تحلیل آماری، اعتبارسنجی، ویرایش متن

References

1. Alam, S., Dobbie, G., Koh, Y. S., Riddle, P., & Rehman, S. U. (2014). Research on particle swarm optimization based clustering: a systematic review of literature and techniques. *Swarm and Evolutionary Computation*, 17, 1-13. https://doi.org/10.1016/j.swevo.2014.02.001
2. Ayub, H., Nadeem, M., Mohsin, M., Ambreen, S., Khan, F. A., Oranab, S., Rahim, M. A., Zubair khalid, M., Zongo, E., & Zarlasht, M. (2023). A comprehensive review on the availability of bioactive compounds, phytochemicals, and antioxidant potential of plum (*Prunus Domestica*). *International Journal of Food Properties*, *26*(1), 2388-2406. https://doi.org/10.1080/10942912.2023.2249254
3. Chang, C.-W., Laird, D. A., Mausbach, M. J., & Hurburgh, C. R. (2001). Near-infrared reflectance spectroscopy–principal components regression analyses of soil properties. *Soil Science Society of America Journal*, *65*(2), 480-490. https://doi.org/10.2136/sssaj2001.652480x
4. Dorigo, M., Birattari, M., & Stutzle, T. (2006). Ant colony optimization. IEEE computational intelligence magazine, 1(4), 28-39.Kashan, A. H. (2014). League Championship Algorithm (LCA): An algorithm for global optimization inspired by sport championships. *Applied Soft Computing*, *16*, 171-200. https://doi.org/10.1016/j.asoc.2013.12.005
5. Gao, S., & Xie, W. (2024). SSC and pH prediction and maturity classification of grapes based on hyperspectral imaging. *Smart Agricultural Technology*, *8*, 100457. https://doi.org/10.1016/j.atech.2024.100457
6. Golmohammadi, A., Tahmasebi, M., & Razavi, M. S. (2022). Near infrared hyperspectral imaging for non-destructive determination of pH value in red delicious apple fruit during shelf life. *Innovative Food Technologies*, *9*(2), 99-111. https://doi.org/10.22104/jift.2021.5124.2059
7. Hasanzadeh, B., Abbaspour-Gilandeh, Y., Soltani-Nazarloo, A., Hernández-Hernández, M., Gallardo-Bernal, I., & Hernández-Hernández, J. L. (2022). Non-destructive detection of fruit quality parameters using hyperspectral imaging, multiple regression analysis and artificial intelligence. *Horticulturae*, *8*(7), 598. https://doi.org/10.3390/horticulturae8070598
8. Huang, H., Liu, L., & Ngadi, M. O. (2014). Recent developments in hyperspectral imaging for assessment of food quality and safety. *Sensors*, *14*(4), 7248-7276. https://doi.org/10.3390/s140407248
9. Kashan, A. H. (2014). League Championship Algorithm (LCA): An algorithm for global optimization inspired by sport championships. *Applied Soft Computing*, *16*, 171-200. https://doi.org/10.1016/j.asoc.2013.12.005

10. Kavuncuoğlu, E., Çetin, N., Yildirim, B., Nadimi, M., & Paliwal, J. (2023). Exploration of machine learning algorithms for pH and moisture estimation in apples using VIS-NIR imaging. *Applied Sciences*, *13*(14), 8391. https://doi.org/10.3390/app13148391
11. Khodabakhshian, R., & Baghbani, R. (2026). Non-destructive Internal Quality Evaluation of Apple Fruit Using X-ray CT. *Journal of Agricultural Machinery*, *16*(1), 167-181. https://doi.org/10.22067/jam.2025.90983.1317
12. Latifi Amoghin, M., Abbaspour-Gilandeh, Y., Tahmasebi, M., & Arribas, J. I. (2024a). Automatic non-destructive estimation of polyphenol oxidase and peroxidase enzyme activity levels in three bell pepper varieties by Vis/NIR spectroscopy imaging data based on machine learning methods. *Chemometrics and Intelligent Laboratory Systems*, 105137. https://doi.org/10.1016/j.chemolab.2024.105137
13. Latifi Amoghin, M., Abbaspour-Gilandeh, Y., Tahmasebi, M., Kaveh, M., El-Mesery, H. S., Szymanek, M., & Sprawka, M. (2024b). VIS/NIR Spectroscopy as a Non-Destructive Method for Evaluation of Quality Parameters of Three Bell Pepper Varieties Based on Soft Computing Methods. *Applied Sciences*, *14*(23), 10855. https://doi.org/10.3390/app142310855
14. Liu, J., Sun, J., Wang, Y., Liu, X., Zhang, Y., & Fu, H. (2025). Non-Destructive Detection of Fruit Quality: Technologies, Applications and Prospects. *Foods*, *14*(12), 2137. https://doi.org/10.3390/foods14122137
15. Liu, Y., Wang, H., Fei, Y., Liu, Y., Shen, L., Zhuang, Z., & Zhang, X. (2021). Research on the prediction of green plum acidity based on improved XGBoost. *Sensors*, *21*(3), 930. https://doi.org/10.3390/s21030930
16. Majeed, R., & Jawandha, S. (2016). Enzymatic changes in plum (*Prunus salicina* Lindl.) subjected to some chemical treatments and cold storage. *Journal of Food Science and Technology*, *53*, 2372-2379 . https://doi.org/10.1007/s13197-016-2209-9
17. Masoudi-Sobhanzadeh, Y., & Motieghader, H. (2016). World Competitive Contests (WCC) algorithm: A novel intelligent optimization algorithm for biological and non-biological problems. *Informatics in Medicine Unlocked*, *3*, 15-28. https://doi.org/10.1016/j.imu.2016.06.002
18. Masoudi-Sobhanzadeh, Y., Motieghader, H., & Masoudi-Nejad, A. (2019). FeatureSelect: a software for feature selection based on machine learning approaches. *BMC Bioinformatics*, *20*, 1-17. https://doi.org/10.1186/s12859-019-2754-0
19. McGlynn, W. (2003). Importance of food pH in commercial canning operations [superseded]. openresearch.okstate.edu
20. Narendra, K. S., & Thathachar, M. A. (2012). Learning automata: an introduction. Courier corporation.
21. Pu, H., Liu, D., Wang, L., & Sun, D.-W. (2016). Soluble solids content and pH prediction and maturity discrimination of lychee fruits using visible and near infrared hyperspectral imaging. *Food Analytical Methods*, *9*, 235-244. https://doi.org/10.1007/s12161-015-0186-7
22. Purwanto, Y .A., Zainal, P. W., Ahmad, U., Sutrisno, M., Makino, Y., Oshita, S., Kawagoe, Y., & Kuroki, S. (2013). Non destructive prediction of pH in mango fruit cv. Gedong Gincu using NIR spectroscopy. *International Journal of Engineering and Technology*, *13*, 70-73.
23. Rahman, A., Kandpal, L. M., Lohumi, S., Kim, M. S., Lee, H., Mo, C., & Cho, B.-K. (2017). Nondestructive estimation of moisture content, pH and soluble solid contents in intact tomatoes using hyperspectral imaging. *Applied Sciences*, *7*(1), 109. https://doi.org/10.3390/app7010109
24. Razavi, M .S., Sharabiani, V. R., Tahmasebi, M., Grassi, S., & Szymanek, M. (2025). Chemometric and meta-heuristic algorithms to find optimal wavelengths and predict 'Red Delicious' apples traits using Vis-NIR. *Applied Food Research*, *5*(1), 100853. https://doi.org/10.1016/j.afres.2025.100853
25. Trendafilova, A ,.Ivanova, V., Trusheva, B., Kamenova-Nacheva, M., Tabakov, S., & Simova, S. (2022). Chemical composition and antioxidant capacity of the fruits of European plum cultivar "*Čačanska Lepotica*" influenced by different rootstocks. *Foods*, *11*(18), 2844. https://doi.org/10.3390/foods11182844
26. Wang, X., Xu, L., Chen, H., Zou, Z., Huang, P., & Xin, B. (2022). Non-destructive detection of pH value of kiwifruit based on hyperspectral fluorescence imaging technology. *Agriculture*, *12*(2), 208. https://doi.org/10.3390/agriculture12020208
27. Weng, S., Yu, S., Guo, B., Tang, P., & Liang, D. (2020). Non-destructive detection of strawberry quality using multi-features of hyperspectral imaging and multivariate methods. *Sensors*, *20*(11), 3074. https://doi.org/10.3390/s20113074
28. Zhang, Z., Cheng, H., Chen, M., Zhang, L., Cheng, Y., Geng, W., & Guan, J. (2024). Detection of Pear Quality Using Hyperspectral Imaging Technology and Machine Learning Analysis. *Foods*, *13*(23), 3956. https://doi.org/10.3390/foods13233956
29. Zhiming, G., Wenqian, H., Liping, C., Yankun, P., & Xiu, W. (2014). Shortwave infrared hyperspectral imaging for detection of pH value in Fuji apple. *International Journal of Agricultural and Biological Engineering*, *7*(2), 130-137. https://doi.org/10.3965/j.ijabe.20140702.016
30. Zhu, H., Chu, B., Fan, Y., Tao, X., Yin, W., & He, Y. (2017). Hyperspectral imaging for predicting the internal quality of kiwifruits based on variable selection algorithms and chemometric models. *Scientific Reports*, *7*(1), 7845. https://doi.org/10.1038/s41598-017-08509-6

Journal of Agricultural Machinery

Homepage: https://jame.um.ac.ir

Research Article
Vol. 16, No. 4, 2026, p. 693-710

Estimation of Greenhouse Gas Emission Reduction, Social Costs of Pollutants, and Energy Use Efficiency Improvement in Wheat Cultivation under Site-Specific Management of Chemical Inputs

A. Jalilian[1*], M. M. Ghasemi[2], H. Ghasemi Mobtaker[3], A. Kaab[3,4]

1- Department of Agronomy and Plant Breeding, Faculty of Agricultural, College of Agriculture and Natural Resources, University of Tehran, Karaj, Iran
2- Agricultural Engineering Research Institute, Agricultural Research, Education and Extension Organization, Karaj, Iran
3- Department of Agricultural Machinery Engineering, Faculty of Agricultural Engineering and Technology, University of Tehran, Karaj, Iran
4- Mechanization and Remote Sensing Expert, Sugarcane Agro-Industrial Development Company of Khuzestan Province, Ahwaz, Iran
(*- Corresponding Author Email: ashkanjalilian@ut.ac.ir)

Received: 10 December 2025
Revised: 20 January 2026
Accepted: 10 February 2026
Available Online: 22 April 2026

How to cite this article:
Jalilian, A., Ghasemi, M. M., Ghasemi Mobtaker, H., & Kaab, A. (2026). Estimation of Greenhouse Gas Emission Reduction, Social Costs of Pollutants, and Energy Use Efficiency Improvement in Wheat Cultivation under Site-Specific Management of Chemical Inputs. *Journal of Agricultural Machinery*, *16*(4), 693-710. [in Persian]. https://doi.org/10.22067/jam.2026.96928.1453

Introduction

Improving the sustainability of agricultural systems requires the optimisation of inputs use, especially chemical fertilisers and pesticides, which are major contributors to energy consumption and environmental degradation. Variable Rate Technology (VRT), as a precision agriculture strategy, allows site-specific management of inputs based on spatial variability in soil fertility, weed distribution, and crop requirements. Although VRT has shown promise in enhancing resource-use efficiency, its integrated effects on energy indicators and environmental burdens in wheat production under irrigated conditions remain insufficiently investigated. This study assessed the impact of VRT on energy performance and environmental emissions in comparison with conventional uniform application, using a real six-hectare winter wheat field in Karaj, Iran.

Materials and Methods

A comprehensive field-scale simulation of VRT was conducted for nitrogen, phosphorus, potassium fertilisers, herbicides, and insecticides. Spatial maps of soil fertility and weed distribution were generated using UAV-based remote sensing and ground sampling. Two scenarios were examined: (1) VRT-based variable application of chemical inputs and (2) conventional uniform application. Energy inputs and other outputs were calculated based on standard coefficients and categorised as direct, indirect, renewable, and non-renewable. Environmental impacts, including Global Warming Potential (GWP) and pollutant emissions to air, water, and soil, were quantified using the ReCiPe 2016 Midpoint (H) method. All results were compared for the production of 34,800 kg of wheat.

Results and Discussion

Energy Indicators

The total energy input under VRT (131,631.57 MJ) was lower than that of consumed under conventional

Authors retain the copyright. This is an open access article distributed under Creative Commons Attribution 4.0 International License (CC BY 4.0).

https://doi.org/10.22067/jam.2026.96928.1453

management (160,318.55 MJ). Direct and indirect energy uses declined by 12.64 MJ and 19.31 MJ, respectively, in the VRT system. VRT improved all energy indicators i.e., energy ratio increased to 6.82 (21.79% higher than the conventional method), energy productivity rose to 0.264 kg MJ^{-1}, and energy intensity decreased to 3.78 MJ kg^{-1}. Net energy under VRT reached 765,705.76 MJ, exceeding the conventional value. Major reductions were attributed to substantial decreases in herbicide use (80.40%) and potassium fertiliser (77%), driven by UAV-derived weed distribution maps and soil fertility maps.

Environmental Impacts

The GWP of the VRT scenario was 17,691.21 kg CO_2-eq, representing approximately a 20% reduction compared to the 22,202.74 kg CO_2-eq emitted under conventional application. Nearly half of the GWP originated from direct field emissions, followed by nitrogen fertiliser use. Optimisation of nitrogen rates and reduced field-level emissions were the primary contributors to the decrease. Pollutant emissions to the atmosphere also declined significantly: CO_2 by 16.2%, N_2O by 21.9%, and NH_3 by 22.5%. Waterborne pollutants were reduced, with nitrate declining by 22.4% and phosphorus by 38.9%. Heavy metal emissions to soil also decreased, with Pb reduced by 22.4% and Zn by 35.0%, while elements with naturally low accumulation (Fe, B, Mn, Mo) remained unchanged. These improvements align with previous international findings demonstrating the effectiveness of UAV-assisted VRT in reducing chemical inputs, enhancing energy efficiency, and minimising environmental pollution across diverse cropping systems.

Conclusion

The results demonstrate that implementing VRT for applaying chemical inputs in wheat production substantially reduces both energy consumption and environmental impacts. Compared with the conventional uniform method, VRT improved all energy indicators, decreased total energy inputs, and increased net energy output. Environmentally, VRT reduced GWP by roughly 20%, lowered key atmospheric pollutants, and substantially decreased nutrient leaching and heavy metal accumulation in soil. Overall, VRT proves to be a highly effective strategy for achieving sustainable wheat production through optimised input management, enhanced energy efficiency, and minimised ecological burdens.

Acknowledgement

The authors gratefully acknowledge the support of the agricultural research team and field specialists involved in data collection, UAV operations, and soil and crop analyses throughout the study.

Keywords: Energy Efficiency, Environmental Emissions, Global Warming Potential, Precision Agriculture, UAV Remote Sensing, Variable Rate Technology, Wheat Production

نشریه ماشین‌های کشاورزی
https://jame.um.ac.ir

مقاله پژوهشی
جلد ۱۶، شماره ۴، زمستان ۱۴۰۵، ص ۷۱۰-۶۹۳

برآورد کاهش انتشار گازهای گلخانه‌ای، هزینه اجتماعی آلاینده‌ها و ارتقای کارایی مصرف انرژی در کشت گندم در مدیریت مکان محور نهاده‌های شیمیایی

اشکان جلیلیان[۱*]، محمد مهدی قاسمی[۲]، حسن قاسمی مبتکر[۳]، علی کعب[۳،۴]

تاریخ دریافت: ۱۴۰۴/۰۹/۱۹
تاریخ پذیرش: ۱۴۰۴/۱۱/۲۱

چکیده

افزایش بهره‌وری مصرف نهاده‌های شیمیایی و کاهش پیامدهای زیست‌محیطی، از چالش‌های اصلی کشاورزی مدرن است. مصرف بی‌رویه کودها و علف‌کش‌ها ضمن افزایش هزینه‌های تولید، باعث تشدید انتشار گازهای گلخانه‌ای و آلودگی منابع آب و خاک می‌شود. پژوهش حاضر با هدف ارزیابی اثر کاربرد نرخ متغیر کودها و علف‌کش‌ها بر شاخص‌های انرژی و انتشار آلاینده‌ها در کشت گندم آبی انجام شد. مطالعه در سال زراعی ۱۴۰۳-۱۴۰۲ در مزرعه‌ای تحقیقاتی به وسعت ۶ هکتار در کرج، استان البرز، با دو رویکرد مدیریتی شامل روش مرسوم و فناوری نرخ متغیر (VRT) اجرا شد. در رویکرد VRT، با استفاده از تصاویر پهپاد چندطیفی و داده‌های خاک، نقشه‌های مکانی توزیع عناصر غذایی تهیه و نرخ بهینه مصرف نیتروژن، فسفر، پتاسیم و علف‌کش‌ها تعیین شد. نتایج نشان داد که مصرف نیتروژن، فسفر و پتاسیم به‌ترتیب ۲۲/۲، ۳۸/۹ و ۷۷ درصد و مصرف علف‌کش ۸۲/۴ درصد کاهش یافت. ورودی کل انرژی در رویکرد نرخ متغیر ۱۷/۴ درصد کمتر بود و شاخص‌های نسبت انرژی، بهره‌وری انرژی و انرژی خالص به‌ترتیب ۱۸/۹، ۲۱/۴ و ۲۲/۷ درصد افزایش یافتند. ارزیابی چرخه زندگی با روش ReCiPe2016 نشان داد که کاربرد نرخ متغیر نهاده‌ها پتانسیل گرمایش جهانی را ۲۷/۸ درصد و میانگین انتشار آلاینده‌ها را حدود ۲۳ درصد کاهش داد. نتایج بیانگر آن است که فناوری نرخ متغیر می‌تواند ضمن کاهش مصرف نهاده‌ها و انتشار آلاینده‌ها، کارایی انرژی و پایداری تولید گندم را به شکل قابل‌توجهی بهبود دهد.

واژه‌های کلیدی: آلودگی محیط‌زیست، بهره‌وری منابع، کشاورزی پایدار، تأثیرات زیست‌محیطی، کارایی نهاده‌ها

مقدمه

کشاورزی مدرن با هدف افزایش عملکرد، بر استفاده گسترده از کودهای شیمیایی تکیه دارد؛ با این حال، رویکردهای کوتاه‌مدت در مدیریت اراضی می‌تواند پایداری بلندمدت تولید غذا را تهدید کند (Radočaj, Jurišić, & Gašparović, 2022). مدیریت نادرست و درک ناکافی از نحوه مصرف کودها، آثار منفی قابل‌توجهی بر محیط‌زیست و منابع طبیعی برجای می‌گذارد (Pogrzeba, Rusinowski, & Krzyżak, 2018). هرچند کودهای نیتروژن (N)، فسفر (P) و پتاسیم (K) موجب افزایش عملکرد می‌شوند، اما کارایی مصرف پایین آن‌ها منجر به نشت نیترات به منابع آب و انتشار اکسید نیتروژن در اتمسفر می‌شود (Kaab, Sharifi, Mobli, Nabavi-Pelesaraei, & Chau, 2019a). این دو ترکیب، از گونه‌های فعال نیتروژن بوده و به‌ترتیب به‌عنوان گاز گلخانه‌ای و آلاینده آب‌های زیرزمینی، در بروز گرمایش جهانی و تهدید سلامت انسان نقش دارند (Hou *et al.*, 2024).

علف‌های هرز از مهم‌ترین عوامل زیستی کاهش‌دهنده عملکرد محصولات در جهان هستند (Esposito, Crimaldi, Cirillo, Sarghini, & Maggio, 2021). این گیاهان با رقابت برای آب، مواد غذایی، نور و فضا، رشد گیاه زراعی را محدود کرده و بسته به تراکمشان می‌توانند خسارت‌های متفاوتی به بار آورند (Ghasemi-

۱- گروه زراعت و اصلاح نباتات، دانشکده کشاورزی، دانشگاه تهران، کرج، ایران
۲- موسسه تحقیقات فنی و مهندسی کشاورزی، کرج، ایران
۳- گروه مهندسی ماشین‌های کشاورزی، دانشکده مهندسی و فناوری کشاورزی، دانشگاه تهران، کرج، ایران
۴- کارشناس مکانیزاسیون و سنجش از دور، شرکت توسعه نیشکر و صنایع جانبی استان خوزستان، اهواز، ایران
(*- نویسنده مسئول: Email: ashkanjalilian@ut.ac.ir)
https://doi.org/10.22067/jam.2026.96928.1453

Mobtaker, Mostashari-Rad, Saber, Chau, & Nabavi-Pelesaraei, 2020). انعطاف‌پذیری ریخت‌شناسی، فیزیولوژیکی و آناتومیکی بالای آن‌ها سبب سازگاری بیشتر در برابر تنش‌های محیطی و در نتیجه کاهش عملکرد گیاهان زراعی می‌شود (Kaur, Kaur, & Chauhan, 2018). افزون بر این، علف‌های هرز می‌توانند به‌عنوان پناهگاه آفات گیاهی مانند حشرات، قارچ‌ها و باکتری‌ها عمل کرده و خطر آلودگی محصولات مجاور را افزایش دهند (Taherzadeh-Shalmaei *et al*., 2023). در سطح جهانی، رقابت علف‌های هرز موجب کاهش قابل‌توجه عملکرد محصولات اصلی مانند گندم (۲۳ درصد)، سویا (۳۷ درصد)، برنج (۳۷ درصد)، ذرت (۴۰ درصد)، پنبه (۳۶ درصد) و سیب‌زمینی (۳۰ درصد) می‌شود (Soltani *et al*., 2016). در آمریکای شمالی، این خسارت برای ذرت و سویا تا ۵۰ درصد تولید سالانه رسیده و زیانی بیش از ۲۶/۷ میلیارد دلار در پی دارد. روش‌های کنترل علف‌های هرز شامل وجین دستی، استفاده از علف‌کش‌های شیمیایی، روش‌های مکانیکی، راهکارهای پایدار و فناوری‌های هوش مصنوعی است (Meesaragandla, Jagtap, Khatri, Madan, & Vadduri, 2024). با وجود کارایی بالای علف‌کش‌های شیمیایی در کاهش تراکم علف‌های هرز (Basavalingaiah *et al*., 2020)، مصرف بی‌رویه آن‌ها اثرات منفی بر محیط‌زیست و سلامت انسان دارد (MacLaren, Storkey, Menegat, Metcalfe, & Dehnen-Schmutz, 2020). ازاین‌رو، رویکردهای نوین و سیاست‌های جهانی، به‌ویژه در اتحادیه اروپا، بر کاهش مصرف علف‌کش‌ها و بهینه‌سازی کاربرد آن‌ها تأکید دارند (Monteiro & Santos, 2022). برآوردها نشان می‌دهد سالانه حدود دو میلیون تن آفت‌کش در کشاورزی مصرف می‌شود که ۴۷/۵ درصد آن مربوط به علف‌کش‌هاست (Sharma *et al*., 2019).

کشاورزی دقیق (PA[1]) با رویکرد داده‌محور و با بهره‌گیری از فناوری‌های نوین به‌عنوان یکی از پایه‌های کشاورزی پایدار امکان بهینه‌سازی مصرف نهاده‌های کشاورزی را ممکن ساخته است (Misbah, Laamrani, Khechba, Dhiba, & Chehbouni, 2021). در این چارچوب، کاربرد هدفمند کود به‌منزله سرمایه‌گذاری راهبردی برای افزایش بهره‌وری هر ناحیه زراعی محسوب می‌شود (Radočaj *et al*., 2022). کشاورزی دقیق با شناسایی تنوع مکانی زمین، به کاهش هزینه‌ها و مصرف منابع و درعین‌حال بهبود عملکرد محصولات کمک می‌کند (Esposito *et al*., 2021). تقسیم مزرعه به نواحی مدیریتی کوچک‌تر نیز کنترل مکانی ویژه را بهبود می‌بخشد (Wang *et al*., 2023). از فناوری‌های کلیدی این نظام، کاربرد نرخ متغیر (VRT) است که بر اساس داده‌های سنجش از دور یا حسگرهای میدانی، میزان نهاده‌ها را متناسب با نیاز هر بخش از زمین تنظیم می‌کند. به‌کارگیری VRT با کاهش مصرف نهاده‌های شیمیایی، کمینه‌سازی آلودگی، افزایش کارایی مصرف عناصر غذایی و بهبود عملکرد و سودآوری، گامی مؤثر در جهت کشاورزی پایدار محسوب می‌شود (Fabiani *et al*., 2020). پهپادها (UAVs) از مؤثرترین فناوری‌های کشاورزی دقیق به‌شمار می‌آیند و با قابلیت پرواز در ارتفاع پایین، تصاویر چندطیفی با وضوح بالا برای پایش و مدیریت مزرعه فراهم می‌کنند (Monteiro & Santos, 2022; Saha *et al*., 2018). این تصاویر، همراه با داده‌های حاصل از سنجش از دور، GPS و GIS، امکان شناسایی مکانی علف‌های هرز و اجرای مدیریت هدفمند را فراهم می‌سازند (Radočaj *et al*., 2022). نقشه‌برداری علف‌های هرز با UAV ها نقش مهمی در کاهش مصرف نهاده‌ها، محدود کردن اثرات زیست‌محیطی و بهبود عملکرد محصولات دارد (Roslim *et al*., 2021). با وجود شواهد گسترده در کاربرد VRT وUAV ها در مدیریت نهاده‌ها، هنوز اطلاعات محدودی در زمینه ارزیابی هم‌زمان اثرات این فناوری‌ها بر شاخص‌های انرژی و انتشار آلاینده‌ها در مزرعه‌های گندم آبی ایران موجود است. این شکاف علمی نشان می‌دهد که بررسی جامع مصرف انرژی، بهره‌وری نهاده‌ها و کاهش آلاینده‌ها در شرایط واقعی مزرعه‌ای، نیازمند پژوهش‌های کاربردی و داده‌محور است.

در زمینه تغذیه گیاهی، استفاده از داده‌های مکانی برای مدیریت نیتروژن در کشت گندم موجب افزایش کارایی مصرف و کاهش انتشار اکسید نیتروژن شده است (You, Yao, Xu, Zhang, & Meng, 2022). همچنین، به‌کارگیری فناوری سنجش از دور باعث بهبود کارایی کوددهی و کاهش آلاینده‌های محیطی می‌شود (Radočaj *et al*., 2022). در مدیریت علف‌های هرز، روش‌های مکان‌محور (SSWM[2]) می‌توانند مصرف علف‌کش‌ها را ۶۰–۴۰ درصد کاهش دهند (Jensen, Jacobsen, Pedersen, & Tavella, 2012)، در حالی‌که فراتحلیل‌ها از کاهش ۹۷ درصد در مصرف علف‌کش، ۷۰ درصد در حشره‌کش و ۸۹ درصد در تراکم علف‌های هرز خبر می‌دهند (Anastasiou *et al*., 2023). کاربرد فناوری نرخ متغیر (VRT) در مدیریت علف‌کش‌ها نشان داده است که می‌تواند مصرف علف‌کش‌ها را تا ۹۳ درصد و هزینه‌های عملیاتی را ۳۴ یورو در هر هکتار کاهش دهد (Gutjahr, Sökefeld, & Gerhards, 2012). همچنین، مطالعات مبتنی بر UAV نشان می‌دهند که حسگرهای RGB توانایی شناسایی ۹۷–۹۲ درصد علف‌های هرز را دارند و کنترل هدفمند گونه‌هایی مانند *Setaria faberi* و *Galium aparine* در مزارع گندم با اثربخشی تا ۹۸ درصد امکان‌پذیر است. ادغام UAV ها با هوش مصنوعی و حسگرهای طیفی، چشم‌اندازی نویدبخش برای مدیریت دقیق علف‌های هرز فراهم می‌کند (Meesaragandla *et al*., 2024).

1- Precision agriculture

2- Site-Specific Weed Management

افزایش بهره‌وری انرژی و بهینه‌سازی مصرف نهاده‌ها از اهداف کلیدی کشاورزی مدرن است، زیرا مدیریت مؤثر منابع در مراحل مختلف تولید از اتلاف و آسیب زیست‌محیطی جلوگیری می‌کند (Jalilian, Jahansouz, Ghasemi Mobtaker, Oveisi, & Moghadam, 2023). بهبود کارایی انرژی علاوه بر صرفه‌جویی مالی، موجب حفظ سوخت‌های فسیلی و کاهش آلودگی هوا می‌شود (Kaab, Khanali, Shadamanfar, & Jalalvand, 2024). گسترش استفاده از انرژی‌های تجدیدپذیر نیز برای کاهش گازهای گلخانه‌ای و بهبود کیفیت هوا ضروری است (Saadi, Behnia, Taki, & Kaab, 2025). در مقابل، مصرف بیش از حد نهاده‌هایی مانند کودهای شیمیایی، آفت‌کش‌ها و سوخت‌های فسیلی، سبب تشدید گرمایش جهانی، کاهش تنوع زیستی و تخریب خاک و هوا می‌شود؛ ازاین‌رو، مدیریت صحیح نهاده‌ها برای حفظ منابع طبیعی حیاتی است (Mostashari-Rad *et al.*, 2021). انتشار ناشی از انرژی حدود دو سوم گازهای گلخانه‌ای جهانی را شامل می‌شود که بخش کشاورزی سهمی معادل ۱۰ تا ۱۲ درصد دارد (Nabavi-Pelesaraei, Rafiee, Mohammadkashi, Chau, & Mostashari-Rad, 2022). در کشت گندم آبی نیز، مصرف کودهای نیتروژن و فسفر مهم‌ترین عامل افزایش آلودگی محیط‌زیست شناخته شده است (Taherzadeh-Shalmaei, Sharifi, Ghasemi-Mobtaker, & Kaab, 2021).

استفاده گسترده از کودها و علف‌کش‌ها در کشاورزی مدرن، هرچند موجب افزایش عملکرد محصولات می‌شود، اما پیامدهای منفی قابل‌توجهی بر محیط‌زیست و سلامت انسان دارد. کشاورزی دقیق با تکیه بر فناوری‌های نوین، راهکاری مؤثر برای بهینه‌سازی مصرف نهاده‌ها، کاهش اثرات زیست‌محیطی و افزایش بهره‌وری ارائه می‌دهد. مطالعه حاضر با شبیه‌سازی VRT و تحلیل هم‌زمان اثرات انرژی و انتشار آلاینده‌ها، نوآوری خود را در ارائه داده‌های عملی و کاربردی برای بهبود پایداری کشاورزی نشان می‌دهد. این رویکرد امکان سنجش مستقیم تاثیر مدیریت مکان‌محور نهاده‌ها بر عملکرد محصول و اثرات زیست‌محیطی را فراهم می‌آورد، که تاکنون در مطالعات مشابه کمتر مورد توجه قرار گرفته است. بر این اساس، فرض می‌شود که به‌کارگیری فناوری نرخ متغیر (VRT) در مصرف کودها و علف‌کش‌ها می‌تواند مصرف نهاده‌ها، انرژی و انتشار آلاینده‌ها را کاهش داده و در عین حال عملکرد گندم آبی را حفظ کند. از این رو، کاربرد این روش می‌تواند مقدار آلاینده‌های تولیدی در کشت گندم تحت سیستم نرخ متغیر را نسبت به روش مرسوم به‌طور معنی‌داری کاهش دهد. بر این اساس، هدف این مطالعه، ارزیابی اثر کاربرد نرخ متغیر نهاده‌های شیمیایی بر ردپای زیست‌محیطی و شاخص‌های انرژی در مزرعه‌ای شش‌هکتاری از گندم آبی است.

مواد و روش‌ها

جمع‌آوری داده‌ها و منطقه مطالعه

این مطالعه در سال زراعی ۱۴۰۳-۱۴۰۲ در استان البرز، شهرستان کرج، ایران، در مزرعه تحقیقاتی شرکت توسعه خدمات مهندسی آب و خاک پارس انجام شد. مزرعه تحقیقاتی شامل ۶ هکتار از مجموع ۱۰۰ هکتار زمین کشاورزی است. شهرستان کرج، واقع در استان البرز، با ارتفاع ۱۳۲۰ متر بالاتر از سطح دریا و بارش سالانه متوسط ۲۵۰ میلی‌متر، دارای اقلیم نیمه‌مرطوب می‌باشد (شکل ۱) (Ministry of jihad-e-agri, 2021). داده‌های این مطالعه از طریق یک بررسی میدانی در سطح ۶ هکتار جمع‌آوری شد. تمام مراحل کاشت، داشت و برداشت گندم بر اساس دستورالعمل‌های استاندارد موسسه ثبت و صدور گواهینامه بذر و گیاه انجام شد.

رویکردهای پژوهش

در این مطالعه، دو سامانه مصرف نهاده‌های شیمیایی بررسی شد:

روش متداول مصرف نهاده‌های شیمیایی

این روش شامل استفاده از کودهای فسفر، پتاسیم و نیتروژن به‌همراه علف‌کش شیمیایی برای گندم، مطابق با شیوه‌های سنتی منطقه و بر اساس توصیه‌های فنی کاشت و میزان علف‌کش به‌صورت یکنواخت در کل سطح در هر هکتار است. در این رویکرد، در طول دوره رشد گندم، به‌ازای هر هکتار ۲۰۷ کیلوگرم نیتروژن، ۶۹ کیلوگرم فسفات و ۵۰ کیلوگرم پتاسیم با توزیع یکنواخت در مزرعه مصرف می‌شود. همچنین، ترکیبی از علف‌کش‌های Oxial One (Syngenta) و Bazagran DP (BASF) به میزان ۲/۵ لیتر در هکتار استفاده می‌شود. این الگوی مصرف مطابق با روش مرسوم منطقه است و علف‌کش‌ها در ۱۰۰ درصد سطح مزرعه اعمال می‌شوند.

روش نرخ متغیر (Variable Rate Technology– VRT) مصرف نهاده‌ها

این سیستم مبتنی بر فناوری مکانیزه است که نرخ کاربرد علف‌کش‌ها و کودهای شیمیایی را به‌طور اختصاصی برای هر موقعیت مکانی با استفاده از نقشه‌های مکانی تهیه‌شده تنظیم می‌کند. نقشه‌های پراکنش مکانی علف‌های هرز و کودهای شیمیایی در سطح ۶ هکتار با استفاده از پهپادی مجهز به حسگرهای چندطیفی و همچنین آزمایش‌های میدانی خاک تهیه شد. با این حال، به دلیل نبود تجهیزات لازم برای اجرای عملیات پاشش و کوددهی با نرخ متغیر در مزرعه، تمامی برآوردها برای این رویکرد بر اساس شرایط شبیه‌سازی‌شده انجام شد. بنابراین، مزرعه تحقیقاتی فعلی با روش

متداول مدیریت می‌شود و عملکرد به‌دست‌آمده در هر دو رویکرد یکسان است؛ با این حال، داده‌های ورودی برای سیستم محاسباتی، مصرف نهاده‌ها را بر اساس شبیه‌سازی فناوری نرخ متغیر محاسبه می‌کند (جدول ۱).

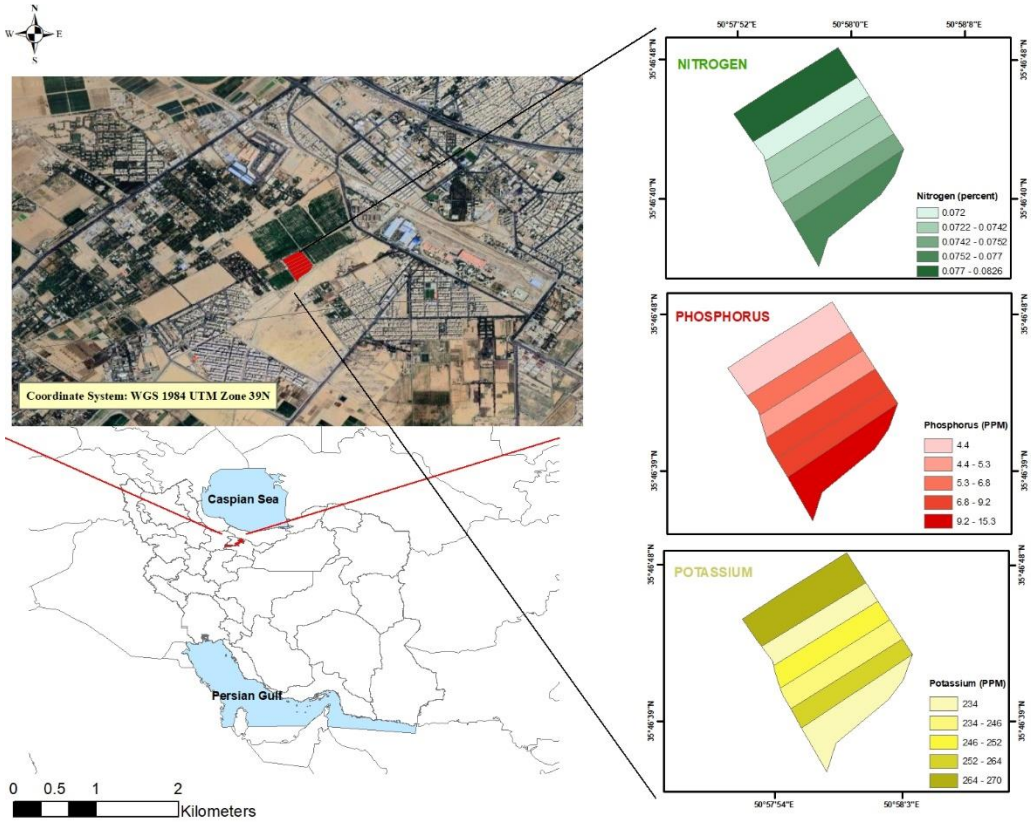

شکل ۱– منطقه مورد مطالعه، مزرعه زراعی و ویژگی‌های خاک در مزرعه گندم به مساحت ۶ هکتار

Fig.1. Study region, agricultural field, and soil characteristics in the 6-hectare wheat cultivation area

نقشه پراکنش و تراکم علف‌های هرز

برای شناسایی علف‌های هرز در مزرعه گندم، از پهپاد چندطیفی DJI Phantom 4 ساخت چین مجهز به دوربین‌های Parrot SEQUOIA+ استفاده شد. تصاویر سنجش از دور در تاریخ ۱۴ مارس ۲۰۲۳ از مزرعه گندم و با ارتفاع پرواز ۵۰ متر ثبت شدند. این تصاویر با وضوح مکانی بالا و پوشش طیفی گسترده، به‌ویژه در نواحی مرئی (قرمز، سبز، آبی) و مادون‌قرمز نزدیک (NIR) تهیه شدند. پهپادها نسبت به سایر پلتفرم‌های سنجش از دور، با قابلیت پرواز در ارتفاع پایین، ثبت تصاویر با رزولوشن میلی‌متری و ارائه داده‌ها در لحظات حساس متمایز می‌شوند. علاوه بر این، پهپادها نسبت به وسایل نقلیه زمینی بدون سرنشین (UGV) زمان کمتری برای پایش یا بازدید مزارع نیاز دارند و در حضور موانع طبیعی، مانورپذیری بهتری ارائه می‌دهند که در عملیات بین ردیف‌های محصولات اهمیت دارد (Monteiro & Santos, 2022). تمام مراحل تصویربرداری، پردازش تصاویر و تحلیل‌های فنی توسط شرکت آسمان سرخ آدینه انجام شد.

مزرعه انتخاب‌شده، شامل سطح ۶ هکتاری، در مزرعه تحقیقاتی شرکت خدمات مهندسی آب و خاک پارس واقع شده است و مختصات جغرافیایی آن ۴۶°۳۵'۴۲/۶" شمالی و ۵۷°۵۰'۱/۵۹" شرقی است. منطقه مطالعه شامل بخش‌های مختلف محصول و علف‌های هرز با تراکم‌ها و گونه‌های متفاوت بود (شکل ۲). بر اساس درصد حضور علف‌های هرز در مزرعه (۱۷/۶۶ درصد)، در رویکرد کاربرد علف‌کش با نرخ متغیر، همین درصد از سطح مزرعه تحت پوشش قرار گرفت.

برای اطمینان از پوشش طیفی مناسب و جامع، تصاویر در مرحله افزایش طول ساقه گندم و پیش از کنترل شیمیایی علف‌های هرز ثبت شدند. برای ارزیابی دقت شناسایی علف‌های هرز، داده‌های میدانی و نمونه‌های زمینی جمع‌آوری‌شده در همان تاریخ‌ها استفاده شد. علف‌های هرز مشاهده‌شده شامل یولاف وحشی (*Avena ludoviciana*)، جو وحشی (*Hordeum spontaneum*)، علف‌های دم‌موشی (*Setaria viridis*)، و علف‌های پهن‌برگ شامل ارشته

خطایی (*Lepyrodiclis holosteoides*)، خردل وحشی (*Sinapis arvensis*)، کیسه کشیش (*Capsella bursa-pastoris*)، سیزاب ایرانی (*Veronica persica*)، و سلمه تره (*Chenopodium album*) بودند.

جدول ۱- نهاده‌های مصرفی در کشت گندم تحت دو رویکرد مدیریت نهاده شامل روش مرسوم و نرخ متغیر

Table 1- Inputs used in wheat cultivation under conventional and variable rate (VRT) input management systems

ورودی Input	واحد Unit	روش نرخ متغیر VRT (6 ha^{-1})	روش مرسوم Non-VRT (6 ha^{-1})	ضرایب معادل Coefficient equivalent (MJ unit^{-1})	منابع Reference
نیروی انسانی Human labor	h ha^{-1}	511	551	1.96	(Kaab *et al*, 2019a)
ماشین‌ها Machinery	h ha^{-1}	31.5	39.5	62.70	(Ghasemi-Mobtaker *et al*., 2020)
سوخت دیزل Diesel fuel	L ha^{-1}	510	585	56.31	(Saber *et al*., 2021)
نیتروژن Nitrogen	kg ha^{-1}	966	1242	66.14	(Nabavi-Pelesaraei, Rafiee, Hosseinzadeh-Bandbafha, & Shamshirband, 2016)
فسفات Phosphate	kg ha^{-1}	253	414	12.44	(Basavalingaiah *et al*., 2020)
پتاسیم Potassium	kg ha^{-1}	75	300	11.15	(Rostami, Azizpanah, Fathi, & Taki, 2025)
ریزمغذی‌ها Micronutrients	kg ha^{-1}	15	15	120	(Hesampour, Hassani, Hanafiah, & Heidarbeigi, 2022)
علف‌کش Herbicide	L ha^{-1}	2.64	15	85	(Ghasemi-Mobtaker, Ataiee, Akram, & Kaab, 2024)
حشره‌کش Insecticide	L ha^{-1}	0.45	0.45	199	(Ozkan, Akcaoz, & Fert, 2004)
قارچ‌کش Fungicide	L ha^{-1}	0	0	92	(Kaab, Ghasemi-Mobtaker, & Sharifi, 2023)
بذر Seed	kg ha^{-1}	1500	1500	20.01	(Dekamin, Kheiralipour, & Afshar, 2022)
خروجی Output	kg ha^{-1}	34800	34800	–	

نمونه‌برداری و تحلیل خاک

نمونه‌برداری خاک در کل مساحت ۶ هکتاری با روش تصادفی-سیستماتیک انجام شد تا پوشش یکنواخت و نماینده‌ای از مزرعه حاصل شود. برای هر هکتار، پنج نمونه ترکیبی جمع‌آوری شد. هر نمونه ترکیبی از ادغام ۲۰-۱۵ نمونه جزئی جمع‌آوری‌شده به‌صورت تصادفی در الگوی زیگزاگ تهیه شد. وزن هر نمونه ترکیبی حدود ۱- ۱/۵ کیلوگرم بود. نمونه‌ها از عمق ۳۰-۰ سانتی‌متر، هم پیش از کاشت گندم و هم پس از برداشت محصول قبلی (ذرت علوفه‌ای) جمع‌آوری شدند. نمونه‌ها برای تعیین نیتروژن کل (N)، فسفر قابل‌دسترس (P)، پتاسیم قابل‌دسترس (K)، بافت خاک، هدایت الکتریکی و pH خمیر اشباع خاک مورد تجزیه و تحلیل قرار گرفتند. بر اساس ویژگی‌های اندازه‌گیری‌شده خاک، نقشه‌های پراکنش مکانی N، P و K تهیه شد تا اجرای روش VRT و مدیریت دقیق‌تر حاصلخیزی خاک امکان‌پذیر گردد. در رویکرد VRT، نرخ کوددهی مطابق با نیاز واقعی گندم تنظیم شد که منجر به مصرف ۷۷/۷۸ درصد نیتروژن، ۶۱/۱۱ درصد فسفر و ۲۳ درصد پتاسیم نسبت به روش متداول شد (شکل ۱).

روش‌شناسی ارزیابی چرخه زندگی (LCA)

رویکرد LCA، که به آن تحلیل تعادل زیستی یا گهواره تا گور نیز گفته می‌شود، اثرات زیست‌محیطی مرتبط با هر مرحله از چرخه عمر محصول را شامل استخراج مواد خام، پردازش، تولید، حمل‌ونقل، مصرف، نگهداری و دفع یا بازیافت نهایی بررسی می‌کند LCA به طراحان کمک می‌کند تا اثرات زیست‌محیطی محصولات خود را

ارزیابی و بهینه‌سازی کنند و از تمرکز محدود بر مسائل منفرد زیست‌محیطی جلوگیری می‌کند (Khanali, Salehpour, Rajabipour, & Kaab, 2025). در این مطالعه، تعریف هدف و محدوده شامل واحد عملکردی، مرزهای سیستم، توزیع منابع و تأثیر انتخاب بخش‌ها است (Kaab, Sharifi, & Moradi, 2021). انتخاب مرز سیستم اهمیت ویژه‌ای دارد، زیرا چالش‌های زیست‌محیطی مرتبط با سیستم‌های کشاورزی حتی پس از برداشت نیز ادامه دارند (Nejad, Almassi, & Ghahderijani, 2023).

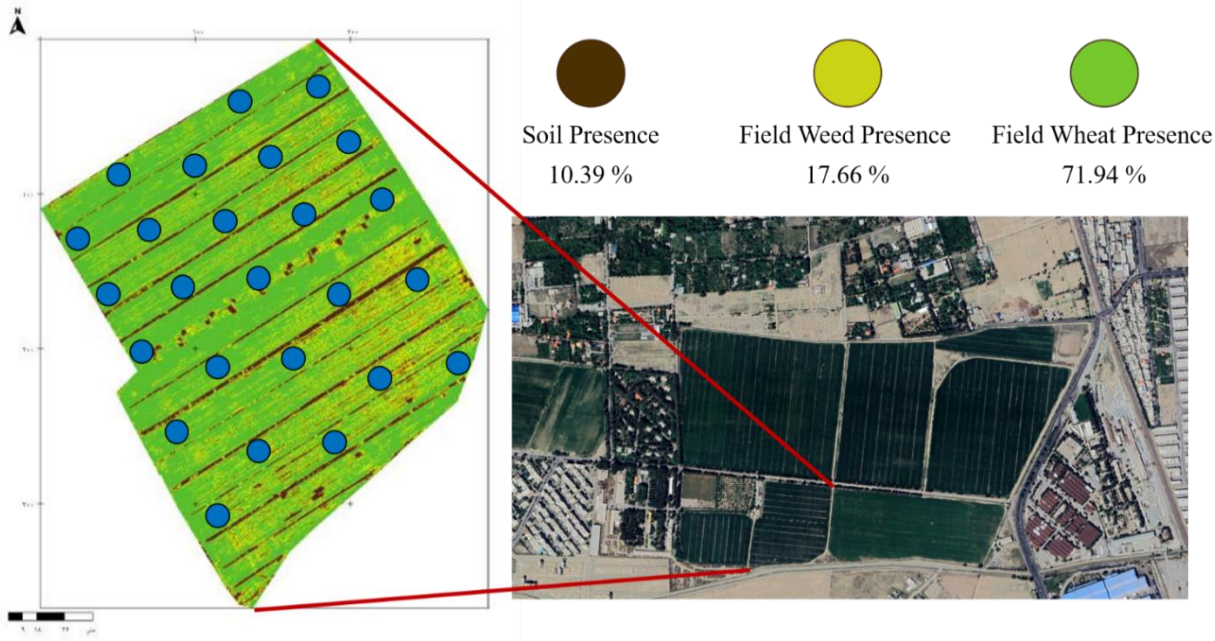

شکل ۲- میزان آلودگی علف‌های هرز در مدیریت نرخ متغیر در مزرعه گندم و نقاط نمونه‌برداری ترکیبی خاک

Fig. 2. Weed infestation levels under variable rate management in the wheat field, and locations of composite soil sampling points (blue dots)

مرز سیستم این مطالعه مربوط به کشت گندم در یک قطعه شش‌هکتاری است، که تمامی ورودی‌ها و خروجی‌های داخل آن بررسی می‌شوند. واحد عملکردی در این مطالعه تولید گندم در مساحت ۶ هکتار است و آلاینده‌های زیست‌محیطی بر اساس ورودی‌های مصرف‌شده برای تولید محصول محاسبه می‌شوند (Azizpanah, Fathi, & Taki, 2023). تحلیل نتایج در این مرحله، منابع مصرف‌شده و انتشار آلاینده‌ها در کل یا بخشی از چرخه عمر تولید گندم مورد بررسی قرار گرفت. منابع ورودی شامل نیروی کار، دیزل، کودهای شیمیایی، آفت‌کش‌ها، بذر و ماشین‌آلات بود. خروجی سیستم محصول گندم شامل دانه و کاه است. سیستم تولید با دو رویکرد تحلیل شد: نرخ متغیر و روش مرسوم منطقه‌ای.

هزینه اجتماعی کربن

این شاخص نمایانگر هزینه اقتصادی ناشی از انتشار هر تن اضافی CO_2 معادل است و به‌عنوان شاخصی برای ارزیابی اثرات اجتماعی و اقتصادی کاهش یا افزایش انتشار گازهای گلخانه‌ای در نظر گرفته خواهد شد. مقادیر SCC[1] برای گازهای مورد مطالعه بر اساس میانگین بین‌المللی و مطالعات ایران اعمال شد. هزینه اجتماعی کل گازهای گلخانه‌ای برای هر رویکرد با استفاده از رابطه شماره ۱ محاسبه خواهد شد (Wang *et al.*, 2019):

$$SCC_{total} = \sum_i (E_i \times SCC_i) \quad (۱)$$

که در آن E_i: میزان انتشار گاز هر آلاینده بر حسب کیلوگرم CO_2 معادل در هر هکتار (kg CO_2-eq ha^{-1})، SCC_i: هزینه اجتماعی هر واحد انتشار بر حسب دلار بر تن CO_2 معادل (USD t^{-1} CO_2-eq)، SCC_{total}: هزینه اجتماعی کل گازهای گلخانه‌ای بر حسب دلار بر هکتار (USD ha^{-1}) خواهد بود.

ورودی و خروجی انرژی

ورودی‌های انرژی شامل نیروی کار، سوخت دیزل، کودهای شیمیایی، آفت‌کش‌ها، بذر و ماشین‌آلات کشاورزی بودند. انرژی خروجی از محصول گندم شامل دانه و بقایای کاه و کلاله حاصل

1- Social cost of carbon

می‌شود. برای تبدیل دقیق این ورودی‌ها و خروجی‌ها به واحدهای انرژی قابل‌مقایسه، از ضرایب معادل انرژی استفاده شد (جدول ۱). ارزیابی مصرف و تولید انرژی در تولید گندم با دو رویکرد نرخ متغیر و غیرمتغیر انجام شد. چند شاخص کلیدی انرژی شامل نسبت انرژی، بهره‌وری انرژی، شدت انرژی و خالص انرژی به‌دست‌آمده مورد استفاده قرار گرفتند (Kaab, Sharifi, Mobli, Nabavi-Pelesaraei, & Chau, 2019b) (جدول ۲). این شاخص‌ها بر اساس واحد عملکردی ۶ هکتار استاندارد شدند تا مقایسه‌ای عادلانه بین سیستم‌های کشت فراهم گردد.

جدول ۲- شاخص‌های انرژی در کشت گندم تحت دو رویکرد مدیریت نهاده شامل روش مرسوم و نرخ متغیر

Table 2- Energy indicators of wheat cultivation under conventional and variable rate (VRT) input management systems

شاخص Index	واحد Unit	رابطه Equation
نسبت انرژی Energy Ratio	-	$Total\ output\ energy/Total\ input\ energy$
بهره‌وری انرژی Energy Productivity	kg MJ^{-1}	$Wheat\ yield/Total\ input\ energy$
شدت انرژی Specific Energy	MJ kg^{-1}	$Total\ input\ energy/Wheat\ yield$
افزوده خالص انرژی Net Energy Gain	MJ ha^{-1}	$Total\ output\ energy - Total\ input\ energy$

نرم‌افزارهای مورد استفاده

در این مطالعه جهت ارزیابی اثرات زیست‌محیطی و شاخص گرمایش جهانی از روش ReCiPe2016 و نرم‌افزار SimaPro V9.6 استفاده شد (Huijbregts *et al.*, 2017). همچنین جهت ترسیم نقشه‌های حاصلخیزی خاک از نرم‌افزار Arc Gis V10.4 استفاده شد. به‌منظور پردازش تصاویر سنجنده چندطیفی پهپادی از نرم‌افزار ENVI 5.3 استفاده شد.

نتایج

ارزیابی شاخص گرمایش جهانی و آلایندها به به هوا، آب و خاک

ارزیابی اثرات زیست‌محیطی شاخص گرمایش جهانی بر اساس روش ReCiPe 2016 Midpoint (H) V1.08 / World (2010) برای کشت گندم زمستانه تحت شرایط آبیاری در یک قطعه شش‌هکتاری در کرج، ایران، نشان داد شاخص گرمایش جهانی (Global Warming Potential – GWP) برای رویکرد کاربرد نرخ متغیر (VRA) در تولید گندم، برای تولید کل ۳۴/۸۰۰ کیلوگرم گندم، ۱۷/۶۹۱ کیلوگرم معادل CO_2 برآورد شد (شکل ۳). از میان منابع مختلف، انتشار مستقیم ناشی از کاربرد نرخ متغیر با۸/۶۰۳ کیلوگرم CO_2 معادل، تقریباً ۴۹ درصد از کل GWP را تشکیل می‌دهد. مصرف کود نیتروژن دومین منبع اصلی انتشار گازهای گلخانه‌ای بود که ۶/۸۹۲ کیلوگرم CO_2 معادل سهم داشت و نقش مهمی در افزایش گرمایش جهانی ایفا می‌کند. سایر منابع شامل بذر و سوخت دیزل ماشین‌آلات به‌ترتیب با ۱/۱۵۷ و ۳۹۰ کیلوگرم CO_2 معادل، سهم قابل‌توجهی دارند، در حالی‌که نقش ماشین‌آلات، فسفر، پتاسیم و ریزمغذی‌ها نسبتاً کمتر است. قابل‌توجه است که در این رویکرد، علف‌کش و حشره‌کش هیچ سهمی در GWP ندارند که نشان‌دهنده کاهش مصرف یا بهینه‌سازی کاربرد این نهاده‌هاست. شاخص گرمایش جهانی در رویکرد روش مرسوم یا بدون نرخ متغیر (N-VRT) برای تولید ۳۴/۸۰۰ کیلوگرم گندم، برابر با ۲۲۲۰۲/۷۴ کیلوگرم معادل CO_2 برآورد شد (شکل ۳). بیشترین سهم انتشار از انتشار مستقیم N-VRT با ۱۰۶۶۴/۴۴کیلوگرم CO_2 معادل ناشی می‌شود که تقریباً نیمی از کل GWP را تشکیل می‌دهد. همچنین، کود نیتروژن با ۸۸۶۱/۴۸ کیلوگرم CO_2 معادل دومین منبع مهم گرمایش جهانی محسوب می‌شود. سایر منابع شامل فسفر (۶۷۶/۹۲ kg CO_2 eq)، پتاسیم (۱۵۰/۷۹ kg CO_2 eq)، بذر (۱۱۵۷/۳۲ kg CO_2 eq) و سوخت دیزل (۴۴۷ kg CO_2 eq) هستند که هر کدام سهمی جزئی اما قابل‌توجه در کل انتشار دارند، در حالی‌که ماشین‌آلات (۲۱۶.۲۵ kg CO_2 eq) و ریزمغذی‌ها (۲۸/۵۵ kg CO_2 eq) تأثیر نسبتاً محدودی بر GWP دارند. همچنین، علف‌کش و حشره‌کش در این رویکرد سهمی ندارند که بیانگر کاهش یا بهینه‌سازی مصرف آن‌هاست (شکل ۳).

در مقایسه شاخص گرمایش جهانی بین دو رویکرد روش مرسوم یا بدون نرخ متغیر (Non-VRT) و روش نرخ متغیر (VRA)، تفاوت قابل‌توجهی مشاهده می‌شود. مقدار کل GWP برای رویکرد مرسوم ۲۲۲۰۲/۷۴ کیلوگرم معادل CO_2 است، در حالی‌که در رویکرد نرخ متغیر این عدد به ۱۷۶۹۱/۲۱ کیلوگرم معادل CO_2 کاهش یافته است (شکل ۳).

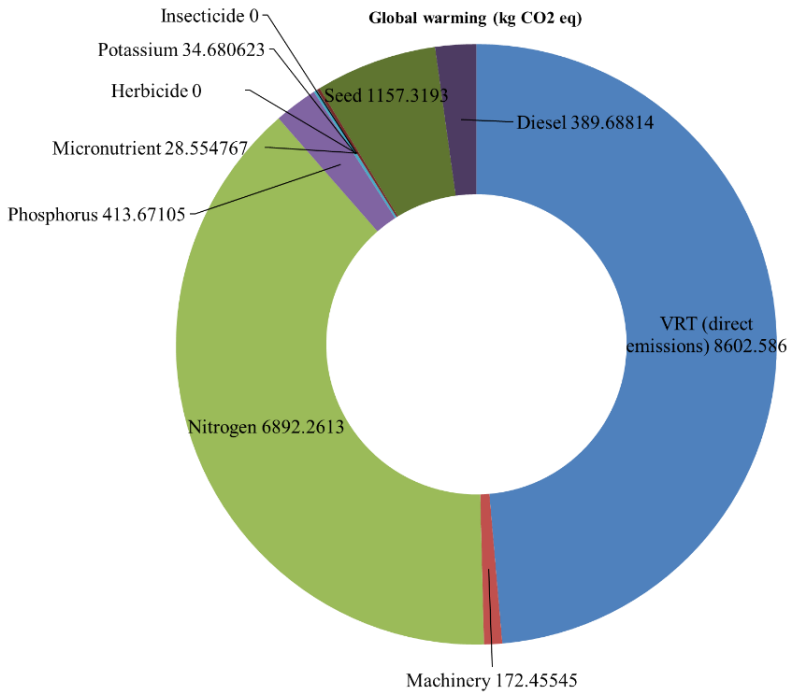

الف a

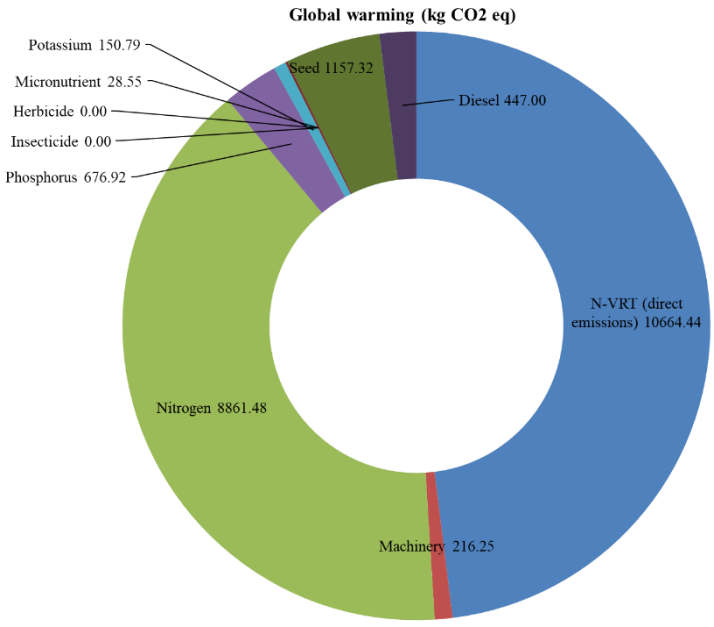

ب b

شکل ۳– سهم نهاده‌ها در شاخص گرمایش جهانی در شرایط مزرعه با دو رویکرد (الف) VRT و (ب) N-VRT

Fig. 3. Contribution of inputs to the Global Warming Potential in field conditions under (a) VRT and (b) N-VRT scenarios

جدول ۳- انتشار آلاینده‌ها در شرایط مزرعه‌ای تحت دو رویکرد کشت با نرخ متغیر (VRT) و توزیع یکنواخت (N-VRT) به هوا، آب و خاک

Table 3- Emissions to air, water, and soil from wheat production under conventional (N-VRT) and variable rate (VRT) systems in field conditions

انتشار به هوا **Emission to Air**	واحد **Unit**	روش نرخ متغیر **VRT (ha^{-1})**	روش مرسوم **Non-VRT (ha^{-1})**
کربن دی‌اکسید Carbon dioxide (CO_2)	kg ha^{-1}	4.04E+03	4.82E+03
اکسیدهای نیتروژن Nitrogen oxides (NO_x)	kg ha^{-1}	2.33E+02	2.96E+02
مونواکسید کربن Carbon monoxide (CO)	kg ha^{-1}	4.31E+00	4.94E+00
ذرات معلق Particulates (b2.5 µm)	kg ha^{-1}	3.07E+00	3.52E+00
هیدروکربن‌ها Hydro carbons (HC, as NMVOC)	kg ha^{-1}	1.95E+00	2.24E+00
دی‌اکسید گوگرد Sulfur dioxide (SO_2)	kg ha^{-1}	6.92E-01	7.94E-01
متان Methane (CH_4)	kg ha^{-1}	8.85E-02	1.01E-01
دی‌نیتروژن مونواکسید Dinitrogen monoxide (N_2O)	kg ha^{-1}	1.53E+01	1.96E+01
آمونیاک Ammonia (NH_3)	kg ha^{-1}	1.17E+02	1.51E+02
بنزن Benzene	kg ha^{-1}	5.00E-03	5.73E-03
انتشار به آب **Emission to Water**			
نیترات Nitrate	kg ha^{-1}	1.28E+02	1.65E+02
فسفر Phosphorus	kg ha^{-1}	5.52E+00	9.04E+00
انتشار به خاک **Emission to Soil**			
کادیوم Cd (Cadmium)	mg	28707.50	44979.00
مس Cu (copper)	mg	80539.50	123000.00
روی Zn (Zinc)	mg	684994.50	1053168.00
سرب Pb (lead)	mg	5264168.50	6782184.00
نیکل Ni (Nickel)	mg	71632.90	110935.80
کروم Cr (chromium)	mg	391023.90	615331.80
جیوه Hg (Mercury)	mg	281.20	444.00
آهن Fe (Iron)	mg	1500.00	1500.00
بور B (Boron)	mg	150.00	150.00
منگنز Mn (Manganese)	mg	1530.00	1530.00
مولیبدن Mo (Molybdenum)	mg	1500.00	1500.00

این کاهش نشان‌دهنده صرفه‌جویی حدود ۴/۵۱۲ کیلوگرم CO_2 معادل، معادل کاهش تقریبی ۲۰ درصد در انتشار گازهای گلخانه‌ای است. تحلیل منابع نشان می‌دهد که در روشVRA ، مصرف بهینه کود نیتروژن و کاهش انتشار مستقیم مزرعه‌ای اصلی‌ترین دلایل کاهش GWP هستند، در حالی‌که در رویکرد مرسوم، انتشار مستقیم و مصرف نیتروژن سهم بالاتری از گرمایش جهانی دارند. این مقایسه نشان می‌دهد که به‌کارگیری فناوری نرخ متغیر در تولید گندم می‌تواند به‌طور مؤثری اثرات گرمایش جهانی را کاهش داده و پایداری زیست‌محیطی را بهبود بخشد.

نتایج نشان داد که استفاده از روش نرخ متغیر (VRT) در تولید گندم، منجر به کاهش قابل‌توجه انتشار آلاینده‌ها نسبت به روش مرسوم (Non-VRT) شد. در بخش انتشار به هوا، مقدار دی‌اکسید کربن از ۴/۸۲۰ به ۴/۰۴۰ کیلوگرم در هکتار کاهش یافت که معادل کاهش حدود ۱۶/۲ درصد است. انتشار N_2O و NH_3 نیز به‌ترتیب از ۱۹/۶ و ۱۵۱ به ۱۵/۳ و ۱۱۷ کیلوگرم در هکتار کاهش یافت، که نشان‌دهنده کاهش ۲۱/۹ درصد و ۲۲/۵ درصد است (جدول ۳). سایر آلاینده‌های هوا شامل NOx، CO، PM2.5، HC و SO_2 نیز کاهش قابل‌توجهی بین ۱۲ تا ۲۱ درصد را نشان دادند. در بخش انتشار به آب، استفاده از VRT باعث کاهش نیترات از ۱۶۵ به ۱۲۸ کیلوگرم در هکتار (۲۲/۴ درصد کاهش) و فسفر از ۹/۰۴ به ۵/۵۲ کیلوگرم در هکتار (۳۸/۹ درصد کاهش) شد، که بیانگر بهبود کیفیت منابع آبی و کاهش اثرات تغذیه بیش از حد است. همچنین در بخش انتشار به خاک، تمام فلزات سنگین آلاینده از جمله Cd، Cu، Zn، Pb، Ni، Cr و Hg در رویکرد VRT کاهش قابل‌توجهی داشتند؛ برای مثال انتشار Pb از ۶۷۸۲/۱۸۴ به ۵۲۶۴۱۶۸/۵ میلی‌گرم (۴۶ درصد کاهش) و Zn از ۱۰۵۳/۱۶۸ به ۶۸۴۹۹۴/۵ میلی‌گرم (۳۵ درصد کاهش) کاهش یافت. فلزات کم‌اثرتر مانند Fe، B، Mn و Mo تغییر قابل‌توجهی نشان ندادند (جدول ۳).

شاخص هزینه اجتماعی آلاینده‌ها

بررسی میزان هزینه‌های اجتماعی آلاینده‌های ناشی از فرآیند تولید در هر دو رویکرد نرخ متغیر و توزیع یکنواخت نهاده‌ها به روش مرسوم نشان داد که به‌ترتیب اکسید نیتروژن (NO)، دی‌نیتروژن مونواکسید (N_2O) و کربن دی‌اکسید (CO_2) بیشتر هزینه‌ی اجتماعی را به‌خود اختصاص داده‌اند (جدول ۴). کمترین هزینه اجتماعی تحمیل‌شده نیز در هر دو رویکرد مختص به آلاینده محیطی متان (CH_4) می‌باشد.

جدول ٤– هزینه اجتماعی انتشار آلاینده‌های تولیدی در روش مرسوم و روش نرخ متغیر

Table 4– Social Cost of Emission under conventional and variable rate input management systems

شاخص Index	ضریب هزینه‌های اجتماعی آلاینده‌ها ESC Coefficient ($ Unit^{-1})	روش مرسوم Non-VRT (ha^{-1})	روش نرخ متغیر VRT (ha^{-1})	هزینه اجتماعی روش مرسوم Non-VRT ESC ($ 6ha^{-1})	هزینه اجتماعی روش نرخ متغیر VRT ESC ($ 6ha^{-1})
کربن دی‌اکسید Carbon dioxide (CO_2)	0.01	4.82E+03	4.04E+03	48.2	40.4
اکسیدهای نیتروژن Nitrogen oxides (NO_x)	0.6	2.96E+02	2.33E+02	177.6	139.8
مونواکسید کربن Carbon monoxide (CO)	0.19	4.94E+00	4.31E+00	0.9386	0.8189
دی‌اکسید گوگرد Sulfur dioxide (SO_2)	1.82	7.94E-01	6.92E-01	1.44508	1.25944
متان Methane (CH_4)	0.21	1.01E-01	8.85E-02	0.02121	0.018585
دی‌نیتروژن مونواکسید Dinitrogen monoxide (N_2O)	4.58	1.96E+01	1.53E+01	89.768	70.074
هزینه اجتماعی کل گازهای گلخانه‌ای SCC Total	-	-	-	317.97289	252.370925

به‌طور کلی میزان هزینه اجتماعی در رویکرد نرخ متغیر کمتر از روش مرسوم می‌باشد، به‌طوری‌که کل هزینه اجتماعی نرخ متغیر مصرف نهاده‌ها ۲۵۲/۳۷ دلار به‌ازای ۶ هکتار مزرعه مورد بررسی بود که این میزان نسبت به ۳۱۷/۹۷ دلار به‌ازای ۶ هکتار روش مرسوم در حدود ۲۰/۶۳ درصد کمتر بود (جدول ۴).

شاخص‌های انرژی و سهم انرژی نهاده‌ها

روش فناوری نرخ متغیر (VRT) برای مدیریت مصرف نهاده‌های شیمیایی در تولید گندم، منجر به مصرف کل انرژی ورودی معادل ۱۳۱۶۳۱/۵۷ مگاژول شد. از این مقدار، ۲۹۷۱۹/۶۶ مگاژول به انرژی مستقیم (نیروی انسانی و سوخت دیزل) و ۱۰۱۹۱۱/۹۱ مگاژول به انرژی غیرمستقیم (مربوط به تولید نهاده‌هایی همچون کودها و آفت‌کش‌ها) اختصاص یافت (جدول ۵). مصرف انرژی‌های تجدیدپذیر و غیرتجدیدپذیر به‌ترتیب برابر با ۳۱۰۱۶/۵۶ مگاژول و ۱۰۰۶۱۵/۰۱مگاژول محاسبه شد. کل انرژی خروجی این سیستم نیز برابر با ۸۹۷۳۳۷/۳۳ مگاژول برآورد شد. ارزیابی شاخص‌های انرژی در این رویکرد مدیریتی نشان داد که نسبت انرژی ۶/۸۲، بهره‌وری انرژی ۰/۲۶۴کیلوگرم بر مگاژول و شدت انرژی ۳/۷۸ مگاژول بر کیلوگرم است. همچنین، خالص انرژی به‌دست‌آمده در این روش برابر با ۷۶۵۷۰۵/۷۶ مگاژول محاسبه شد (جدول ۵).

در سیستم مدیریت متداول مصرف نهاده‌های شیمیایی، مصرف کل انرژی ورودی به ۱۶۰۳۱۸/۵۵ مگاژول رسید. از این مقدار، ۳۴۰۲۱/۳۱ مگاژول به انرژی مستقیم و ۱۲۶۲۹۷/۲۴مگاژول به انرژی غیرمستقیم تعلق داشت (جدول ۵). مصرف انرژی تجدیدپذیر برابر با ۳۱۰۹۴/۹۶ مگاژول و انرژی غیرتجدیدپذیر ۱۲۹۲۲۳/۵۹ مگاژول بود. کل انرژی خروجی این سیستم ۸۹۷۳۳۷/۳۳ مگاژول گزارش شد. شاخص‌های عملکرد انرژی برای این رویکرد به شرح زیر بودند: نسبت انرژی ۵/۵۹، بهره‌وری انرژی ۰/۲۱۷ کیلوگرم بر مگاژول و شدت انرژی ۴/۶۰ مگاژول بر کیلوگرم. خالص انرژی این سیستم برابر با ۷۳۷۰۱۸/۷۸ مگاژول محاسبه شد (جدول ۵). تحلیل شاخص‌های انرژی نشان داد که تمامی معیارهای مرتبط با انرژی در سیستم فناوری نرخ متغیر (VRT) نسبت به روش متداول بهبود یافته‌اند. به‌عنوان مثال، نسبت انرژی و بهره‌وری انرژی در رویکرد VRT به‌ترتیب ۲۱/۷۹ درصد بیشتر از مقادیر مشاهده‌شده در مدیریت متداول بود. علاوه‌بر این، شدت انرژی در روش VRT معادل ۱۷/۸۹ مگاژول بر کیلوگرم بود که نشان‌دهنده مصرف کمتر انرژی به‌ازای هر واحد محصول است.

جدول ۵- شاخص‌های انرژی در کشت گندم تحت دو سیستم مدیریت نهاده شامل روش مرسوم و روش نرخ متغیر

Table 5-Energy indicators of wheat cultivation under conventional and variable rate input management systems.

شاخص Index	روش مرسوم Non-VRT (MJ 6 ha^{-1})	روش نرخ متغیر VRT (MJ 6 ha^{-1})	نسبت (روش نرخ متغیر به روش مرسوم) Ratio (VRT vs N-VRT)
نسبت انرژی Energy Ratio	5.59	6.81	21.79
بهروه‌وری انرژی Energy Productivity (kg MJ^{-1})	0.21	0.26	21.79
شدت انرژی Specific Energy (MJ kg^{-1})	4.60	3.78	-17.9
افزوده خالص انرژی Net Energy Gain (MJ ha^{-1})	737018.78	765705.76	3.892
انرژی مستقیم Direct Energy	34021.31	29719.66	-12.6
انرژی غیرمستقیم Indirect Energy	126297.24	101911.91	-19.3
انرژی تجدیدپذیر Renewable Energy	31094.96	31016.56	-0.25
انرژی غیرتجدیدپذیر Non-renewable Energy	129223.59	100615.01	-22.1
کل انرژی ورودی Total Energy Input	160318.55	131631.57	-17.9
کل انرژی خروجی Total Energy Output	897337.33	897337.33	-

مصرف انرژی مستقیم و غیرمستقیم در سیستمVRT نیز به‌ترتیب ۱۲/۶۴ مگاژول و ۱۹/۳۱ مگاژول کمتر از سیستم متداول بود (جدول ۵). روند کاهشی مشابهی در سایر شاخص‌های انرژی مشاهده شد. به‌طور کلی، این اعداد کاهش قابل‌توجهی در ورودی‌های انرژی و بهبود کارایی انرژی را در هنگام استفاده از نهاده‌های شیمیایی با استراتژی نرخ متغیر نسبت به کاربرد یکنواخت نشان می‌دهند.

بحث

شبیه‌سازی فناوری نرخ متغیر (VRT) در مصرف نهاده‌های شیمیایی به‌ویژه کودهای نیتروژن، فسفر و پتاسیم منجر به کاهش ۱۷/۹ درصد در انرژی مصرفی نهاده‌ها شد. با توجه به ۱۲/۹۵میلیون هکتار زمین کشاورزی قابل‌کشت در ایران که از این میزان، ۱۰/۲ میلیون هکتار به غلات اختصاص دارد (Ministry of jihad-e-agri, 2021)، چنین کاهش انرژی می‌تواند تأثیر قابل‌توجهی بر تراز انرژی ملی داشته باشد. بهبود کلی تمام شاخص‌های انرژی در این مطالعه نشان می‌دهد که حرکت به سوی مدیریت مکان‌محور و تنظیم نرخ مصرف نهاده‌ها می‌تواند پایداری تولید را افزایش دهد. بیشترین درصد کاهش در مصرف مربوط به علف‌کش‌های شیمیایی (۸۰/۴۰٪) و کودهای پتاسیم (۷۷٪) بود. کاهش علف‌کش‌ها بر اساس نقشه پراکنش علف‌های هرز و کاهش کود پتاسیم ناشی از میزان بالای پتاسیم خاک طبق نقشه حاصلخیزی زمین تعیین شد. استفاده از حشره‌کش‌ها بدون تغییر باقی ماند، زیرا روش کاربرد آن‌ها نیازمند پوشش یکنواخت در تمام سطح مزرعه است. برخلاف پراکنش علف‌های هرز، حضور آفات تکه‌ای نیست و باید به‌طور جامع مدیریت شود (Baradaran Motie, Saeidirad, & Jafarian, 2023).

در رویکرد VRT، سهم کودها و علف‌کش‌ها در کل انرژی مصرفی کاهش یافت، در حالی‌که سهم بذر از ۱۸/۷۲ درصد به ۲۲/۸۰ درصد افزایش یافت. این افزایش در نهاده‌های تجدیدپذیر به پایداری تولید کمک می‌کند.

تحلیل مستقیم داده‌های این مطالعه نشان می‌دهد که کاهش مصرف نیتروژن و پتاسیم مستقیماً با کاهش انتشار گازهای گلخانه‌ای (GWP) و آلاینده‌ها در هوا، آب و خاک مرتبط است. به‌طور مثال، کاهش مصرف کود نیتروژن در سیستم VRT باعث کاهش ۲۰ درصدی شاخص گرمایش جهانی شد و کاهش مصرف سوخت دیزل و انرژی مستقیم مزرعه‌ای منجر به کاهش انتشار CO_2 و N_2O شد. این یافته‌ها تأکید می‌کنند که مدیریت مکان‌محور نهاده‌ها می‌تواند همزمان بهبود کارایی انرژی و کاهش اثرات زیست‌محیطی را تضمین کند.

مطالعات قبلی نشان داده‌اند که VRT مبتنی بر نقشه‌های هوایی تهیه‌شده توسط پهپادهای مجهز به دوربین‌های چندطیفی قادر به شناسایی علف‌های هرز می‌تواند مصرف نهاده‌های شیمیایی را کاهش داده و کارایی آن‌ها را افزایش دهد، که در نهایت به کاهش انرژی مصرفی منجر می‌شود (Meesaragandla *et al*., 2024). به‌عنوان نمونه، نقشه‌برداری با پهپاد از Cirsium arvense در مزارع گندم و جو باعث کاهش ۵۰ درصدی مصرف علف‌کش‌ها شد (Esposito *et al*., 2021). مطالعات دیگر نشان داده‌اند که استفاده از پهپاد برای کنترل مورچه‌خوار ساقه شکر می‌تواند مصرف آفت‌کش را تا ۹۰ درصد کاهش داده و کارایی سمپاشی را تا ۱۴ برابر افزایش دهد (Zhang *et al*., 2019). همچنین، پهپادهای مورد استفاده برای نقشه‌برداری علف‌های هرز و اعمال علف‌کش‌ها می‌توانند ۰/۳ تا ۳ برابر کاراتر از روش‌های متداول باشند (Hunter, Gannon, Richardson, Yelverton, & Leon, 2020). یکی از راهکارهای مؤثر بهینه‌سازی، استفاده از سنجش از دور برای پایش علف‌های هرز و ارزیابی حاصلخیزی خاک است (Roslim *et al*., 2021).

با وجود تأثیر مثبت فناوری نرخ متغیر (VRT) در کاهش مصرف نهاده‌ها و انتشار آلاینده‌ها، پیاده‌سازی عملی آن با محدودیت‌های قابل‌توجهی مواجه است. هزینه بالای تجهیزات پهپاد و نرم‌افزارهای پیشرفته تحلیل داده‌های مکانی، یکی از موانع اصلی گسترش این فناوری در مزارع است، در حالی‌که کمبود زیرساخت فنی و نیروی انسانی متخصص، به‌ویژه در مزارع کوچک و پراکنده، اجرای آن را با چالش‌های عملی مواجه می‌سازد. علاوه‌بر این، ویژگی‌های پراکندگی آفات و نیاز به پوشش یکنواخت در برخی نهاده‌ها مانند حشره‌کش‌ها، توانایی سیستم VRT در بهینه‌سازی کامل مصرف انرژی و کاهش انتشار آلاینده‌ها را محدود می‌کند. این محدودیت‌ها نشان می‌دهند که به‌رغم پتانسیل بالای VRT در بهبود پایداری زیست‌محیطی و کارایی انرژی، موفقیت عملی آن نیازمند توسعه زیرساخت‌ها، آموزش نیروی انسانی و طراحی استراتژی‌های کاربردی متناسب با شرایط واقعی مزارع است. برآورد شده است که حدود ۱۵ درصد از هزینه‌های تولید کشاورزی در سطح مزرعه مرتبط با انرژی است. استفاده مؤثرتر از منابع انرژی و گسترش بهره‌برداری از انرژی‌های تجدیدپذیر در سطح مزرعه می‌تواند هم هزینه‌ها را کاهش دهد و هم انتشار گازهای گلخانه‌ای را کاهش دهد (Jensen *et al*., 2012). استفاده از فناوری نرخ متغیر در مصرف آفت‌کش‌ها در باغات پرتقال منجر به کاهش ۴۶ درصدی مصرف آفت‌کش شد که به افزایش بهره‌وری انرژی (از ۰/۵۹۴ به ۰/۶۵۰) و کارایی انرژی (از ۰/۳۱۳ به ۰/۳۴۲ کیلوگرم بر مگاژول) منجر گردید (Fathi, Ghasemi-Nejad-Raeini, Abdanan Mehdizadeh, Taki, & Mardani Najafabadi, 2025). در کشت غلات، فناوری نرخ متغیر در مصرف کودهای

شیمیایی باعث کاهش ۳۳ درصد تا ۵۶ درصد در مصرف کودها شد که به نوبه خود کارایی اقتصادی را بهبود داده و آلاینده‌های محیطی را کاهش داد (Guerrero & Mouazen, 2021). اعمال علف‌کش‌ها با استفاده از پهپاد، عملکرد گندم و بازده اقتصادی را تا ۱۴/۶ درصد افزایش داد، به‌طوری‌که عملکرد با پهپاد به ۹۲۸۳/۴ کیلوگرم در هکتار رسید، در حالی‌که در روش دستی ۸۰۹۷/۵۸ کیلوگرم در هکتار بود (Hunter *et al*., 2020). نتایج استفاده از نرخ متغیر نیتروژن نشان داد که این روش منجر به کاهش شستشوی نیترات و افزایش بازده اقتصادی خالص نسبت به کاربرد یکنواخت نیتروژن شد. علاوه‌بر این، آلودگی محیطی کمتری در محدوده ۱۳/۶ هکتاری مطالعه ایجاد کرد (Basso *et al*., 2016).

نتیجه‌گیری و پیشنهادها

مطالعات حاضر نشان داد که استفاده از فناوری نرخ متغیر (VRT) برای مدیریت نهاده‌های شیمیایی در تولید گندم، به‌طور هم‌زمان باعث بهبود کارایی انرژی و کاهش اثرات زیست‌محیطی شد. شاخص‌های انرژی نشان دادند که سیستم VRT نسبت به روش مرسوم، مصرف کل انرژی ورودی کمتری دارد و تمامی شاخص‌های انرژی شامل نسبت انرژی، بهره‌وری انرژی و شدت انرژی بهبود یافته‌اند. خالص انرژی تولیدشده در سیستم VRT نیز بیشتر از سیستم مرسوم بود و نشان‌دهنده استفاده بهینه از انرژی‌های مستقیم و غیرمستقیم است. از دیدگاه زیست‌محیطی، استفاده از VRT منجر به کاهش قابل‌توجه انتشار گازهای گلخانه‌ای و آلاینده‌ها به هوا، آب و خاک شد. شاخص گرمایش جهانی (GWP) در این سیستم حدود ۱۷/۶۹۱ کیلوگرم CO_2 معادل بود که نسبت به رویکرد مرسوم کاهش تقریبی ۲۰ درصد را نشان می‌دهد. این کاهش عمدتاً ناشی از بهینه‌سازی مصرف کود نیتروژن و کاهش انتشار مستقیم مزرعه‌ای بود. همچنین، کاهش انتشار آلاینده‌های هوا مانند CO_2، N_2O و NH_3 به‌ترتیب ۱۶/۲ درصد، ۲۱/۹ درصد و ۲۲/۵ درصد، و کاهش آلاینده‌های آب مانند نیترات و فسفر به‌ترتیب ۲۲/۴ درصد و ۳۸/۹ درصد، نشان‌دهنده بهبود کیفیت منابع هوا و آب است. در خاک نیز فلزات سنگین آلاینده مانند Pb و Zn به‌ترتیب حدود ۲۲/۴ درصد و ۳۵ درصد کاهش یافتند، در حالی‌که فلزات کم‌اثر مانند Fe، B، Mn و Mo تغییر قابل‌توجهی نشان ندادند. کل هزینه اجتماعی روش VRT نسبت به سیستم مرسوم در حدود ۲۰ درصد کاهش یافت. در مجموع، نتایج این مطالعه تأکید می‌کند که پیاده‌سازی سیستم نرخ متغیر نهاده‌ها می‌تواند هم‌زمان منجر به صرفه‌جویی انرژی، کاهش انتشار آلاینده‌ها و افزایش پایداری زیست‌محیطی تولید گندم شود. این یافته‌ها کاربرد عملی و علمی روش VRT را به‌عنوان یک راهکار مؤثر برای مدیریت پایدار نهاده‌ها و کاهش اثرات منفی زیست‌محیطی تأیید می‌کنند.

تعارض منافع

هیچ‌گونه تعارض منافع توسط نویسندگان بیان نشده است.

مشارکت نویسندگان

اشکان جلیلیان: جمع‌آوری داده‌ها، تحلیل آماری، استخراج و تهیه متن اولیه

محمد مهدی قاسمی: اعتبارسنجی، مشاوره فنی

حسن قاسمی مبتکر: پردازش داده‌ها، روش‌شناسی

علی کعب: تصویرسازی نتایج، پردازش داده‌ها، ویرایش متن

References

1. Anastasiou, E., Fountas, S., Voulgaraki, M., Psiroukis, V., Koutsiaras, M., Kriezi, O., Lazarou, E., Vatsanidou, A., Fu, L., Bartolo, F. Di, Barreiro-Hurle, J., & Gómez-Barbero, M. (2023). Precision farming technologies for crop protection: A meta-analysis. *Smart Agricultural Technology*, *5*, 100323. https://doi.org/10.1016/J.ATECH.2023.100323
2. Azizpanah, A., Fathi, R., & Taki, M. (2023). Eco-energy and environmental evaluation of cantaloupe production by life cycle assessment method. *Environmental Science and Pollution Research*, *30*(1), 1854-1870. https://doi.org/10.1007/S11356-022-22307-2
3. Baradaran Motie, J. B., Saeidirad, M. H., & Jafarian, M. (2023). Identification of Sunn-pest affected (*Eurygaster Integriceps* put.) wheat plants and their distribution in wheat fields using aerial imaging. *Ecological Informatics*, *76*, 102146. https://doi.org/10.1016/J.ECOINF.2023.102146
4. Basavalingaiah, K., Ramesha, Y. M., Paramesh, V., Rajanna, G. A., Jat, S. L., Dhar Misra, S., Kumar Gaddi, A., Girisha, H. C., Yogesh, G. S., Raveesha, S., Roopa, T. K., Shashidhar, K. S., Kumar, B., El-Ansary, D. O., & Elansary, H. O. (2020). Energy Budgeting, Data Envelopment Analysis and Greenhouse Gas Emission from Rice Production System: A Case Study from Puddled Transplanted Rice and Direct-Seeded Rice System of Karnataka, India. *Sustainability*, *12*(16), 6439. https://doi.org/10.3390/su12166439
5. Basso, B., Dumont, B., Cammarano, D., Pezzuolo, A., Marinello, F., & Sartori, L. (2016). Environmental and economic benefits of variable rate nitrogen fertilization in a nitrate vulnerable zone. *Science of The Total Environment*, 227-235. https://doi.org/10.1016/J.SCITOTENV.2015.12.104

6. Dekamin, M., Kheiralipour, K., & Afshar, R. K. (2022). Energy, economic, and environmental assessment of coriander seed production using material flow cost accounting and life cycle assessment. *Environmental Science and Pollution Research*, *29*, 83469-83482. https://doi.org/10.1007/S11356-022-21585-0
7. Esposito, M., Crimaldi, M., Cirillo, V., Sarghini, F., & Maggio, A. (2021). Drone and sensor technology for sustainable weed management: a review. *Chemical and Biological Technologies in Agriculture*, *8*(1), 1-11. https://doi.org/10.1186/S40538-021-00217-8
8. Fabiani, S., Vanino, S., Napoli, R., Zajíček, A., Duffková, R., Evangelou, E., & Nino, P. (2020). Assessment of the economic and environmental sustainability of Variable Rate Technology (VRT) application in different wheat intensive European agricultural areas. A Water energy food nexus approach. *Environmental Science & Policy*, *114*, 366-376. https://doi.org/10.1016/J.ENVSCI.2020.08.019
9. Fathi, R., Ghasemi-Nejad-Raeini, M., Abdanan Mehdizadeh, S., Taki, M., & Mardani Najafabadi, M. (2025). Energy-environmental evaluation of conventional and variable rate technology sprayer; application of Life Cycle Assessment. *PLOS ONE*, *20*(2), e0314911. https://doi.org/10.1371/journal.pone.0314911
10. Ghasemi-Mobtaker, H., Mostashari-Rad, F., Saber, Z., Chau, K., & Nabavi-Pelesaraei, A. (2020). Application of photovoltaic system to modify energy use, environmental damages and cumulative exergy demand of two irrigation systems-A case study: Barley production of Iran. *Renewable Energy*, *160*, 1316-1334. https://doi.org/10.1016/j.renene.2020.07.047
11. Ghasemi-Mobtaker, H., Ataiee, F. S., Akram, A., & Kaab, A. (2024). Feasibility study of using photovoltaic cells for a commercial hydroponic greenhouse: Energy analysis and life cycle assessment. e-Prime- *Advances in Electrical Engineering, Electronics and Energy*, *8*, 100597. https://doi.org/10.1016/J.PRIME.2024.100597
12. Guerrero, A., & Mouazen, A. M. (2021). Evaluation of variable rate nitrogen fertilization scenarios in cereal crops from economic, environmental and technical perspective. *Soil and Tillage Research*, *213*, 105110. https://doi.org/10.1016/J.STILL.2021.105110
13. Gutjahr, C., Sökefeld, M., & Gerhards, R. (2012). Evaluation of two patch spraying systems in winter wheat and maize. *Weed Research*, *52*(6), 510-519. https://doi.org/10.1111/J.1365-3180.2012.00943.X
14. Hesampour, R., Hassani, M., Hanafiah, M. M., & Heidarbeigi, K. (2022). Technical efficiency, sensitivity analysis and economic assessment applying data envelopment analysis approach: A case study of date production in Khuzestan State of Iran. *Journal of the Saudi Society of Agricultural Sciences*, *21*, 197-207. https://doi.org/10.1016/j.jssas.2021.08.003
15. Hou, D., Meng, X., Qin, M., Zheng, E., Chen, P., Meng, F., & Zhang, C. (2024). Nitrous oxide (N_2O) emission characteristics of farmland (rice, wheat, and maize) based on different fertilization strategies. *PLOS ONE*, *19*(7). https://doi.org/10.1371/JOURNAL.PONE.0305385
16. Huijbregts, M. A. J., Steinmann, Z. J. N., Elshout, P. M. F., Stam, G., Verones, F., Vieira, M., Zijp, M., Hollander, A., & van Zelm, R. (2017). ReCiPe2016: a harmonised life cycle impact assessment method at midpoint and endpoint level. *International Journal of Life Cycle Assessment*, *22*(2), 138-147. https://doi.org/10.1007/S11367-016-1246-Y
17. Hunter, J. E., Gannon, T. W., Richardson, R. J., Yelverton, F. H., & Leon, R. G. (2020). Integration of remote-weed mapping and an autonomous spraying unmanned aerial vehicle for site-specific weed management. *Pest Management Science*, *76*(4), 1386-1392. https://doi.org/10.1002/ps.5651
18. Jalilian, A., Jahansouz, M. R., Ghasemi Mobtaker, H., Oveisi, M., & Moghadam, H. (2023). Evaluation of Energy Indicators in Monoculture, Intercropping, and Agroforestry Systems of Okra (*Abelmoschus esculentus* L.) Production in Khuzestan Province. *Iranian Journal of Field Crop Science*, *54*(2), 141-154. https://doi.org/10.22059/ijfcs.2022.348292.654938
19. Jensen, H. G., Jacobsen, L. B., Pedersen, S. M., & Tavella, E. (2012). Socioeconomic impact of widespread adoption of precision farming and controlled traffic systems in Denmark. *Precision Agriculture*, *13*(6), 661-677. https://doi.org/10.1007/S11119-012-9276-3
20. Kaab, A., Khanali, M., Shadamanfar, S., & Jalalvand, M. (2024). Assessment of energy audit and environmental impacts throughout the life cycle of barley production under different irrigation systems. *Environmental and Sustainability Indicators*, *22*, 100357. https://doi.org/10.1016/J.INDIC.2024.100357
21. Kaab, A., Sharifi, M., Mobli, H., Nabavi-Pelesaraei, A., & Chau, K. (2019a). Combined life cycle assessment and artificial intelligence for prediction of output energy and environmental impacts of sugarcane production. *Science of The Total Environment*, *664*, 1005-1019. https://doi.org/10.1016/j.scitotenv.2019.02.004
22. Kaab, A., Sharifi, M., Mobli, H., Nabavi-Pelesaraei, A., & Chau, K. (2019b). Use of optimization techniques for energy use efficiency and environmental life cycle assessment modification in sugarcane production. *Energy*, *181*, 1298-1320. https://doi.org/10.1016/j.energy.2019.06.002
23. Kaab, A., Sharifi, M., & Moradi, H. (2021). Analysis of Energy Indicators and Environmental Impacts of Dryland Cantaloupe Production with Life Cycle Assessment Approach (Case Study: Ilam). *Journal of Agricultural Machinery*, *11*(2), 491-504. https://doi.org/10.22067/jam.v11i2.82119
24. Kaab, A., Ghasemi-Mobtaker, H., & Sharifi, M. (2023). A study of changes in energy consumption trend and

environmental indicators in the production of agricultural crops using a life cycle assessment approach in the years 2018-2022. *Iranian Journal of Biosystem Engineering*, *54*, 1-18. https://doi.org/10.22059/ijbse.2023.364738.665522

25. Kaur, S., Kaur, R., & Chauhan, B. S. (2018). Understanding crop-weed-fertilizer-water interactions and their implications for weed management in agricultural systems. *Crop Protection*, *103*, 65-72. https://doi.org/10.1016/J.CROPRO.2017.09.011
26. Khanali, M., Salehpour, T., Rajabipour, A., & Kaab, A. (2025). Mitigating environmental impacts of cineraria production in greenhouses: A life cycle assessment approach for sustainability. *Energy Nexus*, *18*, 100453. https://doi.org/10.1016/J.NEXUS.2025.100453
27. MacLaren, C., Storkey, J., Menegat, A., Metcalfe, H., & Dehnen-Schmutz, K. (2020). An ecological future for weed science to sustain crop production and the environment. A review. *Agronomy for Sustainable Development*, *40*(4), 24. https://doi.org/10.1007/s13593-020-00631-6
28. Meesaragandla, S., Jagtap, M. P., Khatri, N., Madan, H., & Vadduri, A. A. (2024). Herbicide spraying and weed identification using drone technology in modern farms: A comprehensive review. *Results in Engineering*, *21*, 101870. https://doi.org/10.1016/J.RINENG.2024.101870
29. Ministry of Jihad-e-Agriculture of Iran. (2021). Annual Agricultural Statistics. www.maj.ir.
30. Misbah, K., Laamrani, A., Khechba, K., Dhiba, D., & Chehbouni, A. (2021). Multi-Sensors Remote Sensing Applications for Assessing, Monitoring, and Mapping NPK Content in Soil and Crops in African Agricultural Land. *Remote Sensing*, *14*(1), 81. https://doi.org/10.3390/rs14010081
31. Monteiro, A., & Santos, S. (2022). Sustainable Approach to Weed Management: The Role of Precision Weed Management. *Agronomy*, *12*(1), 118. https://doi.org/10.3390/agronomy12010118
32. Mostashari-Rad, F., Ghasemi-Mobtaker, H., Taki, M., Ghahderijani, M., Kaab, A., Chau, K., & Nabavi-Pelesaraei, A. (2021). Exergoenvironmental damages assessment of horticultural crops using ReCiPe2016 and cumulative exergy demand frameworks. *Journal of Cleaner Production*, *278*, 123788. https://doi.org/10.1016/j.jclepro.2020.123788
33. Nabavi-Pelesaraei, A., Rafiee, S., Mohammadkashi, N., Chau, K., & Mostashari-Rad, F. (2022). Principle of Life Cycle Assessment and Cumulative Exergy Demand for Biodiesel Production: Farm-To-Combustion Approach. In *Synergy Development in Renewables Assisted Multi-carrier Systems* (pp. 127–169). Springer, Cham. https://doi.org/10.1007/978-3-030-90720-4_6
34. Nabavi-Pelesaraei, A., Rafiee, S., Hosseinzadeh-Bandbafha, H., & Shamshirband, S. (2016). Modeling energy consumption and greenhouse gas emissions for kiwifruit production using artificial neural networks. *Journal of Cleaner Production*, 133, 924-931. https://doi.org/10.1016/j.jclepro.2016.05.188
35. Nejad, M. S., Almassi, M., & Ghahderijani, M. (2023). Life cycle energy and environmental impacts in sugarcane production: A case study of Amirkabir Sugarcane Agro-Industrial Company in Khuzestan province. *Results in Engineering*, *20*, 101545. https://doi.org/10.1016/j.rineng.2023.101545
36. Ozkan, B., Akcaoz, H., & Fert, C. (2004). Energy input–output analysis in Turkish agriculture. *Renewable Energy*, *29*, 39-51. https://doi.org/10.1016/S0960-1481(03)00135-6
37. Pogrzeba, M., Rusinowski, S., & Krzyżak, J. (2018). Macroelements and heavy metals content in energy crops cultivated on contaminated soil under different fertilization—case studies on autumn harvest. *Environmental Science and Pollution Research*, *25*(12), 12096-12106. https://doi.org/10.1007/S11356-018-1490-8
38. Radočaj, D., Jurišić, M., & Gašparović, M. (2022). The Role of Remote Sensing Data and Methods in a Modern Approach to Fertilization in Precision Agriculture. *Remote Sensing*, *14*(3), 778. https://doi.org/10.3390/rs14030778
39. Roslim, M. H. M., Juraimi, A. S., Che'Ya, N. N., Sulaiman, N., Manaf, M. N. H. A., Ramli, Z., & Motmainna, M. (2021). Using Remote Sensing and an Unmanned Aerial System for Weed Management in Agricultural Crops: A Review. *Agronomy*, *11*(9), 1809. https://doi.org/10.3390/agronomy11091809
40. Rostami, H., Azizpanah, A., Fathi, R., & Taki, M. (2025). Comparative analysis of environmental impact and energy consumption in sesame and mung bean production using life cycle assessment and data envelopment analysis. *Energy Nexus*, *17*, 100397. https://doi.org/10.1016/J.NEXUS.2025.100397
41. Saadi, H., Behnia, M., Taki, M., & Kaab, A. (2025). A comparative study on energy use and environmental impacts in various greenhouse models for vegetable cultivation. *Environmental and Sustainability Indicators*, *25*, 100553. https://doi.org/10.1016/J.INDIC.2024.100553
42. Saber, Z., van Zelm, R., Pirdashti, H., Schipper, A.M., Esmaeili, M., Motevali, A., Nabavi-Pelesaraei, A., & Huijbregts, M. A. J. (2021). Understanding farm-level differences in environmental impact and eco-efficiency: The case of rice production in Iran. *Sustainable Production and Consumption*, *27*, 1021-1029. https://doi.org/10.1016/j.spc.2021.02.033
43. Saha, A. K., Saha, J., Ray, R., Sircar, S., Dutta, S., Chattopadhyay, S. P., & Saha, H. N. (2018). IOT-based drone for improvement of crop quality in agricultural field. *2018 IEEE 8th Annual Computing and Communication Workshop and Conference, CCWC 2018*, *2018-January*, 612-615. https://doi.org/10.1109/CCWC.2018.8301662

44. Sharma, A., Kumar, V., Shahzad, B., Tanveer, M., Sidhu, G. P. S., Handa, N., Kohli, S. K., Yadav, P., Bali, A. S., Parihar, R. D., Dar, O. I., Singh, K., Jasrotia, S., Bakshi, P., Ramakrishnan, M., Kumar, S., Bhardwaj, R., & Thukral, A. K. (2019). Worldwide pesticide usage and its impacts on ecosystem. *SN Applied Sciences*, *1*(11), 1-16. https://doi.org/10.1007/S42452-019-1485-1
45. Soltani, N., Dille, J. A., Burke, I. C., Everman, W. J., VanGessel, M. J., Davis, V. M., & Sikkema, P. H. (2016). Potential Corn Yield Losses from Weeds in North America. *Weed Technology*, *30*(4), 979-984. https://doi.org/10.1614/WT-D-16-00046.1
46. Taherzadeh-Shalmaei, N., Rafiee, M., Kaab, A., Khanali, M., Vaziri Rad, M. A., & Kasaeian, A. (2023). Energy audit and management of environmental GHG emissions based on multi-objective genetic algorithm and data envelopment analysis: An agriculture case. *Energy Reports*, *10*, 1507-1520. https://doi.org/10.1016/J.EGYR.2023.08.020
47. Taherzadeh-Shalmaei, N., Sharifi, M., Ghasemi-Mobtaker, H., & Kaab, A. (2021). Evaluating the energy use, economic and environmental sustainability for smoked fish production from life cycle assessment point of view (case study: Guilan Province, Iran). *Environmental Science and Pollution Research*, *28*(38), 53833-53846. https://doi.org/10.1007/S11356-021-14437-W
48. Wang, Y., Yuan, Y., Yuan, F., Ata-UI-Karim, S. T., Liu, X., Tian, Y., Zhu, Y., Cao, W., & Cao, Q. (2023). Evaluation of Variable Application Rate of Fertilizers Based on Site-Specific Management Zones for Winter Wheat in Small-Scale Farming. *Agronomy*, *13*(11), 2812. https://doi.org/10.3390/agronomy13112812
49. You, M., Yao, D., Xu, F., Zhang, C., & Meng, J. (2022). Surface modification of rGO with PEG for the improvement of water/salt selectivity of CTA/rGO nanocomposites for desalination membrane applications. *Polymer*, *256*, 125228. https://doi.org/10.1016/J.POLYMER.2022.125228
50. Zhang, X. Q., Liang, Y. J., Qin, Z. Q., Li, D. W., Wei, C. Y., Wei, J. J., Li, Y. R., & Song, X. P. (2019). Application of Multi-rotor Unmanned Aerial Vehicle Application in Management of Stem Borer (Lepidoptera) in Sugarcane. *Sugar Tech*, *21*(5), 847-852. https://doi.org/10.1007/S12355-018-0695-Y

Journal of Agricultural Machinery

Homepage: https://jame.um.ac.ir

Research Article
Vol. 16, No. 4, 2026, p. 711-729

Design and Development of an Intelligent Golden Raisin Grading System Based on a Deep Convolutional Neural Network

H. Mirkhorasani[1], M. Abbasgholipour[1*], B. Mohammadi Alasti[1]

1- Department of Bio-System Mechanical Engineering, Bon.C., Islamic Azad University, Bonab, Iran
(*- Corresponding Author Email: mahdiabbasgholipour@iau.ac.ir)

Received: 26 December 2025
Revised: 11 February 2026
Accepted: 24 February 2026
Available Online: 06 June 2026

How to cite this article:
Mirkhorasani, H., Abbasgholipour, M., & Mohammadi Alasti, B. (2026). Design and Development of an Intelligent Golden Raisin Grading System Based on a Deep Convolutional Neural Network. *Journal of Agricultural Machinery*, *16*(4), 711-729. [in Persian]. https://doi.org/10.22067/jam.2026.97133.1458

Introduction

The qualitative grading of raisins, as an important agricultural commodity, plays a critical role in determining market value, pricing strategies, and competitiveness in both domestic and international markets. Conventional intelligent grading approaches have largely relied on manual feature extraction and complex image preprocessing techniques, which substantially increase computational cost and system complexity. Consequently, there is an increasing demand for automated, accurate, and non-destructive grading methods based on deep learning technologies, particularly for golden Sultana raisins.

The primary objective of this study is to develop a deep convolutional neural network (DCNN) capable of grading and evaluating golden Sultana raisins without requiring explicit image preprocessing, while simultaneously reducing processing time and computational overhead. Unlike previous studies that mainly focused on computational limitations or restricted classification schemes, the proposed model automatically extracts discriminative visual features; including texture, shape, and colour to accurately assess raisin quality and size under varying imaging conditions. This capability enhances robustness against variations in illumination, imaging angle, and background, thereby eliminating the need for complex preprocessing pipelines or manual parameter tuning.

Materials and Methods

In this study, a dedicated deep convolutional neural network, referred to as Raisin_DCNN, was specifically designed for grading golden Sultana raisin grains. The dataset consisted of 3,320 images representing four distinct quality grades. All images were acquired using a flatbed scanner under controlled lighting conditions to ensure consistency and uniform image quality.

To increase dataset diversity and reduce the risk of overfitting, data augmentation techniques were applied. These techniques included random horizontal and vertical flipping, cropping, shifting, zooming, and rotation. Notably, the proposed model was trained directly on the augmented images without applying complex preprocessing operations or manual feature extraction methods.

The Raisin_DCNN architecture was purpose-built to effectively extract visual features from each raisin. It comprises multiple convolutional layers with small kernel sizes, followed by MaxPooling layers for spatial dimensionality reduction, and fully connected layers at the final stage. ReLU activation functions were employed to facilitate the learning of nonlinear feature representations, while a Softmax function was used in the output layer to perform four-class classification. The architecture was carefully optimised to achieve an appropriate balance between classification accuracy and computational efficiency.

The dataset was divided into training, validation, and test subsets. Network training was performed using the Adam optimisation algorithm in conjunction with the categorical cross-entropy loss function. Learning rate

Authors retain the copyright. This is an open access article distributed under Creative Commons Attribution 4.0 International License (CC BY 4.0).

https://doi.org/10.22067/jam.2026.97133.1458

scheduling and early stopping strategies were implemented to improve convergence and prevent overfitting. Hyperparameter tuning was conducted through iterative experimentation based on validation performance.

For comprehensive performance evaluation, the proposed Raisin_DCNN model was compared with transfer learning approaches based on pre-trained InceptionV3 and InceptionResNetV2 architectures, as well as classical machine learning methods employing histogram-oriented gradients (HOG) and scale invariant feature transform (SIFT) feature extraction combined with support vector machine (SVM), k-nearest neighbours (KNN), and logistic regression (LR) classifiers.

Results and Discussion

Model performance was assessed using accuracy, precision, recall, and F1-score metrics. Experimental results demonstrated that the Raisin_DCNN model achieved an overall classification accuracy of 96%, outperforming both the transfer learning models and classical feature-based approaches. This superior performance highlights the effectiveness of the proposed network in automatically learning discriminative features directly from images of raisins. Furthermore, the elimination of complex preprocessing stages significantly reduced computational cost, thereby improving system efficiency and practical applicability.

Conclusion

The results of this study confirm that a dedicated deep convolutional neural network can provide an accurate, robust, and reliable solution for the automatic grading of golden Sultana raisins. The proposed Raisin_DCNN model demonstrates strong potential for real-world deployment in industrial grading systems and offers an effective approach for enhancing quality control processes in agricultural product inspection.

Acknowledgements

The authors sincerely thank all individuals and research groups who contributed to this work and provided technical assistance throughout the study. The authors would like to thank Department of Bio-System Mechanical Engineering, Islamic Azad University of Bonab Branch for their support and participation in this study. The authors also gratefully acknowledge the anonymous reviewers for their insightful comments and constructive suggestions, which significantly improved the quality of this manuscript.

Keywords: Convolutional layer, Feature extraction, Machine learning, Non-destructive evaluation, Transfer learning

نشریه ماشین‌های کشاورزی
https://jame.um.ac.ir

مقاله پژوهشی
جلد ۱۶، شماره ٤، زمستان ۱٤۰۵، ص ۷۲۹-۷۱۱

طراحی و توسعه سیستم هوشمند درجه‌بندی کشمش طلایی مبتنی بر شبکه عصبی کانولوشن عمیق

حامد میرخراسانی[۱]، مهدی عباسقلی پور[۱*]، بهزاد محمدی الستی[۱]

تاریخ دریافت: ۱۴۰۴/۱۰/۰۵
تاریخ پذیرش: ۱۴۰۴/۱۲/۰۵

چکیده

در تحقیق حاضر هدف اصلی، توسعه یک روش هوشمند، غیرمخرب و دقیق برای ارزیابی کیفی کشمش تیزآبی طلایی، مبتنی بر شبکه عصبی کانولوشن عمیق با عنوان Raisin_DCNN و بدون نیاز به پیش‌پردازش پیچیده تصویر و استخراج دستی ویژگی‌ها است. به‌منظور آموزش و ارزیابی مدل پیشنهادی، مجموعه‌داده‌ای شامل ۳۳۲۰ تصویر از دانه‌های کشمش در چهار سطح کیفی مختلف جمع‌آوری شد. مدل پیشنهادی Raisin_DCNN یک شبکه عصبی کانولوشن عمیق اختصاصی است که به‌طور خاص برای استخراج ویژگی‌های بصری دانه‌های کشمش طراحی شده است. در این شبکه از چندین لایه کانولوشن و توابع فعال‌ساز برای طبقه‌بندی چهارکلاسه استفاده شد. این شبکه، درجه‌بندی کشمش تیزآبی طلایی را بدون نیاز به پیش‌پردازش و با زمان پردازش کمتر با تکیه بر استخراج خودکار ویژگی‌های تصویری در شرایط تصویربرداری متغیر را انجام می دهد. عملکرد مدل پیشنهادی با دو مدل از پیش‌آموزش‌دیده مبتنی بر یادگیری انتقالی شامل InceptionV3 و InceptionResNetV2 و همچنین چندین الگوریتم کلاسیک یادگیری ماشین مبتنی بر ویژگی‌های HOG و SIFT و طبقه‌بندی‌کننده‌های ماشین بردار پشتیبان (SVM)، نزدیک ترین همسایگی K (KNN) و رگرسیون لجستیک (LR) مقایسه شد. ارزیابی مدل‌ها با استفاده از معیارهای دقت، صحت، حساسیت و F1-score انجام گرفت. نتایج نشان داد که مدل Raisin_DCNN با دستیابی به دقت کلی ۹۶ درصد، عملکردی برتر نسبت به مدل‌های یادگیری انتقالی و روش‌های کلاسیک ارائه می‌دهد. بر اساس نتایج به‌دست‌آمده، طراحی یک شبکه عصبی عمیق اختصاصی متناسب با ویژگی‌های بصری دانه‌های کشمش، نقش مؤثری در افزایش دقت درجه‌بندی دارد.

واژه‌های کلیدی: ارزیابی غیرمخرب، استخراج ویژگی، لایه کانولوشن، یادگیری انتقالی، یادگیری ماشین

مقدمه

کشمش میوه خشک‌شده انگور با نام علمی *ویتیس وینیفرا*[۲] است که طی فرآیند خشک‌شدن حدود ۷۵ تا ۸۰ درصد از رطوبت خود را از دست داده و به منبعی غلیظ از مواد مغذی تبدیل می‌شود. این محصول منبعی عالی از کربوهیدرات‌ها، فروکتوز و گلوکز، ویتامین‌های گروه B و K و نیز مواد معدنی همچون پتاسیم، کلسیم و منیزیم محسوب می‌شود (Kanellos *et al.*, 2013; Malek Madani & Soleimani, 2025; Schuster, Wang, Hawkins, & Painter, 2017). بر اساس گزارش سازمان خواربار و کشاورزی ملل متحد[۳]، ایران با قرار گرفتن در جایگاه سوم صادرات کشمش در جهان پس از ترکیه و آمریکا (FAO, 2023)، از جایگاهی مهمی در بازار جهانی این محصول برخوردار است. تنوع گسترده گونه‌های کشمش که در سطح جهانی مبادله می‌شوند، این محصول را به یک کالای راهبردی و اقتصادی پراهمیت تبدیل کرده است. درجه‌بندی کشمش تیزآبی طلایی (فرآوری‌شده از رقم انگور بی‌دانه سلطانی)، فرآیندی ضروری برای تعیین کیفیت و ارزش این محصول صادراتی است. این کار بر اساس معیارهایی مانند اندازه، رنگ و یکنواختی انجام می‌شود. درجه‌بندی استاندارد، کیفیت را تضمین کرده، رضایت مشتری را جلب می‌کند و اعتماد خریداران بین‌المللی را افزایش می‌دهد. در نهایت، این

۱- گروه مهندسی مکانیک بیوسیستم، واحد بناب، دانشگاه آزاد اسلامی، بناب، ایران
(*- نویسنده مسئول: Email: mahdiabbasgholipour@iau.ac.ir)
https://doi.org/10.22067/jam.2026.97133.1458

2- *Vitis vinifera*

3- FAO

امر به موفقیت در بازارهای جهانی و حفظ جایگاه رقابتی محصول کمک شایانی می‌کند (Malek Madani & Soleimani, 2025).

از این‌رو، ایجاد یک سیستم ارزیابی دقیق برای تشخیص کیفیت کشمش و شناسایی دانه‌های نامطلوب از اهمیت بالایی برخوردار است و ضرورت انجام این تحقیق را نشان می‌دهد. روش‌های سنتی در طبقه‌بندی دانه‌های خشکبار معمولاً از دقت کافی برخوردار نبوده و غالباً زمان‌بر هستند و دارای پیچیدگی‌های فنی می‌باشند (Abbasgholipour, Omid, Keyhani, & Mohtasebi, 2011; Mollazade, Omid, & Arefi, 2012). در سال‌های اخیر فناوری بینایی کامپیوتر به‌طور فزاینده‌ای در ارزیابی کنترل کیفیت و درجه‌بندی کشمش مورد توجه قرار گرفته است (Çınar, Koklu, & Taşdemir, 2020). روش‌های متعدد پردازش تصویر برای سنجش کمی کیفیت کشمش و تعیین معیارهای هندسی مانند اندازه و شکل ارائه شده‌اند (Omid, Abbasgolipour, Keyhani, & Mohtasebi, 2010). این روش‌ها شامل تحلیل رنگ، تخمین طول و ابعاد کشمش (Omid, Sharouzi, & Keyhani, 2010) و تعیین نسبت کشمش‌های سالم به ناسالم (Abbasgholipour *et al.*, 2011) می‌باشند. اگرچه تمامی این تکنیک‌های پردازش تصویر به نتایج بهتری منجر می‌شوند، اما همگی در یک ویژگی مشترک هستند: این الگوریتم‌ها کارایی تشخیص بلادرنگ را کاهش می‌دهند، چرا که به پیش‌پردازش گسترده تصویر و تکنیک‌های استخراج ویژگی نیاز دارند (Angadi & Hiregoudar, 2016).

یادگیری عمیق به‌عنوان یک فناوری نوین در حوزه یادگیری ماشین، انقلابی در عرصه هوش مصنوعی ایجاد کرده و قابلیت‌هایی را فراهم ساخته که پیش از این غیرقابل دسترس بودند. شبکه عصبی کانولوشنی[1] (CNN) به‌عنوان پیشرفته‌ترین فناوری این حوزه، مدلی مؤثر برای نمایش دادن و طبقه‌بندی داده‌ها ثابت شده است (Zhu, Li, Li, Wu, & Yue, 2018). شبکه‌های عصبی کانولوشنی عملکرد برجسته‌ای از خود نشان داده و مزایای آشکاری در مقایسه با سایر الگوریتم‌های کلاسیک یادگیری ماشین در تشخیص و طبقه‌بندی دارند (Wang, Shi, Zhang, & Ying, 2017). مزیت کلیدی استفاده از شبکه‌های عصبی کانولوشنی در این است که از پیکسل‌های تصویر به‌عنوان ورودی مستقیم شبکه استفاده می‌کند و هیچ‌گونه پردازش پیچیده تصویر یا تکنیک استخراج دستی ویژگی مورد نیاز نیست. علاوه‌بر این، به دلیل عملیات نمونه‌برداری و تجمیع که در لایه‌های مختلف شبکه انجام می‌شود، عملکرد شبکه‌های عصبی کانولوشنی نسبت به تبدیل‌های اولیه مانند چرخش و جابه‌جایی حساسیت کمتری نشان می‌دهد (Hinton *et al.*, 2012). در پژوهش‌های متعددی CNN به‌طور گسترده برای تقسیم‌بندی و طبقه‌بندی تصاویر به‌کار رفته است (Din *et al.*, 2024; Falahat Nejad Mahani & Karami, 2023; Fatehi, Bagherpour, & Amiri Parian, 2025; Raihen & Akter, 2024; Singla, Sarangi, Sahoo, & Singh, 2022). به‌عنوان مثال، لی و همکاران (Liu, Yang, Chen, Yu, & Li, 2022) شبکه عصبی کانولوشن را برای قطعه‌بندی تصاویر پزشکی مورد ارزیابی قرار دادند. این شبکه‌های عصبی از شبکه‌های عصبی کانولوشن عمیق[2] (DCNN) هستند و می‌توانند چندین ویژگی را به‌طور هم‌زمان از یک تصویر استخراج کنند. لایه‌های کانولوشنی، بخش تشخیص ویژگی را ایجاد می‌کنند که در فرآیند یادگیری آموزش‌پذیر است. هرچه شبکه عمیق‌تر و پیچیده‌تر شود، توانایی یادگیری آن افزایش می‌یابد، اما این افزایش عملکرد به هزینه محاسباتی و زمان بیشتر نیاز دارد. در نتیجه، مدل‌های یادگیری ماشینی مبتنی بر یادگیری انتقالی[3] (TL) به‌عنوان رویکردی کارآمد برای کاهش هزینه‌های محاسباتی و زمان آموزش مورد توجه قرار گرفته‌اند. با گسترش کاربردهای یادگیری ماشین در سال‌های اخیر، نیاز به مجموعه‌داده‌های بزرگ نیز افزایش یافته و این موضوع موجب پیشرفت چشمگیر روش‌های یادگیری شده است. از منظر یادگیری ماشین، مدل‌هایی که بر روی مجموعه‌داده‌های گسترده و متنوع آموزش دیده‌اند، توانایی تعمیم‌یابی بالایی پیدا می‌کنند و قادرند تصاویر را در دامنه‌های جدید با دقت قابل‌توجهی تشخیص دهند. در تحقیقی نادری بنی و همکاران (Naderi Beni, Bagherpour, & Amiri Parian, 2024) در رویکرد اول با استفاده از یادگیری انتقالی، دو الگوریتم مهم Inception-ResNet-v2 و ResNet-101 و در رویکرد دوم یک الگوریتم بهینه‌شده پیشنهادی برای طبقه‌بندی بیماری‌ها استفاده کردند. نتایج مدل‌ها نشان داد که حذف تصادفی باعث اصلاح دقت بعضی مدل‌ها گردید و بیشترین عملکرد با ۶۴ نورون در لایه مخفی حاصل گردید.

یو و همکاران (Yu, Liu, Wu, & He, 2012) با استفاده از روش ماشین بردار پشتیبان[4] (SVM)، کشمش‌ها را بر اساس رنگ، شکل و میزان چین‌وچروک به چهار دسته تقسیم کردند. آن‌ها با به‌کارگیری ویژگی‌های رنگ و بافت در تصاویر کشمش، به حدود ۹۵ درصد دقت طبقه‌بندی دست یافتند. در تحقیقی، باکس و خجسته نژند (Backes & Khojastehnazhand, 2024) با استفاده از روش بینایی ماشین، ۱۵ کلاس مختلف کشمش فله‌ای بر اساس ترکیب دانه‌های خوب و بد و چوب خشک را بررسی کردند. از ویژگی‌های بافت تصاویر برای طبقه‌بندی استفاده شد و بهترین ترکیب الگوریتم‌های استخراج بافت تصویر با استفاده از روش بهینه‌سازی

1- Convolutional neural networks (CNN)

2- Deep convolutional neural networks (DCNN)
3- Transfer learning (TL)
4- Support vector machines (SVM)

ازدحام ذرات[1] (PSO) ارزیابی شد. سه طبقه‌بندی‌کننده مختلف به نام‌های ماشین بردار پشتیبان، تحلیل تشخیص خطی[2] (LDA) و نزدیکترین همسایگی 3K (KNN) برای مدل‌سازی استفاده شدند. نتایج نشان داد که ترکیب چندین روش استخراج ویژگی بافت با استفاده از بهینه‌سازی ازدحام ذرات، دقت طبقه‌بندی را برای همه طبقه‌بندی‌کننده‌ها بهبود می‌بخشد. بهترین نتایج با استفاده از مدل‌سازی ماشین بردار پشتیبان و تحلیل تشخیص خطی به‌ترتیب با ۹۹/۳۳ و ۹۹/۷۳ درصد به‌دست آمد. البته قابل‌ذکر است که نتایج این تحقیق برای طبقه‌بندی کشمش فله‌ای گزارش شده است و طبقه‌بندی دانه‌های کشمش به‌صورت مجزا تحقیق متفاوتی است. در پژوهشی که اینچکارا (İncekara, 2024) انجام داد، دانه‌های کشمش با استفاده از مجموعه‌داده‌ی کشمش از مخزن یادگیری ماشین UCI و با به‌کارگیری سه روش مختلف شبکه عصبی مصنوعی طبقه‌بندی شدند. در این مطالعه، عملکرد سه مدل شبکه عصبی لایه رقابتی[4] (CLNN)، شبکه عصبی تشخیص الگو[5] (PRNN) و نقشه خودسازمان‌دهنده[6] (SOM) مورد ارزیابی قرار گرفت. نتایج نشان داد که مدل شبکه عصبی تشخیص الگو بهترین عملکرد را دارد، در حالی‌که نقشه خودسازمان‌دهنده نسبت به دو روش دیگر ضعیف‌تر عمل می‌کند. از سوی دیگر، شبکه عصبی لایه رقابتی عملکردی نزدیک به شبکه عصبی تشخیص الگو ارائه داده و می‌تواند به‌عنوان جایگزینی مناسب برای آن در طبقه‌بندی دانه‌های کشمش تیزآبی مورد استفاده قرار گیرد.

با توجه به این‌که شبکه عصبی کانولوشن عمیق یک روش جامع و کلی برای توسعه یک سیستم هوشمند تشخیص و شناسایی می‌باشد لذا طراحی یک شبکه اختصاصی با پارامترها و متغیرهای ویژه، برای ارزیابی کیفی کشمش، نوآوری اصلی این پژوهش می‌باشد؛ به‌طوری‌که طراحی یک شبکه عصبی کانولوشن عمیق (DCNN) می‌تواند فرآیند درجه‌بندی و ارزیابی کشمش تیزآبی طلایی را بدون نیاز به پیش‌پردازش و با زمان پردازش و هزینه محاسباتی کمتر انجام دهد. برخلاف مطالعات قبلی که بیشتر بر مسائل محاسباتی یا طبقه‌بندی‌های محدود تمرکز داشتند، مدل پیشنهادی این تحقیق با تکیه بر استخراج خودکار ویژگی‌های تصویری مانند بافت، شکل و رنگ، قادر است کیفیت و اندازه دانه‌ها را حتی در شرایط تصویربرداری متغیر به‌طور دقیق تشخیص دهد. این ویژگی باعث می‌شود مدل نسبت به تغییرات نور، زاویه و پس‌زمینه حساسیت کمتری داشته باشد و دیگر نیازی به مراحل پیچیده‌ی پیش‌پردازش یا تنظیمات دستی نباشد.

هدف این تحقیق، بررسی امکان استفاده از شبکه‌های عصبی کانولوشن عمیق برای شناسایی و طبقه‌بندی انواع کشمش با استفاده از تصاویر آن می‌باشد. همچنین، این مطالعه به دنبال توسعه یک سیستم طبقه‌بندی هوشمند، غیرمخرب، مستقل و کارآمد است که بتواند در درجه‌بندی کشمش نقش موثری را ایفا نماید.

مواد و روش‌ها

در این مطالعه، پس از جمع‌آوری تصاویر دانه‌های کشمش تیزآبی طلایی، مربوط به چهار درجه مختلف از این نوع کشمش، این تصاویر به‌عنوان ورودی، وارد مدل‌های شبکه عصبی خواهند شد. یک مدل شبکه عصبی کانولوشن عمیق ساده به نام Raisin_DCNN و دو مدل پیش‌آموزش‌دیده، یعنی InceptionV3 و InceptionResNetV2، برای آزمایش استفاده خواهد شد. نتایج به‌دست‌آمده همچنین با روش‌های سنتی یادگیری ماشین مقایسه خواهد گردید.

برای انجام این پژوهش، ابتدا مجموعه جامعی از تصاویر دانه‌های کشمش تیزآبی طلایی مطابق با جدول ۱ تهیه شد. تصاویر نمونه‌هایی از دانه‌های کشمش تیزآبی طلایی با چهار درجه مختلف در شکل ۱ نشان داده شده است. طبق استعلام از اداره تحقیقات کشاورزی شهرستان بناب درجه‌بندی کشمش تیزآبی طلایی حداقل به دو درجه و حداکثر به چهار درجه طبق استانداردهای صادراتی، توجیه اقتصادی دارد لذا بر اساس تعاریف آورده‌شده در جدول ویژگی‌های درجه‌های مختلف کشمش تیزآبی طلایی، در این تحقیق از حداکثر تعداد درجه‌بندی کشمش تیزآبی طلایی (چهار درجه مختلف) استفاده شد.

جمع‌آوری و پردازش اولیه داده‌ها

از نمونه‌های استانداردِ درجه‌بندی‌شده‌ی کشمش تیزآبی طلایی (فرآوری‌شده از رقم انگور بی‌دانه سلطانی) در اداره تحقیقات کشاورزی شهرستان بناب، از هر درجه (کلاس) ۸۳۰ دانه به‌صورت تصادفی انتخاب شد؛ در نتیجه، در مجموع ۳۳۲۰ تصویر برای ایجاد مجموعه‌داده تهیه گردید. این تصاویر با اسکن تک‌تک دانه‌های کشمش به‌وسیله‌ی یک اسکنر با وضوح بالا تهیه شدند. تصویربرداری از دانه‌های کشمش با استفاده از اسکنر تخت Scanjet Pro 2500 hp با وضوح اسکن نوری 200 dpi و عمق رنگی ۲۴ بیت انجام پذیرفت. در هر مرحله، ۲۴ دانه از یک درجه کشمش به‌صورت تصادفی روی صفحه شیشه‌ای اسکنر چیده شده و با یک لایه کاغذ سفید پوشانده شدند تا تصاویری با فرمت PNG تولید شود که سپس

1- Particle swarm optimisation (PSO)
2- Linear discriminant analysis (LDA)
3- K-Nearest Neighbours (KNN)
4- Competitive layer neural network (CLNN)
5- Pattern recognition artificial neural network (PRNN)
6- Self-organising map (SOM)

در حافظه رایانه ذخیره گردید. این جای‌گذاری تصادفی با هدف شبیه‌سازی سناریوهای دنیای واقعی و توزیع طبیعی و تنوع دانه‌های کشمش انجام شد. چیدمان تصادفی، مسئله‌ی شناسایی و تمایز دقیق دانه‌های منفرد را چالش‌برانگیزتر کرد. هر یک از ۳۳۲۰ تصویر، نمایانگر یک دانه کشمش منفرد است که در نهایت به ایجاد مجموعه‌داده‌ای جامع برای تجزیه و تحلیل منجر شد. سپس مجموعه‌داده به دو زیرمجموعه، مجموعه آموزش و مجموعه اعتبارسنجی تقسیم شد. مجموعه آموزش شامل ۲۲۴۰ تصویر و مجموعه اعتبارسنجی شامل ۱۰۸۰ تصویر بود. مجموعه داده‌های آزمایش نیز متشکل از ۱۲۰ تصویر دانه کشمش بود که متخصصین اداره تحقیقات کشاورزی شهرستان بناب –به‌منظور حفظ یکپارچگی و اطمینان از ارزیابی بی‌طرفانه مدل– درجه‌بندی آن‌ها را افشا نکردند.

این مجموعه آزمایشی برای ارزیابی مدل‌های یادگیری عمیق طراحی‌شده در این تحقیق و مدل‌های دیگر یادگیری ماشین مورد استفاده قرار گرفت. شرح جامع مجموعه‌داده‌های کشمش در جدول ۲ ارائه شده است. با توجه به این‌که الگوریتم شبکه عصبی مصنوعی به تصاویر ورودی با ابعاد ثابت نیاز دارد، لذا کلیه تصاویر با استفاده از کدی در نرم‌افزار پایتون به ابعاد ۵۱۲ × ۵۱۲ پیکسل برش داده و تغییر اندازه داده شدند. هرچه‌قدر اندازه تصویر دانه‌های کشمش بزرگ‌تر انتخاب شود کیفیت تصویر بیشتر شده و دقت شناسایی و درجه‌بندی آن بهتر انجام خواهد گرفت اما زمان پردازش افزایش خواهد یافت لذا حالت بهینه اندازه تصویر، با توجه به تحقیقات مشابه گذشته، به ابعاد ۵۱۲ × ۵۱۲ پیکسل انتخاب گردید.

جدول ۱- ویژگی‌های درجه‌های مختلف کشمش تیزآبی طلایی

Table 1- Golden raisin grading

درجه Grade	رنگ Colour	اندازه Size	شکل و بافت Shape & Texture
درجه ۱ (عالی) (Excellent)	طلایی روشن و یکنواخت Bright and uniform golden	بزرگ و یکسان Large and uniform	شکل منظم و بافت یکنواخت Regular shape and uniform texture
درجه ۲ (متوسط) (Premium)	طلایی با لکه جزئی Golden with slight spotting	متوسط تا نسبتاً بزرگ Medium to relatively large	نسبتاً منظم با بافت متعادل Relatively regular with balanced texture
درجه ۳ (استاندارد) (Standard)	طلایی تیره‌تر یا لکه‌دار Darker golden or spotted	اندازه متوسط Medium size	شکل نامنظم‌تر و بافت خشک‌تر Irregular shape and drier texture
درجه ۴ (ضعیف) (Low Grade)	رنگ ناهماهنگ و تیره Inconsistent and dark color	ریز و کوچک Small and tiny	شکل نامنظم و بافت نامطلوب Irregular shape and undesirable texture

جدول ۲- توزیع داده‌های آموزش، اعتبارسنجی و آزمایش برای چهار درجه از کشمش تیزآبی طلایی

Table 2- The distribution of the training, validation, and test datasets for the four grades of golden raisins

درجه کشمش Raisin grade	هاتعداد آموزش Training samples	تعداد اعتبارسنجی Validation samples	تعداد آزمون Test samples
درجه ۱ (Grade 1)	560	270	30
درجه ۲ (Grade 2)	560	270	30
درجه ۳ (Grade 3)	560	270	30
درجه ۴ (Grade 4)	560	270	30
مجموع (Sum)	2240	1080	120

در مرحله‌ی پردازش اولیه داده‌ها، ابتدا تعداد تصاویر با استفاده از روش‌های افزایش مصنوعی داده‌ها، گسترش یافت. در این فرایند، مجموعه‌ی تصاویر به‌صورت دسته‌ای آماده و سپس تغییر اندازه داده شدند. هدف از افزایش داده، ایجاد تنوع بیشتر در نمونه‌ها و جلوگیری از بیش‌برازش بود. برای این منظور، مجموعه‌ای از تبدیلات تصادفی مانند وارونه‌سازی، برش، جابه‌جایی، بزرگ‌نمایی و چرخش بر هر تصویر اعمال شد. این تبدیلات مدل را در معرض طیف گسترده‌تری از تغییرات ظاهری قرار می‌دهد و احتمال حفظ نمونه‌های خاص توسط مدل را کاهش می‌دهد. پس از انجام عملیات افزایش داده، تصاویر تولیدشده در قالب دسته‌های منظم سازمان‌دهی شدند.

دسته‌ای‌سازی، امکان پردازش هم‌زمان چندین تصویر را فراهم می‌کند که باعث افزایش کارایی آموزش و مدیریت بهتر حافظه می‌شود، زیرا نیازی به بارگذاری تمام مجموعه‌داده در حافظه‌ی سیستم به‌صورت یک‌باره نیست. در ادامه، اندازه‌ی تمام تصاویر در هر دسته به ۵۱۲ × ۵۱۲ پیکسل تغییر داده شد. همچنین در مرحله‌ی نرمال‌سازی، مقادیر پیکسل‌ها که در ابتدا در بازه‌ی [۲۵۵-۰] قرار داشتند، به محدوده‌ی [۱-۰] مقیاس‌بندی شدند تا شرایط برای آموزش پایدار و کارآمد مدل فراهم شود.



درجه ۱ (Grade 1) درجه ۲ (Grade 2) درجه ۳ (Grade 3) درجه ۴ (Grade 4)

شکل ۱- نمونه‌هایی از دانه‌های کشمش تیزآبی طلایی با چهار درجه مختلف

Fig. 1. Samples of golden raisins in four different grades

مدل پیشنهادی Raisin_DCNN

برای طبقه‌بندی دانه‌های کشمش تیزآبی طلایی، یک مدل جدید مبتنی بر شبکه عصبی کانولوشن عمیق با نام Raisin_DCNN پیاده‌سازی شد که در شکل ۲ نشان داده شده است. در این پژوهش، تصاویر دانه‌های کشمش با ابعاد ثابت ۵۱۲ × ۵۱۲ پیکسل به‌عنوان ورودی به مدل Raisin_DCNN داده شدند. مدل طبقه‌بندی پیشنهادی، با استفاده از زبان برنامه‌نویسی پایتون و بهره‌گیری از کتابخانه یادگیری عمیق Keras بر بستر TensorFlow در محیط Google Colab توسعه داده شد. ساختار معماری مدل Raisin_DCNN در جدول ۳ نشان داده شده است. این معماری شامل ده بلوک کانولوشن Conv. Blocks و دو بلوک کاملاً متصل F.C. Blocks[1] می‌باشد. هر بلوک کانولوشن (به‌جز اولین بلوک) از یک لایه کانولوشن، یک لایه نرمال‌سازی دسته‌ای[2]، یک لایه فعال‌سازی Relu و یک لایه تجمیع حداکثری Maxpooling تشکیل شده است. اولین بلوک، فقط شامل یک لایه کانولوشن، یک لایه نرمال‌سازی دسته‌ای و یک لایه فعال‌سازی Relu است. پیکربندی فیلترها (کرنل‌ها) در بلوک‌های کانولوشن به این صورت است که در دو بلوک اول ۱۶ عدد فیلتر با ابعاد ۵ × ۵ در بلوک‌های سوم و چهارم ۳۲ عدد فیلتر با ابعاد ۳ × ۳ در بلوک‌های پنجم و ششم ۶۴ عدد فیلتر با ابعاد ۳ × ۳ در بلوک‌های هفتم و هشتم ۱۲۸ عدد فیلتر با ابعاد ۳ × ۳ و در بلوک‌های نهم و دهم ۱۹۲ عدد فیلتر با ابعاد ۳ × ۳ استفاده شده است. ویژگی‌های که مدل مذکور توسط اولین بلوک کانولوشن یادگرفته، در شکل ۳ قابل مشاهده است. ابعاد ماتریس ویژگی‌ها با استفاده از لایه تجمیع حداکثری به یک ماتریس ۲×۲ کاهش بعد داده شد. برای یادگیری ترکیب ویژگی‌های تولیدشده توسط لایه‌های کانولوشنی، از بلوک‌های کاملاً متصل F.C. Block استفاده شد. اولین F.C. Block شامل یک لایه کاملاً متصل با ۱۹۲ نورون، یک لایه نرمال‌سازی دسته‌ای (BN)، یک لایه فعال‌سازی ReLu و یک لایه حذف Dropout است. آخرین F.C. Block نیز شامل یک لایه کاملاً متصل با ۴ نورون (متناظر با تعداد کلاس‌های خروجی یعنی چهار درجه کشمش تیزآبی طلایی) و یک تابع فعال‌سازی Softmax برای تبدیل ورودی به توزیع احتمال می‌باشد. در کل ساختار معماری Raisin_DCNN از تابع فعال‌سازی ReLu استفاده شده است. این تابع با حفظ مقادیر مثبت ورودی، مسئله ناپدید شدن گرادیان را حل می‌کند و به آموزش مؤثر مدل کمک می‌نماید. لایه نرمال‌سازی دسته‌ای در بلوک‌های کانولوشن گنجانده شد و مدل با ۵۰ دوره[3] آموزش داده شد. تکنیک نرمال‌سازی دسته‌ای می‌تواند تغییرپذیری متغیرهای کمکی داخلی را کاهش داده و فرآیند آموزش شبکه‌های عصبی عمیق را تسریع ببخشد (Alom, Hasan, Yakopcic, Taha, & Asari, 2020) در این آزمایش، یک لایه نرمال‌سازی دسته‌ای بین لایه کانولوشن و لایه فعال‌سازی ReLu قرار داده شد. با به‌کارگیری لایه حذف Dropout که ترکیبی تقریبی از پیکربندی‌های متعدد شبکه عصبی را ارائه می‌دهد، می‌توان از بروز پدیده بیش‌برازش جلوگیری کرد (Vidyarthi, Singh, Xiao, & Tiwari, 2021). در این پژوهش، نرخ حذف[4] بر روی ۰/۵ ثابت نگه داشته شد. از الگوریتم بهینه‌ساز Adam با نرخ یادگیری[5] (lr) ۰/۰۰۰۳ استفاده شد. این پارامترها به‌منظور دستیابی به بهترین عملکرد مدل و جلوگیری از همگرایی زودهنگام تنظیم شدند.

1- Fully Connected
2- Batch Normalisation

3- Epoch
4- Dropout rate
5- Learn rate

جدول ۳- ساختار مدل Raisin_DCNN

Table 3- Raisin_DCNN model architecture

بلوک Block	لایه‌های عملکردی Operational layers	تعداد فیلترها Filters	اندازه فیلتر Filter size	فعال‌سازی Activation	پارامترها Parameters
	لایه ورودی Input layer			512 × 512 × 3	
Conv. Block 1	Conv* layer BN layer + Relu	16	5 × 5	512 × 512 × 16	1,216
Conv. Block 2	Conv layer BN layer + Relu + Maxpooling	16	5 × 5	512 × 512 × 16	6,416
Conv. Block 3	Conv layer BN layer + Relu + Maxpooling	32	3 × 3	256 × 256 × 16	4,640
Conv. Block 4	Conv layer BN layer + Relu + Maxpooling	32	3 × 3	128 × 128 × 32	9,248
Conv. Block 5	Conv layer BN layer + Relu + Maxpooling	64	3 × 3	64 × 64 × 64	18,496
Conv. Block 6	Conv layer BN layer + Relu + Maxpooling	64	3 × 3	32 × 32 × 64	36,928
Conv. Block 7	Conv layer BN layer + Relu + Maxpooling	128	3 × 3	16 × 16 × 128	73,856
Conv. Block 8	Conv layer BN layer + Relu + Maxpooling	128	3 × 3	8 × 8 × 128	147,584
Conv. Block 9	Conv layer BN layer + Relu + Maxpooling	192	3 × 3	4 × 4 × 192	147,584
Conv. Block 10	Conv layer BN layer + Relu + Maxpooling	192	3 × 3	2 × 2 × 192	221,376
F.C. Block 1	Dense layer BN layer + Relu + Dropout layer			1 × 1 × 192	37,056
F.C. Block 2	Dense layer + Softmax layer			1 × 1 × 4	772

*Conv: کانولوشن (Convolution)، BN: نرمال‌سازی دسته‌ای (Batch Normalisation) ، F.C.: کاملاً متصل (Fully Connected)

نحوه انتخاب تعداد لایه‌ها و نوع توابع فعال‌سازی و پارامترهای شبکه، براساس تعداد لایه‌ها و نوع توابع به‌کار رفته در تحقیقات مشابه و مقدار پارامترها به روش سعی و خطا انتخاب گردید.

الگوریتم‌های ماشین بردار پشتیبان، نزدیکترین همسایگی K و رگرسیون لجستیک[1] از رایج‌ترین الگوریتم‌های یادگیری ماشین در طبقه‌بندی داده‌ها محسوب می‌شوند. بر این اساس، در ادامه این تحقیق، عملکرد مدل پیشنهادی Raisin_DCNN با الگوریتم‌های یادگیری ماشین مذکور مقایسه خواهد شد. کلیه آزمایش‌ها بر روی مجموعه‌داده‌ای متشکل از ۲۲۴۰ تصویر آموزشی و ۱۰۸۰ تصویر اعتبارسنجی انجام خواهد پذیرفت.

مدل‌های یادگیری انتقالی

یادگیری انتقالی یک روش مؤثر در یادگیری عمیق است که از مدل‌هایی استفاده می‌کند که قبلاً با داده‌های بزرگ آموزش دیده‌اند و ویژگی‌های مهم را آموخته‌اند. در این شیوه، به جای شروع آموزش از ابتدا، از دانشی که این مدل‌ها از قبل دارند برای حل مسئله جدید بهره گرفته می‌شود. با انجام تنظیمات دقیق[2] و سازگار کردن مدل با داده‌های حوزه هدف (که معمولاً کوچک‌تر هستند) می‌توان سرعت یادگیری را افزایش داد، دقت را بهبود بخشید و عملکرد مدل را پایدارتر کرد. این موضوع زمانی اهمیت بیشتری پیدا می‌کند که داده‌های کمی در اختیار داشته باشیم؛ زیرا مدل می‌تواند از تجربه قبلی خود برای یادگیری بهتر در شرایط جدید استفاده کند. بنابراین، هنگام کار با مجموعه‌داده‌های محدود، استفاده از یادگیری انتقالی یک راهکار ضروری است تا از بیش‌برازش جلوگیری شده و نتایج قابل‌اعتمادتری به‌دست آید.

در این مطالعه از دو معماری پیشرفته کانولوشنی، یعنی InceptionV3 و InceptionResNetV2، بهره گرفته شد (Alom *et al.*, 2020).

این دو مدل پیش‌تر بر روی پایگاه داده بزرگ ImageNet (Fei-Fei, Deng, & Li, 2009) آموزش دیده‌اند و بنابراین قادرند

1- Logistic Regression

2- Fine-tuning

ویژگی‌های اساسی تصاویر را به‌خوبی استخراج کنند. در روند پیاده‌سازی، بخش‌های انتهایی این شبکه‌ها که معمولاً شامل لایه‌های کاملاً متصل و خروجی Softmax هستند و صرفاً برای وظیفه طبقه‌بندی اولیه طراحی شده‌اند از ساختار مدل حذف می‌شوند. حذف این بخش‌ها شرایطی فراهم می‌کند تا مدل بتواند ضمن حفظ الگوهای آموخته‌شده در لایه‌های ابتدایی و میانی، برای مسئله جدید، سازگار شده و عملکرد بهتری در وظیفه جدید ارائه دهد. در معماری شبکه‌های عصبی عمیق، لایه‌های نهاییِ طبقه‌بندی متناسب با وظیفه اولیه و مجموعه‌داده مرجع، طراحی می‌شوند و نقش آن‌ها نگاشت بردارهای ویژگی به برچسب‌های خروجی است. حذف این بخش‌ها امکان پیکربندی مجدد مدل را فراهم می‌سازد تا شبکه بتواند وظایف تخصصی‌تری را برای مسئله جدید، مانند استخراج ویژگی‌های مرتبط با درجه‌بندی‌های دانه‌های کشمش، فراگیرد. در این تحقیق، از پیاده‌سازی دو مدل پیش‌آموزش‌دیده InceptionV3 و InceptionResNetV2 در کتابخانه Keras بهره گرفته شد. به‌کارگیری یادگیری انتقالی و انتقال بخشی از وزن‌های آموزش‌دیده بر پایه پایگاه داده ImageNet باعث شد مدل، ضمن حفظ دانش عمومی حاصل از داده‌های گسترده، با ویژگی‌های خاص مجموعه‌داده هدف نیز سازگار شود.

مدل InceptionV3 با تنظیمات دقیق

در این پژوهش، مدل InceptionV3 که پیش‌تر روی مجموعه‌داده ImageNet (مجموعه داده‌ای با ۱۴ میلیون تصویر و ۱۰۰۰ دسته) آموزش دیده بود، در ابتدا بدون تنظیم دقیق و تنها به‌عنوان استخراج‌کننده ویژگی مورد استفاده قرار گرفت. در شکل ۵ مراحل اعمال تنظیمات دقیق روی مدل InceptionV3 نشان داده شده است. در این مدل قبل از عملیات Flatten خروجی آخرین لایه یعنی لایه mixed7 به‌عنوان لایه استخراج‌کننده ویژگی، انتخاب گردید. به دلیل اختصاصی‌بودن لایه‌های کاملاً متصل مدل اولیه برای ImageNet، این لایه‌ها حذف شدند و دو بلوک کاملاً متصل بر روی مدل طراحی شدند. لایه اول شامل یک لایه Dense با ۱۰۲۴ نورون، یک لایه نرمال‌سازی دسته‌ای، یک تابع فعال‌سازی ReLu و یک لایه حذف با نرخ حذف ۰/۲ می‌باشد و بلوک دوم شامل یک لایهDense چهار نورونی و یک تابع Softmax می‌باشد. همان‌طوری که در شکل ۵ نشان داده شده است آموزش مدل در دو مرحله انجام شد. ابتدا فقط بلوک‌های کاملاً متصل آموزش داده شدند و بخش پیش‌آموزش‌دیده ثابت ماند. سپس لایه‌های ماژول mixed7 از حالت انجماد خارج شده و تنظیم دقیق برای سازگاری با مجموعه‌داده جدید اجرا شد آزمایش‌ها برای ۵۰ دوره با نرخ یادگیری ۰/۰۰۰۰۳ و اندازه دسته[1] ۳۲ انجام گرفت. این پارامترها به‌منظور دستیابی به تعادل بهینه بین سرعت همگرایی و دقت مدل انتخاب شدند.

مدل ترکیبی InceptionResNetV2 با تنظیم دقیق

معماری مدل InceptionResNetV2 ترکیبی از ساختارهای چندلایه‌ای مدل‌های آغازین و اتصالات باقی‌مانده است. این شبکه با استفاده هم‌زمان از بلوک‌های Inception و مسیرهای میان‌بُر، هم سرعت و هم زمان یادگیری عمیق را بهبود می‌بخشد. در این پژوهش، این مدل برای طبقه‌بندی چهار درجه از دانه‌های کشمش تیزآبی طلایی با اعمال تنظیم‌دقیق به‌کار گرفته شد. همان‌طوری که در شکل ۵ نشان داده شده است فرایند آموزش در دو گام صورت گرفت در مرحله اول تمام لایه‌های مدل اصلی قفل شدند و یک Head جدید جایگزین سه لایه کاملا متصل پایانی شد. این Head شامل یک لایه Pooling و سه بلوک کاملاً متصل می‌باشد. دو بلوک اول و دوم هر کدام به‌ترتیب شامل یک لایه Dense با ۵۱۲ و ۱۲۸ نورون، یک لایه حذف با نرخ ۰/۲ و یک لایه با تابع فعال‌سازی ReLu می‌باشند. بلوک آخر شامل یک لایه Dense با ۴ نورون و یک لایه با تابع Softmax برای خروجی نهایی (چهار درجه کشمش تیزآبی طلایی) می‌باشد. تمام وزن‌های Head به‌طور تصادفی مقداردهی اولیه شدند. در مرحله دوم پس از آموزش Head، بخشی از لایه‌های InceptionResNetV2 فعال و شبکه به‌صورت مشترک آموزش داده شد تا وزن‌های مدل پایه نیز تنظیم دقیق شوند. آموزش با بهینه‌ساز Adam و نرخ یادگیری ۰/۰۰۰۰۳ انجام شد. آزمایش‌ها در ۵۰ دوره و با اندازه دسته ۳۲ اجرا گردید.

معیارهای ارزیابی عملکرد مدل‌ها

برای مقایسه و ارزیابی عملکرد مدل‌های مختلف از معیارهای ویژه‌ای همچون دقت (رابطه ۱)، صحت (رابطه ۲)، حساسیت (رابطه ۳) و معیار F1-score (رابطه ۴) استفاده می‌شود. این معیارها را می‌توان از ماتریس اغتشاش استخراج کرد (Grandini, Bagli, & Visani, 2020). مقادیر مثبت واقعی (TP)، منفی واقعی (TN)، مثبت کاذب (FP) و منفی کاذب (FN) برای محاسبه این معیارهای عملکردی مورد استفاده قرار گرفتند.

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

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

$$\text{حساسیت} = \frac{TP}{TP+TN} \quad (۳)$$

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

1- Batch size

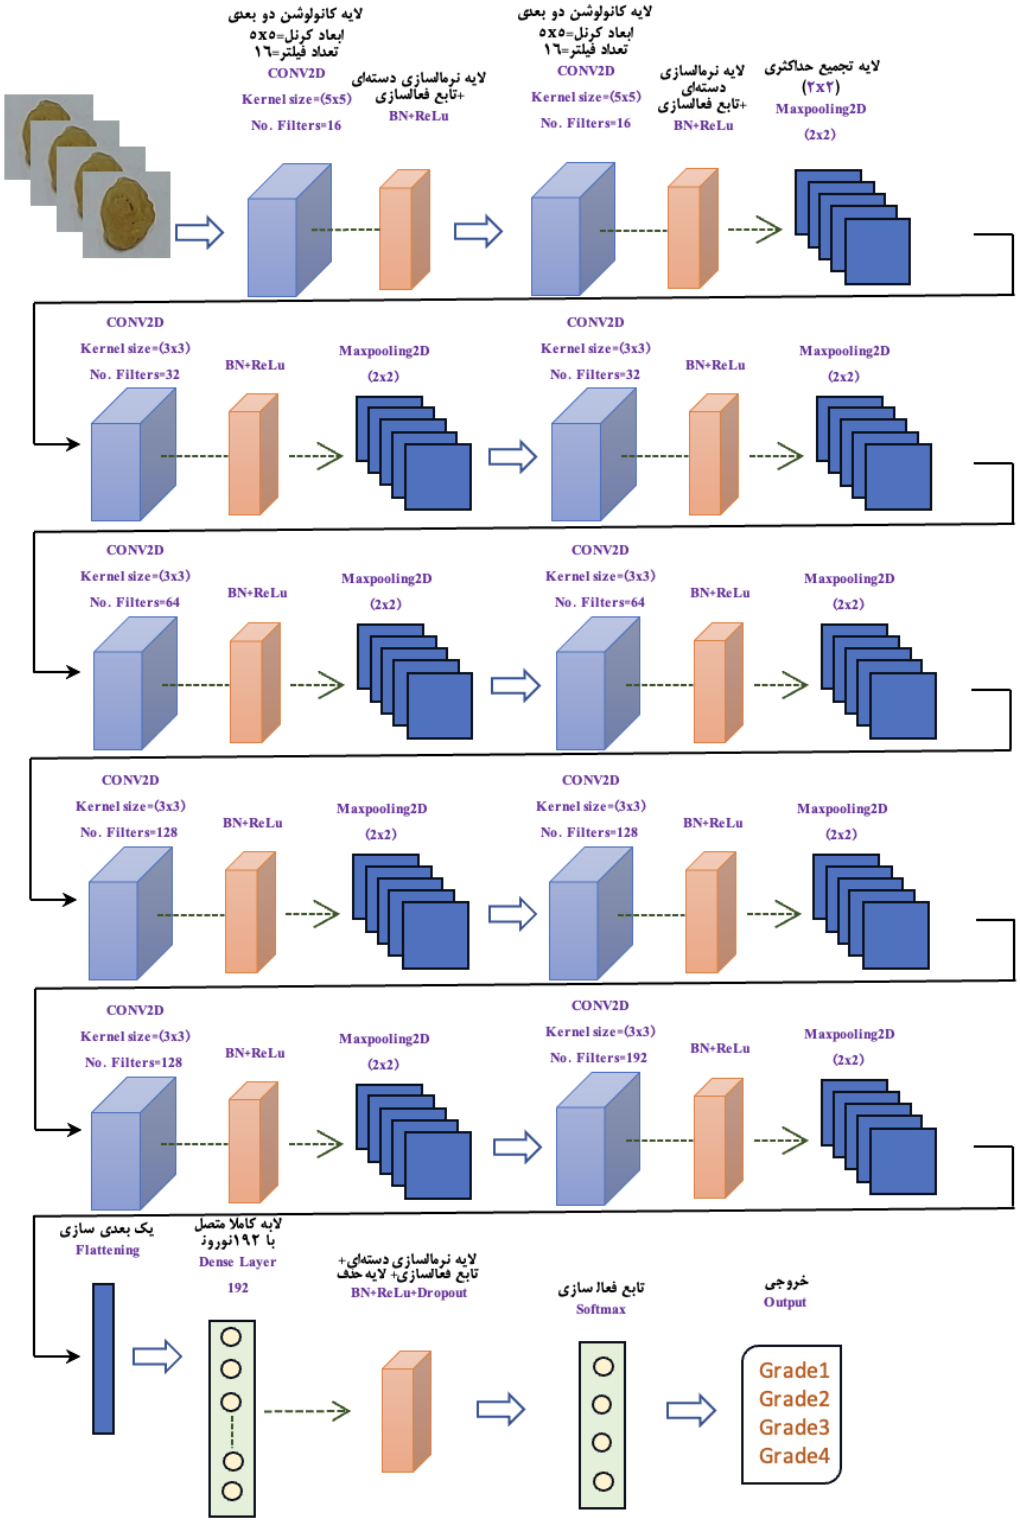

شکل ۲- ساختار معماری مدل Raisin_DCNN

Fig. 2. Raisin_DCNN model architecture

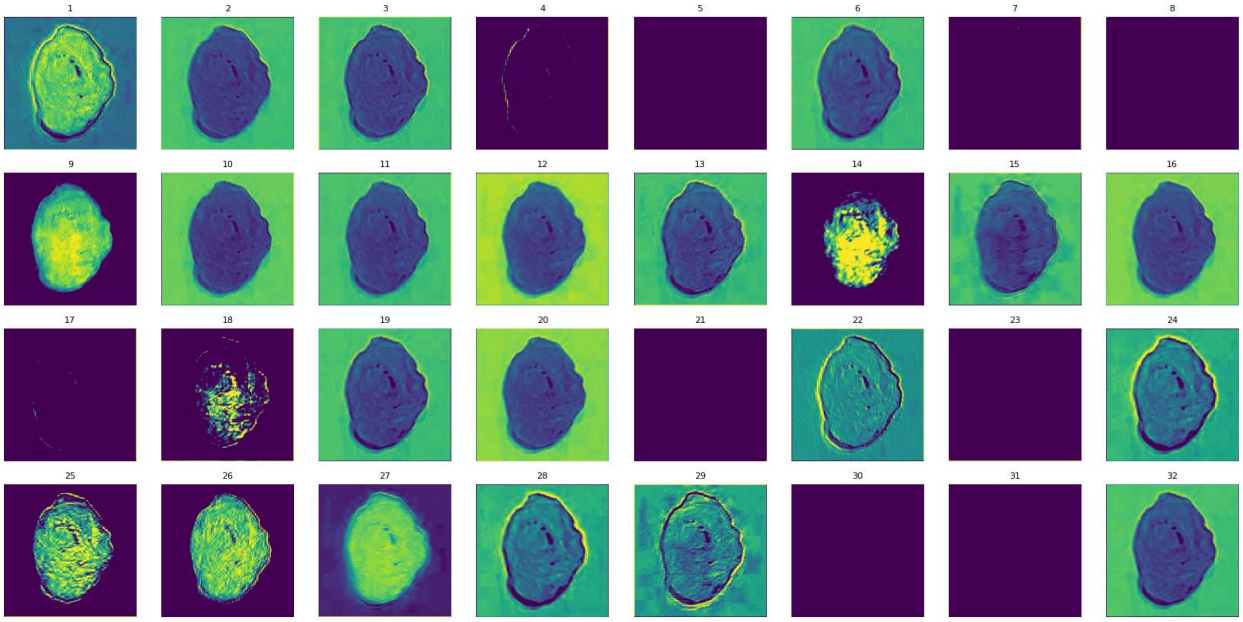

شکل ۳– ویژگی‌های آموخته‌شده توسط اولین بلوک کانولوشن با ۱۶ هسته کانولوشن (کرنل) با ابعاد ۵ × ۵

Fig. 3. Features learned by the first convolution block with 16 convolutional kernels of size 5 × 5 × 16

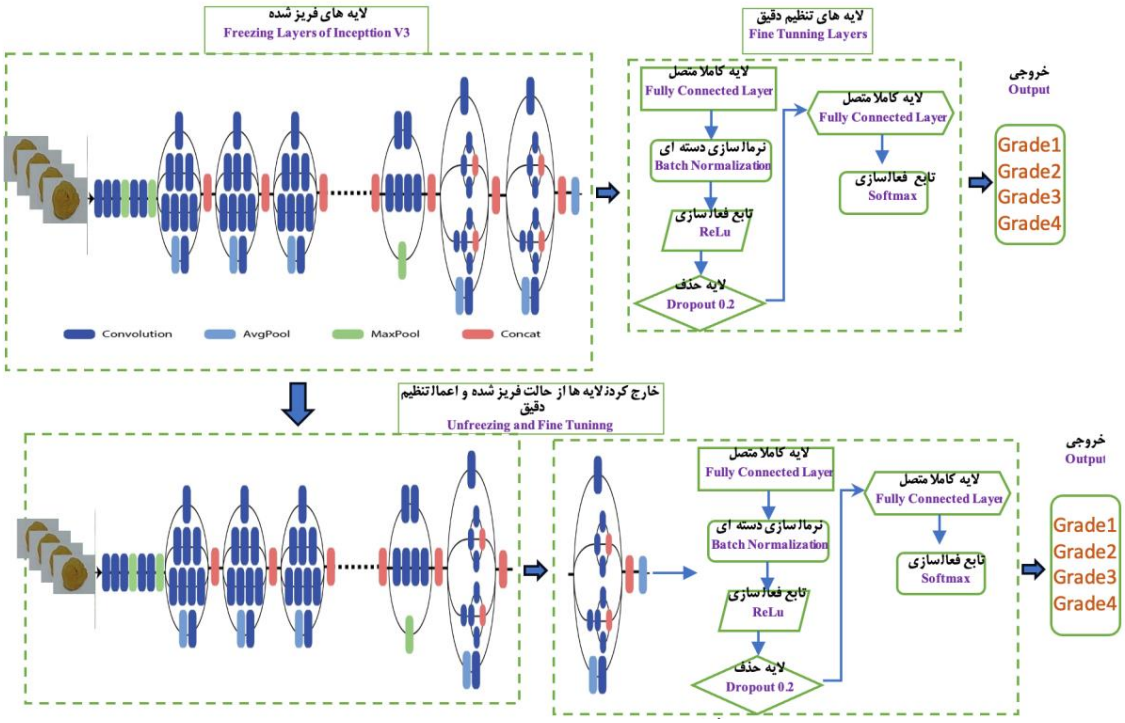

شکل ٤– تنظیم دقیق InceptionV3

Fig. 4- Fine-tuning InceptionV3

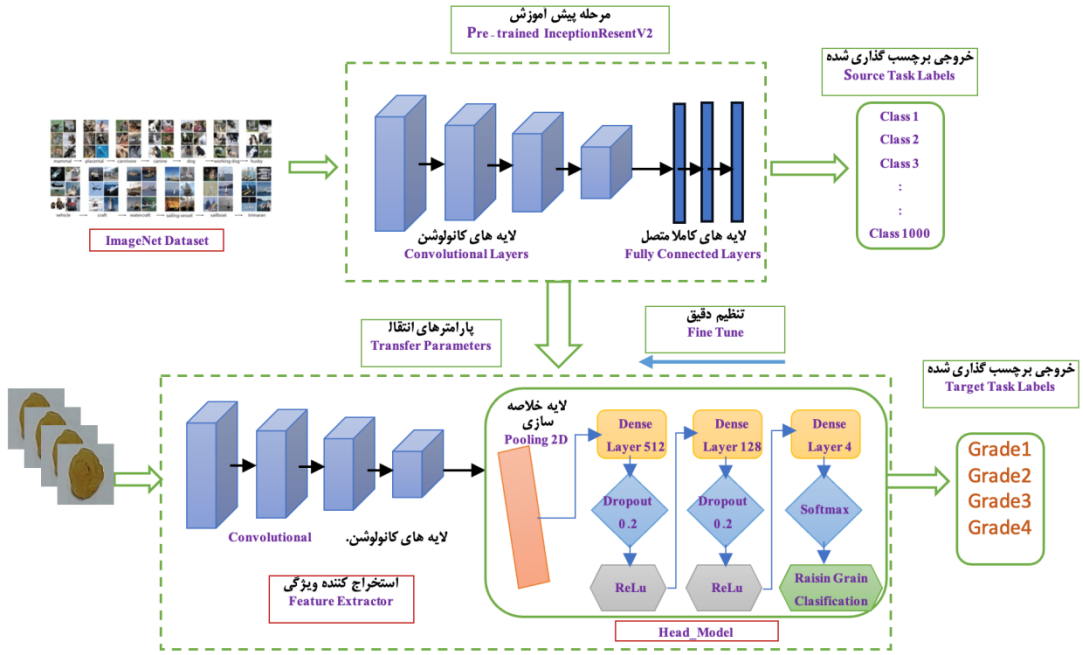

شکل ۵- مدل از پیش آموزش‌دیده InceptionResnetV۲ با تنظیم دقیق برای درجه‌بندی دانه‌های کشمش تیزآبی طلایی

Fig. 5. The pre-trained InceptionResnetV2 model with fine-tuning for grading of golden raisin grains

نتایج و بحث

نتایج آزمایش‌های Raisin_DCNN

آموزش مدل Raisin_DCNN روی پردازنده گرافیکی T4GPU در محیط Colab Google انجام شد. برای بهینه‌سازی پارامترهای مدل و کاهش خطای انتشار معکوس در طول فرآیند آموزش، از بهینه‌ساز Adam با نرخ یادگیری ۰/۰۰۰۳ استفاده گردید. پارامتر دوره آموزش روی ۵۰ تنظیم گردید. با توجه به مناسب بودن تابع آنتروپی متقاطع[1] برای مسائل طبقه‌بندی چندکلاسه، از این تابع به‌عنوان تابع هزینه استفاده شد. ماتریس اغتشاش و نمودار مشخصه عملکرد[2] (ROC) مربوط به مجموعه داده‌های آزمون روی مدل Raisin_DCNN در شکل ۶ نمایش داده شده است. برای ارزیابی عملکرد طبقه‌بندی این مدل، از دقت، صحت، حساسیت و معیار F1-score استفاده شد. مقادیر این معیارها روی مجموعه آزمون در جدول ۴ ارائه شده است. نسبت تصاویر صحیح‌شناسایی‌شده دانه‌های کشمش به کل تصاویر، دقت کلی مدل را در تمامی کلاس‌ها نشان می‌دهد که در این پژوهش به ۹۶ درصد رسیده است. روند دقت و تابع هزینه داده‌های آموزش و اعتبارسنجی مدل Raisin_DCNN در طول ۵۰ دوره در شکل ۷ ترسیم شده است.

با توجه به شکل ۶ الف دانه‌های دسته اول (درجه ۱) با دقت ۱۰۰٪ به‌طور کامل شناسایی شدند. اما دانه‌های کشمش از دسته دوم (درجه ۲) با دقت ۹۳/۷۰ درصد طبقه‌بندی شدند. همان‌طور که از ماتریس اغتشاش در شکل ۶ الف مشهود است، دو نمونه از دانه‌های کشمش درجه ۲ به اشتباه به‌عنوان دانه‌های درجه ۳ طبقه‌بندی شدند و سه نمونه از دانه‌های کشمش دسته سوم (درجه ۳) به اشتباه به‌عنوان دانه‌های درجه ۲ و دانه‌های درجه ۴ طبقه‌بندی شدند و همچنین دانه‌های دسته چهارم (درجه ۴) با دقت ۱۰۰٪ به‌طور کامل شناسایی شدند.

نتایج آزمایش‌های InceptionV3 و InceptionResNetV2

آزمایش‌های یادگیری انتقالی روی پردازنده گرافیکی T4GPU در محیط Colab Google انجام شد. برای ارزیابی عملکرد هر مدل شبکه عصبی کانولوشن عمیق از پیش آموزش‌دیده، مجموعه‌داده به صورت تصادفی به سه بخش آموزش، اعتبارسنجی و آزمایش تقسیم شد. تعداد نمونه‌ها در این بخش‌ها به‌ترتیب در مقادیر ثابت ۲۲۴۰، ۱۰۸۰ و ۱۲۰ در نظر گرفته شد. در جدول ۲ توصیف کامل مجموعه‌داده آورده شده است. برای تعیین کارآمدترین پارامترها برای هر دو مدل شبکه عصبی کانولوشن عمیق از پیش آموزش‌دیده، آموزش با بهینه‌ساز Adam و نرخ یادگیری ۰/۰۰۰۳ و در ۵۰ دوره و با اندازه دسته ۳۲ انجام گرفت.

در مرحله آموزش، هر دو مدل شبکه عصبی کانولوشن عمیق از پیش آموزش‌دیده، به دقت طبقه‌بندی بالای ۹۰ درصد دست یافتند

1- Cross-entropy function
2- Receiver operating characteristic (ROC)

(جدول ۸). همچنین این مدل‌ها تقریباً در دوره ۳۰ ام به همگرایی رسیدند. ماتریس‌های اغتشاش مربوط به مجموعه داده‌های آزمایش مدل‌های شبکه عصبی کانولوشن عمیق از پیش آموزش‌دیده، پس از اتمام مرحله آموزش استخراج شدند (شکل ۸). علاوه بر این، جداول ۵ و ۶ به‌ترتیب معیارهای عملکرد InceptionV3 و InceptionResNetV2 را که از ماتریس‌های اغتشاش حاصل شده‌اند، ارائه می‌دهند. برای مقایسه جامع‌تر، عملکرد تمامی مدل‌های شبکه عصبی کانولوشن عمیق روی داده‌های آزمایش مورد ارزیابی قرار گرفت. نتایج مربوط به دقت، حساسیت و معیار F1-Score برای هر مدل شبکه عصبی کانولوشن عمیق در شکل ۹ نمایش داده شده است.

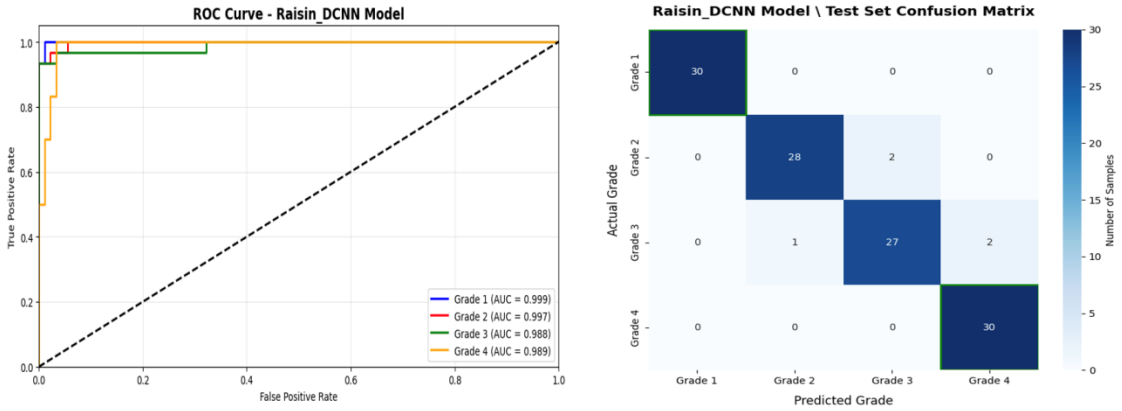

ب) b (

الف) a)

شکل ٦– الف) ماتریس اغتشاش و ب) نمودار مشخصه عملکرد مدل Raisin_DCNN روی مجموعه داده‌های آزمون کشمش تیزآبی طلایی

Fig. 6. (a) Raisin_DCNN confusion matrix, and (b) receiver operating characteristic of the test raisins data

جدول ٤– عملکرد مدل Raisin_DCNN روی داده‌های آزمایش دانه‌های کشمش تیزآبی طلایی

Table 4- Performance of Raisin_DCNN model using the test raisins dataset

Grade	Accuracy	Precision	Recall	F1-Score
Grade 1	100.00	94.10	100.00	97.00
Grade 2	93.70	96.12	93.20	95.00
Grade 3	90.40	99.63	93.33	96.25
Grade 4	100.00	90.12	93.34	92.43
Accuracy	96.00			
macro avg		94.99	94.97	95.17
weighted avg		94.99	94.97	95.17

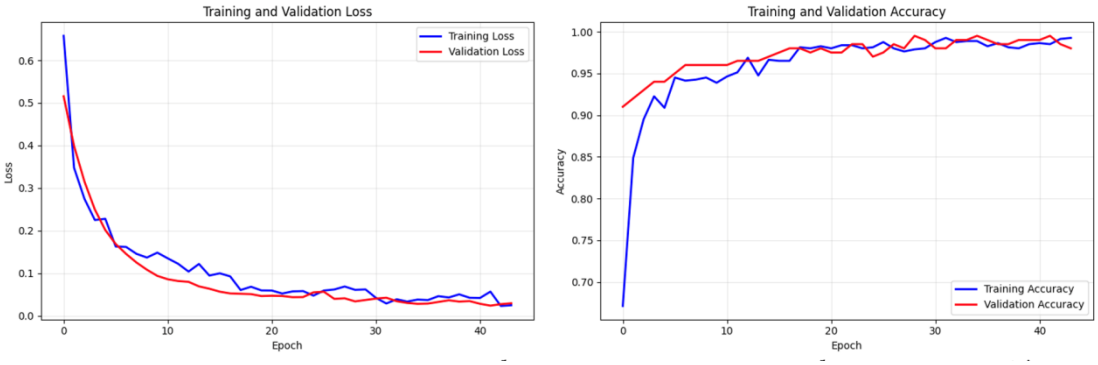

ب b

الف a

شکل ۷– الف) روند دقت آموزش و اعتبارسنجی و ب) روند تابع هزینه آموزش و اعتبارسنجی مدل Raisin_DCNN در طول ۵۰ دوره

Fig. 7. (a) Training and validation accuracy, (b) Training and validation loss of Raisin_DCNN for 50 epochs

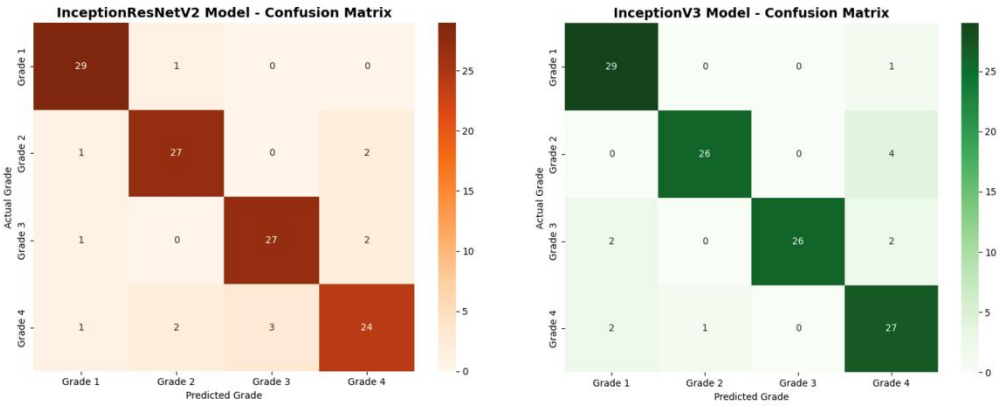

الف a ب b

شکل ۸- الف) ماتریس اغتشاش مدل InceptionV3 و ب) ماتریس اغتشاش مدل InceptionResNetV2 روی مجموعه داده‌های آزمون کشمش تیزآبی طلایی

Fig. 8. (a) Raisin_DCNN confusion matrix, and (b) receiver operating characteristic of the test raisins data

جدول ۵- عملکرد مدل InceptionV3 روی داده‌های آزمایش دانه‌های کشمش

Table 5- Performance of the InceptionV3 model using the test raisins dataset

Grade	Accuracy	Precision	Recall	F1-Score
Grade 1	91.10	88.20	97.30	92.00
Grade 2	89.20	96.30	87.40	91.50
Grade 3	89.30	100.00	87.10	93.20
Grade 4	90.40	79.50	90.00	84.30
Accuracy	90.00			
macro avg		91.00	90.45	90.25
weighted avg		91.00	90.45	90.25

جدول ٦- عملکرد مدل InceptionResNetV2 روی داده‌های آزمایش دانه‌های کشمش

Table 6- Performance of the InceptionResNetV2 model using the test raisins dataset

Grade	Accuracy	Precision	Recall	F1-Score
Grade 1	90.12	91.30	97.30	94.30
Grade 2	89.32	90.40	90.40	90.25
Grade 3	89.34	90.20	90.10	90.33
Grade 4	90.40	86.30	80.25	83.40
Accuracy	89.80			
macro avg		89.55	89.51	89.57
weighted avg		89.55	89.51	89.57

نتایج به‌وضوح نشان می‌دهد که مدل پیشنهادی Raisin_DCNN با دستیابی به دقتی بالاتر، عملکرد بهتری نسبت به سایر مدل‌های از پیش آموزش‌دیده دارد. با دستیابی به دقت ۹۶ درصد، مدل Raisin_DCNN صرف‌نظر از زمان آموزش، بالاترین عملکرد طبقه‌بندی را در مقایسه با مدل‌های تنظیم‌شده InceptionV3 و InceptionResNetV2 به‌دست آورد (شکل ۹). زمان آموزش مدل‌های DCNN به‌طور مستقیم تحت تأثیر منابع سخت‌افزاری قرار دارد و استفاده از پردازنده‌های گرافیکی قدرتمندتر می‌تواند همزمان هم دقت و هم سرعت آموزش و آزمون این مدل‌ها را بهبود ببخشد. یافته‌های این پژوهش به‌وضوح برتری مدل Raisin_DCNN را از نظر دقت، صحت و فراخوانی در مقایسه با مدل‌های از پیش آموزش‌دیده نشان می‌دهد. این برتری را می‌توان به چندین عامل کلیدی نسبت داد: نخست، مدل‌های از پیش آموزش‌دیده ابتدا بر روی مجموعه‌داده‌هایی آموزش دیده بودند که شباهت کافی با وظیفه طبقه‌بندی دانه‌های کشمش تیزآبی طلایی نداشتند و این امر توانایی آن‌ها در یادگیری ویژگی‌های خاص و ضروری برای طبقه‌بندی دقیق را محدود می‌کرد. در حالی‌که مدل Raisin_DCNN که یک شبکه عصبی کانولوشن عمیق ساده است،

به‌طور خاص برای مجموعه‌داده طبقه‌بندی دانه‌های کشمش تیزآبی طلایی طراحی و آموزش داده شده است و همین امر توانایی آن در یادگیری و تشخیص الگوهای مرتبط را به‌طور چشمگیری افزایش داده است. دوم، مدل‌های از پیش آموزش‌دیده InceptionV3 و InceptionResNetV2 به دلیل دارا بودن معماری‌های عمیق و پیچیده، از ساختارهای پردازشی پیچیده‌تری برخوردارند. این مدل‌ها عموماً بر روی مجموعه‌داده‌های بزرگ با کلاس‌های متنوع آموزش می‌بینند که ممکن است کاملاً با ویژگی‌های منحصر به‌فرد دانه‌های کشمش همخوانی نداشته باشند. در حالی‌که مدل Raisin_DCNN که به‌طور خاص بر روی مجموعه‌داده‌هایی با مقیاس کوچک آموزش دیده است، توانست خود را با الگوهای خاص این داده‌ها به‌طور مؤثرتری تطبیق دهد.

جدول ۷ مقایسه‌ای با مطالعات پیشین در حوزه طبقه‌بندی دانه‌های کشمش ارائه می‌دهد. با بررسی این مطالعات مشخص می‌شود که مدل Raisin_DCNN مورد استفاده در این پژوهش به بالاترین نرخ موفقیت در طبقه‌بندی دست یافته است. با این حال، لازم به تأکید است که هر مجموعه‌داده ذکرشده در جدول ۷ منحصر به‌فرد بوده و از نظر انواع دانه‌های کشمش، اندازه مجموعه‌داده و تعداد ویژگی‌های مورد بررسی، متفاوت است.

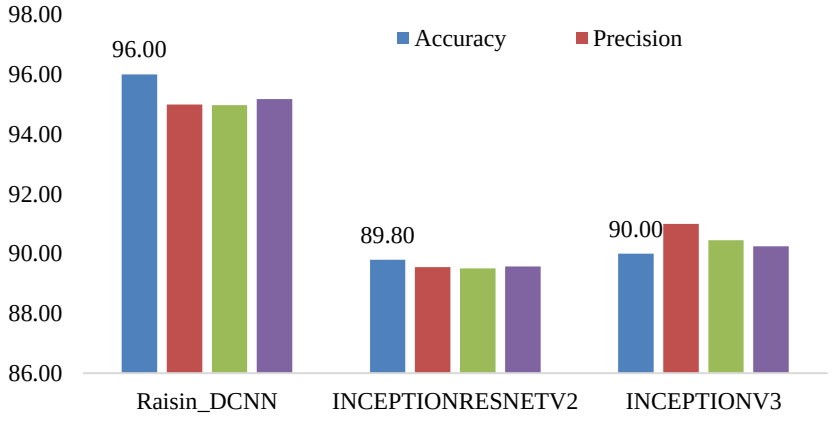

شکل ۹- مقایسه معیارهای ارزیابی مدل‌های Raisin_DCNN، InceptionV3 و InceptionResNetV2

Fig. 9. Comparison of performance measures of Raisin_DCNN, InceptionV3, and InceptionResNetV2 models

جدول ۷- مقایسه تحقیق حاضر با مطالعات مشابه

Table 7- Comparison of proposed work with similar studies

مرجع Reference	اندازه داده‌ها dataset size	کلاس‌ها Classes	مدل Model	دقت Accuracy
(Yu *et al.*, 2012)	480	4	ماشین بردار پشتیبان (SVM)	95
(İncekara, 2024)	6300	2	شبکه عصبی تشخیص الگو (PRNN)	89.5
مطالعه حاضر (Present study)	3320	4	شبکه عصبی کانولوشن عمیق (Raisin_DCNN)	96

با توجه به نقش مهم بخش کشاورزی در تأمین نیازهای جمعیت قابل‌توجهی از جهان، تولید و شناسایی انواع باکیفیت کشمش از اهمیت بالایی برخوردار است. روش‌های سنتی شناسایی و طبقه‌بندی کشمش معمولاً پرهزینه، زمان‌بر و مستعد خطا هستند. برای رفع این چالش‌ها، این پژوهش از قابلیت‌های بینایی کامپیوتر به‌عنوان یک فناوری پیشرفته در پردازش تصویر و تحلیل داده‌ها بهره برده است. در این مطالعه، چهار درجه از دانه‌های کشمش تیزآبی طلایی مورد تجزیه و تحلیل قرار گرفتند. سیستم Raisin_DCNN که مبتنی بر معماری شبکه عصبی کانولوشن عمیق است، به‌منظور بهبود دقت شناسایی انواع دانه کشمش تیزآبی طلایی طراحی شد. برای ارتقای عملکرد مدل، از تکنیک‌های مختلف افزایش داده به‌منظور تقویت مجموعه‌داده آموزشی و افزایش مؤثر تنوع و تغییرپذیری نمونه‌های آموزشی استفاده گردید. علاوه‌بر این، یادگیری انتقالی با بهره‌گیری از مدل‌های از پیش آموزش‌دیده شبکه عصبی کانولوشنی شامل InceptionV3 و InceptionResNetV2 که با بهینه‌ساز Adam تنظیم دقیق شده بودند، به‌کار گرفته شد. عملکرد Raisin_DCNN با روش‌های کلاسیک یادگیری ماشین شامل HOG[1]-SVM،

1- Histogram oriented gradients (HOG)

SIFT-SVM[1]، HOG-LR، SIFT-LR، HOG-KNN و SIFT-KNN مقایسه گردید. به‌طوری‌که در شکل ۱۰ نشان داده شده است مدل Raisin_DCNN از نظر دقت پیش‌بینی، برتری قابل‌توجهی نسبت به سایر روش‌ها دارد. در حالی‌که سایر مدل‌های یادگیری ماشین به دقتی بین ۲۶ تا ۷۵ درصد دست یافتند، مدل‌های Raisin_DCNN، InceptionV3 و InceptionResNetV2 به‌ترتیب به دقت ۹۶، ۹۰ و ۸۹/۸۰ درصد دست یافتند.

مدل پیشنهادی Raisin_DCNN با هدف رفع چالش‌های موجود در روش‌های مرسوم شناسایی دانه‌ها، توسعه یافته است. تغییرات شرایط نوری به‌عنوان یکی از موانع رایج، تأثیر مستقیمی بر ظاهر و کیفیت تصاویر دانه‌ها دارد. برای مقابله با این چالش، Raisin_DCNN با بهره‌گیری از عملیات افزایش داده همچون تغییر مقیاس، چرخش و تبدیل‌های تصادفی، توانایی شناسایی دانه‌ها در شرایط نوری متنوع را کسب می‌کند و براین اساس قابلیت تطبیق‌پذیری خود در محیط‌های عملیاتی واقعی را ارتقا می‌بخشد. علاوه بر این، ادغام این مدل با فناوری‌های نوظهور نظیر اینترنت اشیا (IoT) و بلاک‌چین در آینده، چشم‌اندازهای امیدوارکننده‌ای برای بهبود قابلیت ردیابی و کنترل کیفیت در سامانه‌های تشخیص دانه فراهم خواهد آورد. همچنین، گنجاندن انواع متنوع‌تری از دانه‌ها در مجموعه‌داده‌های آموزشی، ظرفیت مدل را برای تشخیص و طبقه‌بندی طیف وسیع‌تری از ارقام کشمش به‌همراه درجه‌بندی آن‌ها را گسترش خواهد داد.

تحلیل مقایسه‌ای مدل‌های یادگیری ماشین و یادگیری عمیق

در این پژوهش، مقایسه‌ای نظام‌مند میان مدل پیشنهادی Raisin_DCNN، مدل‌های از پیش آموزش‌دیده InceptionV3 و InceptionResNetV2 با الگوریتم‌های مبتنی بر ویژگی‌های کلاسیک شامل HOG-SVM، HOG-LR، HOG-KNN، SIFT-SVM، SIFT-LR و SIFT-KNN به‌منظور طبقه‌بندی دانه‌های کشمش تیزآبی طلایی انجام شد. در این راستا، ۱۷۶۴ ویژگی توسط الگوریتم HOG و ۲۰۰ ویژگی توسط استخراج‌کننده ویژگی SIFTاستخراج گردید.

در پیاده‌سازی مدل طبقه‌بندی‌کننده SVM، از تابع پایه شعاعی[2] (rbf) و کرنل خطی استفاده شد (kernel = ['linear','rbf']). به‌منظور تنظیم دقیق ابرپارامترهای SVM، الگوریتم GridSearchCV به‌کار برده شد و محدوده جستجوی هر پارامتر C [0.1, 1, 10, 100], gamma = ['scale','auto'] = بود. از میان ۱۶ ترکیب پارامتری آزمایش‌شده بر روی داده‌های آموزش، بالاترین دقت پیش‌بینی با مقادیر C=1، 'gamma='scale و 'kernel=' linear ' برای هر دو الگوریتم HOG-SVM و HOG-LR به‌دست آمد.

همان‌گونه که در جدول ۸ نشان داده شده است، دقت‌های حاصل از مدل‌های DCNN به‌طور معناداری برتر از روش‌های ترکیبی مبتنی بر ویژگی‌های دست‌ساز بوده‌اند. نتایج دقت بر روی مجموعه آزمون برای مدل‌های HOG-SVM، HOG-LR، HOG-KNN، SIFT-SVM، SIFT-LR و SIFT-KNN به‌ترتیب برابر با ۷۵، ۴۶/۶۷، ۴۰، ۲۷/۵۰، ۲۲/۵۰ و ۲۶/۶۷ درصد به‌دست آمد. در حالی‌که بالاترین دقت پیش‌بینی (۹۶ درصد) متعلق به مدل پیشنهادی Raisin_DCNN بود که برتری روش‌های یادگیری عمیق را در طبقه‌بندی دانه‌های کشمش به‌وضوح نشان می‌دهد.

نتیجه‌گیری

در این مقاله، یک معماری جدید مبتنی بر شبکه عصبی کانولوشنی عمیق با نام Raisin_DCNN برای درجه‌بندی دانه‌های کشمش تیزآبی طلایی که از نمونه‌های محلی جمع‌آوری شده بودند، طراحی شده است. در این معماری، از لایه‌های کانولوشنی و لایه‌های تجمیع برای استخراج ویژگی‌های پیچیده و عمیق دانه‌های کشمش استفاده گردید. همچنین دو مدل از پیش آموزش‌دیده DCNN یعنی InceptionV3 و InceptionResNetV2 برای درجه‌بندی دانه‌های کشمش تیزآبی طلایی به‌کار گرفته شدند. به‌کارگیری تکنیک‌های متنوع افزایش داده بر روی مجموعه آموزشی، موجب افزایش تنوع مجموعه‌داده و بهبود قابلیت تعمیم مدل‌های DCNN شده و همزمان از بروز پدیده بیش‌برازش جلوگیری به‌عمل می‌آورد. بر اساس نتایج آزمایش‌ها، مدل Raisin_DCNN بدون آن‌که نشانه‌ای از تخریب عملکرد یا بیش‌برازش در آموزش مدل مشاهده شود، با دستیابی به دقت ۹۶ درصد در مجموعه داده‌های آزمایش پس از ۵۰ دوره آموزش، عملکرد برتری در مقایسه با سایر معماری‌ها از خود نشان داد. برای ارزیابی عینی کارایی مدل‌های پیشنهادی DCNN، نتایج حاصل از چندین مدل شناخته‌شده یادگیری ماشین با ویژگی‌های استخراج‌شده توسط روش‌های HOG-SVM، SIFT-SVM، HOG-LR، SIFT-LR، HOG-KNN و SIFT-KNN با نتایج مدل Raisin_DCNN و مدل‌های یادگیری انتقالی روی مجموعه‌داده دانه‌های کشمش مقایسه گردید. تحلیل‌های مقایسه‌ای به‌وضوح نشان می‌دهند که مدل‌های DCNN به‌طور پیوسته و در تمامی وظایف مشابه بینایی ماشین، عملکردی برتر از سایر رویکردها ارائه می‌دهند.

1- Scale invariant feature transform (SIFT)
2- Radial basis function

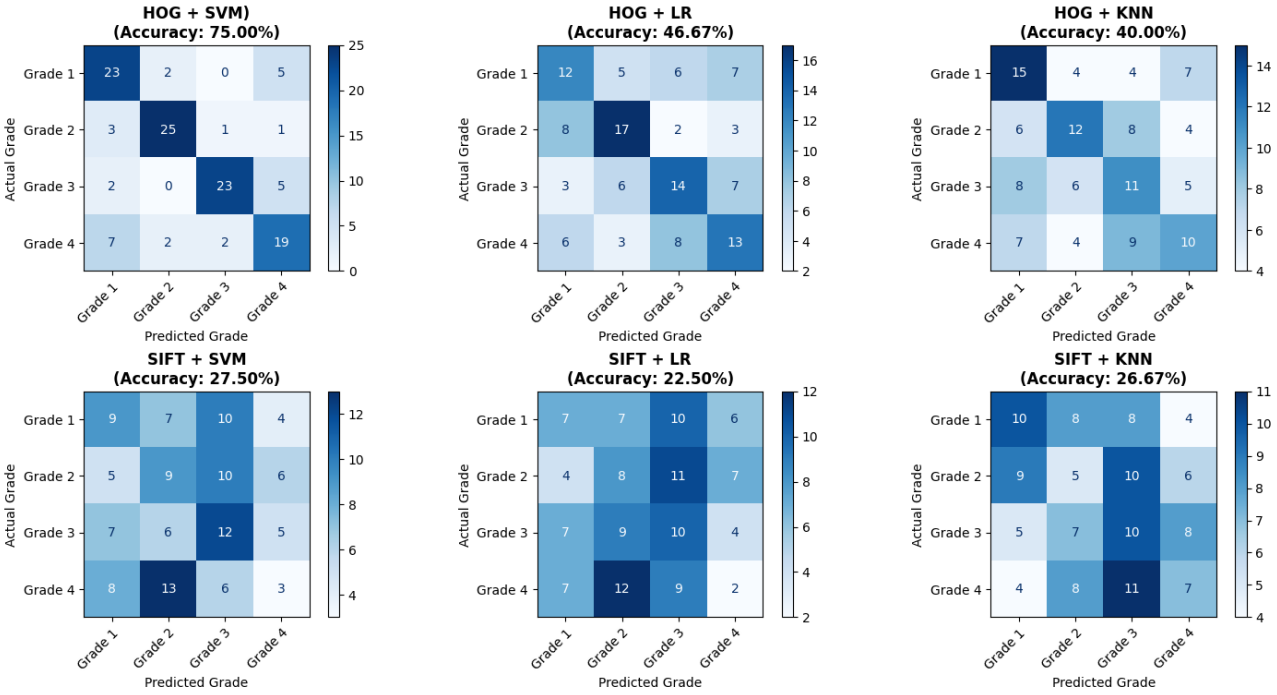

شکل ۱۰– ماتریس‌های اغتشاش همراه با دقت تشخیص داده‌های آزمون برای روش‌های طبقه‌بندی مختلف

Fig. 10. Confusion matrices for different classification methods

جدول ۸– تحلیل مقایسه‌ای نتایج آزمایش روش‌های مختلف برای درجه‌بندی چهار درجه کشمش طلایی

Table 8- Comparative analysis of the experimentation results of different methods for four grades of golden raisin

مدل Model	دقت آموزش Training Accuracy	دقت آزمون Test Accuracy
HOG-SVM	90.40	75
HOG-LR	95.30	46.67
HOG-KNN	82.25	40
SIFT-SVM	85.47	27.5
SIFT-LR	75.67	22.5
SIFT-KNN	79.59	26.67
Raisin_DCNN	92.34	96
InceptionV3	94.67	90
InceptionResNetV2	90.45	89.80

تعارض منافع

هیچ‌گونه تعارض منافع توسط نویسندگان بیان نشده است.

مشارکت نویسندگان

حامد میرخراسانی: جمع‌آوری داده‌ها، پردازش داده‌ها، شبیه‌سازی عددی یا کامپیوتری، استخراج و تهیه متن اولیه

مهدی عباسقلی پور: نظارت و مدیریت، مفهوم‌سازی، روش‌شناسی، تحلیل آماری، اعتبارسنجی، شبیه‌سازی عددی یا کامپیوتری، ویرایش متن

بهزاد محمدی الستی: روش‌شناسی، مشاوره فنی، خدمات نرم‌افزاری، ویرایش متن

References

1. Abbasgholipour, M., Omid, M., Keyhani, A., & Mohtasebi, S. S. (2011). Color image segmentation with genetic algorithm in a raisin sorting system based on machine vision in variable conditions. *Expert Systems with Applications*, *38*(4), 3671-3678. https://doi.org/10.1016/j.eswa.2010.09.023

2. Alom, M. Z., Hasan, M., Yakopcic, C., Taha, T., & Asari, V. (2020). Improved inception-residual convolutional neural network for object recognition. *Neural Computing and Applications, 32*(1), 279-293. https://doi.org/10.1007/s00521-018-3627-6
3. Angadi, Sh. A., & Hiregoudar, N. (2016). A cost effective algorithm for grading raisins using image processing. *International Journal of Recent Trends in Engineering & Research (IJRTER), 2*, 2455-1457.
4. Backes, A. R., & Khojastehnazhand, M. (2024). Optimizing a combination of texture features with partial swarm optimizer method for bulk raisin classification. *Signal, Image and Video Processing, 18*(3), 2621-2628. https://doi.org/10.1007/s11760-023-02935-y
5. Çınar, İ., Koklu, M., & Taşdemir, Ş. (2020). Classification of raisin grains using machine vision and artificial intelligence methods. *Gazi Journal of Engineering Sciences, 6*(3), 200-209. https://doi.org/10.30855/gmbd.2020.03.03
6. Din, N. M. U., Assad, A., Dar, R. A., Rasool, M., Sabha, S. U., Majeed, T., Islam, Z. U., Gulzar, W., & Yaseen, A. (2024). RiceNet: A deep convolutional neural network approach for classification of rice varieties. *Expert Systems with Applications, 235*, 121214. https://doi.org/10.1016/j.eswa.2023.121214
7. Falahat Nejad Mahani, Sh., & Karami, A. (2023). Maize Tassel Detection and Counting Using Deep Learning Techniques. *Journal of Agricultural Machinery, 13*(2), 175-194. https://doi.org/10.22067/jam.2022.72477.1062
8. FAO. (2023). Food and Agricultural Organization of the United Nations. *FAOSTAT Database*. http://apps.fao.org/
9. Fatehi, F., Bagherpour, H., & Amiri Parian, J. (2025). Investigating the Potential of the Innovative YOLOv8s Model for Detecting Bloomed Damask Roses in Open Fields. *Journal of Agricultural Machinery, 15*(3), 275-289. https://doi.org/10.22067/jam.2024.88066.1249
10. Fei-Fei, L., Deng, J., & Li, K. (2009). ImageNet: Constructing a large-scale image database. *Journal of Vision, 9*(8), 1037-1037. https://doi.org/10.1167/9.8.1037
11. Grandini, M., Bagli, E., & Visani, G. (2020). Metrics for multi-class classification: an overview. *arXiv preprint arXiv:2008.05756*. https://doi.org/10.48550/arXiv.2008.05756
12. Hinton, G., Deng, L., Yu, D., Dahl, G. E., Mohamed, A., Jaitly, N., ..., & Sainath, T. N. (2012). Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups. *IEEE Signal Processing Magazine, 29*(6), 82-97. https://doi.org/10.1109/MSP.2012.2205597
13. İncekara, H. (2024). Classification of raisin grains using different artificial neural network methods. *Intelligent Methods in Engineering Sciences, 3*(3), 99-107. https://doi.org/10.58190/imiens.2024.104
14. Kanellos, P. T., Kaliora, A. C., Gioxari, A., Christopoulou, G. O., Kalogeropoulos, N., & Karathanos, V. T. (2013). Absorption and bioavailability of antioxidant phytochemicals and increase of serum oxidation resistance in healthy subjects following supplementation with raisins. *Plant Foods for Human Nutrition, 68*(4), 411-415. https://doi.org/10.1007/s11130-013-0389-2
15. Liu, X., Yang, L., Chen, J., Yu, S., & Li, K. (2022). Region-to-boundary deep learning model with multi-scale feature fusion for medical image segmentation. *Biomedical Signal Processing and Control, 71*, 103165. https://doi.org/10.1016/j.bspc.2021.103165
16. Malek Madani, P., & Soleimani, N. (2025). Risk Analysis and Economic Strategies of Iranian Raisin Supply Chain with Failure Mode Analysis (FMEA): A Case Study of Malayer Raisin Industry. *Journal of Applied Economics Studies in Iran (AESI), 14*(53), 135-167. https://doi.org/10.22084/aes.2025.30475.3762
17. Mollazade, K., Omid, M., & Arefi, A. (2012). Comparing data mining classifiers for grading raisins based on visual features. *Computers and Electronics in Agriculture, 84*, 124-131. https://doi.org/10.1016/j.compag.2012.03.004
18. Naderi Beni, A., Bagherpour, H., & Amiri Parian, J. (2024). Development and Optimization of a Novel Deep Learning Model for Diagnosis of Quince Leaf Diseases. *Journal of Agricultural Machinery, 14*(4), 445-458. https://doi.org/10.22067/jam.2024.88013.1248
19. Omid, M., Abbasgolipour, M., Keyhani, A., & Mohtasebi, S.S. (2010). Implementation of an efficient image processing algorithm for grading raisins. *International Journal of Signal and Image Processing, 1*(1), 31-34.
20. Omid, M., Sharouzi, M., & Keyhani, A. (2010). Development of an Automated Machine for Grading Raisins based on Color and Size. *Journal of Modelling and Simulation of System, 1*(3), 157-162.
21. Raihen, M. N., & Akter, S. (2024). Prediction modeling using deep learning for the classification of grape-type dried fruits. *International Journal of Mathematics and Computer in Engineering, 2*(1), 1-12. https://doi.org/10.2478/ijmce-2024-0001
22. Schuster, M. J., Wang, X., Hawkins, T., & Painter, J. E. (2017). A Comprehensive review of raisins and raisin components and their relationship to human health. *Journal of Nutrition and Health, 50*(3), 203-216. https://doi.org/10.4163/jnh.2017.50.3.203
23. Singla, Ch., Sarangi, P. K., Sahoo, A. K., & Singh, P. K. (2022). Deep learning enhancement on mammogram images for breast cancer detection. *Materials Today: Proceedings, 49*, 3098-3104. https://doi.org/10.1016/j.matpr.2020.10.951
24. Vidyarthi, S. K., Singh, S. K., Xiao, H. W., & Tiwari, R. (2021). Deep learnt grading of almond kernels. *Journal*

of Food Process Engineering, *44*(4), e13662. https://doi.org/10.1111/jfpe.13662
25. Wang, Ch., Shi, J., Zhang, Q., & Ying, Sh. (2017). *Histopathological image classification with bilinear convolutional neural networks.* Paper presented at the 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), Jeju, Korea (South). https://doi.org/10.1109/embc.2017.8037745
26. Yu, X., Liu, K., Wu, D., & He, Y. (2012). Raisin quality classification using least squares support vector machine (LSSVM) based on combined color and texture features. *Food and Bioprocess Technology*, *5*(5), 1552-1563. https://doi.org/10.1007/s11947-011-0531-9
27. Zhu, L., Li, Zh., Li, Ch., Wu, J., & Yue, J. (2018). High performance vegetable classification from images based on AlexNet deep learning model. *International Journal of Agricultural and Biological Engineering*, *11*(4), 217-223. https://doi.org/10.25165/j.ijabe.20181104.2690

Journal of Agricultural Machinery

Homepage: https://jame.um.ac.ir

Research Article
Vol. 16, No. 4, 2026, p. 731-749

Investigation of the Effect of Sensors' Chamber Geometry and Fluid Type on Fluid Flow in the Electronic Nose System Using Computational Fluid Dynamics Simulation

A. Altafi[1], S. S. Mohtasebi[1*], A. Jafari[1], M. Ghasemi Varnamkhasti[2]

1- Department of Agricultural Machinery Engineering, Faculty of Agricultural Engineering and Technology, University of Tehran, Karaj, Iran
2- Department of Biosystem Mechanical Engineering, Faculty of Agriculture, University of Shahrekord, Shahrekord, Iran
(*- Corresponding Author Email: mohtaseb@ut.ac.ir)

Received: 22 January 2026
Revised: 06 March 2026
Accepted: 05 May 2026
Available Online: 20 May 2026

How to cite this article:
Altafi, A., Mohtasebi, S. S., Jafari, A., & Ghasemi Varnamkhasti, M. (2026). Investigation of the Effect of Sensors' Chamber Geometry and Fluid Type on Fluid Flow in the Electronic Nose System Using Computational Fluid Dynamics Simulation. *Journal of Agricultural Machinery*, *16*(4), 731-749. [in Persian]. https://doi.org/10.22067/jam.2026.97514.1466

Introduction

The electronic nose (e-nose) system analyses the volatile compounds in products by mimicking the human olfactory system and is capable of providing both chemical and sensory information. One of the most important applications of the electronic nose is gas sensors widely used in various industries, including construction, chemical and petrochemical, environmental monitoring, medical and pharmaceutical, agricultural, and food industries, as well as in many other processes where gas monitoring and analysis are essential. Due to the increasing cost of experimental testing, computational fluid dynamics (CFD) can be employed to investigate the effects of key factors in the electronic nose. CFD is a branch of numerical methods used to solve the governing equations describing various flow phenomena. In CFD, different methods and algorithms are utilised to obtain solutions; however, in all cases, the problem domain is discretised into a large number of small elements, and the governing equations are solved for each element. A review of previous studies indicates that simulation processes aimed at achieving reliable results in this field have received considerable attention, and the data obtained from these simulations can be highly accurate and efficient. Moreover, the sensor chamber plays an important role in enhancing the performance, stability, and sensitivity of an electronic nose. Therefore, four different configurations of 3D sensing chambers were simulated using ANSYS FLUENT software, examining both air and CO_2 as fluids. Numerical simulations were carried out to investigate the gas flow behaviour inside these four chambers and specify the optimal chamber design with the best stability time.

Materials and Methods

In the present study, four chamber geometries namely cylindrical, pyramidal, conical, and hemispherical, were designed using CATIA software. Subsequently, three-dimensional simulations were performed using Ansys Fluent software. To predict the fluid flow behaviour, the continuity equation and the Navier–Stokes equations were employed. The boundary conditions were identical for all geometries, and given the equal inlet and outlet cross-sectional areas across all configurations, the only difference among the models lies in their overall geometric structure. The electronic nose chambers were tested with a laminar flow and the SIMPLEC method.

Results and Discussion

The 3-Dimensional simulations were conducted for the four geometries under two fluid injections, air and

Authors retain the copyright. This is an open access article distributed under Creative Commons Attribution 4.0 International License (CC BY 4.0).

https://doi.org/10.22067/jam.2026.97514.1466

carbon dioxide, while maintaining identical boundary conditions. To investigate the fluid behaviour inside the geometries, flow field contours were presented at 25 s, 50 s, 75 s, and under approximate stability conditions when the contours became nearly time-invariant. In the air injection case, the fluid inside the hemispherical geometry reached steady-state conditions by 25 s, faster than in the other geometries, and maintained a similar flow pattern at later times. Based on the simulation results, the hemispherical geometry exhibited the best overall performance. This favourable behaviour can be attributed to the geometric dimensions of the hemisphere in the sensor surface region. In contrast, the behaviour of carbon dioxide differed significantly from that of air. Under carbon dioxide injection, similar to the air injection case, the fluid in the hemispherical geometry reached steady-state conditions by 25 s and fully covered the outlet region. In this geometry, the flow attained a nearly uniform distribution at 25 s, and the fluid fully contacted the sensor surface. Also, results showed that small vortices produced near the sensor surface can improve the stability time, and they can help to bring the fluid to the surface faster.

Conclusion

In the present study, four geometries were investigated under two injection conditions: air and carbon dioxide. The evaluations were conducted to identify the optimal geometry in terms of fluid flow behaviour, sensor surface coverage, and flow stability. The results demonstrated that the hemispherical geometry exhibited the best performance under both air and carbon dioxide injection conditions. This indicates that providing a larger fluid–sensor contact area along with a balanced geometric configuration can lead to improved fluid behaviour and overall system performance.

Keywords: Fluid flow pattern, Olfactory machine, Three-dimensional modelling

نشریه ماشین‌های کشاورزی
https://jame.um.ac.ir

مقاله پژوهشی
جلد ۱۶، شماره ٤، زمستان ۱٤۰۵، ص ۷٤۹-۷۳۱

بررسی اثر هندسه محفظه حسگرها و نوع سیال بر جریان سیال در سامانه بینی الکترونیکی با استفاده از شبیه‌سازی دینامیک سیالات محاسباتی

عارفه الطافی[۱]، سید سعید محتسبی[۱*]، علی جعفری[۱]، مهدی قاسمی ورنامخواستی[۲]

تاریخ دریافت: ۱۴۰۴/۱۱/۰۲
تاریخ پذیرش: ۱۴۰۵/۰۲/۱۵

چکیده

سامانه بینی الکترونیکی قابلیت تجزیه‌وتحلیل مواد فرار موجود در محصولات، با تقلید از بینی انسان را دارا بوده و داده‌های خروجی آن می‌تواند شامل اطلاعات شیمیایی و حسی بسیار مفیدی باشند. با توجه به نیاز به صرف هزینه و زمان زیاد برای ساخت و داده‌برداری از این محفظه‌ها به‌صورت تجربی، طراحی و شبیه‌سازی عددی صحیح و کارامد آن‌ها می‌تواند دستیابی انسان به داده‌های مدنظر را بسیار تسهیل کند. بدین منظور و با هدف دستیابی به طراحی بهینه‌ی محفظه این سامانه‌ها جهت عملکرد بهتر حسگرها، در پژوهش حاضر چهار هندسه مختلف در دو حالت تزریق هوا و دی‌اکسیدکربن (CO_2) به‌صورت سه‌بعدی شبیه‌سازی و مورد بررسی قرار گرفته‌اند. هندسه‌ها طوری طراحی شده‌اند که از نظر ابعادی و همچنین سطح مقطع ورودی و خروجی یکسان بوده تا عملکرد جریانی و سیالاتی به ساختار ذاتی هندسه‌ها معطوف گردد. همچنین شرایط مرزی و مشخصات سیال برای تمامی هندسه‌ها یکسان بوده است. بررسی‌ها جهت یافتن بهترین هندسه از نظر نوع عملکرد سیال و پوشش سطح حسگرها و همچنین پایداری مناسب‌تر مورد ارزیابی قرار گرفتند. بررسی‌ها نشان داد که هندسه نیم‌کره بهترین عملکرد جریان را در هر دو حالت تزریق هوا و CO_2 داراست و سیال در زمان کمتری به سطح رسیده و همچنین به شرایط تعادلی می‌رسد. در این هندسه مناطق راکد کمتری در جریان سیال داخل محفظه پدید آمده و این امر موجب بهبود عملکرد و افزایش قابلیت اطمینان حسگرها می‌شود. نتایج همچنین نشان داد که پیدایش گردابه‌ها می‌تواند زمان رسیدن سیال به سطح حسگر را کاهش دهد.

واژه‌های کلیدی: الگوی جریان سیال، شبیه‌سازی سه‌بعدی، ماشین بویایی

مقدمه

سامانه بینی الکترونیکی، علاوه بر توانایی ارزیابی ترکیب‌های بودار، تخمین غلظت آن‌ها و یا تعیین برخی از خواص ذاتی آن‌ها، قابلیت تحلیل مواد فرار موجود در محصولات را با تقلید از بینی انسان دارا می‌باشد و می‌تواند اطلاعات شیمیایی و حسی بسیار کاربردی را ارائه دهد. از جمله کاربردهای این نوع سامانه‌ها، انواع حسگرهای گازی است که در قالب سامانه تشخیص یک دستگاه بینی الکترونیکی مورد استفاده قرار می‌گیرند. این حسگرها، باید قادر به ایجاد رد اثر متفاوتی برای هر نوع خاصی از گاز باشند. حسگرهای گازی در صنایع مختلفی مانند صنایع ساختمانی، شیمیایی، پتروشیمی، محیط‌زیست، پزشکی و دارویی، کشاورزی، غذایی و بسیاری دیگر از فرایندهایی که کنترل و تحلیل گاز در آن الزامی است، کاربرد دارند. ازجمله کاربردهای سامانه بینی الکترونیکی در بخش کشاورزی می‌توان به پایش سلامت و تشخیص آلودگی محصولات (Rezaee, Mohtasebi, & Firouz, 2024a, 2024b) شناسایی و تشخیص نوع چوب (Nikoutadbir, Tarmian, Mohtasebi, Mohtasebi, & Oladi, 2024)، تشخیص درصد تقلب در محصولات غذایی (Oliveros *et al.*, 2002) پیش‌بینی زمان برداشت، میزان رسیدگی محصول (Zhang, Pan, Zhao, & Tu, 2016) و تعیین کیفیت محصولات در طول دوره انبارداری (Hui *et al.*, 2015) اشاره کرد. کاربردهای تشخیصی و طبقه‌بندی مواد غذایی به روش ماشین بویایی، به دلیل سادگی عملکرد، غیر مخرب بودن، سرعت و غیره

۱- گروه مهندسی ماشین‌های کشاورزی، دانشکده مهندسی و فناوری کشاورزی، دانشگاه تهران، کرج، ایران
۲- گروه مهندسی مکانیک بیوسیستم، دانشکده کشاورزی، دانشگاه شهرکرد، شهرکرد، ایران
(*- نویسنده مسئول: Email: mohtaseb@ut.ac.ir)
https://doi.org/10.22067/jam.2026.97514.1466

روزبه‌روز در حال گسترش است. از مزایای بینی الکترونیکی، به‌ویژه نسبت به آنالیزهای شیمیایی، می‌توان به هزینه کم، سهولت استفاده و توانایی پاسخ سریع به مخلوط‌های پیچیده اشاره کرد که آن را به یک فناوری قدرتمند برای تجزیه‌وتحلیل ترکیبات شیمیایی فرار تبدیل می‌کند. یک سامانه بینی الکترونیکی شامل محفظه نمونه، محفظه حسگرها، پمپ، منبع تغذیه، فیلتر و سامانه جمع‌آوری داده است (Pearce, Schiffman, Nagle, & Gardner, 2006; Rezaee *et al.*, 2024b).

علی‌رغم این‌که فناوری بینی الکترونیکی از زمان معرفی به‌طور گسترده به‌عنوان یک فناوری بالقوه پیشگام شناخته‌شده است، چالش‌های متعددی هنوز کاربردهای حسگرهای گازی و بینی الکترونیکی را در فعالیت‌های تحقیقاتی محدود می‌کند (Covington, Marco, Persaud, Schiffman, & Nagle, 2021). عوامل مداخله‌گری که به‌ویژه در کاربردهای بینی الکترونیکی حیاتی به‌نظر می‌رسد شامل رطوبت، درجه حرارت، جریان، نرخ جریان و دینامیک سیال محفظه است. استراتژی‌های جبران سخت‌افزاری با هدف بهبود کیفیت پاسخ حسگرهای بینی الکترونیکی شامل انتخاب و طراحی حسگر، روش‌های نمونه‌گیری برای محدود کردن اثرات عوامل مداخله‌گر و هندسه محفظه حسگرها می‌باشد (Karimzadeh & Assar, 2016; Kumar *et al.*, 2020). رطوبت یکی از مشکلاتی است که اغلب در مطالعات به‌دلیل تاثیر قابل‌توجه آن بر پاسخ حسگرها مورد مطالعه قرار می‌گیرد (Chai *et al.*, 2022; Korotcenkov & Cho, 2011). به‌عنوان یک قاعده کلی، وجود رطوبت منجر به جابه‌جایی کل خط پایه حسگرهای بینی الکترونیکی، کاهش دامنه پاسخ حسگرها و درنتیجه کاهش حساسیت حسگرها می‌شود. در مورد تأثیر دما بر پاسخ حسگرهای بینی الکترونیکی می‌بایست دو نوع دما در نظر گرفته شود. این دماها شامل دمای عملکرد حسگر و دمای نمونه گازی هستند. دمای کار حسگر (دمایی که در آن لایه فعال و حساس گرم می‌شود)، پارامتری مهم به‌ویژه برای حسگرهای MOS یا مبتنی بر گرافن می‌باشد. زیرا واکنش‌های سطحی به شدت به دمای عنصر حسگر بستگی دارد. حسگرهای پلیمر رسانا در دمای محیط کار می‌کنند، اما نشان داده‌شده است که افزایش دمای کاری تا حدود ۷۰ درجه سلسیوس، که پلیمرها شروع به تجزیه می‌کنند، می‌تواند حساسیت را افزایش داده و خرابی حسگر را کاهش دهد (Dey, 2018; Yuan, Benck, Eatmon, Blankschtein, & Strano, 2018). یکی دیگر از عوامل مؤثر بر پاسخ حسگرهای گازی، جریان گاز نمونه‌برداری است. در مورد تغییرات جریان گاز در حسگرهای بینی الکترونیکی، باید در نظر داشت که در برخی از کاربردها، نمونه‌برداری و تجزیه‌وتحلیل در زمان‌های مختلف انجام می‌شود. در مقابل، در برخی دیگر، نمونه‌گیری و تجزیه‌وتحلیل هم‌زمان اتفاق می‌افتد. در این موارد، جنبه اصلی که باید موردتوجه قرار گیرد، هندسه محفظه و پایداری نرخ جریان گاز در مرحله تجزیه‌وتحلیل است (Robbiani, Lotesoriere, Dellacà, & Capelli, 2023). اسکات و همکاران (Scott, James, Ali, & O'Hare, 2004) عنوان کردند که دینامیک سیال محفظه بینی الکترونیکی بر پاسخ حسگرهای مورداستفاده تأثیر می‌گذارد. در این مطالعه نتیجه‌گیری شد که وجود یک مانع عملکرد حسگرها را ازنظر زمان پاسخ افزایش می‌دهد. درنتیجه پاسخ سریع‌تری نسبت به موقعیتی که سطح حسگرها در جهت عمود بر مسیر جریان قرار می‌گیرند، ایجاد می‌کند (Lezzi *et al.*, 2001; Sedlák & Kuberský, 2020; Shyla, Naidu, & Kumar, 2013). محققین با تمرکز بر طراحی محفظه حسگرها بیان کرده‌اند که در داخل محفظه، شرایط پایدار و یکنواخت باید در سریع‌ترین زمان ممکن حاصل شود (Cheng, Liu, & Meng, 2020; Sedlák & Kuberský, 2020). برای اطمینان از شرایط پایدار و یکنواخت، جریان آرام در محفظه موردنیاز است. برای جبران عوامل فیزیکی مؤثر بر پاسخ حسگرها، روش‌های مختلف سخت‌افزاری می‌توانند در سامانه‌های بینی پیاده‌سازی شوند. چنین راه‌حل‌هایی می‌تواند شامل اصلاحات و طرح‌های خاص مربوط به روش‌های ساخت حسگرها (Hunter *et al.*, 2020; Liu, Ma, Pinna, & Zhang, 2017; Xue *et al.*, 2020)، طراحی سامانه نمونه‌برداری و از همه مهم‌تر، طراحی هندسه محفظه باشد (Covington *et al.*, 2021; Dragonieri, Pennazza, Carratu, & Resta, 2017; Fonollosa, Fernández, Gutiérrez-Gálvez, Huerta, & Marco, 2016; Laref, Ahmadou, Losson, & Siadat, 2017).

هندسه محفظه جنبه‌ای حیاتی برای افزایش پاسخ حسگرها ازنظر زمان پاسخ و قابلیت اطمینان است. الزامات یک محفظه حسگر بینی الکترونیکی برای تضمین پاسخ‌های سریع و قابل‌اعتماد عبارتند از: (الف) حجم کم، (ب) عدم گردش مجدد یا مناطق راکد، و (ج) جریان آرام. علاوه بر این، بیشتر مطالعات اشاره می‌کنند که داشتن لایه فعال حسگر عمود برجهت جریان می‌تواند پاسخ آن را افزایش دهد. چاودری و همکاران (Chowdhury, Kumar, Kumar, Karar, & Bhondekar, 2016) چگونگی کاهش حجم داخلی یک محفظه را مورد مطالعه قرار دادند. نویسندگان در این پژوهش سه هندسه محفظه را در نظر گرفتند. شبیه‌سازی‌های CFD نشان داد طرحی که شرایط یکسانی را برای همه حسگرها تضمین می‌کند بهتر از دو طرح دیگر عمل کرد. سامیان و ادی (Samiyan & Addi, 2017) هندسه سه محفظه مستطیلی، لوله‌ای شکل و کروی را با شبیه‌سازی توزیع جریان در داخل محفظه و انجام آزمایش‌هایی بر روی زمان پاسخ حسگرهای MOS هنگام قرار گرفتن در معرض الکل مقایسه کردند. نتایج ایشان نشان داد که محفظه‌های مستطیلی و لوله‌ای شکل تحت تأثیر نواحی چرخشی و راکد قرار می‌گیرند و این فرایند تاثیر منفی

روی عملکرد محفظه خواهد داشت. آنانوش و همکاران در مطالعات خود عملکرد یک حسگر واحد را در دو محفظه قایق‌شکل و صلیب‌شکل شبیه‌سازی و مقایسه کردند. نویسندگان به این نتیجه رسیدند که محفظه قایق‌شکل به دلیل کاهش حجم داخلی و کاهش مناطق راکد و در حال چرخش، بهتر از محفظه صلیب‌شکل عمل می‌کند (Annanouch *et al.*, 2018; Annanouch *et al.*, 2019). دوهره و همکاران (Dohare, Bagchi, & Bhondekar, 2020) از مانع برای بهینه‌سازی جریان داخل محفظه استفاده کردند. نتایج شبیه‌سازی نشان داد که هرچه سرعت جریان بیشتر باشد، مناطق راکد کمتر می‌شوند. در پژوهشی که توسط لوپز و همکاران (Lopez *et al.*, 2020) انجام شد، عملکرد دو هندسه محفظه مقایسه شدند تا مناطق راکد را در این هندسه‌ها مورد بررسی قرار دهند. هارموزی و همکاران (Harmouzi, Amari, & Masmoudi, 2023) یک نمونه بینی الکترونیکی را شبیه‌سازی کردند. نویسندگان با بهره‌گیری از هندسه‌های ارائه‌شده توسط سامیان و ادی (Samiyan & Addi, 2017) و اعمال اصلاحات روی محفظه، یک قوس مماسی برای حذف گوشه در دو طرف محفظه استفاده کردند که توزیع جریان هوا در محفظه‌ی اصلاح‌شده به‌طور کلی یکنواخت و بدون تلاطم بود.

جهت بررسی تجربی هندسه‌های مختلف، علاوه‌بر صرف هزینه زیاد جهت ساخت هندسه‌ها و تامین حسگرها، زمان زیاد داده‌برداری و تامین شرایط محیطی مناسب، داده‌هایی از جمله زمان رسیدن سیال به حسگر و زمان عملکرد حسگرها به‌دست خواهد آمد و برای دستیابی به شکل‌های کانتوری و وکتورها، نیاز به ابزار و حسگرهای خاص و گران‌قیمت می‌باشد که در نتیجه انجام فرایند تجربی و دستیابی به داده‌ها را بسیار پرهزینه و زمان‌بر خواهد کرد. در نتیجه با انجام فرایند شبیه‌سازی می‌توان علاوه بر صرف زمان کم، هزینه کم، هندسه‌های متنوع‌تری را تحلیل و پس از یافتن بهترین هندسه محفظه، صرفا همان هندسه را جهت راستی‌آزمایی به‌صورت تجربی تحلیل کرد. در همین خصوص، بررسی مطالعات انجام‌شده در سال‌های اخیر نیز نشان داد که فرایند شبیه‌سازی جهت دستیابی به نتایج مناسب در این زمینه بسیار مورد توجه قرار گرفته و داده‌های به‌دست‌آمده از این شبیه‌سازی‌ها بسیار دقیق و کارآمد هستند. لازم به ذکر است که فرایند شبیه‌سازی نیز دارای محدودیت‌هایی از جمله نیاز به سیستم‌های رایانه‌ای با توانمندی بالاست که قادر به انجام شبکه‌بندی‌های سه‌بعدی و از همه مهم‌تر شبیه‌سازی سیالاتی آن‌ها باشد. روش دینامیک سیالات محاسباتی (CFD[1]) شاخه‌ای است از روش‌های عددی برای حل معادلات حاکم بر کشف قوانین و پدیده‌های مختلف جریان. اکنون روش CFD جای خود را در میان روش‌های آزمایشگاهی و تحلیلی برای تحلیل مسائل سیالات و انتقال حرارت باز کرده است و استفاده از این روش برای انجام تحلیل‌های مهندسی امری عادی شده است. با توجه به تاثیر حائز اهمیت هندسه محفظه سامانه بر جریان سیال و عملکرد حسگرها، با هدف دستیابی به هندسه‌ی بهینه‌ی محفظه، در پژوهش حاضر فرایند طراحی و شبیه‌سازی چهار هندسه مختلف و با ساختار متنوع شامل استوانه، هرم، نیم‌کره و مخروط به‌صورت سه‌بعدی و با نرم‌افزارهای CATIA و Ansys Fluent انجام شد تا تاثیر ساختارهای فیزیکی هندسه‌هایی که می‌توانند بسیار مورد استفاده قرار گرفته و کاربردی باشند، مورد بررسی قرار گیرد. همچنین شبیه‌سازی تمامی هندسه‌ها با تزریق دو سیال هوا و CO_2 صورت گرفته و نتایج با یکدیگر مقایسه شده‌اند. از هوا به‌عنوان سیال جهت پاک‌سازی محفظه و حسگرها استفاده شده است. با توجه به این‌که CO_2 یکی از گازهای حاصل از تنفس محصولات کشاورزی پس از برداشت آن‌ها می‌باشد، از این سیال به‌عنوان سیال هدف برای حسگرها استفاده شده است. در نتیجه در مطالعه حاضر علاوه‌بر طراحی و شبیه‌سازی چهار هندسه متنوع، کاربردی و متفاوت از لحاظ ساختاری، تاثیر تغییر نوع سیال با استفاده از دو سیال مهم و حائز اهمیت نیز صورت پذیرفته است. در حالی‌که در سایر مطالعات شبیه‌سازی، بررسی هم‌زمان دو نوع سیال و رفتار آن‌ها در چهار هندسه متفاوت که از لحاظ ابعاد و ساختاری جدید می‌باشند، انجام نشده است. این مقایسه درک بسیار مناسبی از نوع رفتار و عملکرد سیال در حالات مختلف را نشان داده و می‌تواند بینش بسیار مفیدی را در این زمینه ایجاد کند.

مواد و روش‌ها

معادلات حاکم، روش حل و شرایط مرزی

در مطالعه حاضر، چهار هندسه مختلف با استفاده از نرم‌افزار CATIA طراحی شده‌اند. سپس، فرایند شبیه‌سازی به‌صورت سه‌بعدی و با استفاده از نرم‌افزار Ansys Fluent انجام شد. برای پیش‌بینی جریان سیال، از معادلات پیوستگی و ناویراستوکس (روابط ۱ و ۲) استفاده می‌شود (Dohare *et al.*, 2020):

$$\frac{\partial \rho}{\partial t} = 0 \qquad (۱)$$

$$\rho \frac{DV}{Dt} = -\nabla P + \mu \nabla^2 V + \rho g \qquad (۲)$$

که در این روابط V سرعت، P فشار، ρ چگالی جرم هوا و μ ضریب ویسکوزیته دینامیکی است. روش حل Second order upwind برای تقریب معادله مومنتوم استفاده شده‌است. سیال آرام[2] در نظر گرفته شده و همچنین کوپل سرعت و فشار نیز با استفاده از

1- Computational fluid dynamics

2- Laminar

الگوریتم SIMPLEC صورت پذیرفته است. حلگر مورداستفاده مشابه با مقاله چانگ و همکاران (Chang *et al.*, 2018)، Pressure based و در حالت Transient بوده است. هندسه‌ها طوری طراحی شده‌اند که از نظر طولی و همچنین سطح مقطع ورودی و خروجی یکسان بوده تا عملکرد جریانی و سیالاتی به ساختار هندسه‌ها معطوف گردد. جهت شبکه‌بندی این هندسه‌ها سعی‌شده‌است تا حد امکان از شبکه‌های ساختاری (مربعی- مکعبی) که نتایج بهتری نسبت به سایر شبکه‌بندی‌ها دارند استفاده گردد. شرایط مرزی برای تمامی هندسه‌ها مشابه بوده و با توجه به سطح مقطع یکسان ورودی و خروجی در تمامی هندسه‌ها، تنها تفاوت در ساختار کلی و ذاتی هندسه‌ها می‌باشد. شرایط مرزی اعمال‌شده از قبیل سرعت ورودی ۰/۸ متر برثانیه و شرط مرزی Pressure outlet برای خروجی است.

تصاویر هندسه‌ها، ابعاد آن‌ها و نوع شبکه‌بندی آن‌ها در شکل‌های ۱ و ۲ قابل مشاهده است.

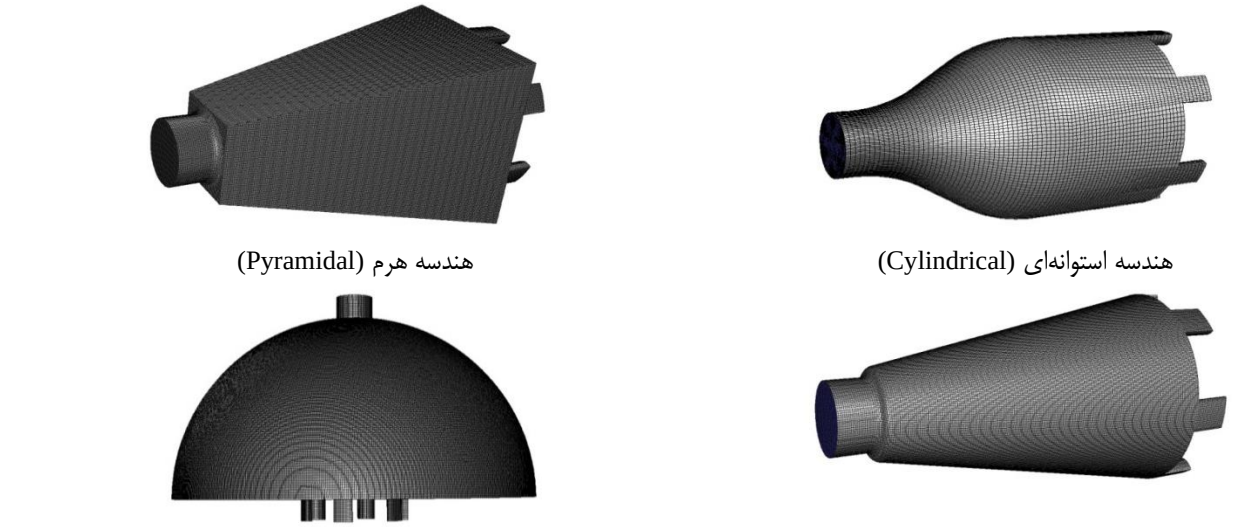

شکل ۱- ساختار شبکه‌بندی هندسه‌های مورد بررسی در شبیه‌سازی

Fig. 1. Meshing structure of the geometries investigated in the simulation

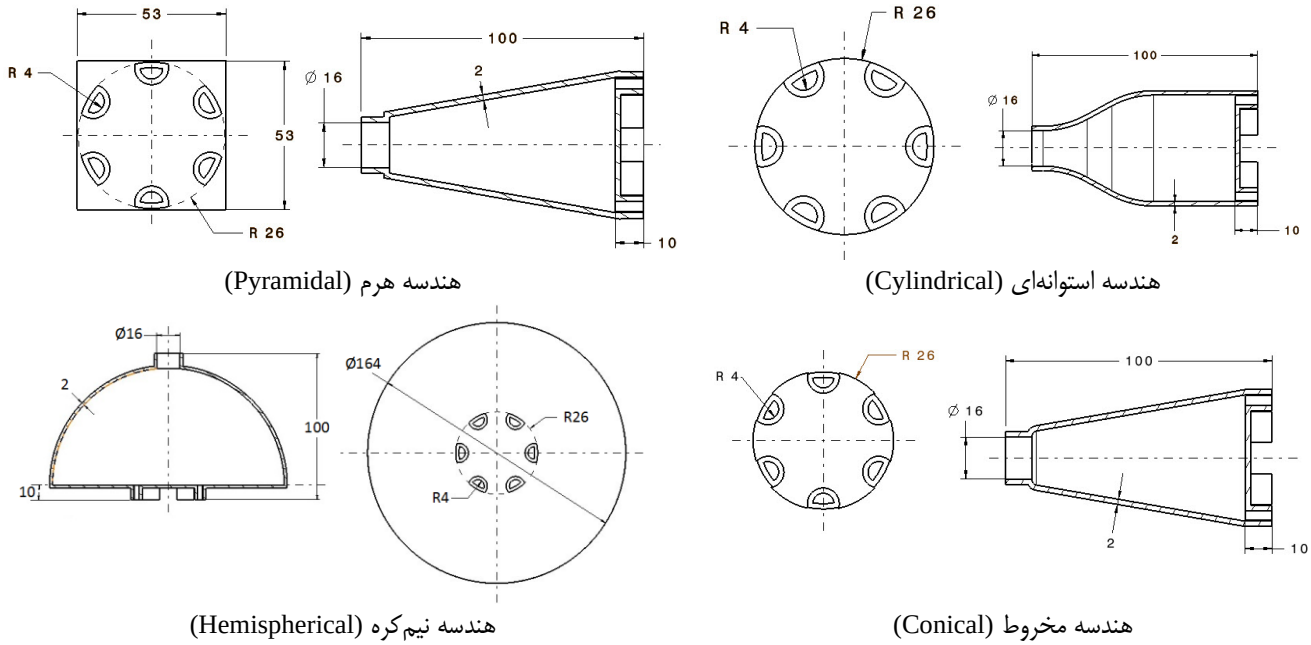

شکل ۲- ابعاد هندسه‌های موردبررسی در شبیه‌سازی

Fig. 2. Dimensions of the geometries investigated in the simulation

اعتبارسنجی و استقلال از شبکه

اولین مرحله جهت آغاز فرایند طراحی و ساخت محفظه و شبیه‌سازی آن، دستیابی به روش حل درست با انجام فرایند اعتبارسنجی با مقالات مشابه می‌باشد. انجام فرایند اعتبارسنجی می‌تواند خط مشی مناسبی برای ادامه مسیر پروژه باشد و به همین جهت، مقاله‌ای مشابه در زمینه طراحی بهینه بیونیک محفظه بینی الکترونیکی برای تشخیص نفت و گاز مورد بررسی، طراحی و شبیه‌سازی قرار گرفت. هندسه مورد مطالعه در این مقاله در شکل ۳ مشاهده می‌شود. جهت آغاز فرایند، ابعاد مطابق با تصویر مقاله مذکور طراحی و برای اجرای شبیه‌سازی، شبکه‌بندی در نرم‌افزارهای Ansys (ICEM) انجام شده است.

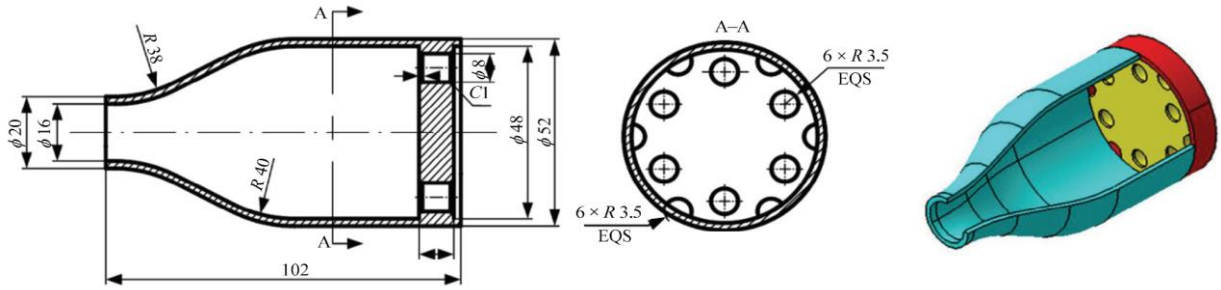

شکل ۳- هندسه مورد بررسی در مقاله Chang *et al.* (2018)

Fig. 3. The investigated geometry Chang *et al.* (2018)

فرایند شبیه‌سازی نیازمند وجود داده‌های اولیه نظیر سرعت ورودی، نوع سیال، دانسیته سیال و غیره می‌باشد، که این داده ها از تحقیقات مشابه برداشت شده و شبیه‌سازی با استفاده از نرم‌افزار Ansys Fluent انجام گردید. نتایج به‌دست‌آمده از شبیه‌سازی‌ها با نتایج مقاله چانگ و همکارانش مورد بررسی قرار گرفت و همان‌طور که در شکل ۴ مشاهده می‌شود، کانتور و وکتور سرعت به‌دست‌آمده در شبیه‌سازی کنونی، تطابق بسیار خوبی با داده‌های این مقاله دارد. همچنین، مشابه مقاله مذکور، مقدار دبی خروجی در این اعتبارسنجی نیز عدد ۰/۱۹۶۸ به‌دست آمده است که دقت شبیه‌سازی حاضر را تایید می‌کند (Chang *et al.*, 2018).

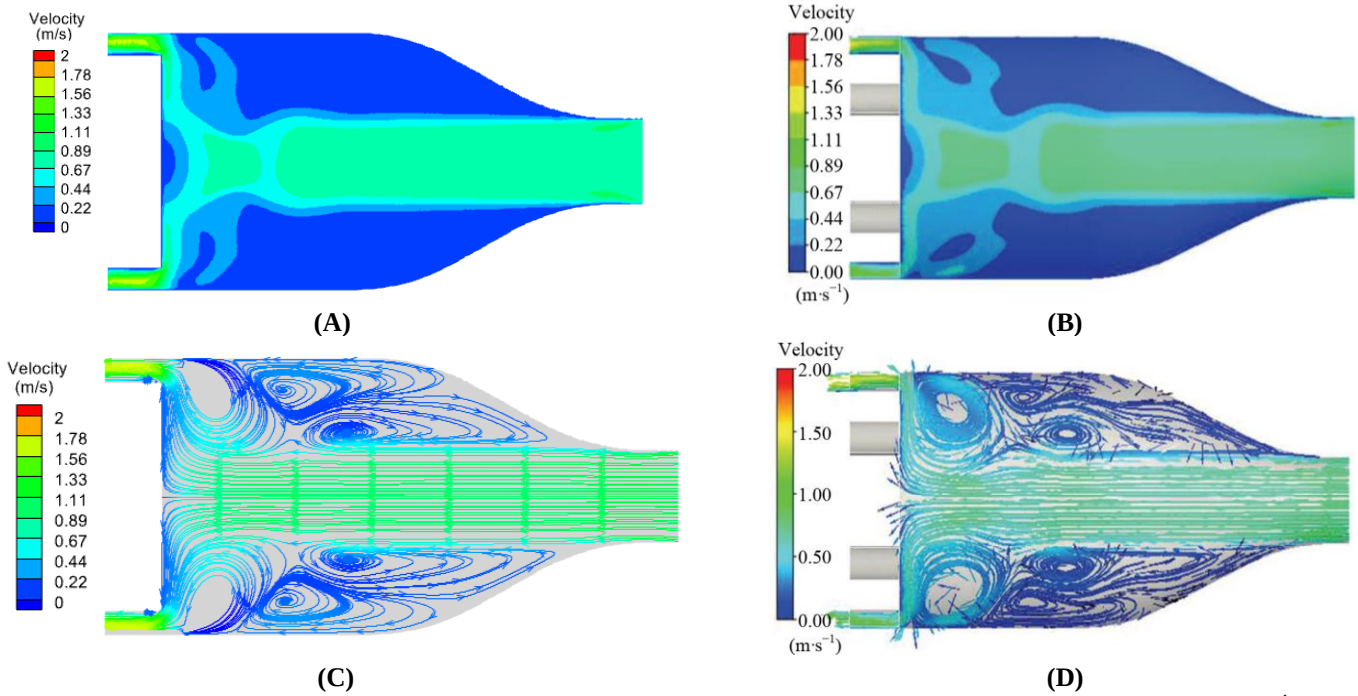

شکل ٤- مقایسه داده‌های مقاله با نتایج شبیه‌سازی: (A) کانتور و (C) وکتورهای سرعت در شبیه‌سازی صورت‌گرفته، و (B) کانتور و (D) وکتورهای سرعت در مقاله مورد بررسی

Fig. 4. Comparison between the data reported in the reference article and the simulation results: velocity (A) contour and (C) vectors obtained from the performed simulation, and velocity (B) contour and (D) vectors reported in the reference article

جهت بررسی استقلال از شبکه، مش‌های مختلفی با تعداد شبکه‌های نشان داده در شکل ۵ مورد بررسی قرار گرفت. همانطور که در شکل مشاهده می‌شود، با افزایش تعداد شبکه تا تعداد ۵۵۰ هزار، مقدار دبی خروجی به مقدار صحیح (۰/۱۹۶۸ (10^{-3} kgs^{-1}) می‌رسد. با ادامه روند افزایش تعداد شبکه تا ۱۳۰۰۰۰۰ شبکه، مقدار دبی همچنان در عدد ۰/۱۹۶۸ مانده و لذا نتایج شبیه‌سازی از تعداد شبکه مستقل شده است. در نتیجه مقدار شبکه کمتر برای انجام شبیه‌سازی‌ها انتخاب گردیده است.

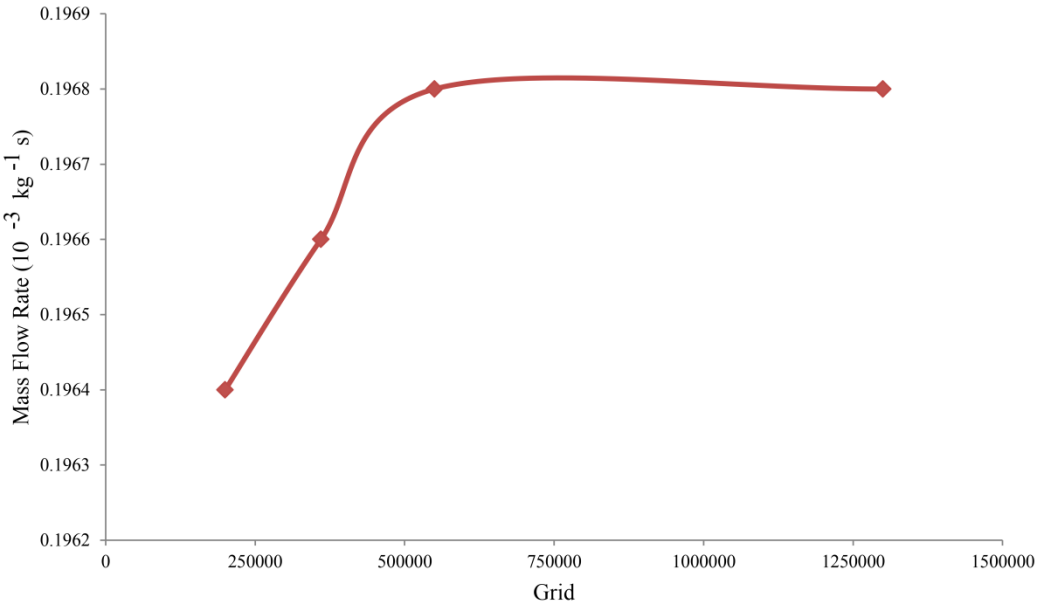

شکل ۵– نمودار استقلال از شبکه

Fig. 5. Grid independence plot

نتایج و بحث

همان‌طور که بیان شد، در پژوهش حاضر فرایند شبیه‌سازی چهار هندسه مختلف شامل استوانه، هرم، مخروط و نیم‌کره به‌صورت سه‌بعدی و در دو حالت تزریق سیال هوا و CO_2 و با شرایط مرزی یکسان صورت پذیرفته است. جهت بررسی رفتار سیال در هندسه‌ها از جمله زمان رسیدن به سطح حسگرها و زمان تقریبی پایداری، تصاویر آن‌ها در زمان‌های ۲۵، ۵۰ و ۷۵ ثانیه و شرایطی که تقریبا پایدار است (زمانی‌که کانتورها تقریبا دارای فرم ثابتی شدند) نشان داده شده و با یکدیگر مقایسه شده‌اند. علاوه‌بر کانتورهای سرعت، نمودارهای خطوط مسیر سیال[1] نیز جهت نمایش بهتر عملکرد هندسه‌ها آورده شده‌است.

جهت مقایسه عملکرد چهار هندسه در حالت تزریق هوا، همانطور که در شکل ۶ و برای هندسه استوانه‌ای قابل مشاهده‌است، با افزایش زمان شبیه‌سازی، سیال در زمانی کمتر از ۵۰ ثانیه سطح حسگرها را لمس و در زمان ۷۵ ثانیه به‌طور کامل سطح حسگرها را پوشش داده و جهت دستیابی به پایداری کامل آن، نیازمند انجام شبیه‌سازی بیشتری است (تصویر Stable state). مشابه این پدیده در هندسه‌های هرمی و مخروطی (شکل ۷ و ۸) نیز اتفاق افتاده است. در شکل ۷ (هندسه هرمی)، سیال در زمان شبیه‌سازی ۷۵ ثانیه کاملا سطح حسگرها را لمس کرده و تفاوت آن با هندسه استوانه‌ای در آن است که هندسه هرم در زمان ۷۵ ثانیه به پایداری بهتری رسیده‌است. هندسه مخروطی (شکل ۸) نیز در زمان ۷۵ ثانیه کاملا روی سطح قرار گرفته‌است ولی جهت رسیدن به تعادل کامل به زمان بسیار بیشتری نسبت به دو هندسه قبل نیاز دارد. اما رفتار هندسه نیم‌کره بسیار متفاوت از سه هندسه دیگر است. همانطور که در شکل ۹ مشاهده می‌شود، سیال در این حالت در زمان ۲۵ ثانیه کاملا به پایداری رسیده و در زمان‌های بیشتر شکل یکسانی را دارا می‌باشد. برای هندسه نیم‌کره، جهت دید بهتر عملکرد سیال (به علت این‌که در زمان کمتر از ۵۰ ثانیه به تعادل می‌رسد)، تصاویر در زمان‌های ۵، ۲۵ و۵۰ ثانیه و شرایطی که تقریبا پایدار است (زمانی‌که کانتورها تقریبا دارای فرم ثابتی شدند) نشان داده شده‌است. لازم به ذکر است که سرعت سیال نقش حیاتی در توزیع همگن سیال داخل محفظه دارد

1- Path line

(Cai, Ding, & Wang, 2025) و همان‌طور که در شکل‌ها مشاهده می‌شود، ناحیه‌های جانبی محفظه‌ها دارای قسمت‌های مرده هستند و سرعت سیال در قسمت میانی جریان اصلی برای هندسه‌های هرمی، مخروطی و نیم‌کره افزایش یافته‌است که در نتیجه می‌تواند باعث رسیدن زودتر سیال به سطح حسگرها (تماس اولیه با سطح حسگرها) شود.

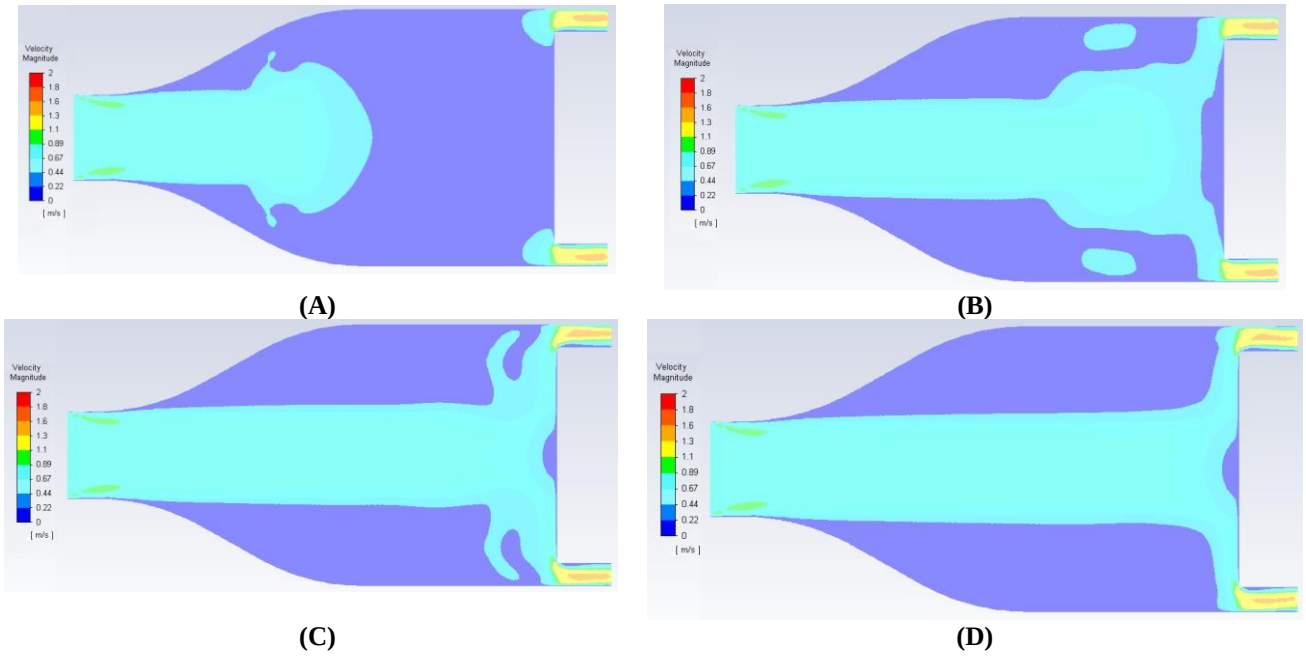

شکل ٦– کانتورهای سرعت هندسه استوانه‌ای در زمان‌های 25 s(A)، 50 s(B)، 75 s(C) و (D) شرایط پایداری نسبی برای هوا

Fig. 6. Velocity contours of the cylindrical geometry at (A) 25 s, (B) 50 s, (C) 75 s, and (D) stability conditions for air

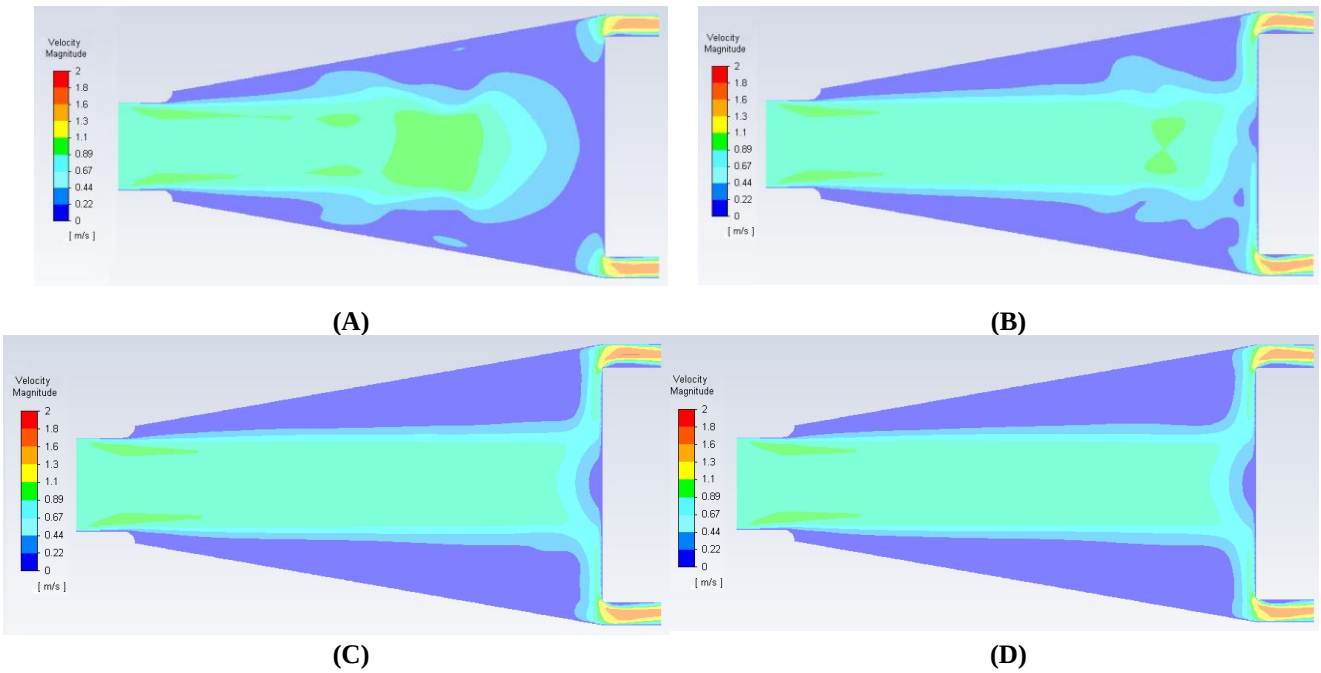

شکل ۷– کانتورهای سرعت هندسه هرمی در زمان‌های 25 s(A)، 50 s(B)، 75 s(C) و (D) شرایط پایداری نسبی برای هوا

Fig. 7. Velocity contours of the pyramidal geometry at (A) 25 s, (B) 50 s, (C) 75 s, and (D) stability conditions for air

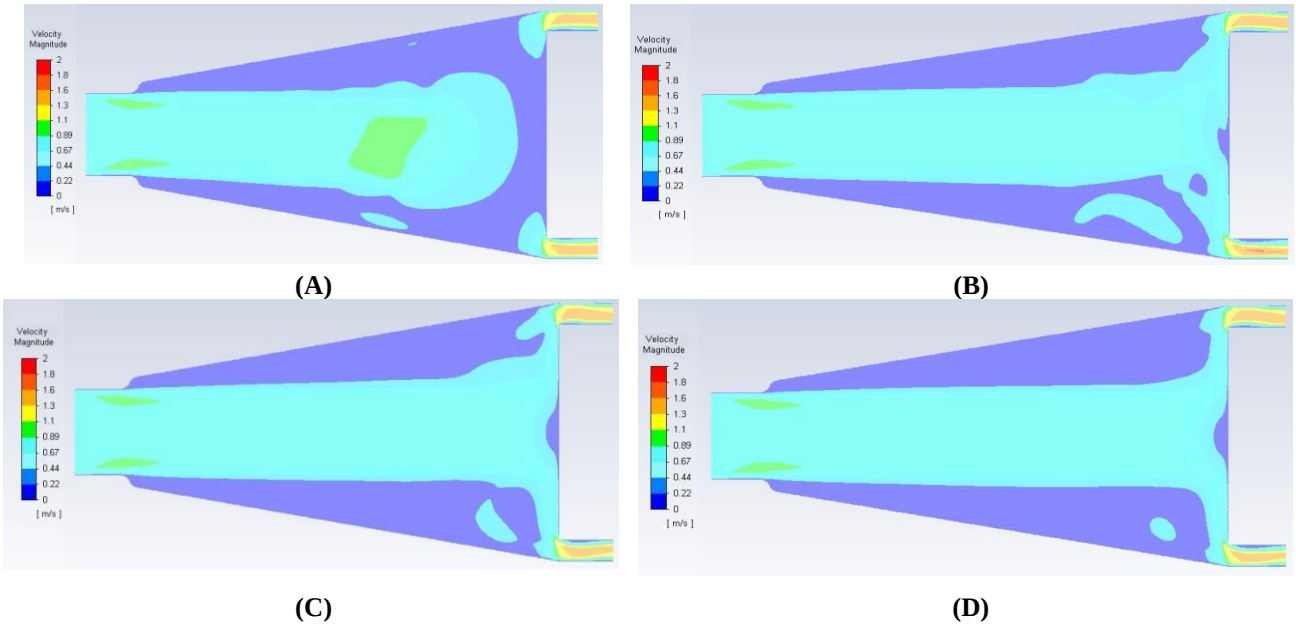

شکل ۸– کانتورهای سرعت هندسه مخروطی در زمان‌های 25 s(A)، 50 s(B)، 75 s(C) و (D) شرایط پایداری نسبی برای هوا

Fig. 8. Velocity contours of the conical geometry at (A) 25 s, (B) 50 s, (C) 75 s, and (D) stability conditions for air

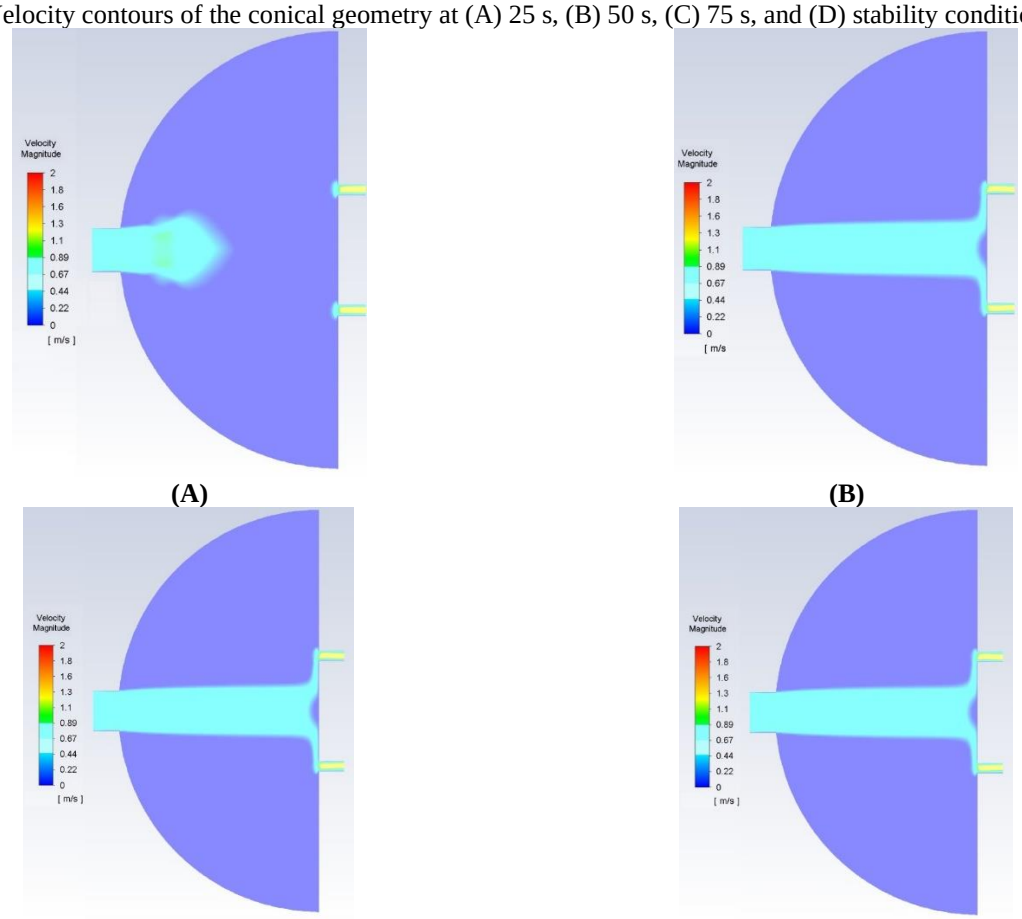

شکل ۹– کانتورهای سرعت هندسه نیم‌کره در زمان‌های 5 s(A)، 25 s(B)، 50 s(C) و (D) شرایط پایداری نسبی برای هوا

Fig. 9. Velocity contours of the hemispherical geometry at (A) 25 s, (B) 50 s, (C) 75 s, and (D) stability conditions for air

برای بررسی بهتر رفتار سیال در این هندسه‌ها، نمودارهای مسیر سیال در این هندسه‌ها، برای زمان‌های مشخص‌شده نیز مورد بررسی قرار گرفته‌است. در هندسه استوانه‌ای (شکل ۱۰) با افزایش زمان، گردابه‌هایی در اطراف جریان اصلی (جریان میانی) و مماس به دیواره شکل گرفته و تا انتهای مسیر جریان میانی را همراهی می‌کند. با نزدیک شدن سیال به سطح حسگرها، پیدایش گردابه‌ها در سطوح جانبی نیز افزایش یافته به‌آرامی این گردابه‌ها کوچک‌تر می‌شوند که این عمل باعث هم‌گرایی بهتر سیال می‌شود که توسط ژائو و همکاران هم تایید شده است (Zhao, Dalton, Yang, & Scherer, 2006). با افزایش گردابه‌های کوچک در نزدیکی سطح حسگرها، سرعت سیال روی سطح کمتر و در نتیجه این عمل باعث لمس بهتر سیال با سطح حسگرها شده و باعث چسبیدن بهتر سیال به آن شده‌است که این پدیده در بررسی چانگ و همکاران نیز مشاهده گردیده است (Chang *et al.*, 2018). وجود گردابه‌های نامتقارن در هندسه هرمی شکل (شکل ۱۱) باعث ناپایداری جریان در زمان ۵۰ ثانیه شده است. وجود دیواره‌های مسطح و کنج‌ها (محل برخورد سطوح دیواره به هم)، باعث پیدایش گردابه‌های بزرگی در این ناحیه‌ها خواهد شد که به‌تدریج با سطح میانی سیال رسیده و باعث ناپایداری کل سیال خواهند شد. تعداد گردابه‌های ایجادشده در هندسه مخروطی بیشتر از هندسه هرمی است ولی با این تفاوت که مشابه هندسه استوانه‌ای، این گردابه‌ها بیشتر به سمت سیال میانی حرکت کرده و آن را هدایت می‌کنند (شکل ۱۲). در انتها و حین رسیدن به سطح حسگر نیز به‌تدریج باعث چسبیدن سیال به سطح حسگر و حرکت به سمت دیواره‌ها هستند. ولی همچنان مشابه هندسه هرمی دارای گردابه‌های نامتقارنی هستند. دلیل پیدایش گردابه‌های نامتقارن، چرخش جانبی سیال است. این بدان معنی است که سیال به جای حرکت مستقیم، کمی نیز دارای جابه‌جایی و چرخش به دور محور اصلی جریان بوده و این عمل گردابه‌ها را به یک سمت سوق می‌دهد. در این میان، هندسه کره بهترین عملکرد را دارا می‌باشد. دلیل این عملکرد مناسب می‌تواند ابعاد کره در قسمت سطح حسگر آن باشد. این تغییر ابعاد در سطح حسگر سیال (سطح تخت) باعث شده‌است که سیال در زمان ورود به هندسه کره، عکس‌العملی مشابه با یک تونل باد آزمایشگاهی داشته و با توجه به دور بودن دیواره کره از خروجی‌های تعبیه‌شده روی سطح حسگر آن، گردابه‌ها فضای کافی برای پخش‌شدن به سمت‌های دیگر داشته و در نتیجه سیال مرکزی به‌راحتی به سطح حسگر رسیده و همگرا شود. لازم به ذکر است که مانند سایر هندسه‌ها، در این هندسه نیز گردابه‌ها سیال میانی را تا سطح دیواره خروجی همراهی کرده و بعد از همگرایی به‌تدریج به طرفین حرکت می‌کنند. می‌توان گفت که تاثیر حرکت سیال روی دیواره‌های جانبی و درهم‌کنش سیال میانی و گردابه‌های ایجادشده روی سطوح جانبی می‌تواند باعث مقاومت سیال در همگرایی سریع‌تر گردد و در نتیجه هندسه کروی از این حیث دارای شرایط بهتری نسبت به سایر هندسه‌ها می‌باشد.

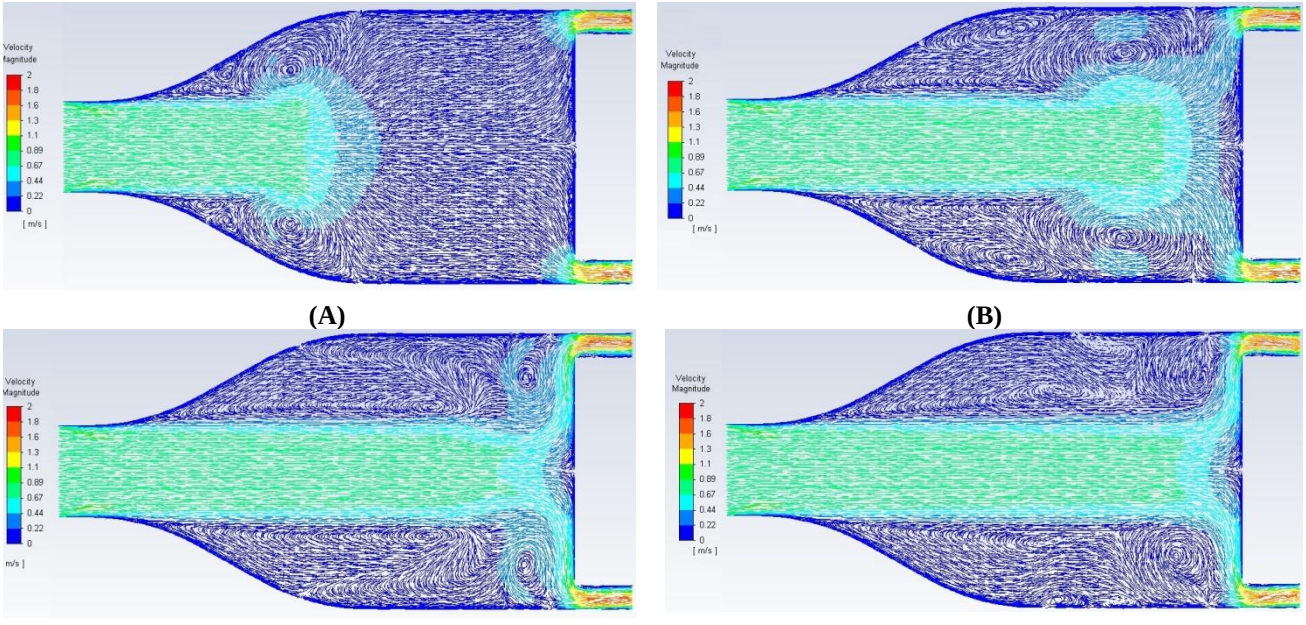

شکل ۱۰– نمودارهای خط مسیر هندسه استوانه‌ای در زمان‌های (A) 25 s، (B) 50 s، (C) 75 s و (D) شرایط پایداری نسبی برای هوا

Fig. 10. Path line plots of the cylindrical geometry at (A) 25 s, (B) 50 s, (C) 75 s, and (D) stability conditions for air

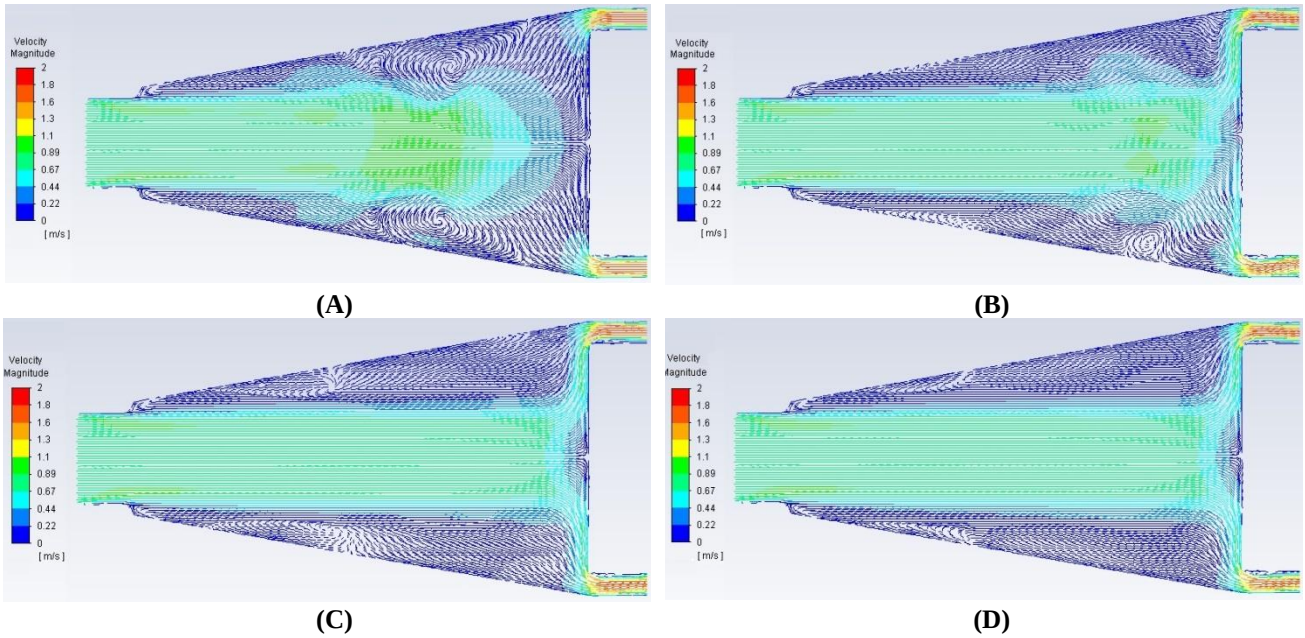

شکل ۱۱– نمودارهای خط مسیر سرعت هندسه هرمی در زمان‌های (A)25 s، (B)50 s، (C)75 s و (D) شرایط پایداری نسبی برای هوا

Fig. 11. Path line plots of the pyramidal geometry at (A) 25 s, (B) 50 s, (C) 75 s, and (D) stability conditions for air

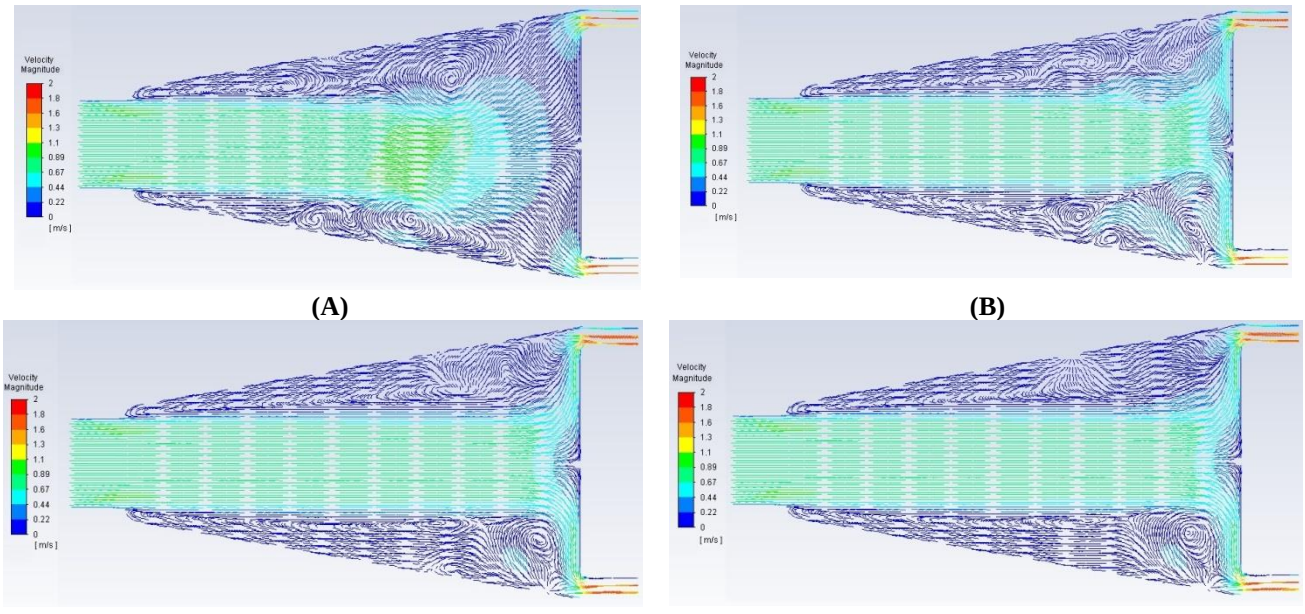

شکل ۱۲– نمودارهای خط مسیر سرعت هندسه مخروطی در زمان‌های (A)25 s، (B)50 s، (C)75 s و (D) شرایط پایداری نسبی برای هوا

Fig. 12. Path line plots of the conical geometry at (A) 25 s, (B) 50 s, (C) 75 s, and (D) stability conditions for air

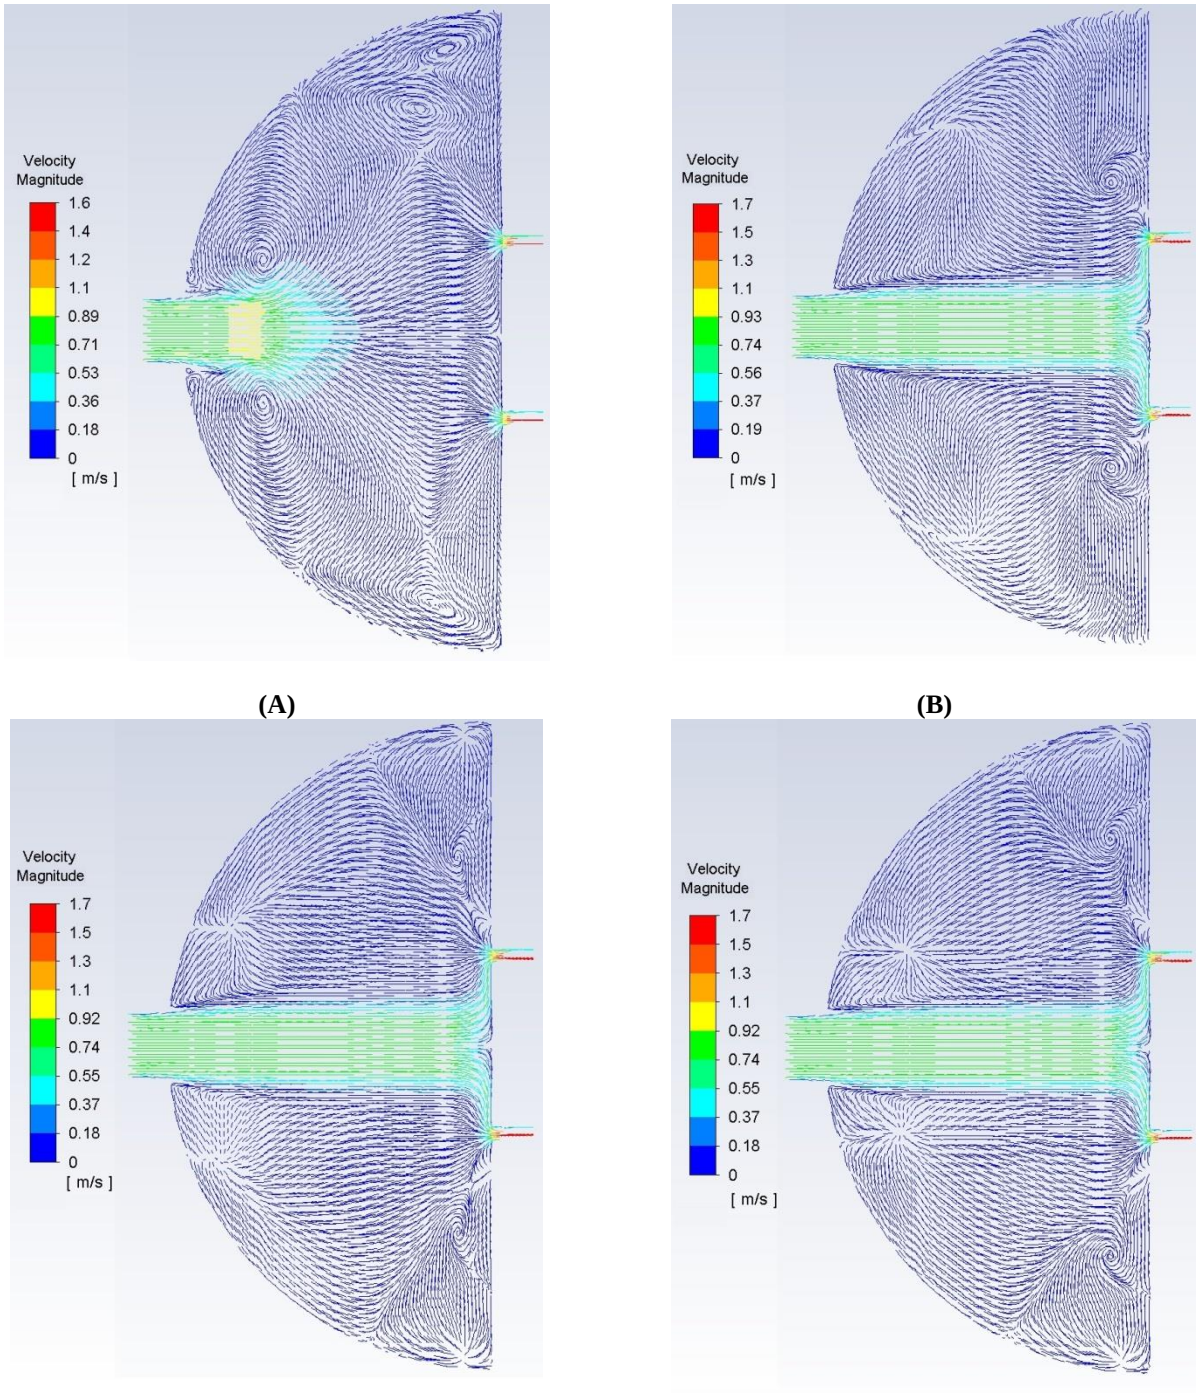

شکل ۱۳– نمودارهای خط مسیر سرعت هندسه نیم‌کره در زمان‌های (A)5 s، (B)25 s، (C)50 s و (D) شرایط پایداری نسبی برای هوا

Fig. 13. Path line plots of the hemispherical geometry at (A) 25 s, (B) 50 s, (C) 75 s, and (D) stability conditions for air

همان‌طور که بیان گردید، علاوه بر بررسی تزریق هوا در هندسه های موجود، تاثیر تزریق سیال CO_2 (سیالی با دانسیته متفاوت نسبت به هوا) نیز مورد بررسی قرار گرفته و نمودارهای خط مسیر سرعت آن بررسی شده‌است. همان‌طور که در شکل ۱۴ مشاهده می‌شود، رفتار CO_2 بسیار متفاوت از هوا است. برای هندسه استوانه‌ای در ثانیه ۵۰، سیال به‌طور کامل سطح حسگر را پوشش داده است. دلیل این امر افزایش نرخ جریان سیال است که باعث شده سیال در زمان کمتری به سطح حسگرها برخورد کند.

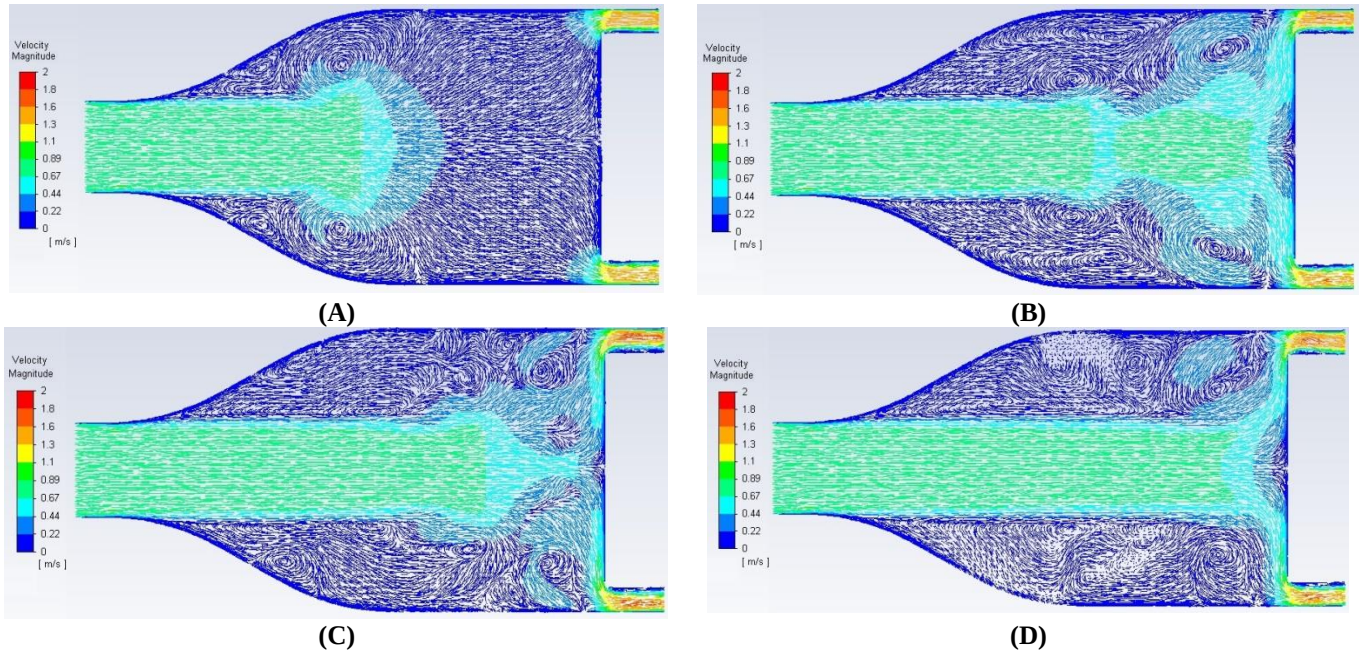

شکل ۱۴– نمودارهای خط مسیر سرعت هندسه استوانه‌ای در زمان‌های (A)25 s، (B)50 s، (C)75 s و (D) شرایط پایداری نسبی برای CO_2

Fig. 14. Path line plots of the cylindrical geometry at (A) 25 s, (B) 50 s, (C) 75 s, and (D) stability conditions for CO_2

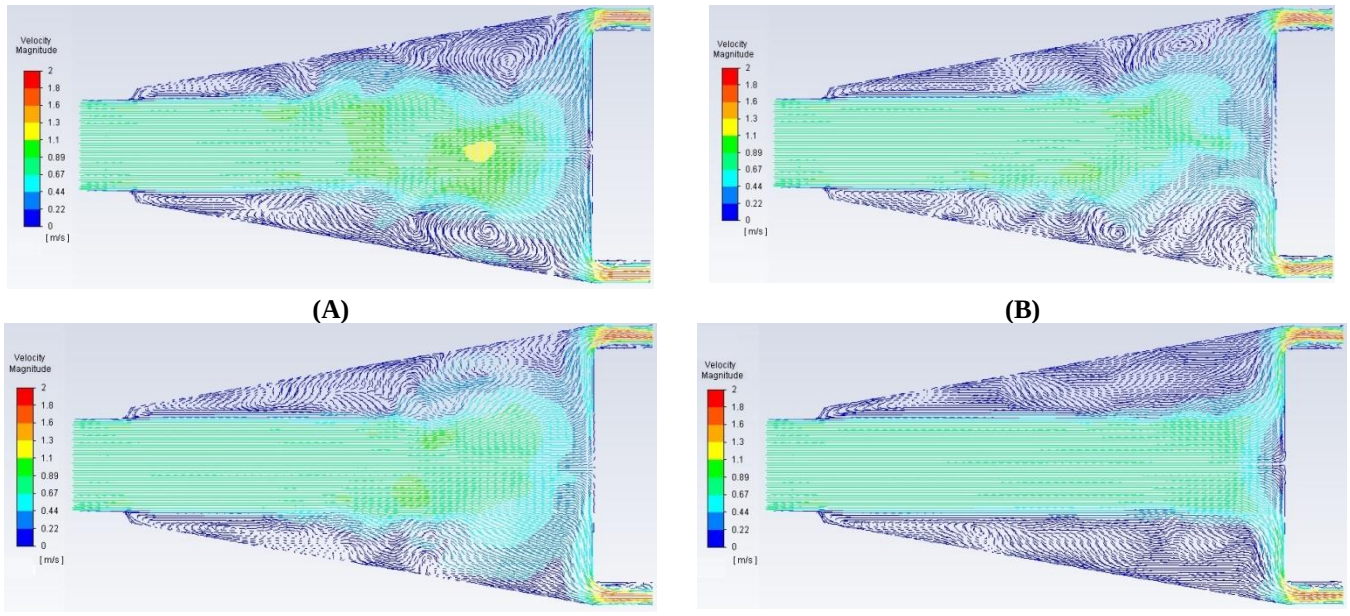

شکل ۱۵– نمودارهای خط مسیر سرعت هندسه هرمی در زمان‌های (A)25 s، (B)50 s، (C)75 s و (D) شرایط پایداری نسبی برای CO_2

Fig. 15. Path line plots of the pyramidal geometry at (A) 25 s, (B) 50 s, (C) 75 s, and (D) stability conditions for CO_2

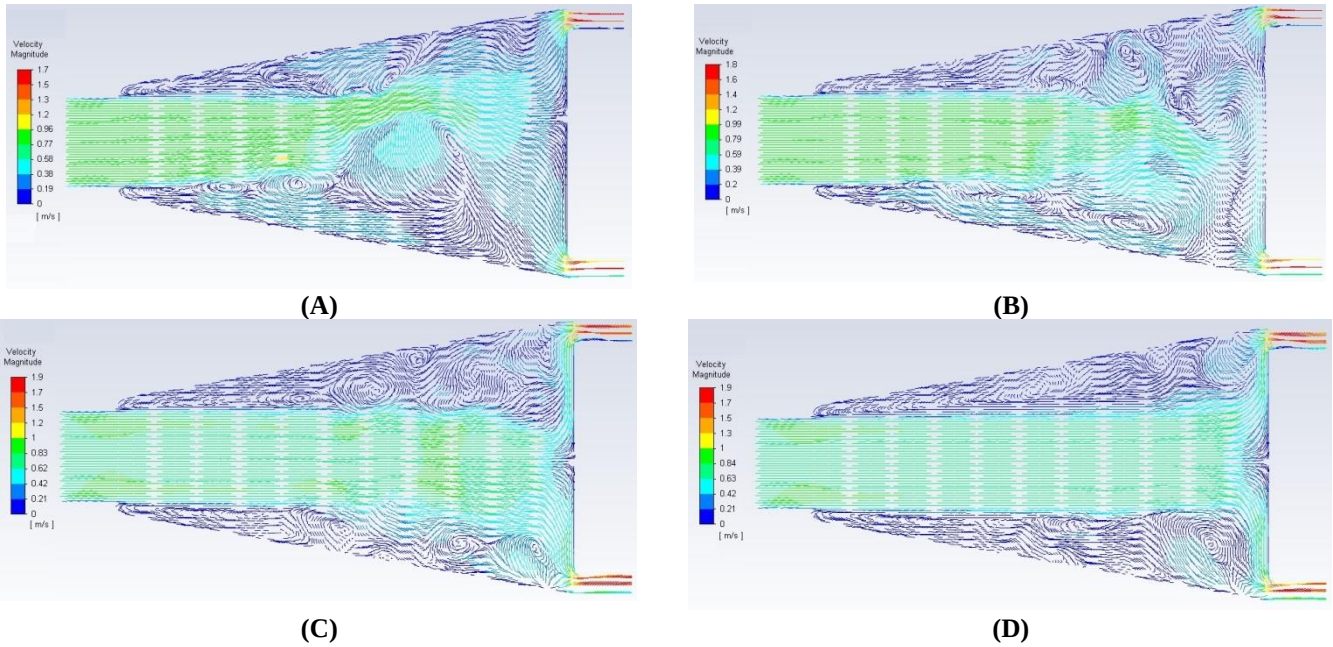

شکل ۱۶- نمودارهای خط مسیر سرعت هندسه مخروطی در زمان‌های (A)25 s، (B)50 s، (C)75 s و (D) شرایط پایداری نسبی برای CO_2

Fig. 16. Path line plots of the conical geometry at (A) 25 s, (B) 50 s, (C) 75 s, and (D) stability conditions for CO_2

ولی با افزایش زمان و ایجاد گردابه‌های بزرگ‌تر و برخورد آن‌ها با هم، سیال یکنواختی خود را از دست داده و با توزیع آن به طرفین، از حالت تعادل خارج می‌گردد. پس از این زمان، با کوچک‌تر شدن گردابه‌ها و حرکت به سمت سطوح جانبی، مجددا سیال به سمت همگرایی حرکت کرده و شرایط آن پایدارتر[1] شده‌است. لازم به ذکر است که عملکرد این هندسه در حالت تزریق هوا مناسب‌تر از CO_2 است. به‌گونه‌ای که جریان گردابه‌های سیال در زمان ۵۰ ثانیه نسبت به حالت تزریق هوا در همان زمان، بسیار متفاوت شده و این تغییر می‌تواند به‌واسطه تغییر در دانسیته سیال و به‌واسطه آن جرم سیال رخ دهد. همان‌طور که در شکل‌ها مشهود است، افزایش گردابه‌های بزرگ و تداخل آن‌ها در نزدیکی سطح حسگرها باعث ناپایداری در جریان سیال شده و مانع از همگرایی سیال در زمان کمتری شده‌است و در نتیجه آن، سیال در زمان بیشتری به حالت تقریبا تعادلی[2] رسیده است. هندسه هرمی در حالت تزریق CO_2 (شکل ۱۵) رفتاری متفاوت از تزریق هوا (شکل ۱۱) از خود نشان داده است. با افزایش زمان، سیال به سطح حسگر رسیده، ولی دارای حالت پایداری نیست. در نتیجه جهت رسیدن به حالت پایدار می‌بایست زمان شبیه‌سازی بسیار بالاتر از زمان مشخص شده باشد. اتفاقی که در این هندسه رخ داده است کمی متفاوت از هندسه استوانه‌ای است. در این هندسه، سیال در زمان ۲۵ ثانیه بسیار بهتر از هوا عمل کرده ولی با افزایش زمان و افزایش گردابه‌ها، ناپایداری بیشتری در سیال حادث شده و در نتیجه در زمان بسیار بیشتری به پایداری تقریبی رسیده است. در نتیجه می‌توان گفت که با افزایش گردابه‌های بزرگ، سرعت رسیدن سیال به سطح حسگرها افزایش یافته، اما تاثیر منفی در زمان پایداری آن ایجاد خواهد کرد و در نهایت با تشکیل گردابه‌های کوچک‌تر، سیال به پایداری بهتری خواهد رسید.

در هندسه مخروطی (شکل ۱۶)، آشفتگی جریان به‌وضوح قابل‌مشاهده است. حرکت جریان سیال به سمت دیواره‌ها و عدم یکنواختی جریان باعث شده است که سیال به سختی و در زمان ۷۵ ثانیه سطح حسگر را لمس کند و پس از آن و تا زمان زیادی بعد از ۷۵ ثانیه نیز به پایداری کامل نرسد. ولی می‌توان گفت که مشابه با حالت تزریق هوا، در زمان ۷۵ ثانیه سطح حسگر را به‌طور کامل پوشش داده‌است. عملکرد هندسه مخروطی در حالت تزریق CO_2، مشابه هرم است ولی از نظر زمان رسیدن سیال به سطح اندکی از آن بهتر است که این امر می‌تواند به علت وجود گردابه‌های بسیار اطراف آن بوده و همین امر نیز در رسیدن به پایداری نهایی نقش منفی ایجاد ایفا کرده است.

همانند حالت تزریق هوا در هندسه نیم‌کره، در حالت تزریق CO_2 (شکل ۱۷) نیز در این هندسه، سیال در زمان ۲۵ ثانیه با پایداری رسیده و قسمت خروجی را به‌طور کامل پوشش داده است. در این هندسه در زمان ۲۵ ثانیه سیال به شرایط تقریبا یکنواختی رسیده و سیال کاملا سطح حسگر را لمس می‌کند. نکته جالب‌توجه در تزریق

1- Stable
2- Stable state

CO_2 در این هندسه این است که با افزایش زمـان، قسـمت انتهـایی جریان اصلی در حال کاهش قطر بوده و این بـدان معنـی اسـت کـه گردابه‌های اطراف آن در حال رشد و همچنین فاصله گرفتن از جـداره بیرونی هستند.

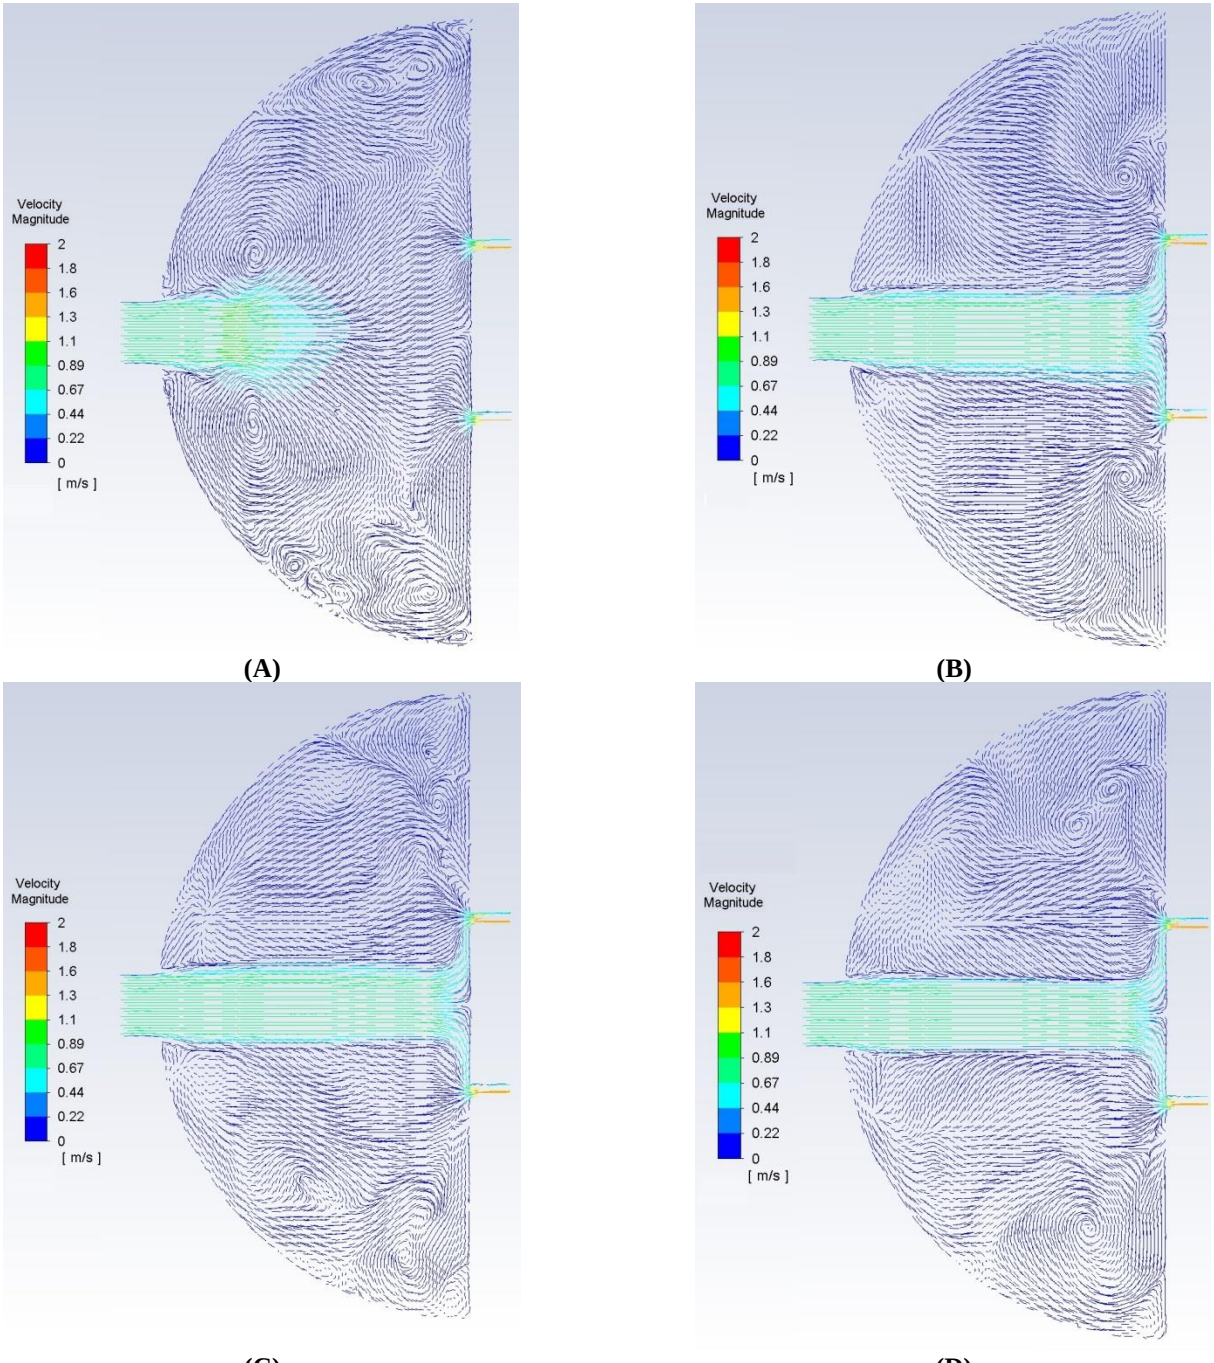

شکل ۱۷– نمودارهای خط مسیر سرعت هندسه نیم‌کره در زمان‌های 5 s(A)، 25 s(B)، 50 s(C) و (D) شرایط پایداری نسبی برای CO_2

Fig. 17. Path line plots of the hemispherical geometry at (A) 25 s, (B) 50 s, (C) 75 s, and (D) stability conditions for CO_2

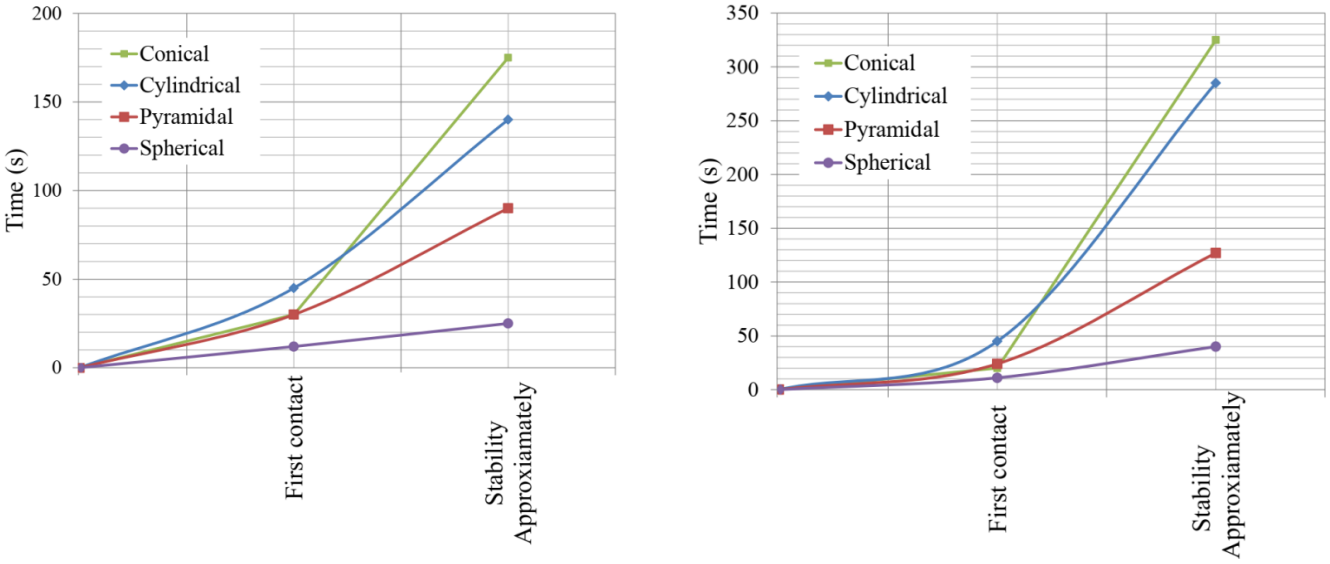

شکل ۱۸– نمودارهای زمان رسیدن سیال به سطح و زمان پایداری هندسه‌های شبیه‌سازی‌شده در دو حالت (A) هوا و (B) CO_2

Fig. 18. Plots of the first contact and stability times of the simulated geometries for (A) Air and (B) CO_2

جهت مقایسه عددی و بهتر هندسه‌ها، نمودارهایی که بیانگر زمان رسیدن سیال به سطح و زمان پایداری آن برای هندسه‌های شبیه‌سازی شده‌است در شکل ۱۸ برای هر دو سیال هوا (شکل A) و CO_2 (شکل B) به تصویر کشیده شده‌است. همان‌طور که مشاهده می‌شود، الگوی رفتاری هندسه‌ها برای هر دو حالت هوا و CO_2 به یک حالت بوده ولی مقادیر آن‌ها متفاوت است. در هندسه استوانه‌ای، زمان رسیدن سیال به سطح در هر دو حالت هوا و CO_2 تقریبا یکسان است ولی همان‌طور که پیشتر نیز بیان گردید، زمان رسیدن به پایداری برای حالت CO_2 بسیار بیشتر شده‌است. هر دو هندسه مخروطی و هرمی تقریبا در زمان مشابهی به سطح می‌رسند (هندسه مخروطی در حالت CO_2 اندکی زودتر به سطح می‌رسد) ولی زمان رسیدن به پایداری در هندسه هرمی در هر دو حالت بسیار بهتر از هندسه مخروطی است. اما هندسه نیم‌کره در هر دو حالت دارای زمان رسیدن به سطح و زمان پایداری بسیار بهتری نسبت به سایر هندسه‌هاست. لازم به ذکر است که هندسه نیم‌کره در حالت سیال هوا، دارای زمان پایداری بسیار بهتری نسبت به حالت CO_2 است.

نتیجه‌گیری

در مطالعه حاضر، چهار هندسه مختلف در دو حالت تزریق سیال هوا و دی‌اکسیدکربن (CO_2) جهت یافتن بهترین هندسه از نظر نوع عملکرد سیال، پوشش سطح حسگرها و همچنین زمان رسیدن سیال به پایداری مورد بررسی و مقایسه قرار گرفته‌اند. بررسی‌های صورت‌گرفته نشان داد که هندسه نیم‌کره بهترین عملکرد را در هر دو حالت تزریق هوا و CO_2 داراست. از دلایل این امر می‌توان به افزایش سطح مقطع هندسه، افزایش سرعت سیال میانی، یکنواختی سطح دیواره‌ها و همچنین توزیع گردابه ایجادشده در اطراف جریان اصلی سیال اشاره کرد. توزیع گردابه ایجادشده در اطراف جریان اصلی سیال در هندسه نیم‌کره به نحوی بوده که مقاومتی جهت تشکیل و حرکت سیال ایجاد نکرده و سیال به‌راحتی مسیر خود را پیموده و به ناحیه خروجی رسیده است. این بدان معنی‌است که با ایجاد سطح تماس بیشتر سیال و حسگر و هندسه متوازن می‌توان شاهد رفتار بهتری از سیال بود. پیدایش گردابه‌های کوچک در سطوح جانبی باعث همگرایی بهتر سیال می‌شود و با افزایش آن‌ها در نزدیکی سطح حسگرها، سرعت سیال روی سطح کمتر و در نتیجه این عمل باعث لمس بهتر سیال با سطح حسگرها شده و باعث چسبیدن بهتر سیال به آن شده‌است. اما تشکیل گردابه‌های بزرگ و نامتقارن باعث افزایش زمان پایداری جریان شده ولی به زمان رسیدن سیال به سطح کمک می‌کند. هندسه مخروطی نیز به علت داشتن هندسه ای همگن و نداشتن لبه‌های تیز، بعد از هندسه کروی، شرایط بهتری را نسبت به سایر هندسه‌ها در زمان رسیدن به سیال به سطح داراست.

پیشنهادات

با توجه به نیاز به انجام بررسی‌های بیشتر در زمینه شبیه‌سازی هندسه‌ها، فرایند شبیه‌سازی این هندسه‌ها با قراردادن مانع در نزدیکی سطح حسگرها که می‌تواند در جریان گردابه‌ها و همچنین توزیع سیال

تاثیرگذار باشد توصیه می‌گردد. همچنین تاثیر شبیه‌سازی برای جریان اغتشاشی و بررسی انواع حالات آن می‌تواند داده‌های مفیدی را ارائه دهد. با توجه به مشخص شدن عملکرد مناسب هندسه کروی، ساخت این هندسه و اعمال شرایط مرزی کنونی و مقایسه داده‌های تجربی و عددی با یکدیگر نیز می‌تواند نتایج بسیار خوبی جهت ارزیابی فرایندهای شبیه‌سازی ارائه نماید.

تعارض منافع

هیچ‌گونه تعارض منافعی توسط نویسندگان بیان نشده است.

مشارکت نویسندگان

عارفه الطافی: مفهوم‌سازی، روش‌شناسی، جمع‌آوری داده‌ها، پردازش داده‌ها، شبیه‌سازی عددی، اعتبارسنجی، تصویرسازی نتایج، استخراج و تهیه متن اولیه، ویرایش متن

سید سعید محتسبی: مفهوم‌سازی، مشاوره فنی، نظارت و مدیریت، ویرایش متن

علی جعفری: مشاوره فنی، نظارت و مدیریت، ویرایش متن

مهدی قاسمی ورنامخواستی: مشاوره فنی، نظارت و مدیریت، ویرایش متن

References

1. Annanouch, F. E., Bouchet, G., Perrier, P., Morati, N., Reynard-Carette, C., Aguir, K., & Bendahan, M. (2018). *How the chamber design can affect gas sensor responses*. Proceedings of the West Mark Ed Association Conference, Eurosensors 2018 Conference, Graz, Austria. https://doi.org/10.3390/proceedings2130820
2. Annanouch, F. E., Bouchet, G., Perrier, P., Morati, N., Reynard-Carette, C., Aguir, K., Martini-Laithier, V., & Bendahan, M. (2019). Hydrodynamic evaluation of gas testing chamber: Simulation, experiment. *Sensors and Actuators B: Chemical, 290*, 598-606. https://doi.org/10.1016/j.snb.2019.04.023
3. Cai, J., Ding, W., & Wang, M. (2025). Design of test-chamber shape for portable electronic nose. *Journal of Physics: Conference Series, 2939*, 012028. https://doi.org/10.1088/1742-6596/2939/1/012028
4. Chang, Z., Sun, Y., Zhang, Y., Gao, Y., Weng, X., Chen, D., David, L., & Xie, J. (2018). Bionic optimization design of electronic nose chamber for oil and gas detection. *Journal of Bionic Engineering, 15(3)*, 533-544. https://doi.org/10.1007/s42235-018-0044-6
5. Chai, H., Zheng, Z., Liu, K., Xu, J., Wu, K., Luo, Y., Liao, H., Debliquy, M., & Zhang, C. (2022). Stability of metal oxide semiconductor gas sensors: A review. *IEEE Sensors Journal, 22*(6), 5470-5481. https://doi.org/10.1109/JSEN.2022.3148264
6. Cheng, L., Liu, Y. B., & Meng, Q. H. (2020). *A novel E-nose chamber design for VOCs detection in automobiles.* In Proceedings of the 39th Chinese Control Conference (CCC), Shenyang, China. https://doi.org/10.23919/CCC50068.2020.9189213
7. Chowdhury, S., Kumar, D., Kumar, R., Karar, V., & Bhondekar, A. (2016). *Simple sensor chamber design for hand-held electronic nose*. Conference: Modern Information and communication technologies for digital India, India.
8. Covington, J. A., Marco, S., Persaud, K. C., Schiffman, S. S., & Nagle, H. T. (2021). Artificial olfaction in the 21st century. *IEEE Sensors Journal, 21(11)*, 12969-12990. https://doi.org/10.1109/JSEN.2021.3076412
9. Dey, A. (2018). Semiconductor metal oxide gas sensors: A review. *Materials Science and Engineering: B, 229*, 206-217. https://doi.org/10.1016/j.mseb.2017.12.036
10. Dohare, P., Bagchi, S., & Bhondekar, A. P. (2020). Performance optimisation of a sensing chamber using fluid dynamics simulation for electronic nose applications. *Turkish Journal of Electrical Engineering & Computer Sciences, 28*, 3068-3078. https://doi.org/10.3906/elk-1903-103
11. Dragonieri, S., Pennazza, G., Carratu, P., & Resta, O. (2017). Electronic nose technology in respiratory diseases. *Lung, 195*(2), 157-165. https://doi.org/10.1007/s00408-017-9987-3
12. Fonollosa, J., Fernández, L., Gutiérrez-Gálvez, A., Huerta, R., & Marco, S. (2016). Calibration transfer and drift counteraction in chemical sensor arrays using direct standardization. *Sensors and Actuators B: Chemical, 236*, 1044-1053. https://doi.org/10.1016/j.snb.2016.05.089
13. Harmouzi, M., Amari, A., & Masmoudi, L. (2023). Conception and simulation of an electronic nose prototype for olfactory acquisition. *Advances in Science, Technology and Engineering Systems Journal, 8(1)*, 101-107. https://doi.org/10.25046/aj080112
14. Hui, G., Jin, J., Deng, S., Ye, X., Zhao, M., Wang, M., & Ye, D. (2015). Winter jujube (*Zizyphus jujube* Mill.) quality forecasting method based on electronic nose. *Food Chemistry, 170*, 484-491. https://doi.org/10.1016/j.foodchem.2014.08.009
15. Hunter, G. W., Akbar, S., Bhansali, S., Daniele, M., Erb, P. D., Johnson, K., Liu, C. C., Miller, D., Oralkan, O., & Hesketh, P. J. (2020). Editors' choice—Critical review—A critical review of solid state gas sensors. *Journal of The Electrochemical Society, 167*(3), 037570. https://doi.org/10.1149/1945-7111/ab729c
16. Karimzadeh, R., & Assar, M. (2016). Effect of laser irradiation on CO gas detecting response of reduced graphene

oxide sensor. *RSC Advances*, *6*(58), 52817-52825. https://doi.org/10.1039/C6RA04618E
17. Korotcenkov, G., & Cho, B. K. (2011). Instability of metal oxide-based conductometric gas sensors and approaches to stability improvement (short survey). *Sensors and Actuators B: Chemical*, *156*(2), 527-538. https://doi.org/10.1016/j.snb.2011.02.024
18. Kumar, J., Singh, H., Raj, V., Nimal, A., Gupta, V., & Singh, V. (2020). Trace detection of nerve agent simulant in the fuel vapour environment using metal oxide surface acoustic wave E-nose. *Defence Science Journal*, *70*(5), 520-528. https://doi.org/10.14429/dsj.70.14584
19. Laref, R., Ahmadou, D., Losson, E., & Siadat, M. (2017). Orthogonal signal correction to improve stability regression model in gas sensor systems. *Journal of Sensors*, *2017*(1), 9851406. https://doi.org/10.1155/2017/9851406
20. Lezzi, A. M., Beretta, G. P., Comini, E., Faglia, G., Galli, G., & Sberveglieri, G. (2001). Influence of gaseous species transport on the response of solid state gas sensors within enclosures. *Sensors and Actuators B: Chemical*, *78*(1), 144-150. https://doi.org/10.1016/S0925-4005(01)00805-X
21. Liu, X., Ma, T., Pinna, N., & Zhang, J. (2017). Two-dimensional nanostructured materials for gas sensing. *Advanced Functional Materials*, *27*(37), 1702168. https://doi.org/10.1002/adfm.201702168
22. Lopez, L., Copa, V., Hayasaka, T., Faustino-Lopez, M.A., Wu, Y., Liu, H., Liu, Y., Estacio, E., Somintac, A., & Lin, L. (2020). Influence of chamber design on the gas sensing performance of graphene field-effect-transistor. *SN Applied Sciences*, *2*(7), 1-11. https://doi.org/10.1007/s42452-020-2676-5
23. Nikoutadbir, A., Tarmian, A., Mohtasebi, S. S., Mohtasebi, S. M., & Oladi, R. (2024). The utilization of an olfactory machine in wood identification demonstrates a promising prospect: discerning disparities in emission profiles of volatile organic compounds between Picea abies and Pinus sylvestris. *European Journal of Wood and Wood Products*, *82*(3), 591-596. https://doi.org/10.1007/s00107-024-02053-7
24. Oliveros, M. C. C., Pavon, J. L. P., Pinto, C. G., Laespada, M. E. F., Cordero, B. M., & Forina, M. (2002). Electronic nose based on metal oxide semiconductor sensors as a fast alternative for the detection of adulteration of virgin olive oils. *Analytica Chimica Acta*, *459*, 219-228. https://doi.org/10.1016/s0003-2670(02)00119-8
25. Pearce, T. C., Schiffman, S. S., Nagle, H. T., & Gardner, J. W. (2006). *Handbook of Machine Olfaction: Electronic Nose Technology*. John Wiley & Sons. https://doi.org/10.1002/3527601597
26. Rezaee, Z., Mohtasebi, S. S., & Firouz, M. S. (2024a). Monitoring pistachio health using data fusion of machine vision and electronic nose (E-nose). *Journal of Food Measurement and Characterization*, *19*, 1851-1858. https://doi.org/10.1007/s11694-024-03078-5
27. Rezaee, Z., Mohtasebi, S. S., & Firouz, M. S. (2024b). An electronic nose system supported by machine learning techniques for rapid detection of Aspergillus flavus in pistachio. *Journal of Food Measurement and Characterization*, *18*(7), 5757-5765. https://doi.org/10.1007/s11694-024-02606-7
28. Robbiani, S., Lotesoriere, B. J., Dellacà, R. L., & Capelli, L. (2023). Physical confounding factors affecting gas sensors response: A review on effects and compensation strategies for electronic nose applications. *Chemosensors*, *11*(10), 514. https://doi.org/10.3390/chemosensors11100514
29. Samiyan, N. S., & Addi, M. M. (2017). Characterization of sensing chamber design for E-nose applications. Journal of Telecommunication, *Electronic and Computer Engineering*, *9*(3-9), 123-127. https://jtec.utem.edu.my/jtec/article/view/3136
30. Scott, S. M., James, D., Ali, Z., & O'Hare, W. T. (2004). Optimising of the sensing chamber of an array of a volatile detection system: Fluid dynamic simulation. *Journal of Thermal Analysis and Calorimetry*, *76*, 693-708. https://doi.org/10.1023/b:jtan.0000034891.68585.4a
31. Sedlák, P., & Kuberský, P. (2020). The effect of the orientation towards analyte flow on electrochemical sensor performance and current fluctuations. *Sensors*, *20*(4), 1038-1054. https://doi.org/10.3390/s20041038
32. Shyla, M. V., Naidu, K. B., & Kumar, G. V. (2013). *Optimization of sensor position on different surfaces using CFD analysis for reducing accidents caused by emission of toxic gas in industries*. In Proceedings of the Fifth International Conference on Advanced Computing (ICoAC). https://doi.org/10.1109/ICoAC.2013.6921950
33. Xue, L., Yamazaki, H., Ren, R., Wanunu, M., Ivanov, A. P., & Edel, J. B. (2020). Solid-state nanopore sensors. *Nature Reviews Materials*, *5*(12), 931-951. https://doi.org/10.1038/s41578-020-0229-6
34. Yuan, Z., Benck, J. D., Eatmon, Y., Blankschtein, D., & Strano, M. S. (2018). Stable, temperature-dependent gas mixture permeation and separation through suspended nanoporous single-layer graphene membranes. *Nano Letters*, *18*(8), 5057-5069. https://doi.org/10.1021/acs.nanolett.8b01866
35. Zhang, W., Pan, L., Zhao, X., & Tu, K. (2016). A study on soluble solids content assessment using electronic nose: Persimmon fruit picked on different dates. *International Journal of Food Properties*, *19*(1), 53-62. https://doi.org/10.1080/10942912.2014.940535
36. Zhao, K., Dalton, P., Yang, G. C., & Scherer, P. W. (2006). Numerical modeling of turbulent andlaminar airflow and odorant transport during sniffing in the human and rat nose. *Methods*, *31*, 107-118. https://doi.org/10.1093/chemse/bjj008

Journal of Agricultural Machinery

Homepage: https://jame.um.ac.ir

Research Article
Vol. 16, No. 4, 2026, p. 751-767

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

M. Afsharipour[1], M. Shamsi[1*], F. Ghasemian[2], H. Khabazzadeh[3]

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)

Received: 09 February 2026
Revised: 12 March 2026
Accepted: 13 April 2026
Available Online: 30 May 2026

How to cite this article:
Afsharipour, M., Shamsi, M., Ghasemian, F., & Khabazzadeh, H. (2026). An Integrated Mechatronic Sorting System for Bitter and Sweet Almonds Based on FTIR Spectroscopy of Shells and MLP Neural Network. *Journal of Agricultural Machinery*, *16*(4), 751-767. [in Persian]. 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-

Authors retain the copyright. This is an open access article distributed under Creative Commons Attribution 4.0 International License (CC BY 4.0).

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

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

نشریه ماشین‌های کشاورزی
https://jame.um.ac.ir

مقاله پژوهشی
جلد ۱۶، شماره ٤، زمستان ۱٤۰۵، ص ۷۶۷-۷۵۱

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

مجتبی افشاری‌پور[۱]، محسن شمسی[۱*]، فهیمه قاسمیان[۲]، حجت الله خبازاده[۳]

تاریخ دریافت: ۱۴۰۴/۱۱/۲۰
تاریخ پذیرش: ۱۴۰۵/۰۱/۲۴

چکیده

تشخیص بادام تلخ به‌دلیل محتوای آمیگدالین و خطر آزادسازی سیانید، یکی از چالش‌های ایمنی غذایی است. در حالی‌که 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 به‌دست آورد. تحلیل ویژگی‌ها، سه باند طیفی کلیدی $1030\ cm^{-1}$، $1740\ cm^{-1}$ و $2920\ cm^{-1}$ را به‌عنوان 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 به‌عنوان یک رویکرد غیرمخرب و عملی برای جداسازی بادام در مقیاس صنعتی به‌کار رود.

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

مقدمه

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*) به‌عنوان یکی از ارزشمندترین خشکبارهای جهان با تولید سالانه بیش از ۱/۳ میلیون تن، نمونه بارزی از این چالش است. چرا که هم‌زمان دو واریته 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 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 قابل‌توجهی در پروتکل‌های ایمنی غذایی و صنعتی ایجاد می‌کنند، جایی‌که 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

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
(*- نویسنده مسئول: Email: shamsi@uk.ac.ir)
https://doi.org/10.22067/jam.2026.97689.1470

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

موفقیت‌هایی در برچسب‌گذاری مواد و محصولات کشاورزی و طبیعی مانند 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 حالی‌که 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 به‌کار 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 دسته‌بندهایی مقاوم و قابل‌تفسیر برای داده‌های طیفی پیچیده شناخته شده‌اند (Breiman, 2001; Ganaie, Tanveer, Suganthan, & Snasel, 2022).

کاربرد یادگیری ماشین و سامانه‌های مکاترونیکی در جداسازی خودکار محصولات کشاورزی طی سال‌های اخیر توسعه چشمگیری داشته است (Hou *et al.*, 2024). تلفیق سامانه‌های مکاترونیکی با الگوریتم‌های هوشمند نه تنها در جداسازی محصولات، بلکه در فرایند برداشت نیز کارایی قابل‌توجهی 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 (Gökalp & Mübarek Mazhar, 2024; Rahimzadeh & Attar, 2020). همچنین، پژوهش‌های مبتنی بر NIR در حبوبات 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 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 فنولیک است را با سامانه مکاترونیکی برای جداسازی خودکار ترکیب نکرده است. این خلأ پژوهشی، ضرورت توسعه سامانه یکپارچه FTIR–یادگیری ماشین–مکاترونیک 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 مکاترونیکی 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 ۰/۵ محاسبه شد (رابطه ۱ و ۲) اندازه برآوردشده 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)، مجموعه‌داده نهایی به ۲۰۰ نمونه افزایش یافت که شامل ۱۰۰ نمونه بادام تلخ و ۱۰۰ نمونه بادام شیرین جمع‌آوری‌شده از باغ‌های کرمان در میان ارقام مختلف تلخ و شیرین بود.

$$n = \frac{Z^2.p.(1-p)}{E^2} \xrightarrow{Z=1.96,E=0.092,p=0.5} n\approx 113.5 \quad (۱)$$

$$\acute{n} = \frac{n}{\frac{n-1}{N}+1} \xrightarrow{n=113.5,N=630} \acute{n}\approx 100.07 \quad (۲)$$

1- Machine Learning
2- Deep Learning

برچسب‌گذاری نمونه‌ها

برچسب‌گذاری اولیه نمونه‌ها بر اساس ویژگی واریته و تأیید حسی تلخی- شیرینی توسط سه ارزیاب آموزش‌دیده 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. به‌منظور کاهش خطرات ناشی از مزه‌کردن بادام تلخ (به‌دلیل محتوای بالای آمیگدالین)، پروتکل‌های ایمنی سختگیرانه شامل محدودسازی تماس با نمونه و شست‌وشوی فوری پس از مزه‌کردن اجرا گردید (Lawless & Heymann, 1999; ISO 13301, 2002). تنها نمونه‌هایی که طبقه‌بندی آن‌ها به‌طور کامل مورد توافق سه ارزیاب قرار گرفت، حفظ شدند تا احتمال خطای برچسب‌گذاری به حداقل برسد. این مطالعه شامل هیچ‌گونه آزمون مصرف انسانی یا حیوانی نبوده و صرفاً به تشخیص کیفی محدود است.

ثبت طیف‌های FTIR

پوسته بادام‌ها به‌صورت دستی از مغز جدا شد. رطوبت باقیمانده با خشک‌کردن در خلأ در دمای ۳۰ درجه سانتی‌گراد و فشار ۰/۸ میلی‌بار به‌مدت ۲۴ ساعت مطابق با مطالعه مکرون حذف گردید (Mekonnen, 2023). سپس پوسته‌های خشک‌شده با استفاده از آسیاب به پودر تبدیل شدند تا جذب یکنواخت پرتو فروسرخ تضمین شود. برای آماده‌سازی قرص‌های FTIR، ۱ تا ۲ میلی‌گرم پودر پوسته با ۱۰۰ میلی‌گرم KBr در هاون مخلوط شد. قرص‌هایی با قطر ۱/۲ سانتی‌متر تحت فشار یکنواخت ۱۰۰۰۰ psi با پرس هیدرولیک فشرده شدند تا نمونه‌هایی شفاف و عاری از رطوبت به‌دست آید.

طیف‌ها با استفاده از طیف‌سنج FTIR مدل (TENSOR 27 FT-IR spectrometer) در محدوده ۴۰۰۰–۴۰۰cm^{-1} با وضوح ۴cm^{-1} و ۳۲ اسکن تجمیعی برای هر نمونه ثبت شدند. هر طیف شامل ۳۷۳۳ نقطه عدد موجی بود و هم به‌صورت داده خام اکسل و هم نمودار طیفی ذخیره گردید. به‌منظور اطمینان از قابلیت بازتولید، برای هر نمونه سه تکرار ثبت شد و میانگین طیف‌ها در تحلیل‌های بعدی استفاده گردید.

پیش‌پردازش طیف‌ها

طیف‌های خام برای افزایش وضوح و کاهش اثرات فیزیکی ناخواسته، پیش‌پردازش شدند. در این مرحله از روش‌های ساویتسکی–گولای[1] شامل مشتق مرتبه اول با پنجره ۱۵ (SG1) و مشتق مرتبه دوم با پنجره ۲۵ (SG2)، به‌همراه نرمال‌سازی واریانس استاندارد (SNV)[2] و اصلاح پراکندگی چندگانه (MSC)[3] بر اساس روش گزارش‌شده توسط نایس و همکاران (Naes, Isaksson, Fearn, & Davies, 2002) استفاده شد. تمامی مراحل پیش‌پردازش با زبان Python و کتابخانه‌های scikit-learn (v1.3.0)، NumPy (v1.25) و SciPy (v1.11) انجام گرفت. تحلیل‌ها بر روی بازه ۴۰۰۰–۴۰۰cm^{-1} متمرکز شدند. این محدوده شامل باندهای تشخیصی مرتبط با ترکیبات فنولیک، لیپیدی و کربوهیدراتی است (Lin *et al.*, 2025). برای بررسی ساختار داده‌ها نیز از تحلیل مؤلفه‌های اصلی (PCA)[4] استفاده شد.

مدل‌های یادگیری

چهار الگوریتم یادگیری نظارت‌شده شامل سه الگوریتم یادگیری ماشین و یک الگوریتم یادگیری عمیق برای طبقه‌بندی پیاده‌سازی شد. ماشین بردار پشتیبان (SVM)[5] با کرنل خطی به‌عنوان مدل پایه برای الگوهای خطی انتخاب شد (Zhang *et al.*, 2025). جنگل تصادفی (RF)[6] با ۱۰۰ درخت تصمیم برای داده‌های غیرخطی و به‌منظور افزایش مقاومت در برابر بیش‌برازش توسعه یافت (Breiman, 2001). همچنین، یک شبکه عصبی پرسپترون چندلایه[7](MLP) با دو لایه پنهان شامل ۶۴ و ۱۲۸ نورون و توابع فعال‌سازی ReLU طراحی شد (Goodfellow *et al.*, 2016). در نهایت، یک معماری ترکیبی خودرمزگذار[8]- MLP طراحی شد که شامل رمزگذار با [۱۰۲۴–۲۵۶–۶۴] نورون و رمزگشای متقارن بود. بر این اساس، تابع فعال‌سازی ReLU به‌منظور 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 مدل‌ها، آزمون McNemar بر روی پیش‌بینی‌های جفت‌شده مدل MLP و بهترین مدل رقیب انجام شد (Sluijterman, Cator, & Heskes, 2025). این آزمون برای داده‌های طبقه‌بندی دودویی مناسب بوده و اختلاف عملکرد را مستقل از توزیع داده‌ها ارزیابی می‌کند. سطح معناداری آماری برابر با $p<0.05$ در نظر گرفته شد. علاوه‌براین، 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.

1- Savitsky–Gulay

2- Standard Normal Variate
3- Multiplicative Scatter Correction
4- Principal Component Analysis
5- Support Vector Machine
6- Random Forest
7- Multi Layer Perceptron
8- Autoencoder

جدول ۱- پارامترهای مدل‌های یادگیری ماشین و یادگیری عمیق

Table 1- Parameters of Machine Learning and Deep Learning Models

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

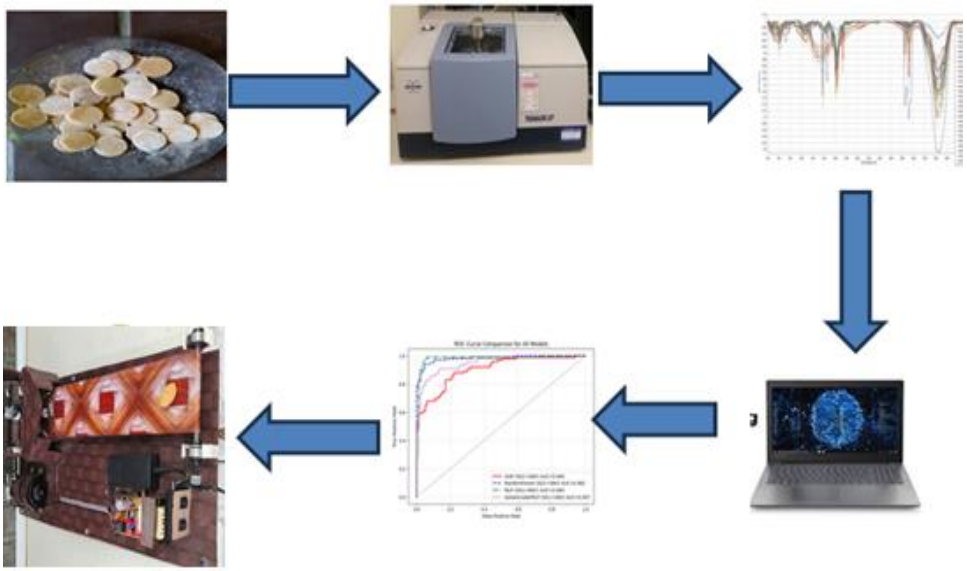

شکل ۱- گردش‌کار سامانه پیشنهادی FTIR- یادگیری ماشین- مکاترونیک برای شناسایی غیرمخرب و جداسازی بادام تلخ و شیرین بر اساس طیف پوسته

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

ارزیابی مدل‌ها و تحلیل آماری

عملکرد مدل‌ها با معیارهای صحت [1]، دقت [2]، یادآوری[3]، امتیاز F1[4] و ROC-AUC[5] ارزیابی شد. تقسیم‌بندی آموزش- آزمون به‌صورت طبقه‌بندی‌شده با نسبت ۷۰- ۳۰ انجام شد. برای تنظیم ابرپارامترها، از اعتبارسنجی متقابل پنج‌تایی استفاده شد. به‌منظور دستیابی به بینش‌های مکانیکی، تحلیل اهمیت متغیرها در جنگل تصادفی با استفاده از روش جابه‌جایی Permutation Importance اجرا شد تا باندهای عدد موجی متمایز مرتبط با ترکیبات فنولیک و لیپیدی شناسایی گردد و نشانگرهای بیوشیمیایی قابل‌تفسیر 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.

طراحی و پیاده‌سازی سامانه‌ی جداساز مکاترونیکی

به‌منظور تبدیل خروجی الگوریتم به یک کنش قابل‌مشاهده در محیط واقعی، یک سامانه‌ی جداساز مکاترونیکی 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 فلزی مقاوم طراحی شد که امکان نصب نوار انتقال‌دهنده و عملگر 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 عملگر، نمونه به مسیر جانبی هدایت می‌شود. طراحی هندسه‌ی انحراف‌گر، زاویه‌ی حرکت و جنس قطعات به‌گونه‌ای انتخاب شده است که از تأخیرهای ناخواسته و گیر مکانیکی جلوگیری شود (شکل ۳).

مطابق با شکل ۴ یک برد کنترلی، وظیفه‌ی پردازش سیگنال دیجیتالی و اعمال فرمان به بخش مکانیکی را بر عهده دارد. در این برد، یک میکروکنترلر ۸ بیتی برای دریافت خروجی طبقه‌بندی و تولید فرمان کنترلی مورد استفاده قرار گرفت.

1- Accuracy
2- Precision
3- Recall
4- F1-score
5- Receiver Operating Characteristic- Area Under the Curve

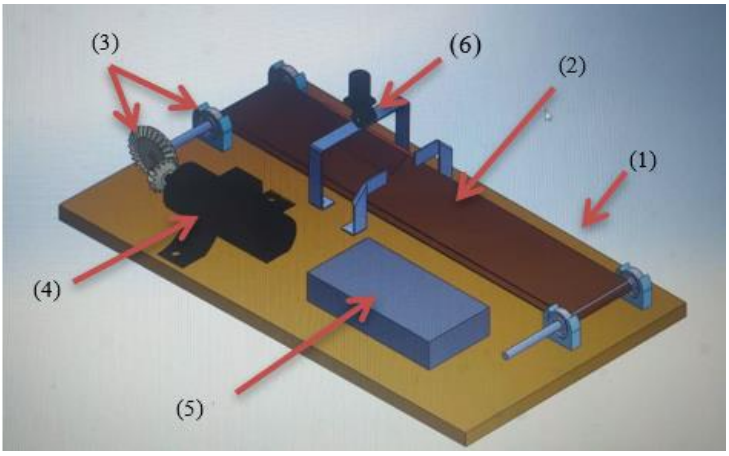

شکل ۲– مدل سه‌بعدی سامانه جداساز مکاترونیکی بادام در مقیاس آزمایشگاهی، طراحی‌شده در نرم‌افزار SolidWorks 2022، شامل (۱) شاسی اصلی، (۲) سیستم تغذیه، (۳) سیستم انتقال توان، (۴) الکتروموتور، (۵) سیستم الکترونی متصل به خروجی FTIR و (۶) مجموعه هدایت‌کننده

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



شکل ٤– 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

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 مسئول 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 صورتی‌که 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

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 خودرمزگذار MLP به دقت ۸۷/۵٪ و AUC برابر ۰/۹۴۵ دست یافت و اثربخشی استخراج ویژگی‌های نهفته را علی‌رغم فشرده‌سازی 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 ۰/۰۲ ± ۰/۹۵۵، Precision برابر با ۰/۰۳ ± ۰/۹۲۵، Recall برابر با ۰/۰۱ ± ۰/۹۹۰، F1-score برابر با ۰/۰۲ ± ۰/۹۵۷ و AUC برابر با ۰/۰۱ ± ۰/۹۸۴. 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 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 مک نمار 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	–

بینش 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 تمایز آن‌ها نشان داده شده است: باند $۱۰۳۰cm^{-1}$ مرتبط با کشش C–O در ترکیبات فنولیک، باند $۱۷۴۰cm^{-1}$ مربوط به کشش C=O در گروه‌های کربونیل، و باند $۲۹۴۰cm^{-1}$ وابسته به کشش C–H در 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 (Taş & Gökmen, 2017). در حالی‌که 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.

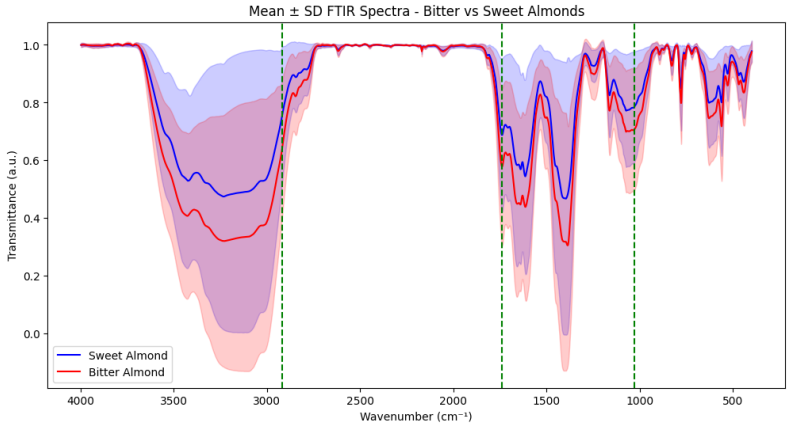

شکل ۵– طیف‌های FTIR همپوشانی‌شده پوسته بادام با برجسته‌سازی باندهای طیفی متمایز مرتبط با ترکیبات فنولیک، کربونیل و لیپیدی

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

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 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.

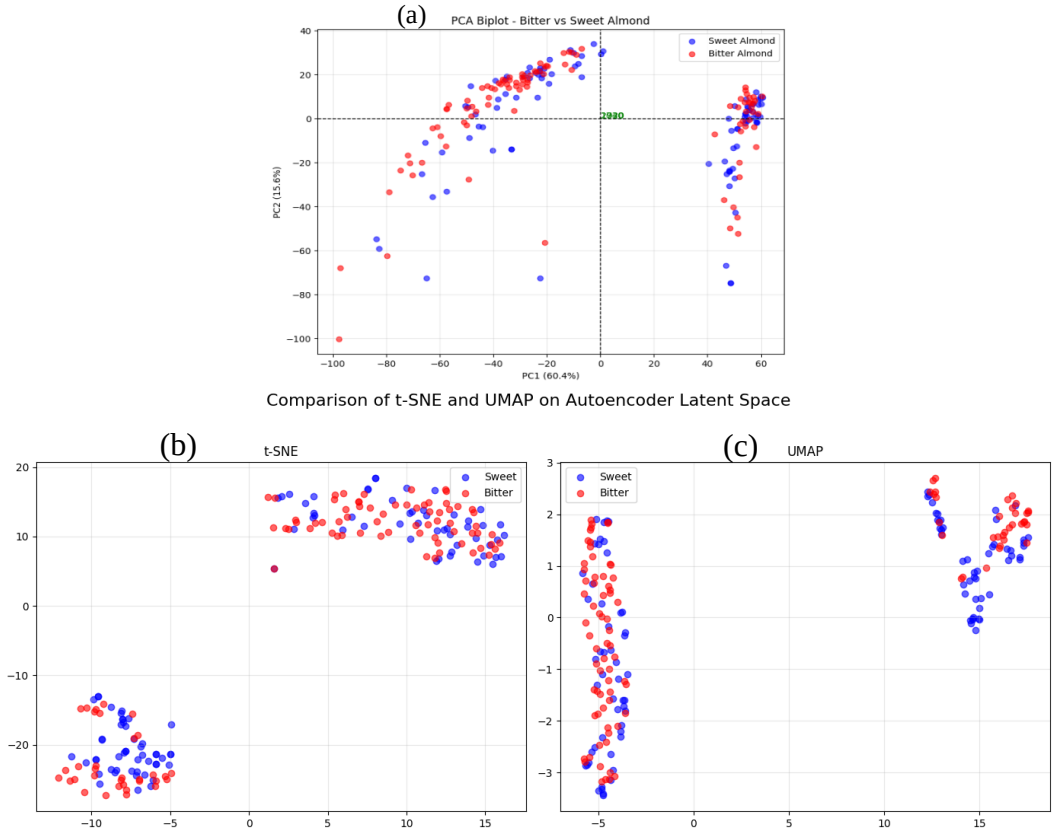

شکل ٦– تجسم داده‌های طیفی با روش‌های کاهش بُعد: (a) نمودار امتیاز PCA، (b) تصویرسازی فضای نهفته با t-SNE و (c) تصویرسازی فضای نهفته با UMAP

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

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 عملگر، نوار انتقال و واحد کنترل تحت نظارت قرار گرفت. دستگاه در تمامی چرخه‌ها وضعیت حرکتی ثابت، تکرارپذیر و هماهنگ با سیگنال دیجیتالی را نشان داد. هیچ‌گونه ناهماهنگی بین فرمان دیجیتال و حرکت فیزیکی گزارش نشد و عملگر 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 عملگر 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 چیدمان نامنظم بادام‌ها 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 مکاترونیکی 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 قابل‌قبول 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 مکاترونیکی در طی حدود ۴ ساعت بهره‌برداری پیوسته، عملکردی یکنواخت، تکرارپذیر و قابل‌اعتماد 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 بازمی‌گشت که نشان‌دهنده طراحی مناسب چرخه کنترلی و پایداری مکانیکی سیستم است.

خطاهای محدود ثبت‌شده عمدتاً به عوامل عملیاتی نظیر چیدمان 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 مکاترونیکی 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 پوسته چندین 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.

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 از ماتریس‌های غذایی (از عسل و روغن‌های خوراکی تا گیاهان دارویی) به دقت‌های بالا (۱۰۰٪–۸۷٪) 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.

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 *et al.* (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 *et al.* (2024)
یادگیری ماشین و عمیق با داده‌های کم نیز مؤثر بودند. ML and DL were effective even with small datasets.	–	100	FTIR + ML / DL	*Boletus tomentipes*	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 *et al.* (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 *et al.* (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)

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

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 حالی‌که 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 کاربردپذیری عملی روش را نیز ارتقا می‌بخشد. بدین ترتیب، چارچوب پیشنهادی می‌تواند به‌عنوان یک ابزار سریع، پایدار و مقرون‌به‌صرفه برای ارزیابی کیفیت و اصالت 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. 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 قابل‌قبول نشان داد. این پایداری را می‌توان به ساختار مبتنی بر تجمیع 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.

یکپارچه‌سازی داده‌های طیفی با سامانه مکانیکی جداسازی، نشان‌دهنده امکان انتقال موفق تصمیم الگوریتمی 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 $۱۰۳۰\ cm^{-1}$، $۱۷۴۰cm^{-1}$ و $۲۹۲۰cm^{-1}$ 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 قابل‌حمل و سامانه‌های یادگیری ماشین و عمیق، این جریان کاری قابلیت انتقال به محیط‌های صنعتی را دارد و ایمنی مصرف‌کننده را تضمین می‌کند در حالی‌که زیان‌های اقتصادی ناشی از خطای طبقه‌بندی را به حداقل می‌رساند و رویکردی مقیاس‌پذیر و مقرون‌به‌صرفه برای کنترل کیفیت بادام 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 به‌دلیل در اختیار گذاشتن تجهیزات FTIR و پشتیبانی فنی در فرآیند ثبت و تحلیل طیف‌ها قدردانی می‌نمایند.

تعارض منافع

هیچ‌گونه تعارض منافعی توسط نویسندگان بیان نشده است.

مشارکت نویسندگان

مجتبی افشاری‌پور: 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

حجت الله خباززاده: نظارت و مدیریت، مفهوم‌سازی، روش‌شناسی، مشاوره فنی، جمع‌آوری داده‌ها، پردازش داده‌ها، ویرایش متن

References

1. 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
2. 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/10.1002/ccr3.8418
3. 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
4. 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
5. 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/10.26434/chemrxiv-2025-f76xt
6. 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
7. Breiman, L. (2001). Random Forests. *Machine Learning*, *45*(1), 5-32. https://doi.org/10.1023/a:1010933404324
8. 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. Ganaie, M. A., Tanveer, M., Suganthan, P. N., & Snasel, V. (2022). Oblique and rotation double random forest. *Neural Networks, 153*, 496-517. https://doi.org/10.1016/j.neunet.2022.06.012
18. 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
19. Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
20. 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
21. 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
22. 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). Retrieved from: https://www.iso.org/standard/36791.html
23. 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
24. 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
25. 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
26. LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature, 521*(7553), 436-444. https://doi.org/10.1038/nature14539
27. 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
28. 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
29. 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
30. Naes, T., Isaksson, T., Fearn, T., & Davies, T. (2002). *A user-friendly guide to multivariate calibration and classification*. NIR Publications.
31. 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
32. 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
33. 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
34. Rahimzadeh, M., & Attar, A. (2020). Detecting and Counting Pistachios based on Deep Learning. arXiv. https://doi.org/10.48550/ARXIV.2005.03990
35. 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
36. 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
37. 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
38. 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
39. 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
40. 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
41. 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
42. 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
43. 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
44. 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
45. 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
46. Unuvar, A., Boyaci, I. H., & Koksel, 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
47. 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
48. 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
49. 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
50. 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
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

Journal of Agricultural Machinery

Homepage: https://jame.um.ac.ir

Research Article
Vol. 16, No. 4, 2026, p. 769-780

Improving Anaerobic Fermentation of Agricultural Wastes Using Ultrasonic Pretreatment to Increase Biohydrogen Production: Study of the Metabolic Pathway of Reactions

M. Mahmoodi-Eshkaftaki[1], A. Lotfalian-Dehkordi[2], H. Khafajeh[1*], S. H. Bahram Shabahrami[1]

1- Department of Mechanical Engineering of Biosystems, Jahrom University, Jahrom, Fars, Iran
2- Department of Mechanical Engineering of Biosystems, Shahrekord University, Shahrekord, Iran
(*- Corresponding Author Email: khafajeh@jahromu.ac.ir)

Received: 07 March 2026
Revised: 12 June 2026
Accepted: 29 June 2026
Available Online: 22 July 2026

How to cite this article:
Mahmoodi-Eshkaftaki, M., Lotfalian-Dehkordi, A., Khafajeh, H., & Bahram Shabahrami, S. H. (2026). Improving Anaerobic Fermentation of Agricultural Wastes Using Ultrasonic Pretreatment to Increase Biohydrogen Production: Study of the Metabolic Pathway of Reactions. *Journal of Agricultural Machinery*, *16*(4), 769-780. [in Persian]. https://doi.org/10.22067/jam.2026.98121.1477

Introduction

The increasing demand for sustainable and renewable energy sources has intensified research on bioenergy production from agricultural wastes. Anaerobic digestion is a widely applied biological process for converting organic residues into valuable gaseous fuels such as biohydrogen and biomethane. However, the efficiency of this process is often limited by the complex structure of lignocellulosic biomass and the slow hydrolysis step, which acts as a rate-limiting factor. Therefore, various pretreatment techniques have been proposed to enhance substrate biodegradability and improve gas yields. Among physical pretreatment methods, ultrasonic pretreatment has attracted significant attention due to its ability to disrupt cell walls, reduce particle size, and enhance solubilisation of organic matter through cavitation effects. Despite numerous studies on biogas enhancement using ultrasonic pretreatment, limited research has simultaneously investigated its effect on biohydrogen production, gas composition (H_2, CH_4, CO, and H_2S), and the associated metabolic pathways for different agricultural residues. Accordingly, the main objective of this study was to evaluate the impact of ultrasonic pretreatment on the anaerobic digestion performance of selected agricultural wastes, including corn residues, potato waste, and banana waste. In addition to gas production performance, particular emphasis was placed on analysing changes in metabolic pathways and alcohol formation to better understand the mechanisms governing hydrogen and methane generation.

Materials and Methods

In this study three types of agricultural wastes, namely corn residues, potato waste, and banana waste, were used as feedstocks. The substrates were mixed with animal manure and water to provide appropriate microbial inoculation and moisture content. The prepared mixtures were mechanically stirred at 500 rpm for 10 minutes to ensure homogeneity. Ultrasonic pretreatment was applied using an ultrasonic device operating at 300 W for 5 minutes. Both pretreated and untreated samples were then subjected to anaerobic digestion under controlled conditions. Total solids (TS) and volatile solids (VS) were measured to characterise the substrates before digestion. During the anaerobic digestion process, the composition of the produced gases, including hydrogen (H_2), methane (CH_4), carbon monoxide (CO), and hydrogen sulfide (H_2S), was monitored. In addition, total alcohol concentration (ALC) was measured to assess shifts in fermentation pathways. The obtained data were analysed to compare the performance of ultrasonic pretreatment across different feedstocks and to evaluate its influence on metabolic reactions.

Authors retain the copyright. This is an open access article distributed under Creative Commons Attribution 4.0 International License (CC BY 4.0).

https://doi.org/10.22067/jam.2026.98121.1477

Results and Discussion

The results demonstrated that the effect of ultrasonic pretreatment on gas production strongly depended on the type of agricultural waste. For corn residues, ultrasonic pretreatment significantly enhanced biohydrogen production, increasing hydrogen concentration from approximately 2,585 ppm to 3,900 ppm. Methane production also showed a moderate increase, rising from about 104,000 ppm to 107,000 ppm. These improvements can be attributed to enhanced solubilisation of organic matter and improved accessibility of fermentable substrates. In contrast, potato waste exhibited decreased hydrogen and methane production following ultrasonic pretreatment. This behaviour suggests that excessive disruption of the substrate structure may have promoted alternative metabolic pathways unfavourable for gas generation. Banana waste showed a substantial percentage increase in hydrogen production after ultrasonic pretreatment, although its effect on methane production was less pronounced. Across all substrates, ultrasonic pretreatment led to an increase in carbon monoxide concentration and a noticeable reduction in hydrogen sulfide, which is considered beneficial due to the corrosive nature of H_2S. Metabolic pathway analysis revealed that ultrasonic pretreatment, particularly in banana and corn wastes, promoted pathways leading to alcohol production, such as ethanol and methanol formation. This shift explains the observed reduction or stagnation in hydrogen and methane production during later stages of digestion, as substrates were partially diverted toward solventogenic reactions.

Conclusion

The results of this study indicate that ultrasonic pretreatment can be an effective approach for improving the performance of anaerobic digestion; however, its effectiveness strongly depends on the type of substrate used. Among the investigated agricultural residues, corn waste demonstrated the most favourable response to ultrasonic pretreatment, showing improvements in both hydrogen and methane production. Banana peel also exhibited a noticeable increase in hydrogen generation after pretreatment, whereas potato waste showed a less favourable response and did not benefit significantly from the ultrasonic treatment. In addition, the variations observed in gas composition and alcohol production suggest that changes in microbial metabolic pathways play an important role in determining the outcomes of pretreatment processes. Overall, these findings suggest that ultrasonic pretreatment has considerable potential for enhancing bioenergy recovery from agricultural wastes, provided that pretreatment conditions are carefully optimised according to the characteristics of each substrate.

Keywords: Agricultural waste, Anaerobic digestion, Biogas, Ultrasonic pretreatment, Volatile particles

نشریه ماشین‌های کشاورزی
https://jame.um.ac.ir

مقاله پژوهشی
جلد ۱۶، شماره ٤، زمستان ۱٤۰۵، ص ۷۸۰-۷٦۹

بهبود تخمیر بی‌هوازی ضایعات کشاورزی با استفاده از پیش‌تیمار فراصوت به‌منظور افزایش تولید بیوهیدروژن: مطالعه مسیر متابولیکی واکنش‌ها

محمود محمودی اشکفتکی[۱]، امین لطفعلیان دهکردی[۲]، حمید خفاجه[۱*]، سیده حدیثه بهرام شابهرامی[۱]

تاریخ دریافت: ۱۴۰۴/۱۲/۱۶
تاریخ پذیرش: ۱۴۰۵/۰۴/۰۸

چکیده

تولید بیوهیدروژن از زیست‌توده‌های کشاورزی به‌عنوان یکی از منابع انرژی تجدیدپذیر مورد توجه قرار گرفته است. در این پژوهش، تأثیر پیش‌تیمار فراصوت بر بهبود تخمیر بی‌هوازی و افزایش تولید بیوهیدروژن از برخی ضایعات کشاورزی مورد بررسی قرار گرفت. برای این منظور، سه نوع زیست‌توده شامل ضایعات ذرت، ضایعات سیب‌زمینی و پوست موز به‌عنوان بستر تخمیر مورد استفاده قرار گرفتند و نمونه‌ها تحت پیش‌تیمار فراصوت به مدت ۵ دقیقه در توان ۳۰۰ وات قرار گرفتند. نتایج نشان داد استفاده از پیش‌تیمار فراصوت به‌طور کلی موجب افزایش ۵۰/۸۷ درصدی تولید بیوهیدروژن نسبت به نمونه‌های بدون پیش‌تیمار شد. همچنین بررسی روند تجمعی گازهای تولیدی نشان داد که اعمال این پیش‌تیمار موجب افزایش ۲/۹ درصدی تولید متان گردید. در میان زیست‌توده‌های مورد بررسی، پوست موز بیشترین تأثیرپذیری از پیش‌تیمار فراصوت را نشان داد، به‌طوری‌که میزان تولید بیوهیدروژن در این بستر حدود ۵۰۰ درصد افزایش یافت. در مقابل، تولید متان در برخی تیمارها اندکی کاهش نشان داد که می‌تواند ناشی از افزایش ترکیبات آنتی‌باکتریال نظیر تانن‌ها و فنول‌ها در محیط تخمیر در اثر اعمال پیش‌تیمار فراصوت باشد. به‌طور کلی نتایج این پژوهش نشان داد که پیش‌تیمار فراصوت می‌تواند به‌عنوان روشی مؤثر برای بهبود کارایی تخمیر بی‌هوازی و افزایش تولید بیوهیدروژن از ضایعات کشاورزی مورد استفاده قرار گیرد.

واژه‌های کلیدی: بیوگاز، پیش‌تیمار فراصوت، ذرات فرار، ضایعات کشاورزی، هضم بی‌هوازی

مقدمه

افزایش تقاضای انرژی، کاهش ذخایر سوخت‌های فسیلی و پیامدهای زیست‌محیطی ناشی از مصرف آن‌ها، ضرورت توسعه منابع انرژی تجدیدپذیر و پاک را بیش از پیش آشکار کرده است. در این میان، زیست‌توده و پسماندهای آلی به‌دلیل فراوانی، قابلیت تجزیه‌پذیری و امکان تبدیل به حامل‌های انرژی، از جایگاه ویژه‌ای برخوردارند. پسماندهای کشاورزی در صورت مدیریت نامناسب می‌توانند موجب آلودگی خاک، آب و هوا شوند؛ اما از سوی دیگر، به‌عنوان منابعی ارزان، در دسترس و تجدیدپذیر برای تولید انرژی زیستی قابل استفاده هستند (Mahmoodi-Eshkaftaki, Ebrahimi, & Ghasemi-Pirbaloti, 2017). مطالعات انجام‌شده در زمینه تبدیل پسماندهای کشاورزی به بیوگاز نیز نشان داده‌اند که استفاده از این مواد می‌تواند ضمن کاهش خطرات زیست‌محیطی، به توسعه سوخت‌های غیرفسیلی و مدیریت پایدار پسماند کمک کند. تقی‌نژاد و همکاران (Taghinazhad, Abdi, & Adl, 2018) در تحقیقی به تولید بیوگاز از بقایای کشاورزی، بر ظرفیت این منابع در تولید انرژی زیستی و کاهش بار آلایندگی پسماندها تأکید کردند. هضم بی‌هوازی یکی از فناوری‌های مؤثر و پایدار برای تبدیل مواد آلی به انرژی است که طی آن ترکیبات آلی در نبود اکسیژن و با فعالیت مجموعه‌ای از میکروارگانیسم‌ها به محصولات گازی و مایع تبدیل می‌شوند. این فرایند افزون بر تولید بیوگاز، می‌تواند در مراحل اسیدزایی و تخمیر تاریک، به تولید بیوهیدروژن نیز منجر شود. بیوهیدروژن به‌عنوان یک حامل انرژی پاک، به‌دلیل ارزش حرارتی بالا و عدم تولید آلاینده‌های کربنی در هنگام مصرف، در سال‌های اخیر توجه زیادی را به خود جلب کرده است. با این حال، بازده تولید بیوهیدروژن از پسماندهای آلی به عوامل مختلفی از جمله نوع

۱- گروه مهندسی مکانیک بیوسیستم، دانشگاه جهرم، جهرم، فارس، ایران
۲- گروه مهندسی مکانیک بیوسیستم، دانشگاه شهرکرد، شهرکرد، ایران
(*- نویسنده مسئول: Email: Khafajeh@jahromu.ac.ir)
https://doi.org/10.22067/jam.2026.98121.1477

خوراک، ترکیب مواد آلی، شرایط pH، دما، نوع میکروارگانیسم‌ها و قابلیت تجزیه‌پذیری زیست‌توده وابسته است. از این رو، انتخاب خوراک مناسب و بهبود دسترسی میکروبی به ترکیبات قابل‌تخمیر، از مهم‌ترین عوامل مؤثر بر افزایش کارایی فرایند محسوب می‌شود (Sami, Akram, & Sharifi, 2021). بخش قابل‌توجهی از ضایعات کشاورزی دارای ساختار لیگنوسلولزی است که عمدتاً از سلولز، همی‌سلولز و لیگنین تشکیل شده است. این ساختار پیچیده و متراکم، دسترسی آسان میکروارگانیسم‌ها و آنزیم‌ها به کربوهیدرات‌های قابل‌تخمیر را محدود می‌کند و در نتیجه می‌تواند سرعت هیدرولیز و تولید گاز را کاهش دهد. علاوه بر این، برخی پسماندهای کشاورزی ممکن است حاوی ترکیبات بازدارنده‌ای مانند ترکیبات فنولی، تانن‌ها یا سایر مواد ضدباکتریایی باشند که فعالیت میکروبی را تحت تأثیر قرار می‌دهند. بنابراین، یکی از چالش‌های اصلی در استفاده از ضایعات کشاورزی برای تولید بیوهیدروژن، افزایش قابلیت هضم زیستی و کاهش محدودیت‌های ساختاری و شیمیایی این مواد است. مطالعات پیشین نشان داده‌اند که نوع پسماند و ترکیب آن می‌تواند اثر چشمگیری بر عملکرد هضم بی‌هوازی داشته باشد؛ به‌طوری‌که صفری و عبدی (Safari & Abdi, 2016) در بررسی بقایای کلزا و گندم در ترکیب با کود دامی، اختلاف معنی‌داری بین تیمارها از نظر تولید متان گزارش کردند و نشان دادند که بقایای کلزا نسبت به گندم پتانسیل بیشتری برای تولید متان دارد. به‌منظور افزایش بازده تبدیل زیست‌توده به انرژی، استفاده از پیش‌تیمارهای فیزیکی، شیمیایی، حرارتی و زیستی پیش از هضم بی‌هوازی مورد توجه قرار گرفته است. هدف اصلی این پیش‌تیمارها، تخریب ساختار سلولی، افزایش سطح تماس، آزادسازی مواد آلی محلول و بهبود انتقال جرم در محیط تخمیر است. در مطالعات مرتبط با هضم بی‌هوازی گزارش شده است که پیش‌تیمار می‌تواند با شکستن غشای سلولی و افزایش انحلال‌پذیری ترکیبات آلی، عملکرد فرایند را بهبود دهد. کمالی و همکاران (Kamali, Abdi, Rohani, Abdollahpour, & Ebrahimi, 2022) در پژوهشی درباره بهینه‌سازی تولید بیوگاز از بخش آلی پسماند شهری تحت پیش‌تیمار حرارتی بیان کردند که هضم بی‌هوازی به‌دلیل بازیابی انرژی و مواد مغذی از پسماند، روشی پایدار برای مدیریت مواد آلی است و اعمال پیش‌تیمار می‌تواند راهکاری مؤثر برای افزایش کارایی تولید بیوگاز باشد. با این وجود، شدت و شرایط پیش‌تیمار باید به‌گونه‌ای انتخاب شود که ضمن افزایش قابلیت تجزیه‌پذیری، از تشکیل یا آزادسازی ترکیبات بازدارنده و کاهش فعالیت میکروبی جلوگیری شود. در میان روش‌های مختلف پیش‌تیمار، فراصوت به‌عنوان یک روش فیزیکی مؤثر، سریع و نسبتاً قابل‌کنترل شناخته می‌شود. این روش با ایجاد پدیده کاویتاسیون، تشکیل و فروپاشی حباب‌های ریز، افزایش تنش‌های برشی و ایجاد نقاط موضعی با فشار و دمای بالا، می‌تواند ساختار سلولی و بافتی مواد آلی را تخریب کرده و ترکیبات قابل‌تخمیر را در دسترس میکروارگانیسم‌ها قرار دهد. در نتیجه، پیش‌تیمار فراصوت می‌تواند مرحله هیدرولیز را که معمولاً یکی از مراحل محدودکننده در هضم بی‌هوازی زیست‌توده‌های پیچیده است، تسریع کند و زمینه افزایش تولید بیوهیدروژن را فراهم سازد. با وجود این، اثرگذاری این روش به نوع پسماند، ترکیب شیمیایی آن، شدت انرژی، زمان اعمال پیش‌تیمار و شرایط تخمیر وابسته است. از این‌رو، بررسی اثر پیش‌تیمار فراصوت بر انواع مختلف ضایعات کشاورزی می‌تواند به شناخت بهتر عملکرد این فناوری در بهبود تولید انرژی زیستی کمک کند (Mahmoodi-Eshkaftaki, Rafiee, & Mahmoudi, 2023). مطالعات انجام‌شده درباره کاربرد فراصوت در فرایندهای زیستی نشان داده‌اند که توان صوتی، زمان اعمال فراصوت و ترکیب سوبسترا از عوامل تعیین‌کننده در تجزیه‌پذیری ساختار لیگنوسلولزی، حذف آلاینده‌ها و بهبود تولید بیوهیدروژن هستند. محمودی اشکفتکی و غنی (Mahmoodi-Eshkaftaki & Ghani, 2022) با بررسی اثر توان و زمان فراصوت و همچنین ترکیب سوبسترا شامل ضایعات گوجه‌فرنگی و کود گاوی، نشان دادند که بهینه‌سازی شرایط پیش‌تیمار می‌تواند موجب افزایش حذف جامدات کل، جامدات فرار، لیگنین، سلولز و همی‌سلولز شده و در نهایت تولید بیوهیدروژن را نسبت به سیستم شاهد افزایش دهد. همچنین در مطالعه‌ای دیگر، اثر پیش‌تیمار فراصوت بر افزایش تجزیه‌پذیری ضایعات گوجه‌فرنگی و بهبود تولید بیوهیدروژن و بیومتان بررسی شد و نتایج نشان داد که عملکرد فرایند به‌شدت تابع توان صوتی، زمان فراصوت و نسبت اختلاط سوبسترا است. با وجود اثرگذاری پیش‌تیمارها بر بهبود تولید سوخت‌های زیستی، اعمال آن‌ها همواره منجر به افزایش بازده فرایند نمی‌شود و در برخی شرایط می‌تواند اثرات بازدارنده ایجاد کند. در طی پیش‌تیمار و تخریب ساختارهای سلولی و میکروسکوپی مواد، امکان آزادسازی ترکیبات فنولی و سایر مواد بازدارنده در محیط تخمیر افزایش می‌یابد. این ترکیبات می‌توانند فعالیت میکروبی را کاهش داده و در نتیجه تولید سوخت زیستی را محدود کنند (Kim, 2018; Mahmoodi-Eshkaftaki & Ghani, 2022; Wang *et al*., 2017). بنابراین، انتخاب شرایط مناسب پیش‌تیمار و بررسی پاسخ هر نوع پسماند به این فرایند، برای دستیابی به بیشترین بازده تولید بیوهیدروژن ضروری است. با وجود پژوهش‌های انجام‌شده درباره هضم بی‌هوازی و پیش‌تیمارهای مختلف، هنوز اطلاعات محدودی درباره مقایسه پاسخ ضایعات کشاورزی با ترکیب‌های متفاوت نسبت به پیش‌تیمار فراصوت وجود دارد. به‌ویژه، در بسیاری از مطالعات تمرکز اصلی بر مقدار گاز تولیدی بوده و تغییرات مسیرهای متابولیکی و ارتباط آن‌ها با تولید بیوهیدروژن کمتر مورد توجه قرار گرفته است. بر همین اساس، پژوهش حاضر با هدف بررسی اثر پیش‌تیمار فراصوت بر بهبود تخمیر بی‌هوازی سه نوع ضایعات کشاورزی شامل ضایعات ذرت، ضایعات

سیب‌زمینی و پوست موز انجام شد. در این مطالعه، ضمن مقایسه عملکرد نمونه‌های پیش‌تیمارشده و شاهد، تغییرات تولید بیوهیدروژن و بیوگاز و نیز مسیرهای متابولیکی احتمالی واکنش‌ها مورد بررسی قرار گرفت تا امکان استفاده مؤثرتر از پسماندهای کشاورزی در تولید انرژی زیستی ارزیابی شود.

مواد و روش‌ها

سه نوع زیست‌توده شامل ضایعات ذرت، ضایعات سیب‌زمینی و پوست موز به‌عنوان ماده مغذی اصلی مورد استفاده قرار گرفتند. هر یک از این مواد به‌صورت جداگانه با مقدار مشخصی آب و اینوکلوم مخلوط شدند. در این مطالعه، کل مواد جامد (Total Solids, TS) و مواد جامد فرّار (Volatile Solids, VS) به‌ترتیب به‌عنوان شاخص‌های بیانگر میزان کل مواد جامد موجود در نمونه و بخش آلی قابل‌تجزیه زیستی آن در نظر گرفته شدند. مقادیرTS، VSو pH اینوکلوم به‌ترتیب برابر با ۴٪، ۸۶٪ و ۲/۵ بود. اینوکلوم از راکتورهای فعال در آزمایشگاه انرژی‌های تجدیدپذیر دانشگاه جهرم استفاده شد. تمامی آزمایش‌ها در آزمایشگاه‌های دانشگاه جهرم، واقع در استان فارس، ایران انجام گرفت. نسبت‌های ترکیب نمونه‌ها در جدول ۱ ارائه شده است. پس از اختلاط، مخلوطها به مدت ۱۰ دقیقه با دور ۵۰۰ دور بر دقیقه هم خوردند تا ساختار یکنواختی برای مواد ایجاد شود. پس از تهیه مخلوط، میزان اسیدیته (pH) هر نمونه با استفاده از دستگاه pHسنج اندازه‌گیری شد. در تمام نمونه‌ها، مقدار pH با اضافه کردن اسید سولفوریک به عدد ۵ تنظیم گردید؛ این مقدار pH، مقدار بهینه pH جهت فعالیت باکتری‌های هیدرولیزکننده است. در این مطالعه، اندازه‌گیری pH با استفاده از pHمتر رومیزی مدل HI2210 انجام شد و عملیات همزدن نمونه‌ها به کمک همزن مکانیکی با حداکثر سرعت ۳۰۰۰ دور بر دقیقه صورت گرفت. در مرحله بعد، نمونه‌ها به دو گروه، گروه اول تحت پیش‌تیمار فراصوت و گروه دوم بدون پیش‌تیمار فراصوت (شاهد) تقسیم‌بندی شدند. پیش‌تیمار فراصوت به مدت ۵ دقیقه در توان ۳۰۰ وات با استفاده از دستگاه حمام فراصوت یک لیتری ELMA آلمان مدل S10H دارای فرکانس ۳۷ کیلوهرتز در دمای ۷۰ درجه سلسیوس انجام شد. لازم به ذکر است که در این پژوهش، تمرکز اصلی بر ارزیابی پتانسیل تولید انرژی از بسترهای مختلف کشاورزی تحت یک شرایط ثابت پیش‌تیمار بوده است. لذا، شرایط عملیاتی فراصوت (۳۰۰ وات، ۵ دقیقه و دمای ۷۰ درجه سلسیوس) بر اساس پیشینه پژوهش و مطالعات مقدماتی به‌عنوان یک نقطه مرجع انتخاب شد و تعیین شرایط بهینه در دامنه متغیرهای مختلف، در اهداف فعلی این مطالعه نبوده است. آزمایش‌ها در سه تکرار مستقل انجام شد.

جدول ۱- ضایعات استفاده‌شده در آزمایش‌های هضم بی‌هوازی

Table 1- Wastes used in the anaerobic digestion experiments

نوع ضایعات Waste type	اسیدیته اولیه Initial pH	آب Water (g)	اینوکلوم Inoculum (g)	پیش‌ماده Substrate (g)
ضایعات ذرت Corn waste	5	120	20	40
ضایعات سیب‌زمینی Potato waste	5.5	120	20	40
پوست موز Banana peel	5.6	120	20	40

به‌منظور اندازه‌گیری TS و VS، مقدار ۸ گرم از هر کدام از نمونه‌ها جدا شد. مابقی نمونه‌ها در راکتورهای بی‌هوازی ریخته شد و فرایند تولید بیوگاز بررسی شد. نمونه‌هایی که برای محاسبه TS جدا شد به مدت ۲۴ ساعت در دمای ۷۰ درجه سلسیوس درون دستگاه آون قرار گرفت، تا نمونه‌ها کاملا خشک شود (Mahmoodi-Eshkaftaki *et al.*, 2023). بعد از خشک شدن نمونه‌ها، نمونه‌ها در بوته چینی ریخته شده و داخل کوره در دمای ۵۸۰ درجه سلسیوس به مدت ۴ ساعت قرارداده شد تا ذرات فرار نمونه‌ها تبخیر شده و خاکستر ته بوته‌ها باقی بماند (Mahmoodi-Eshkaftaki & Rahmanian-Koushkaki, 2020). نمونه‌های فاضلاب به‌دست‌آمده در راکتورهای بی‌هوازی به ابعاد ۵۰۰ میلی‌لیتر ریخته شدند و در انکوباتور به مدت ۲۸ روز در دمای ۳۷ سلسیوس تحت هضم بی‌هوازی قرار گرفتند. ترکیبات بیوگاز تولیدشده از راکتورهای بی‌هوازی شامل مقادیر H_2، CH_4، CO و H_2S به‌صورت هفته‌ای اندازه‌گیری شد. H_2 توسط دستگاه گازسنج چندمتغیره برند GMI مدل GT43 در محدوده دمای اتاق اندازه‌گیری شد و ترکیبات CH_4، CO و H_2S توسط دستگاه گازسنج چندمتغیره مدل BW در دمای اتاق اندازه‌گیری شد (Mahmoodi-Eshkaftaki *et al.*, 2023). میزان الکل کل (ALC) تولیدشده در حین واکنش‌ها با استفاده از دستگاه رفرکتومتر اندازه‌گیری شد. مراحل اجرایی پژوهش شامل آماده‌سازی زیست‌توده، پیش‌تیمار و هضم بی‌هوازی در شکل ۱ به‌صورت شماتیک خلاصه شده است.

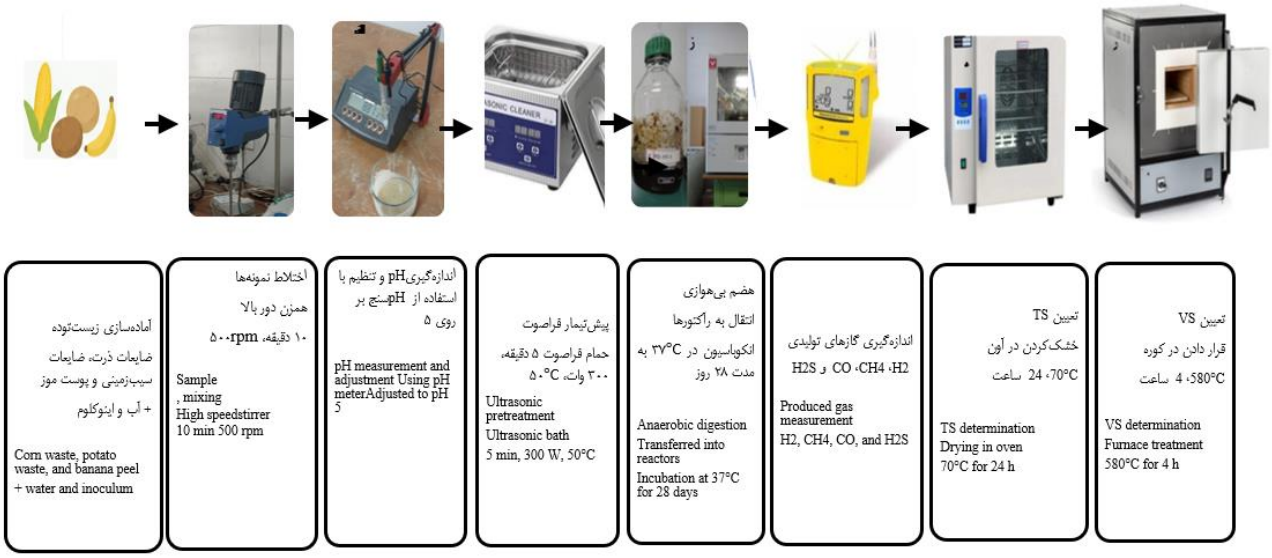

شکل ۱– نمودار شماتیک مراحل آماده‌سازی زیست‌توده، پیش‌تیمار فراصوت، هضم بی‌هوازی و اندازه‌گیری گازهای تولیدی

Fig. 1. Schematic diagram of biomass preparation, ultrasonic pretreatment, anaerobic digestion, and measurement of the produced gases

نتایج و بحث

ویژگی‌های فاضلاب ورودی به رآکتورها

TS و VS از مهم‌ترین فاکتورهای مورد بررسی در تصفیه فاضلاب‌ها می‌باشند. هر چه‌قدر TS یک فاضلاب بیشتر باشد معمولاً بار آلوده آن فاضلاب بیشتر است و هر چه‌قدر VS یک فاضلاب بیشتر باشد، قابلیت تولید بیوگاز آن فاضلاب بیشتر می‌باشد. فاکتورهای TS و VS نمونه‌های فاضلاب‌های تهیه‌شده از هر پیش‌ماده در شرایط پیش‌تیمار فراصوت و بدون پیش‌تیمار اندازه‌گیری شد (جدول ۲).

جدول ۲– مقادیر TS و VS فاضلاب‌های تهیه‌شده از ضایعات مختلف تحت شرایط پیش‌تیمار و بدون پیش‌تیمار

Table 2- TS and VS values of wastewater prepared from different wastes under pretreatment and non-pretreatment conditions

نوع تیمار Treatment	نوع ضایعات Waste type	TS (%)	VS (%)
با پیش‌تیمار فراصوت Ultrasonic pretreatment	ضایعات ذرت Corn waste	32.5	70.692
	ضایعات سیب‌زمینی Potato waste	30	52.500
	ضایعات موز Banana waste	10	86.250
شاهد Control	ضایعات ذرت Corn waste	32.5	71.461
	ضایعات سیب‌زمینی Potato waste	31.4	51.318
	ضایعات موز Banana waste	10	85.500

همانطور کـه از جـدول ۲ مشـخص اسـت، TS ضـایعات ذرت از ضایعات دیگر بیشتر می‌باشد و این فاکتور در ضـایعات مـوز کمتـرین مقدار می‌باشد. این در حالی است که VS ضایعات موز از دو پیش‌ماده دیگر بیشتر می‌باشد. بالا بودن VS ضایعات ذرت و موز ظرفیت بالای این ضایعات در تبدیل به بیوگاز را نشان می‌دهد. بالا بودن TS و VS یک پیش‌ماده، قابلیت بالای آن در تبدیل به یـک سـوخت زیسـتی را نشـان مـی‌دهـد (Mahmoodi-Eshkaftaki & Rahmanian-Koushkaki, 2020).

آنالیز ترکیبات بیوگاز

ترکیبات بیوگـاز ضـایعات مختلـف در یـک دوره هضـم ۲۸ روزه اندازه‌گیری شده و در جداول ۳ تـا ۵ گـزارش شـده اسـت. ترکیبـات اندازه‌گیری‌شده شامل CH_4، H_2، منواکسید کربن CO و H_2S بودنـد که از نمونه‌های تحت پیش‌تیمار و نمونه شاهد اندازه‌گیری شد. نتـایج حاصل از اندازه‌گیری گازهای تولیدشده در فرایند تخمیـر بـی‌هـوازی زیست‌توده‌ها با اعمال متغیر فراصوت و بدون اعمال متغیـر فراصـوت نشان‌دهنده تأثیر مثبت و معنادار این متغیر بر بهبود عملکرد تخمیـری و افزایش بازده تولید گازهای زیسـتی مـی‌باشـد (Yang & Wang, 2019). استفاده از فراصوت در هر سه پیش‌مـاده منجـر بـه افـزایش محسوس در تولید گاز H_2 و CH_4 گردید. این افزایش عمدتاً ناشـی از تسهیل فرایند هیدرولیز، تخریب سـاختار سـلولی، و بهبـود دسترسـی باکتری‌ها به مواد قابل‌تخمیر بوده است (Mahmoodi-Eshkaftaki & Rahmanian-Koushkaki, 2020). انـدازه‌گیـری‌هـا نشـان داد هیدروژن در ضایعات در هفته‌های اول هضم بسـیار بـالا و بـه مـرور کاهش یافته است.

جدول ۳- ترکیبات بیوگاز تولیدی از ضایعات ذرت تحت پیش‌تیمار فراصوت در مقایسه با نمونه‌های شاهد

Table 3- Biogas composition produced from corn waste under ultrasonic pretreatment compared with control samples

دوره هضم Digestion period	H_2 (ppm)	H_2S (ppm)	CH_4 (ppm)	CO (ppm)	ALC (%)	H_2 (ppm)	H_2S (ppm)	CH_4 (ppm)	CO (ppm)	ALC (%)
	پیش‌تیمار فراصوت Ultrasonic pretreatment					شاهد Control				
هفته اول Week 1	1550	1	20000	62	2	65	3	22000	33	0
هفته دوم Week 2	2000	0	20000	0	10	390	0	22000	0	6
هفته سوم Week 3	250	0	25000	57	13	1350	0	20000	8	8
هفته چهارم Week 4	100	0	42000	73	13	780	10	40000	30	90

جدول ٤- ترکیبات بیوگاز تولیدی از ضایعات سیب‌زمینی تحت پیش‌تیمار فراصوت در مقایسه با نمونه شاهد

Table 4- Biogas composition produced from potato wastes under ultrasonic pretreatment compared with control sample

دوره هضم Digestion period	H_2 (ppm)	H_2S (ppm)	CH_4 (ppm)	CO (ppm)	ALC (%)	H_2 (ppm)	H_2S (ppm)	CH_4 (ppm)	CO (ppm)	ALC (%)
	پیش‌تیمار فراصوت Ultrasonic pretreatment					شاهد Control				
هفته اول Week 1	20000	17	22000	491	0	400000	50000	30000	10	0
هفته دوم Week 2	450	51	20000	50	3	1700	51	20000	19	0
هفته سوم Week 3	1050	0	42000	80	6	65	3	50000	0	4
هفته چهارم Week 4	250	0	40000	100	4	10	0	40000	0	4

جدول ۵- ترکیبات بیوگاز تولیدی از ضایعات موز تحت پیش‌تیمار فراصوت در مقایسه با نمونه شاهد

Table 5- Biogas composition produced from banana waste under ultrasonic pretreatment compared with control sample

دوره هضم Digestion period	H_2 (ppm)	H_2S (ppm)	CH_4 (ppm)	CO (ppm)	ALC (%)	H_2 (ppm)	H_2S (ppm)	CH_4 (ppm)	CO (ppm)	ALC (%)
	پیش‌تیمار فراصوت Ultrasonic pretreatment					شاهد Control				
هفته اول Week 1	1200	0	20000	470	5	243	0	20000	100	3
هفته دوم Week 2	340	0	42000	100	8	50	0	30000	0	7
هفته سوم Week 3	250	0	35000	60	15	10	0	38000	0	14
هفته چهارم Week 4	50	0	10000	0	20	0	0	25000	0	11

بر اساس داده‌های ارائه‌شده در جدول ۳، در گازهای حاصل از ضایعات ذرت، بیشترین غلظت هیدروژن در هفته دوم آزمایش و معادل ۲۰۰۰ ppm در شرایط پیش‌تیمار فراصوت ثبت گردید. مقدار در مقایسه با نمونه شاهد (فاقد پیش‌تیمار) چندین برابر افزایش نشان داده و بیانگر نقش مؤثر و تسریع‌کننده پیش‌تیمار فراصوت در فرایند تخمیر می‌باشد. بیشترین میزان تولید هیدروژن در نمونه‌های شاهد در هفته سوم به‌وجود آمد که نشان می‌دهد استفاده از پیش‌تیمارفراصوت توانسته فرایند هیدرولیز را سریع‌تر کند. این نتیجه با نتایج تحقیقات محمودی اشکفتکی و غنی (Mahmoodi-Eshkaftaki & Ghani, 2022) و محمودی اشکفتکی و همکاران (Mahmoodi-Eshkaftaki *et al.*, 2023) همخوانی دارد. این نتایج نشان داد استفاده از پیش‌تیمار فراصوت به‌طور کلی میزان تولید هیدروژن را ۵۰/۸۷ درصد افزایش داده است. بررسی روند تولید متان از ضایعات نشان داد، میزان متان در نمونه‌های پیش‌تیمارشده حدود ppm ۴۲۰۰۰ و در هفته چهارم گزارش شد، در حالی‌که این مقدار در نمونه شاهد کمتر بود. بررسی تجمعی گازهای تولیدشده در ۲۸ روز نشان داد استفاده از پیش‌تیمار فراصوت به‌طور کلی موجب افزایش ۲/۹ درصدی تولید متان شد. این اختلاف حاکی از آن است که اعمال امواج فراصوت با تخریب ساختارهای سلولزی و همی‌سلولزی، موجب بهبود دسترسی میکروارگانیسم‌ها به ترکیبات کربوهیدراتی و در نتیجه افزایش کارایی فرایند هضم بیولوژیک می‌گردد. این افزایش در تولید بیوهیدروژن و متان را می‌توان از دیدگاه مکانیزمی به پدیده کاویتاسیون ناشی از فراصوت نسبت داد. امواج فراصوت با ایجاد حباب‌های میکروسکوپی و انفجار آن‌ها، فشارهای موضعی شدیدی ایجاد می‌کنند که منجر به شکستن ساختار پیچیده لیگنوسلولزی ضایعات کشاورزی (ذرت، سیب‌زمینی و پوست موز) می‌شود. این فرایند باعث کاهش اندازه ذرات و افزایش سطح تماس در دسترس برای میکروارگانیسم‌ها می‌گردد که مستقیماً مرحله هیدرولیز را تسهیل می‌کند. آزادسازی ترکیبات آلی محلول در اثر این پیش‌تیمار، مواد مغذی بیشتری را در دسترس باکتری‌های هیدروژنوژن و متانوژن قرار می‌دهد. با این حال، تفاوت در میزان افزایش تولید بین بسترها (مانند افزایش چشمگیر در پوست موز) نشان‌دهنده واکنش متفاوت ساختارهای مختلف به انرژی فراصوت است. همچنین، باید در نظر داشت که در برخی تیمارها، آزادسازی همزمان ترکیبات بازدارنده مانند فنول‌ها و تانن‌ها ممکن است بر فعالیت متانوژن‌ها اثر منفی نسبی داشته باشد، هرچند که در این مطالعه به دلیل عدم اندازه‌گیری مستقیم متابولیت‌های میانی، این تحلیل‌ها به‌عنوان فرضیه‌های محتمل بر اساس تغییرات ترکیب گاز بیان می‌شوند. این نتایج با تحقیقات دیگر محققین همخوانی دارد (Mahmoodi-Eshkaftaki & Rahmanian-Koushkaki, 2020). در طول دوره آزمایش، اگرچه میزان هیدروژن و متان در بعضی هفته‌ها نوسان داشت، اما بازده کلی در نمونه‌های تحت پیش‌تیمار همواره بالاتر از گروه شاهد بود. بررسی ترکیبات سولفیدهیدروژن و منواکسید کربن نشان داد، استفاده از پیش‌تیمار فراصوت موجب کاهش ترکیب مضر سولفید هیدروژن به‌صورت چشمگیر شد، اما موجب افزایش منواکسیدکربن نیز شد. افزایش ترکیب منواکسیدکربن به‌خاطر شکسته شدن ساختارهای کربوهیدرات و آزاد شدن کربن در محیط بوده که منجر به افزایش تولید متان و منواکسیدکربن شده است. این نتایج با نتایج به‌دست‌آمده در تحقیقات دیگران همخوانی دارد (Kumar & Sharma, 2017; Mahmoodi-Eshkaftaki & Rahmanian-Koushkaki, 2020). نتایج آنالیز الکل در جدول ۳ نشان داد، با گذشت زمان تخمیر، تولید الکل افزایش یافته است. به‌طوری‌که الکل تولیدشده در هفته‌های سوم و چهارم افزایش چشمگیری داشت.

بر اساس داده‌های جدول ۴، بیشترین میزان تولید هیدروژن در

نمونه‌های حاصل از ضایعات سیب‌زمینی در هفته نخست آزمایش و در شرایط شاهد (فاقد پیش‌تیمار فراصوت) معادل ۴۰۰۰۰ ppm ثبت گردید. این مقدار به‌طور معناداری بیشتر از نمونه‌های تحت پیش‌تیمار بود که مقادیر پایین‌تری از هیدروژن تولید کردند. با این حال، روند تولید هیدروژن در طول دوره آزمایش کاهشی بود، به‌طوری‌که مقادیر ثبت‌شده پس از هفته اول به‌طور قابل‌توجهی افت داشت. چنین الگویی نشان می‌دهد که اگرچه سیب‌زمینی به دلیل محتوای بالای قندهای ساده و نشاسته در مراحل ابتدایی تخمیر قابلیت بالایی برای تولید هیدروژن دارد، اما این پتانسیل به‌سرعت کاهش یافته و پایداری فرایند محدود می‌گردد. از نظر تولید متان، بیشترین مقدار در شرایط شاهد حدود ۵۰۰۰۰ ppm مشاهده شد، در حالی‌که نمونه‌های تحت پیش‌تیمار فراصوت میزان کمتری از متان تولید کردند. این یافته می‌تواند بیانگر آن باشد که اعمال پیش‌تیمار فراصوت در مورد ضایعات سیب‌زمینی برخلاف ضایعات ذرت، اثر مثبتی بر بهبود فرایند متان‌زایی نداشته و حتی منجر به کاهش بازده تولید متان شده است. یکی از دلایل احتمالی این پدیده می‌تواند آزادسازی سریع ترکیبات بازدارنده ناشی از شکستن ساختارهای سلولی در اثر پیش‌تیمار باشد که کارایی میکروارگانیسم‌های هیدرولیزکننده و متانوژن را کاهش داده است (Kim, 2018). در ضمن پیش‌تیمار منجر به افزایش ترکیبات مضر بیوگاز مانند منواکسیدکربن شده است که دلیل اصلی آن می‌تواند آزاد شدن کربن در محیط فاضلاب باشد. پیش‌تیمار فراصوت توانسته سولفید هیدروژن را به شدت کاهش دهد و این اثر مثبتی بوده که پیش‌تیمار مذکور بر ضایعات سیب‌زمینی داشته است. تولید الکل در ضایعات سیب‌زمینی از هفته اول تا سوم رو به افزایش و با اوج گرفتن تولید متان کاهش یافت.

بر اساس داده‌های جدول ۵، در هفته نخست آزمایش غلظت هیدروژن در نمونه شاهد تنها ۲۴۳ ppm بود، در حالی‌که در نمونه تحت پیش‌تیمار فراصوت این مقدار به حدود ۱۲۰۰ ppm افزایش یافت. این تفاوت نشان‌دهنده تأثیر مثبت پیش‌تیمار در بهبود آزادسازی اجزای قابل‌تخمیر از ساختار پوست موز می‌باشد. وجود قندهای ساده و فیبرهای نیمه‌سلولزی در پوست موز سبب می‌شود که با اعمال پیش‌تیمار فراصوت، دسترسی میکروارگانیسم‌ها به این ترکیبات تسهیل شده و بازده تولید هیدروژن در مراحل ابتدایی افزایش یابد. از نظر تولید متان، در هفته اول هر دو نمونه (شاهد و پیش‌تیمار) مقدار تقریباً یکسانی معادل ۲۰۰۰۰ ppm نشان دادند. با این حال، در هفته دوم روند تغییرات متان برخلاف هیدروژن بود؛ به‌طوری‌که میزان متان در نمونه پیش‌تیمار به حدود ۴۲۰۰۰ ppm رسید، در حالی‌که این مقدار در نمونه شاهد ۴۴۰۰۰ ppm ثبت شد. این اختلاف اندک می‌تواند نشان‌دهنده تأثیر محدود پیش‌تیمار فراصوت بر بهبود متانوژنز در ضایعات پوست موز باشد. به‌عبارت دیگر، اگرچه پیش‌تیمار توانست تولید هیدروژن را به‌طور محسوسی افزایش دهد، اما تأثیر آن بر فرایند تولید متان چندان قابل‌توجه نبود. به‌طور کلی نتایج نشان داد پیش‌تیمار فراصوت موجب افزایش ۵۰۰ درصد تولید هیدروژن در ترکیبات موز شده است؛ اما تولید متان را اندکی کاهش داده است. کاهش تولید متان می‌تواند ناشی از افزایش ترکیبات آنتی‌باکتریال مانند تانن‌ها و فنول‌ها در فاضلاب در اثر پیش‌تیمار فراصوت باشد (Mahmoodi-Eshkaftaki & Ghani, 2022). نتایج نشان داد ترکیبات منواکسیدکربن و سولفید هیدروژن در بیوگاز تولیدی از ضایعات موز اندک می‌باشد. البته پیش‌تیمار فراصوت موجب افزایش منواکسیدکربن در بیوگاز شده است که می‌تواند ناشی از آزاد شدن کربن در اثر شکستن ساختارهای سلولزی و همی‌سلولزی ضایعات موز باشد. طبق جدول ۵، تولید الکل با گذشت زمان تخمیر افزایش داشت، به‌طوری‌که در هفته سوم و چهارم به اوج خود رسیده است.

مسیرهای سوخت و ساز تبدیل بستر به بیوگاز

جهت تفسیر بهتر نتایج، ترکیبات به‌وجودآمده در طی واکنش بی‌هوازی بررسی شدند و معادلات شیمیایی آن‌ها مطالعه شد. با توجه به درصد ترکیبات قندی بالای موجود در ضایعات موردمطالعه، گلوکز به‌عنوان اصلی‌ترین ترکیب مشترک بین هر سه ضایعات (بیشتر از ۸۰٪ کل) به‌عنوان ماده اصلی در تخمیر انتخاب شد و مسیرهای سوخت و ساز تبدیل گلوکز به بیوگاز، روابط استوکیومتری ترکیبات به‌وجودآمده حین واکنش‌ها و انرژی هر واکنش بررسی شدند. در شکل ۲ مسیرهای واکنش‌ها در تولید متان از گلوکز را نشان می‌دهد. همان‌طور که دیده می‌شود در دوره هضم بی‌هوازی، ترکیبات اسیدی حد واسط از قبیل استات، پروپیونات و بوتیرات و ترکیبات الکلی از قبیل اتانول و متانول تولید می‌شود (Mockaitis *et al.*, 2020). همان‌طور که دیده می‌شود، هیدروژن ابتدا در مراحل اولیه هضم (مرحله هیدرولیز) تولید می‌شود و سپس برای ساخت ترکیبات جدید مصرف می‌شود. هیدروژن در تولید بوتیرات (مسیر ۱)، تولید استات (مسیر ۳)، تجزیه متانول (مسیر ۷) و تجزیه اتانول (مسیر ۸)، تولید می‌شود. در ضمن هیدروژن در تولید پروپیونات (مسیر ۲)، اتانول (مسیر ۵)، متانول (مسیر ۶)، متان‌سازی (مسیر ۱۰) و چرخش استات سازی (مسیر ۱۱) مصرف می‌گردد. مقدار تولید و مصرف هیدروژن از طریق روابط استوکیومتری موجود در جدول ۶ قابل‌بررسی خواهد بود.

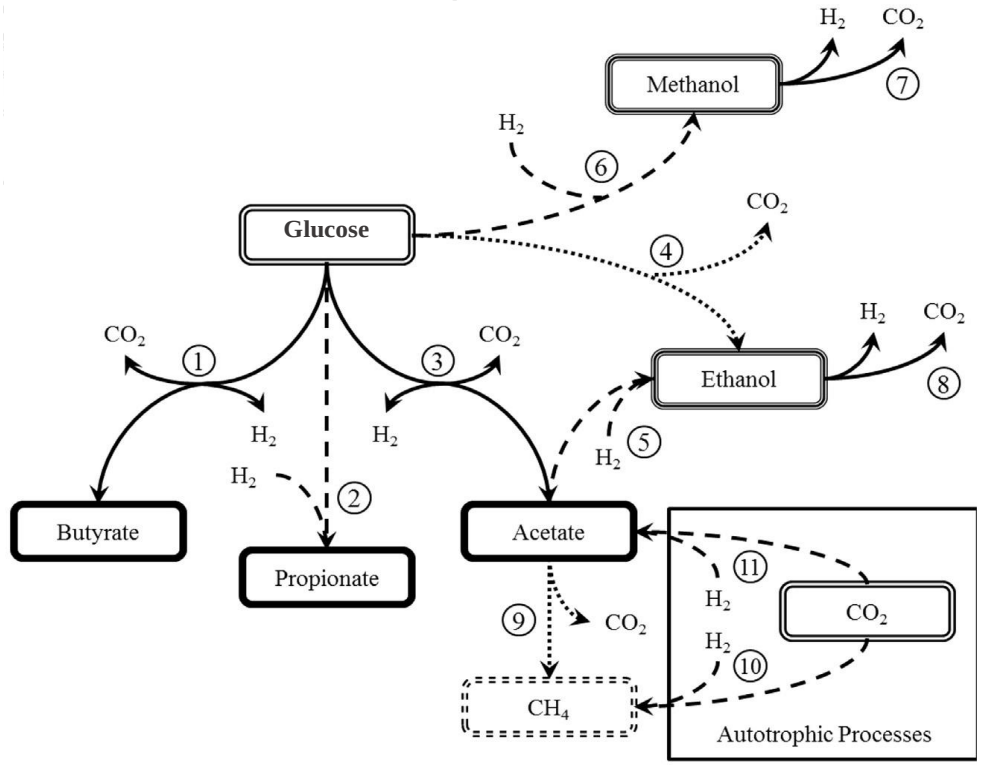

شکل ۲- مسیرهای سوخت و ساز تبدیل گلوکز به بیوگاز (مسیرهای سوخت و ساز با عدد در کنار مسیرها نشان داده شده است)

Fig. 2. Metabolic pathways of glucose conversion to biogas (metabolic pathways are indicated by numbers adjacent to the pathways)

همان‌طور که از جدول ۶ مشخص است، بیش‌ترین میزان تولید هیدروژن در مرحله تولید بوتیرات است که در حقیقت مرحله اسیدسازی در واکنش هضم بی‌هوازی است و معمولاً بین هفته اول و دوم از آغاز مرحله هضم اتفاق می‌افتد. این روند به‌خوبی در نتایج این تحقیق اتفاق افتاده است. به‌طوری‌که در هر سه پیش‌ماده در هفته اول و دوم بیش‌ترین میزان تولید هیدروژن تولید شد و به مرور میزان تولید هیدروژن کاهش یافت. انرژی گیبس در ۶ واکنش اول منفی است که نشان می‌دهد واکنش‌های اولیه مربوط به اسیدسازی و الکل‌سازی، به‌صورت خودکار اتفاق می‌افتد اما واکنش‌های مربوط به شکست اتانول و متانول، گرما نیاز دارد و در صورتی‌که شرایط فراهم نباشد اتفاق نمی‌افتد (Deshavath, Veeranki, & Goud, 2019). منفی‌ترین انرژی گیبس مربوط به تولید اتانول (مرحله ۴) است، بنابراین اگر شرایط تولید اتانول فراهم باشد واکنش در مواد به سمت تولید اتانول می‌رود و میزان تولید گاز کاهش می‌یابد (Tajmirriahi, Momayez, & Karimi, 2020). این نتیجه در بستر موز که ترکیبات قندی بالایی دارد نیز به‌خوبی دیده شد. دلیل اصلی این رویداد می‌تواند تولید اتانول و متانول و فراهم نبودن شرایط شکست اتانول و متانول به‌منظور تولید هیدروژن و پس از آن تولید متان باشد. مقایسه روند تولید متان در ضایعات ذرت و سیب‌زمینی هم نشان داد تولید متان در هفته‌های پایانی در ضایعات سیب‌زمینی بیشتر از ذرت بود که ممکن است به‌خاطر تولید بیشتر اتانول و متانول در ضایعات ذرت به‌خاطر ترکیبات قندی بیشتر آن‌ها نسبت به ضایعات سیب‌زمینی و عدم شکست آن‌ها و تبدیل به هیدروژن و متان باشد (Wang *et al*., 2017). بررسی روند تولید الکل در سه ماده به‌خوبی این نتایج را توجیه می‌کند.

روند تولید متان در ضایعات ذرت و سیب‌زمینی در هفته‌های سوم و چهارم به مقدار بیشینه خود رسید، که دلیل اصلی آن ترکیبات هیدروکربنی بالای این پیش‌مواد می‌باشد که توسط فعالیت باکتری‌های هیدرولیزکننده، اسیدساز و استات‌ساز شکسته و در دسترس باکتری‌های متانوژن قرار داده که منجر به تولید بیشتر متان در هفته‌های سوم و چهارم شده است. این نتیجه با نتایج سایر محققین همخوانی دارد (Mahmoodi-Eshkaftaki & Rahmanian-Koushkaki, 2020; Yalcinkaya & Malina, 2015). در ضایعات موز تولید هیدروژن و متان در هفته‌های اول و دوم بالا و سپس کاهش یافته است که می‌تواند تجزیه‌پذیری بیشتر این ضایعات نسبت به دو ماده دیگر باشد. این بحث با کاهش روند تولید در هفته‌های بعدی قابل‌توجیه است. با وجود نتایج مثبت به‌دست‌آمده در بهبود تولید بیوهیدروژن و متان، باید توجه داشت که

این یافته‌ها مربوط به شدت خاصی از پیش‌تیمار فراصوت (۳۰۰ وات و ۵ دقیقه) است. از آنجا که پاسخ بسترهای مختلف به انرژی فراصوت متفاوت است، عدم بررسی سطوح مختلف توان و زمان به‌عنوان یکی از محدودیت‌های مطالعه حاضر تلقی می‌شود. لذا پیشنهاد می‌گردد در مطالعات آتی، بهینه‌سازی پارامترهای عملیاتی فراصوت به‌صورت چندمتغیره (مانند روش سطح پاسخ) برای هر بستر به‌طور مجزا انجام شود تا پتانسیل بیشینه این فناوری در مقیاس صنعتی بهتر ارزیابی گردد.

جدول ٦- ترکیبات به‌وجودآمده در حین هضم مواد در رآکتور، روابط استوکیومتری مسیرهای سوخت و ساز و انرژی استاندارد گیبس مربوط به هر واکنش

Table 6- Compounds formed during substrate digestion in the reactor, stoichiometric relations of metabolic pathways, and standard Gibbs free energy associated with each reaction

مسیر واکنش Reaction pathway	فرآیند بی‌هوازی Anaerobic process	انرژی گیبس Gibbs free energy ($kJ\ mol^{-1}$)	روابط استوکیومتری Stoichiometric relation
1	بوتیرات‌زایی Butyrate formation	-224	$2C_6H_{12}O_6 + 6H_2O \rightarrow C_4H_8O_2 + 8CO_2 + 18H_2$
2	پروپیونات‌زایی Propionate formation	-473	$C_6H_{12}O_6 + 2H_2 \rightarrow 2C_3H_6O_2 + 2H_2O$
3	استات‌زایی Acetate formation	-100	$C_6H_{12}O_6 + 2H_2O \rightarrow 2C_2H_4O_2 + 2CO_2 + 4H_2$
4	حلال‌زایی اتانول (از گلوکز) Ethanol fermentation (from glucose)	–609	$C_6H_{12}O_6 \rightarrow 2C_2H_6O + 2CO_2$
5	حلال‌زایی اتانول (از استات) Ethanol formation (from acetate)	-37.8	$C_2H_4O_2 + 2H_2 \rightarrow C_2H_6O + H_2O$
6	حلال‌زایی متانول Anaerobic degradation of methanol	–86	$C_6H_{12}O_6 + 6H_2 \rightarrow 6CH_4O$
7	تجزیه بی‌هوازی متانول Anaerobic degradation of methanol	9.14	$CH_4O + H_2O \rightarrow CO_2 + 3H_2$
8	تجزیه بی‌هوازی اتانول Anaerobic degradation of ethanol	97.5	$C_2H_6O + 3H_2O \rightarrow 2CO_2 + 6H_2$
9	متان‌زایی از استات Acetoclastic methanogenesis	-71	$C_2H_4O_2 \rightarrow CH_4 + CO_2$
10	متانوژن‌زایی هیدروژنوتروفیک Hydrogenotrophic methanogenesis	-131	$CO_2 + 4H_2 \rightarrow CH_4 + 2H_2O$
11	هموستوژنز Homoacetogenesis	-59.7	$2CO_2 + 4H_2 \rightarrow C_2H_4O_2 + 2H_2O$

نتیجه‌گیری

نتایج این پژوهش نشان داد که پیش‌تیمار فراصوت می‌تواند نقش مؤثری در بهبود فرایند تخمیر بی‌هوازی زیست‌توده‌های کشاورزی و افزایش تولید بیوهیدروژن داشته باشد. اعمال پیش‌تیمار فراصوت به مدت ۵ دقیقه با توان ۳۰۰ وات موجب افزایش ۵۰/۸۷ درصدی تولید بیوهیدروژن در مقایسه با نمونه‌های بدون پیش‌تیمار شد که این امر احتمالاً به دلیل افزایش دسترسی‌پذیری ترکیبات آلی و تسهیل فعالیت میکروارگانیسم‌ها در محیط تخمیر است. بررسی روند تجمعی گازهای تولیدی نشان داد که استفاده از این پیش‌تیمار علاوه بر افزایش تولید هیدروژن، موجب افزایش حدود ۲/۹ درصدی تولید متان نیز گردید که بیانگر بهبود تجزیه‌پذیری زیستی بسترهای مورد مطالعه است. در میان زیست‌توده‌های بررسی‌شده، پوست موز بیشترین پاسخ را به پیش‌تیمار فراصوت نشان داد و تولید بیوهیدروژن در این بستر حدود ۵۰۰ درصد افزایش یافت. با این حال، در برخی تیمارها کاهش نسبی در تولید متان مشاهده شد که می‌تواند ناشی از حضور یا افزایش ترکیبات آنتی‌باکتریال نظیر فنول‌ها و تانن‌ها در محیط تخمیر پس از اعمال پیش‌تیمار فراصوت باشد. همچنین پاسخ بسترها به پیش‌تیمار فراصوت یکسان نبود و پوست موز بیشترین افزایش در تولید بیوهیدروژن را نشان داد، در حالی‌که تغییرات متان در همه بسترها مشابه نبود. در مجموع، نتایج این تحقیق نشان می‌دهد که پیش‌تیمار فراصوت می‌تواند به‌عنوان روشی مؤثر برای افزایش کارایی تخمیر بی‌هوازی و بهبود تولید بیوهیدروژن از ضایعات کشاورزی موردتوجه قرار گیرد. با این حال، نتایج حاصل نشان‌دهنده یک پاسخ بستر–وابسته است و تعمیم کلی آن به تمامی زیست‌توده‌ها با محدودیت مواجه است.

تعارض منافع

هیچ‌گونه تعارض منافعی توسط نویسندگان بیان نشده است.

مشارکت نویسندگان

محمود محمودی اشکفتکی: نظارت و مدیریت، مفهوم‌سازی، روش‌شناسی، مشاوره فنی
امین لطفعلیان دهکردی: پردازش داده‌ها، تحلیل آماری
حمید خفاجه: استخراج و تهیه متن اولیه، ویرایش متن
سیده حدیثه بهرام شابهرامی: جمع‌آوری داده‌ها

References

1. Deshavath, N. N., Veeranki, V. D., & Goud, V. V. (2019). Lignocellulosic feedstocks for the production of bioethanol: Availability, structure, and composition. In *Sustainable Bioenergy: Advances and Impacts* (pp. 1–19). Elsevier. https://doi.org/10.1016/B978-0-12-817654-2.00001-0
2. Kamali, S. M., Abdi, R., Rohani, A., Abdollahpour, S., & Ebrahimi, S. (2022). Optimization of Biogas Production Efficiency from Anaerobic Digestion of Organic Fraction of Municipal Solid Waste under Thermal Pretreatment at Different Concentrations. *Journal of Agricultural Machinery*, *12*(3), 409-421. https://doi.org/10.22067/jam.2021.68771.1018
3. Kim, D. (2018). Physico-chemical conversion of lignocellulose: Inhibitor effects and detoxification strategies: A mini review. *Molecules*, *23*, 309. https://doi.org/10.3390/molecules23020309
4. Kumar, A. K., & Sharma, S., (2017). Recent updates on different methods of pretreatment of lignocellulosic feedstocks: A review. *Bioresources and Bioprocessing*, *4*, Article 7. https://doi.org/10.1186/s40643-017-0137-9
5. Mahmoodi-Eshkaftaki, M., & Ghani, A. (2022). An efficient process for improvement of biohydrogen and biomethane production from tomato waste: Inhibitory effects of ultrasonic pretreatment. *Fuel*, *328*, 125273. https://doi.org/10.1016/j.fuel.2022.125273
6. Mahmoodi-Eshkaftaki, M., Ebrahimi, R., & Ghasemi-Pirbaloti, A. (2017). Qualitative and quantitative analysis of biogas generated from co-digestion of cow dung, municipal sewage and kitchen waste. *Journal of Agricultural Machinery*, *7*(1), 192-203. https://doi.org/10.22067/jam.v7i1.47760
7. Mahmoodi-Eshkaftaki, M., Rafiee, M. R., & Mahmoudi, M. (2023). Efficiency of ultrasonic pretreatment on improving biodegradability of tomato wastes and increasing biohydrogen production. *BioEnergy Research*, *16*(4), 2590-2603.
8. Mahmoodi-Eshkaftaki, M., & Rahmanian-Koushkaki, H. (2020). An optimum strategy for substrate mixture and pretreatment in biogas plants: Potential application for high-pH waste management. *Waste Management*, *113*, 329-341.
9. Mockaitis, G., Bruant, G., Guiot, S. R., Peixoto, G., Foresti, E., & Zaiat, M. (2020). Acidic and thermal pretreatments for anaerobic digestion inoculum to improve hydrogen and volatile fatty acid production using xylose as the substrate. *Renew Energy*, *145*, 1388-1398. https://doi.org/10.1016/j.renene.2019.06.134
10. Safari, M., & Abdi, R. (2016). Comparison of biogas production from rapeseed and wheat residues in compound with cattle manure. *Journal of Agricultural Machinery*, *6*(2), 476-487. https://doi.org/10.22067/jam.v6i2.45667
11. Sami, M., Akram, A., & Sharifi, M. (2021). Potential evaluation and modeling of biogas production from apple pomace. *Journal of Agricultural Machinery*, *11*(2), 305-316. https://doi.org/10.22067/jam.v11i2.80322
12. Taghinazhad, J., Abdi, R., & Adl, M. (2018). Modeling of biogas production process from cow manure with completely stirred tank reactor under semi continuously feeding. *Journal of Agricultural Machinery*, *8*(1), 159-169. https://doi.org/10.22067/jam.v8i1.57758
13. Tajmirriahi, M., Momayez, F., & Karimi, K. (2020). The critical impact of rice straw extractives on biogas and bioethanol production. *Bioresource Technology*, *319*, 124167. https://doi.org/10.1016/j.biortech.2020.124167
14. Wang, X., Tsang, Y. F., Li, Y., Ma, X., Cui, S., Zhang, T. A., Hu, J. & Gao, M. T. (2017). Inhibitory effects of phenolic compounds of rice straw formed by saccharification during ethanol fermentation by Pichia stipites. *Bioresource Technology*, *244*, 1059-1067. https://doi.org/10.1016/j.biortech.2017.08.096
15. Yalcinkaya, S., & Malina, J. F. (2015). Anaerobic co-digestion of municipal wastewater sludge and un- dewatered grease trap waste for assessing direct feed of grease trap waste in municipal digesters. *International Biodeterioration & Biodegradation,104*, 490-497. https://doi.org/10.1016/j.ibiod.2015.08.007
16. Yang, G., & Wang, J. L. (2019). Ultrasound combined with dilute acid pretreatment of grass for improvement of fermentative hydrogen production. *Bioresource Technology*, *275*, 10-18. https://doi.org/10.1016/j.biortech.2018.12.013

Contents

Research Articles

A Novel Strategy for Classifying Potassium Fertilizer Based on pH Level Using Visible-Near-Infrared Hyperspectral Imaging and Machine Learning 625
M. H. Nargesi, K. Kheiralipour, F. Valizadeh Kakhki, Z. Moradi

Optimisation of Energy and Thermal Parameters in the Drying Process of Modified Starch with Cold Plasma Pretreatment 639
A. Taghavi, A. Ranjbar Nedamani, A. Motevali, S. J. Hashemi

Investigation of the Physicochemical Properties and Essential Oil Quality of Rosa Flower Buds under Different Drying Methods 653
O. R. Roustapour, F. Sefidkon, A. Golshan Tafti, H. R. Gazor

Non-Destructive Prediction of pH in Khormai and Khoni Plums Using a Hyperspectral Imaging System and Machine Learning Methods 669
M. Latifi-Amoghin, Y. Abbaspour-Gilandeh

Estimation of Greenhouse Gas Emission Reduction, Social Costs of Pollutants, and Energy Use Efficiency Improvement in Wheat Cultivation under Site-Specific Management of Chemical Inputs 693
A. Jalilian, M. M. Ghasemi, H. Ghasemi Mobtaker, A. Kaab

Design and Development of an Intelligent Golden Raisin Grading System Based on a Deep Convolutional Neural Network 711
H. Mirkhorasani, M. Abbasgholipour, B. Mohammadi Alasti

Investigation of the Effect of Sensors' Chamber Geometry and Fluid Type on Fluid Flow in the Electronic Nose System Using Computational Fluid Dynamics Simulation 731
A. Altafi, S. S. Mohtasebi, A. Jafari, M. Ghasemi Varnamkhasti

An Integrated Mechatronic Sorting System for Bitter and Sweet Almonds Based on FTIR Spectroscopy of Shells and MLP Neural Network 751
M. Afsharipour, M. Shamsi, F. Ghasemian, H. Khabazzadeh

Improving Anaerobic Fermentation of Agricultural Wastes Using Ultrasonic Pretreatment to Increase Biohydrogen Production: Study of the Metabolic Pathway of Reactions 769
M. Mahmoodi-Eshkaftaki, A. Lotfalian-Dehkordi, H. Khafajeh, S. H. Bahram Shabahrami

Journal of Agricultural Machinery

Vol. 16 **No. 4** **2026**

Published by: Ferdowsi University of Mashhad, (College of Agriculture), Iran

Director-in-Charge: Prof. M. R. Modarres Razavi, Dept. of Mechanical Eng. Ferdowsi University of Mashhad

Editor-in-Chief: Prof. M. H. Abbaspour-Fard, Dept. of Biosystems Eng. Ferdowsi University of Mashhad

Editorial Board:

Abbaspour-Fard, M. H.	Department of Biosystems Engineering, Ferdowsi University of Mashhad, Iran
Aboonajmi, M.	Department of Agrotechnology, College of Abouraihan, University of Tehran, Tehran, Iran
Aghbashlo, M.	Department of Agricultural Machinery Engineering, Faculty of Agricultural Engineering and Technology, University of Tehran, Karaj, Iran
Aghkhani, M. H.	Department of Biosystems Engineering, Ferdowsi University of Mashhad, Iran
Alimardani, R.	Department of Agricultural Machinery Engineering, Faculty of Agricultural Engineering and Technology, University of Tehran, Karaj, Iran
Emadi, B.	Department of Chemical and Biological Engineering, University of Saskatchewan, Saskatoon, Canada
Ghazanfari Moghaddam, A.	Department of Mechanical Engineering of Biosystems, Shahid Bahonar University of Kerman, Iran
Kadkhodayan, M.	Department of Mechanical Engineering, Ferdowsi University of Mashhad, Iran
Khoshtaghaza, M. H.	Department of Biosystems Engineering, Tarbiat Modares University, Tehran. Iran
Loghavi, M.	Department of Biosystems Engineering, Shiraz University, Iran
Modarres Razavi, M.	Department of Mechanical Engineering, Ferdowsi University of Mashhad, Iran
Mohtasebi, S. S.	Department of Agricultural Machinery Engineering, Faculty of Agricultural Engineering and Technology, University of Tehran, Karaj, Iran
Nasirahmadi, A.	Department of Agricultural Engineering University of Kassel, Nordbahnhofstrasse, Witzenhausen, Germany
Raji, A.	Department of Agricultural and Environmental Engineering, Faculty of Technology, University of Ibadan, Nigeria
Rohani, A.	Department of Biosystems Engineering, Ferdowsi University of Mashhad, Iran
Saiedirad, M. H.	Agricultural Engineering Research Institute, Mashhad, Iran
Sayasoonthorn, S	Department of Farm Mechanics, Faculty of Agriculture, Kasetsart University, Thailand

Publisher: Ferdowsi University of Mashhad

Address: College of Agriculture, Ferdowsi University of Mashhad, Iran

P.O. BOX: 91775-1163

Fax: +98-05138787430

E-Mail: jame@um.ac.ir

Web Site: https://jame.um.ac.ir

Ferdowsi University of Mashhad

Journal of Agricultural Machinery

Iranian Society of Mechanical Engineers (ISME)

Vol. 16 No. 4

2026

ISSN: 2228-6829

Contents

Research Articles

A Novel Strategy for Classifying Potassium Fertilizer Based on pH Level Using Visible-Near-Infrared Hyperspectral Imaging and Machine Learning 625
M. H. Nargesi, K. Kheiralipour, F. Valizadeh Kakhki, Z. Moradi

Optimisation of Energy and Thermal Parameters in the Drying Process of Modified Starch with Cold Plasma Pretreatment 639
A. Taghavi, A. Ranjbar Nedamani, A. Motevali, S. J. Hashemi

Investigation of the Physicochemical Properties and Essential Oil Quality of Rosa Flower Buds under Different Drying Methods 653
O. R. Roustapour, F. Sefidkon, A. Golshan Tafti, H. R. Gazor

Non-Destructive Prediction of pH in Khormai and Khoni Plums Using a Hyperspectral Imaging System and Machine Learning Methods 669
M. Latifi-Amoghin, Y. Abbaspour-Gilandeh

Estimation of Greenhouse Gas Emission Reduction, Social Costs of Pollutants, and Energy Use Efficiency Improvement in Wheat Cultivation under Site-Specific Management of Chemical Inputs 693
A. Jalilian, M. M. Ghasemi, H. Ghasemi Mobtaker, A. Kaab

Design and Development of an Intelligent Golden Raisin Grading System Based on a Deep Convolutional Neural Network 711
H. Mirkhorasani, M. Abbasgholipour, B. Mohammadi Alasti

Investigation of the Effect of Sensors' Chamber Geometry and Fluid Type on Fluid Flow in the Electronic Nose System Using Computational Fluid Dynamics Simulation 731
A. Altafi, S. S. Mohtasebi, A. Jafari, M. Ghasemi Varnamkhasti

An Integrated Mechatronic Sorting System for Bitter and Sweet Almonds Based on FTIR Spectroscopy of Shells and MLP Neural Network 751
M. Afsharipour, M. Shamsi, F. Ghasemian, H. Khabazzadeh

Improving Anaerobic Fermentation of Agricultural Wastes Using Ultrasonic Pretreatment to Increase Biohydrogen Production: Study of the Metabolic Pathway of Reactions 769
M. Mahmoodi-Eshkaftaki, A. Lotfalian-Dehkordi, H. Khafajeh, S. H. Bahram Shabahrami