

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. Khairali¹, F. Valizadeh Kakhki², Z. Moradi³

1- Biosystems Mechanical Engineering Department, Faculty of Agriculture, 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)

<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 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

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، ۴۶۹/۹۵، 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 ۴۲-۴-۶ و در حالت استفاده از ویژگی‌های منتخب، دارای ساختار ۷-۴-۴ است. دقت طبقه‌بندی این دو مدل به ترتیب 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

(Allahvirdizadeh & Deljou, 2014; Chen, 2006; Zhao et al., 2016).

یافته‌های پژوهشی نشان می‌دهد که این رویکرد نه تنها موجب افزایش بهره‌وری محصولات می‌گردد، بلکه گامی مؤثر در جهت توسعه کشاورزی ارگانیک و پایدار نیز به‌شمار می‌آید (Griffe, 2003; 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 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.

توجه به جنبه‌های فنی تولید به‌منظور افزایش کمیت محصول، 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 قابل توجهی در کشاورزی ایفا می‌کنند (Perramon, 2016; Bosch-Serra, Domingo, & Boixadera, 2016). کودهای آلی به‌تنهایی قادر به تأمین کامل نیازهای تغذیه‌ای گیاهان نیست (Pandey & Patra, 2015; Siadat & Moradi-Telavat, 2018). از این رو، ترکیب کودهای آلی و شیمیایی به‌عنوان رویکردی مؤثر برای افزایش حاصلخیزی خاک و بهبود عملکرد گیاه، گزینه‌ای امیدبخش برای کشاورزی پایدار محسوب می‌شود.

۳- گروه شیمی، دانشکده علوم پایه، دانشگاه ایلام، ایلام، ایران
(*) نویسنده مسئول: (Email: mohamadhosseini.73@gmail.com)
<https://doi.org/10.22067/jam.2025.93983.1394>

۱- گروه مهندسی مکانیک بیوسیستم، دانشکده کشاورزی، دانشگاه ایلام، ایلام، ایران
۲- دکتری محیط‌زیست گرایش آلودگی‌های محیطی، ایلام، ایران

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, 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 داده‌های پیچیده در نظر گرفته می‌شود (Kheiralipour, Ahmadi, Rajabipour, & Rafiee, 2018; Kheiralipour, Sajadipour, & Nargesi, 2025; Lin, Ma, Wang, & Sun, 2023). در تحقیقی شوتنه 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.


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 شنبليله، 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 چغندر قند 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 قابل انجام 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

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.

نمونه‌های کود پتاسیم از شرکت مجتمع صنایع شیمیایی ایوان، 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،



شکل ۱- مراحل پژوهش

Fig. 1. Research steps

(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

تصویربرداری فراطیفی مرئی-فروسرخ نزدیک


یک سامانه تصویربرداری فراطیفی معمولاً 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, 2023a; 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,)

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 20×40 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 به منظور 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، مؤثرترین 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 مؤثر و استخراج ویژگی

پس از انجام مرحله پیش‌پردازش تصاویر، فرآیند انتخاب طول‌موج‌های مؤثر انجام شد. برای این منظور، از روش تحلیل مؤلفه‌های اصلی^۱ (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., 2015b).

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، مجموعه‌ای از ویژگی‌های کارآمد بود (Bagherpour, Fatehi, Shojaeian, & Bagherpour, 2025; Hosainpour, Kheiralipour, Nadimi, & Paliwal, 2022; Khazaei, Kheiralipour, Hosainpour, Javadikia, & Paliwal, 2022; Kheiralipour, 2022). این روش بر پایه معیار انحراف برازش عمل

نتایج و بحث

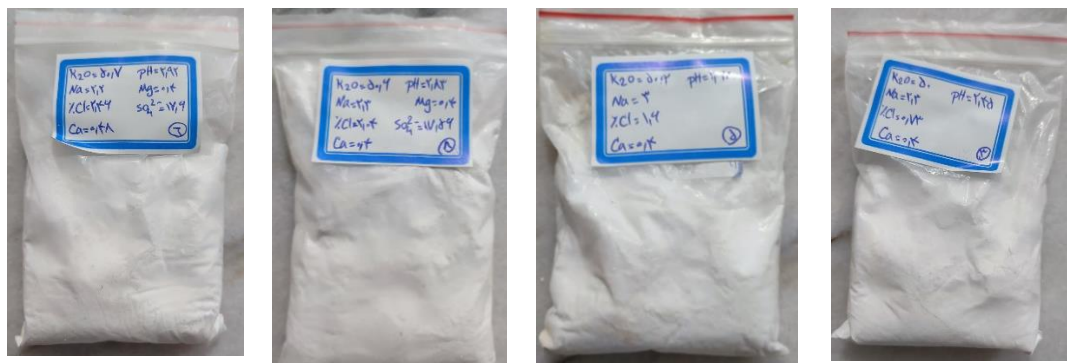
میزان pH نمونه‌ها

میزان pH چهار نمونه کود پتاسیم با استفاده از روش آزمایشگاهی اشاره‌شده در بخش مواد و روش‌ها اندازه‌گیری شد. محدوده اندازه‌گیری شده pH نمونه‌ها ۲/۵، ۲/۶، ۲/۸، و ۲/۹ بود (Pahalvi, Rafiyya, Rashid, Nisar, & Kamili, 2021). بر این اساس، نمونه‌ها برای تصویربرداری آماده شدند (شکل ۳). 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 از pH متر مدل PH 500، 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 دی‌یونیزه (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، الکتروود pH 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).

می‌کند که با محاسبه مجموع تعمیم‌یافته مجذور باقیمانده‌ها، ویژگی‌های مؤثر را تعیین می‌کند (Kheiralipour et al., 2021; Kheiralipour et al., 2023a; 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 به ترتیب 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, 2015a; Salam et al., 2022). این داده‌ها به‌طور تصادفی به سه مجموعه (۶۰، ۲۰، و ۲۰ درصد) به ترتیب برای آموزش، اعتبارسنجی و آزمون تقسیم شدند (Khazaei et al., 2022; Nargesi & Kheiralipour, 2024; Nargesi et al., 2024c).



شکل ۳- آماده‌سازی نمونه‌های آزمایش

Fig. 3. Preparation of test samples


نمودارها، کانال‌های مؤثر تصویر شناسایی و انتخاب شدند. سپس با استفاده از این کلنال‌ها، طول موج‌های متناظر و بهینه در تصاویر فراطیفی تعیین گردیدند. کلنال‌های انتخاب‌شده برای چهار سطح مختلف pH عبارتند از: ۶۵، ۳۲۷، ۳۳۴، ۴۸۲، ۵۱۰، ۶۰۷، ۶۴۴ که در شکل ۴ به‌طور مشخص قابل مشاهده‌اند. طول موج‌های مؤثر متناظر با این کلنال‌ها به ترتیب برابر با ۴۵۳/۳۲، ۴۵۳/۳۲، ۶۶۹/۹۵، ۶۷۵/۷۴، ۷۹۸/۱۱، ۸۲۱/۲۶ و ۹۰۱/۴۷ و ۹۳۲/۰۶ نانومتر بودند. برای استخراج ویژگی‌های

طول موج‌های مؤثر

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 قابل مشاهده است، مقادیر مؤلفه‌های اصلی در سطوح مختلف pH تفاوت قابل توجهی دارند که نشان‌دهنده تأثیر شرایط pH بر اطلاعات طیفی است. بر اساس پیک‌های برجسته موجود در این

فرآیند طبقه‌بندی سطوح مختلف pH مورد استفاده قرار گرفتند.

مؤثر از این طول‌موج‌های منتخب، از هر طول‌موج شش ویژگی استخراج شد. در نتیجه، در مجموع ۴۲ ویژگی حاصل گردید که در




شکل ۴- 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


شش به‌دست آمد (شکل ۵-الف). بهترین عملکرد اعتبارسنجی شبکه در دور شماره ۱۳ با مقدار $0.314 \pm$ مشاهده گردید (شکل ۵-ب). ضرایب همبستگی طبقه‌بندی شبکه عصبی مصنوعی برای داده‌های آموزش، اعتبارسنجی، آزمون، و تمام داده‌ها به ترتیب 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 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



(الف) (a)



(ب) (b)



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

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.

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

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

طبق جدول ۱، میانگین مقادیر ویژگی میانگین در طول موج ۷۹۸/۱۱ نانومتر برای تمامی سطوح pH در بازه $97/7 \times 10^{-3}$ تا

طبق جدول ۱، میانگین مقادیر ویژگی میانگین در طول موج


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 به ترتیب ۹۹/۵۲، ۹۰/۲۵، ۹۲/۲۵ و ۹۶/۳۰ بود. در ماتریس اغتشاش (شکل ۶-د)، طبقات شماره ۱، ۲، ۳ و ۴ به ترتیب 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.




(الف) (a)

$99/5 \times 10^{-3}$ قرار داشت که کمترین و بیشترین مقادیر آن به ترتیب 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 به ترتیب $83/1 \times 10^{-3}$ ، $93/1 \times 10^{-3}$ ، $86/5 \times 10^{-3}$ و $90/7 \times 10^{-3}$ بود. همچنین در همین طول موج، کمترین مقدار میانگین ویژگی میانگین معادل $96/5 \times 10^{-3}$ برای pH برابر با ۲/۸ و بیشترین مقدار معادل $99/0 \times 10^{-3}$ 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 به ترتیب $96/9 \times 10^{-3}$ ، $96/6 \times 10^{-3}$ ، $97/3 \times 10^{-3}$ و $98/4 \times 10^{-3}$ بود. برای ویژگی واریانس نیز مقادیر به ترتیب $3/9 \times 10^{-3}$ ، $10/1 \times 10^{-3}$ و $2/8 \times 10^{-3}$ مشاهده شد. در طول موج ۹۳۲/۰۶ نانومتر، میانگین ویژگی در محدوده $95/3 \times 10^{-3}$ تا $98/6 \times 10^{-3}$ 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



(ب) (b)



شکل ۶- 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

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 بالادرنج برای طبقه‌بندی آنالین پارامتر شیمیایی pH در کود پتاسیم را برجسته می‌کند. چنین سیستمی می‌تواند زمان و هزینه ارزیابی را به‌طور قابل توجهی 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 ایوان به‌خاطر فراهم کردن شرایط لازم اجرای این پژوهش قدردانی می‌شود.

تعارض منافع

هیچ‌گونه تعارض منافی 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.

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 لد (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 تحقیقاتی که گزارش شده 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 کنند. 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

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

- 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>
- 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>
- Allahvirdizadeh, N., & Deljou, M. N. (2014). Effect of humic acid on morph-physiological traits, nutrients uptake and postharvest vase life of pot marigold cut flower (*Calendula officinalis* cv. Crysanth) in hydroponic system. *Journal of Science Technology of Greenhouse Culture*, 5(18), 133-143. (in Persian with English abstract). <https://dorl.net/dor/20.1001.1.20089082.1393.5.2.12.6>
- 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.
- 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>
- Aviara, N. A., Liberty, J. T., Olatunbosun, O. S., Shoyombo, H. A., & Oyeniya, 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>
- 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>
- 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.
- 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>
- 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>
- 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>
- 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.
- 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>
- 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>
- 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>
- 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>
- Khazaei, 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>
- Kheiralipour, K. (2024). *The future of imaging technology*. Nova Science Publishers, Hauppauge, New York, USA. ISBN 979-8-89530-078-7.
- 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. (2015a). 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, Mashhad, Iran.
24. Kheiralipour, K., Ahmadi, H., Rajabipour, A., Rafiee, S., Javan-Nikkhah, M., Jayas, D. S., & Siliveru, K. (2015b). 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. (2023a). *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 adulteration 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.20.139.109>
 42. Pahalvi, H. N., Rafiyya, 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 Qualit*, 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>