

برآورد میزان اکسید پتاسیم در کود پتاس با استفاده از روش‌های پردازش تصویر فراطیفی و

یادگیری ماشین

چکیده

برای افزایش بهره‌وری کشاورزی، مدیریت حاصلخیزی خاک و تأمین عناصر مغذی از جمله پتاسیم بسیار مهم است. پتاسیم نقش حیاتی در رشد گیاه و فرایندهای فیزیولوژیکی دارد؛ اما مصرف نامتعادل آن می‌تواند باعث کاهش کیفیت خاک یا اتلاف شود. روش‌های متداول اندازه‌گیری میزان اکسید پتاسیم پرهزینه و زمان‌بر هستند؛ بنابراین نیاز به روش‌های سریع، دقیق و مقرون به صرفه احساس می‌شود. هدف از این تحقیق، تشخیص میزان اکسید پتاسیم در کود پتاس بر اساس تصاویر فراطیفی است. پس از اکتساب تصاویر فراطیفی و پردازش آن‌ها، با استفاده از روش شبکه‌های عصبی مصنوعی و با دو رویکرد با و بدون انتخاب ویژگی طبقه‌بندی شدند. در رویکرد اول، تمامی ویژگی‌های استخراج‌شده از کانال‌های مؤثر تصاویر فراطیفی مستقیماً به عنوان ورودی مدل‌های طبقه‌بند به کار گرفته شدند؛ اما در رویکرد دوم، تنها ویژگی‌های منتخب وارد فرآیند طبقه‌بندی شدند. نتایج نشان داد که مدل شبکه عصبی مصنوعی بر اساس تمام ویژگی‌های استخراجی (۹۲/۹ درصد) بالاتر از ویژگی‌های منتخب (۹۱/۳ درصد) بود. روش پیشنهادی در تحقیق حاضر می‌تواند در آینده برای تشخیص سایر عناصر شیمیایی در کود پتاس مورد استفاده قرار گیرد. این روش، ابزاری کارآمد برای ارزیابی سریع و غیرمخرب ترکیب کودها ارائه می‌دهد.

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

Estimation of Potassium Oxide Content in Potash Fertilizer Using Hyperspectral Image Processing and Machine Learning Methods

Introduction

Soil fertility is a key factor in crop production, and potassium (K) is one of the most essential macronutrients for plant growth and development. It plays a crucial role in enzyme activity, photosynthesis, and plant resistance to diseases. Potassium fertilizers are classified into chlorine-containing (e.g., KCl) and chlorine-free (e.g., K_2SO_4) types, with the latter being more beneficial for chlorine-sensitive crops. Potassium sulfate (K_2SO_4) is produced through various methods, but laboratory-based determination is costly and time-consuming. Therefore, developing precise, fast, and cost-effective tools for measuring K_2SO_4 is essential. This study

focuses on implementing an accurate, rapid, and economical method for estimating potassium sulfate content.

Materials and Methods

This study was conducted in the Image Processing Laboratory at Ilam University. To determine the potassium oxide (K_2O) level, seven different concentrations were analyzed. The measurement of potassium oxide in the laboratory was performed using a flame photometer. The required images were captured through hyperspectral imaging using a line-scanning method. Six hyperspectral images were taken for each sample, resulting in 18 images per concentration and a total of 126 images per impurity. Image analysis and processing were carried out using MATLAB software, including wavelength selection, feature extraction, and selection of effective features. Finally, the selected features were classified using an artificial neural network (ANN).

Results and Discussion

The results showed that the artificial neural network (ANN) classifier achieved a classification accuracy of 91.3% using selected features from hyperspectral images of potash fertilizer and 92.9% using all extracted features. The proposed method offers high accuracy and reliability, along with advantages over laboratory-based techniques, such as being non-destructive, fast, simple, and cost-effective. This approach can also be utilized in the future for detecting other chemical elements in potash fertilizer.

Conclusions

This study examined the detection of different percentages of K_2O in potash fertilizer using hyperspectral image processing. Classification was performed using an artificial neural network (ANN) with two strategies: with and without feature selection. The classification accuracy was 91.3% with feature selection and 92.9% without it. The proposed method offers high accuracy and reliability while being non-destructive, fast, simple, and cost-effective compared to laboratory-based techniques. Additionally, it has the potential to be expanded for identifying other chemical elements in potash fertilizers.

Author Contributions

M.H. Nargesi: Conceptualization, investigation, software, formal analysis, data curation, writing-original draft preparation, K. Kheiralipour: methodology, software, resources, writing-review and editing. All authors have read and agreed to the published version of the manuscript.

Data Availability Statement

Data available on request from the authors.

Acknowledgements

The authors would like to thank all participants of the present study.

Ethical considerations

The subject of plagiarism has been considered by the authors and this article is without problem.

Conflict of interest

The author declares no conflict of interest.

مقدمه

برای رسیدن به بالاترین میزان تولید محصول در مزرعه، حاصلخیزی خاک یکی از عوامل کلیدی است که باید در مناطق کشت مورد توجه و پایش قرار گیرد (Brunetto et al., 2022; Barbosa et al., 2025). مواد مغذی نقش اساسی در حاصلخیزی خاک و رشد و توسعه گیاهان دارند، پتاسیم (K) به عنوان یکی از حیاتی‌ترین عناصر غذایی، از اصلی‌ترین درشت مغذی‌ها برای گیاهان محسوب می‌شوند (Shrestha et al., 2020). اقدامات زراعی مانند مدیریت مناسب کوددهی پتاسیم می‌تواند مقاومت گیاهان در برابر بیماری‌ها را افزایش دهد (Manzoor et al., 2017; Esa et al., 2025). پتاسیم نقشی حیاتی در عملکرد ده‌ها آنزیم ضروری، مانند سنتز پروتئین، انتقال قند، متابولیسم نیتروژن و فتوسنتز دارد و رشد بهینه گیاه را تضمین می‌کند (Xu et al., 2020). پتاسیم دومین ماده مغذی پس از نیتروژن است که بیشترین میزان جذب را توسط گیاهان دارد، به طوری که حدود ۳۰ درصد از پتاسیم جذب شده از طریق برداشت غلات از خاک خارج می‌شود. مصرف ناکافی کود پتاسیم می‌تواند منجر به کاهش ذخایر پتاسیم در خاک شود، در حالی که مصرف بیش از حد آن ممکن است تلفات ناشی از شستشو را حتی در خاک‌هایی با ظرفیت تبادل کاتیونی متوسط تا بالا تشدید کند. حفظ تعادل مناسب در استفاده از پتاسیم برای جلوگیری از این مشکلات ضروری است (Rodrigues et al., 2014).

کودهای پتاسیمی به دو گروه اصلی تقسیم می‌شوند: کودهای حاوی کلر (مانند کلرید پتاسیم) و کودهای بدون کلر. کلرید پتاسیم (KCl)، یک کود حاوی کلر، ممکن است برای برخی محصولات زراعی مضر باشد؛ زیرا موجب افزایش pH و شوری خاک می‌شود. در مقابل، سولفات پتاسیم (K_2SO_4)، یک کود باکیفیت و بدون کلر، برای محصولات حساس به کلر مانند تنباکو، چای، سیب‌زمینی، هندوانه و چغندر قند بسیار مفید است (Shabbir Dar et al., 2021; Ahmad et al., 2018). تولید K_2SO_4 از سه روش اصلی انجام می‌شود: فرآیند مانهایم شامل واکنش کلرید پتاسیم با اسید سولفوریک است، واکنش کلرید پتاسیم با کلرید پتاسیم سولفات و پردازش منابع طبیعی حاوی سولفات و پتاسیم می‌باشد (Efraim et al., 1996; Giambra et al., 2005; Mientka et al., 2007).

Taboada et al., 2003; Zisner et al., 1996; Nargesi et al., 2024). کله، به عنوان یکی از اجزای اصلی کودها، بر رشد گیاه و حاصلخیزی خاک تأثیر می‌گذارد و به همین دلیل، باید به دقت کنترل شود. آزمایش‌های مرسوم برای تعیین سولفات پتاسیم نیازمند تجهیزات آزمایشگاهی، نیروی متخصص، و هزینه‌های بالا است. از این رو، برای تولید پایدار، علاوه بر بهبود عملکرد فنی، کاهش هزینه‌های عملیاتی اهمیت زیادی دارد (Kheiralipour, 2022). در این راستا، توسعه ابزارهای دقیق، سریع و مقرون به صرفه برای اندازه‌گیری درصد اکسید پتاسیم ضروری به نظر می‌رسد. هدف این تحقیق، پیاده سازی روشی سریع، دقیق، و اقتصادی برای تخمین میزان اکسید پتاسیم است.

یک سامانه تصویربرداری فراطیفی (HSI) شامل اجزای کلیدی است که داده‌های طیفی دقیق را ثبت و تحلیل می‌کند. برخلاف دوربین‌های معمولی که تنها کانال‌های سه‌گانه رنگی (RGB) را ضبط می‌کنند، حسگرهای فراطیفی داده‌هایی را در باندهای باریک و پیوسته طیفی ثبت می‌کنند (Sun et al., 2024b; Kheiralipour & Jayas, 2024). راه‌اندازی یک سامانه ماشین بینایی پیشرفته رومیزی HSI مستلزم استفاده از یک منبع نور، ابزارهای پخش کننده طول موج، آشکارسازهای ناحیه‌ای و یک رایانه مجهز به نرم‌افزار برای مدیریت ثبت تصویر و پردازش داده‌ها است (Kheiralipour et al., 2023a; Qin et al., 2013; Ismail et al., 2023; Min et al., 2023). این سامانه ماشین بینایی به یک دوربین موتوری اسکن خطی مجهز بود که امکان ثبت تصاویر فراطیفی در نواحی خاص را فراهم می‌کرد. اجزای اصلی این سامانه ماشین بینایی شامل یک دوربین فراطیفی، منبع نور و کامپیوتر شخصی بودند که توسط نرم‌افزار اختصاصی برای کنترل فرآیند تصویربرداری و عملیات بعدی مانند رقومی سازی و ذخیره‌سازی داده‌ها پشتیبانی می‌شود.

فناوری سنجش نوری در سال‌های اخیر به عنوان ابزاری بالقوه برای تحلیل غیرمخرب و ارزیابی کیفیت و سلامت مواد غذایی پیشرفت قابل توجهی داشته و اکنون به مرحله‌ای رسیده است که قابل دسترس و استفاده می‌باشد. به ویژه با ترکیب روش‌های طیف‌سنجی و تصویربرداری در یک سامانه یکپارچه که قادر به ایجاد نقشه فضایی از تغییرات طیفی است، تصویربرداری فراطیفی به طور گسترده مورد تحقیق و توسعه قرار گرفته است. این فناوری تاکنون منجر به کاربردهای موفق بسیاری در زمینه ارزیابی کیفیت محصولات کشاورزی مانند شناسایی آسیب‌های مکانیکی، آلودگی‌های باکتریایی و سایر آلودگی‌ها شده است (Wu and Sun, 2013; ElMasry et al., 2012). بازدهی این روش به طور چشمگیری از دیگر روش‌های تصویربرداری بهتر است؛ چرا که هر پیکسل در سطح تصویر نمایانگر اثر طیفی خاص همان شیء در آن نقطه است (Li et al., 2002). محدوده کاربردهای این

روش بسیار وسیع است و از کاربردهای کشاورزی دقیق مانند شناسایی تنش گیاهان یا آلودگی محصولات گرفته تا حوزه‌های پزشکی و ارزیابی کیفیت محصولات کشاورزی و سنجش کیفیت و طبقه‌بندی مواد غذایی را شامل می‌شود (Khazaii, 2010; Kheiralipour et al., 2018; Kheiralipour et al., 2023). روش تصویربرداری فراطیفی در تحلیل مواد کشاورزی و غذایی کاربردهای گسترده‌ای دارد (Kumar et al., 2016; Kheiralipour & Jayas, 2023a; Kheiralipour & Jayas, 2023b; Kheiralipour et al., 2023c). و همچنین تصویربرداری فراطیفی در بررسی محصولات کشاورزی مانند آرد (Nargesi et al., 2024a)، گندم (Singh, 2009)، مرکبات (Li et al., 2013; Gomez-Sanchis et al., 2008)، پودر ادویه (Nargesi & Kheiralipour, 2024b)، دارچین (Nargesi et al., 2024c)، تقلب در پودر فلفل سیاه و قرمز (Nargesi & Kheiralipour, 2024c)، برنج (Siripatrawan & Makino, 2015)، پسته (Kheiralipour et al., 2015)، و تقلب در ادویه‌ها (Nargesi, 2024) استفاده شده است. برای تعیین میزان کلر موجود در پتاس از طبقه‌بندی شبکه عصبی مصنوعی با تصویربرداری فراطیفی استفاده شد (Nargesi et al., 2024).

با توجه به اهمیت بالای تعیین میزان اکسید پتاسیم (K_2O) کود پتاس و مزایا و کاربردهای فناوری تصویربرداری فراطیفی، هدف از تحقیق حاضر طراحی الگوریتم پردازش تصاویر فراطیفی به منظور سنجش میزان K_2O کود پتاس است. در این تحقیق قابلیت تشخیص الگوریتم طراحی شده همراه با مدل طبقه‌بندی مبتنی بر شبکه عصبی مصنوعی در تشخیص میزان اکسید پتاسیم K_2O در کود پتاس با سطوح مختلف بررسی شده است.

مواد و روش‌ها

آماده کردن نمونه‌ها

نمونه‌های سولفات پتاسیم با درصدهای مختلف اکسید پتاسیم از شرکت مجتمع صنایع شیمیایی ایوان واقع در استان ایلام تأمین گردید. هر نمونه به میزان ۵۰ گرم وزن‌کشی شده و در کیسه‌های مجزا بسته‌بندی شد. پس از آماده‌سازی نمونه‌های آزمایش، مقدار K_2O موجود در سولفات پتاسیم با استفاده از نورسنج شعله (فلیم فلومتر) (مدل: PFP7/C، ساخت شرکت: Jenway، ساخت کشور انگلستان) اندازه‌گیری شد (شکل ۱). در ادامه، برای انجام آزمایش ۵۰ گرم از نمونه آماده شده در کیسه زیپ‌دار ریخته شد. تا برای مرحله تصویربرداری فراطیفی مورد استفاده قرار گیرند (شکل ۱).

تصویربرداری فراطیفی


تصویربرداری فراطیفی یک فرامکعب داده‌ای ایجاد می‌کند که شامل تعداد زیادی متغیر است. برای استخراج و تفسیر اطلاعات ارزشمند از این داده‌های طیفی، انجام عملیات پردازش تصویر ضروری است (Nobari Moghaddam et al., 2022). در این تحقیق،

از یک سامانه تصویربرداری فراطیفی در محدوده طول موج ۴۰۰ تا ۹۵۰ نانومتر (مدل اسپکام^۱ شرکت پرتو صنعت، زنجان، ایران) برای تصویربرداری نمونه‌ها استفاده شد (شکل ۱). برای هر نمونه، شش تصویر فراطیفی ثبت شد. بنابراین، برای هر سطح متفاوت K2O، تعداد ۱۸ تصویر ثبت شد و در مجموع ۱۲۶ تصویر فراطیفی برای تمامی سطوح مختلف تهیه گردید. برای تجزیه و تحلیل این تصاویر فراطیفی، از نرم‌افزار MATLAB نسخه ۲۰۱۶ (شرکت متورکس، کارلس‌بد، کالیفرنیا، آمریکا^۲) استفاده شد. همچنین، یک الگوریتم برای پردازش تصاویر فراطیفی طراحی و در محیط نرم‌افزار MATLAB کدنویسی گردید.

ویژگی‌های فراطیفی

^۱ Specam

^۲ MathWorks Inc., Carlsbad, California, USA.



شکل ۱. روندنمای پژوهش.

به منظور پردازش تصاویر فراطیفی به دست آمده، ابتدا فرایند پیش‌پردازش بر روی تصاویر انجام شد. با توجه به اینکه طیف اصلی به دست آمده از تصویربرداری فراطیفی ممکن است تحت تأثیر عواملی همچون پراکندگی نور، نویز تصادفی و نویز سامانه قرار گیرد، این مسائل می‌توانند سیگنال طیفی را تضعیف کرده و عملکرد مدل‌ها را کاهش دهند. بنابراین، پیش‌پردازش تصاویر به عنوان گام ابتدایی در پردازش تصاویر فراطیفی اهمیت ویژه‌ای دارد (Farokhzad et al., 2020; Arjomandi et al., 2022). سطوح غیر یکنواخت نمونه‌های جامد اغلب منجر به پراکندگی نور و ایجاد اثرات افزایشی و ضربی می‌شوند. این اثرات پراکندگی را می‌توان با بهره‌گیری از الگوریتم‌های مبتنی بر طول موج مؤثر و ویژگی‌های کارآمد اصلاح کرد (Malavi et al., 2024). در این مرحله، الگوریتمی در نرم‌افزار متلب طراحی و پیاده‌سازی گردید. بخش مرکزی تصاویر برش داده شد تا برای مراحل بعدی آماده شود. به منظور بهبود عملکرد پیش‌بینی و کاهش پیچیدگی، کاهش حجم داده‌های ورودی ضروری است. بنابراین، در مرحله بعد، مؤثرترین طول موج‌ها از تصاویر انتخاب شدند (Nargesi et al., 2024; Kheiralipour et al., 2014; Arif Chaudhry et al., 2025).

تحلیل مؤلفه‌های اصلی

از روش تحلیل مؤلفه‌های اصلی (PCA) برای تجزیه و تحلیل این داده‌های با ابعاد بالا با استفاده شد. هدف از این تحلیل، کاهش ابعاد داده‌ها ضمن حفظ مهم‌ترین واریانس، و امکان شناسایی باندهای طیفی کلیدی مرتبط بود. این رویکرد امکان ارزیابی کامل عملکرد مدل را فراهم کرد و اطمینان حاصل کرد که نتایج قابل اعتماد و قابل تعمیم هستند (Patiluna et al., 2025). این تعداد بهینه بر اساس قله موج توضیح داده شده و توانایی تمایز بین سطوح مختلف K_2O تعیین شد.

انتخاب طول موج مؤثر

در این مرحله، از روش تحلیل مؤلفه‌های اصلی PCA برای انتخاب طول موج‌های کارا استفاده شد. بر اساس محاسبه میانگین مؤلفه‌های اصلی اول (PC1) و دوم (PC2)، طول موج‌های مؤثر از فرامکعب بر مبنای پیک منحنی‌های PC1 و PC2 انتخاب گردید (Fernandez et al., 2019; Hasan et al., 2022).

استخراج ویژگی کارآمد


پس از انتخاب طول موج‌های مناسب، ویژگی‌های مختلفی از کانال‌های مربوط به این طول موج‌ها استخراج شد. این ویژگی‌ها شامل میانگین، حداقل، حداکثر، میانه، واریانس و انحراف معیار بودند (جدول ۱) (Kheiralipour, 2012; Kheiralipour et al., 2012).

(2014; Singh et al., 2009). در مواردی که تعداد ویژگی‌های استخراج شده زیاد باشد، از روش‌های کاهش ابعاد داده استفاده شد. کاهش تعداد متغیرهای ورودی، به ویژه در شرایطی که تعداد آن‌ها بالا باشد، نقش مهمی در دستیابی به عملکرد طبقه‌بندی بهینه دارد. در این پژوهش، مجموعه‌ای از ویژگی‌ها به عنوان ویژگی‌های کارا از میان تمامی ویژگی‌های استخراج شده، با استفاده از روش انتخاب ویژگی متوالی شناسایی شد (Hosainpour et al., 2022; Khazaei et al., 2022; Kheiralipour & Nargesi, 2024). تشخیص درصد‌های مختلف K_2O در کود پتاس با استفاده از روش شبکه عصبی مصنوعی مورد بررسی و ارزیابی قرار گرفتند. در ادامه، ویژگی‌های استخراج شده برای تحلیل‌های بیشتر به کار گرفته می‌شوند و می‌توان از آن‌ها برای طبقه‌بندی یا پیش‌بینی اهداف خاص بهره برد. روش‌های متنوعی برای طبقه‌بندی و پیش‌بینی ویژگی‌های تصاویر فرایندی وجود دارد که کاربردهای گسترده‌ای در این حوزه دارند (Kheiralipour et al., 2023b; Kheiralipour & Nargesi, 2024; Salam & Kheiralipour, 2022; Kheiralipour & Jayas, 2023c; Kheiralipour et al., 2022; Salam et al., 2022; Kheiralipour et al., 2013). در این روش داده‌های ورودی برای شبکه‌ها مقادیر ویژگی‌های همه تصاویر و داده‌های هدف کدهای مربوط به کلاس‌ها (K_2O سطوح) بودند. داده‌ها به طور تصادفی به سه مجموعه شامل آموزش (۶۰٪)، اعتبارسنجی متقابل (۲۰٪) و آزمون (۲۰٪) تقسیم شدند. (Kheiralipour & Marzbani, 2016; Azadnia & Kheiralipour, 2022; Moosavian, 2012; Nargesi & Kheiralipour, 2024). (Kheiralipour, 2024; Nargesi et al., 2024).

نتایج و بحث

کانال‌های مؤثر تصاویر فرایندی

نمودارهای مولفه‌های اصلی اول و دوم تصاویر فرایندی نمونه‌های سولفات پتاسیم با درصد‌های مختلف K_2O در تمام طول موج‌ها، برای هفت سطح مختلف شامل ۵۰، ۵۰/۱، ۵۰/۲، ۵۰/۴، ۵۰/۵، ۵۰/۶ و ۵۰/۷ درصد، در شکل ۲ محاسبه شدند. قله‌های شناسایی شده در این نمودارها به عنوان کانال‌های مؤثر تعیین شدند. بر اساس شکل ۲، کانال‌های مؤثر مرتبط با درصد‌های مختلف (K_2O) شامل ۶۵، ۳۱۹، ۳۲۷، ۴۷۰، ۵۴۲، ۵۶۸ و ۵۹۵ می‌باشند. طول موج‌های متناظر با این کانال‌ها به ترتیب برابر با ۴۵۳/۳۲، ۶۶۳/۳۴، ۶۶۹/۹۵، ۷۷۸/۱۹، ۸۴۷/۷۲، ۸۶۹/۲۲ و ۸۹۱/۵۵ نانومتر است. این طول موج‌های مؤثر، تفاوت میان درصد‌های مختلف K_2O را به خوبی مشخص می‌کنند و بنابراین، برای انتخاب ویژگی مورد استفاده قرار گرفته‌اند.



شکل ۲. نمودار مولفه‌های اصلی اول و دوم برای کود پتاس.

استخراج ویژگی

شش ویژگی از هر کانال موثر تصاویر فراطیفی انتخاب شد. با انتخاب هفت طول موج موثر، در مجموع ۴۲ ویژگی استخراج شد. ویژگی‌های استخراج شده از طول موج‌های موثر در جدول ۱ نشان داده شده است. ویژگی‌های کارآمد برای طبقه‌بندی انتخاب، و بقیه ویژگی‌ها حذف شدند.

جدول ۱. ویژگی‌های انتخاب شده برای تشخیص سطوح K₂O در سولفات پتاسیم.


ویژگی کارا	طول موج موثر (نانومتر)
میانگین	۴۵۳/۳۲
حداقل	۶۶۳/۳۴
میانگین	۶۶۹/۹۵
حداقل	۷۷۸/۱۹
میانگین	۸۴۷/۷۲
واریانس	۸۶۹/۲۲
میانگین	۸۹۱/۵۵

شبکه‌های عصبی مصنوعی

طبقه‌بندی تصاویر فراطیفی بر اساس دو راهبرد با و بدون انتخاب ویژگی صورت گرفت. در راهبرد بدون انتخاب ویژگی تمام ویژگی‌های استخراج شده از تصاویر فراطیفی در کانال‌های موثر به عنوان ورودی مدل‌های طبقه‌بند مورد استفاده قرار گرفتند. در راهبرد با انتخاب ویژگی، تنها ویژگی‌های کارا برای طبقه‌بندی استفاده شدند.


طبقه‌بندی بر اساس تمام ویژگی‌های استخراج شده

مدل بهینه در طبقه‌بندی نمونه‌های مختلف کد پتاس در شکل ۳ آمده است. تابع فعال‌سازی لایه میانی از نوع $\tanh$ و تابع فعال‌سازی لایه خروجی از نوع purelin به کار گرفته شد. در مدل بهینه طبقه‌بندی، تعداد نورون‌ها در لایه ورودی برابر با ۴۲ (تعداد کل ویژگی‌های کارا)، در لایه خروجی نیز برابر با ۷ (سطوح مختلف K_2O) و در و تعداد نورون‌ها در لایه پنهان شش نظر گرفته شد. بالاترین نرخ طبقه‌بندی صحیح توسط ساختار ۷-۶-۴۲ به دست آمد.




شکل ۳. ساختار شبکه عصبی مصنوعی بهینه در تشخیص درصد‌های مختلف K_2O بر اساس تمام ویژگی‌های استخراج شده.

عملکرد شبکه در مرحله اعتبارسنجی برای تعداد تکرارهای مختلف در شکل ۴ آمده است. مشاهده می‌شود که بعد از اجرای شبکه، کمترین خطای اعتبارسنجی در تکرار ۱۸ برابر با ۰/۰۴۰۹ است.



شکل ۴. نمودار عملکرد شبکه عصبی مصنوعی در مرحله اعتبارسنجی در تشخیص درصد‌های مختلف K_2O بر اساس تمام ویژگی‌های استخراج شده.

هر چه همبستگی بین متغیرهای ورودی و خروجی قوی باشد، طبقه‌بندی دقیق‌تر خواهد بود. ضریب همبستگی شبکه عصبی مصنوعی بهینه در مراحل آموزش، اعتبارسنجی، آزمون، و کل در شکل ۵ نشان داده شده است. همانگونه که مشاهده می‌شود، ضریب همبستگی شبکه بهینه در مراحل آموزش، اعتبارسنجی، آزمون، و کل به ترتیب برابر ۹۶/۹۵، ۸۲/۴۸، ۷۰/۸۰، و ۸۸/۲۷ می‌باشد.



شکل ۵. نمودارهای رگرسیون شبکه عصبی مصنوعی بهینه در تشخیص درصدهای مختلف K_2O بر اساس تمام ویژگی‌های استخراج شده.

در شکل ۶ ماتریس اغتشاش مربوط به طبقه‌بند بهینه به روش شبکه عصبی مصنوعی نشان داده شده است. همان طور که در این شکل نشان داده شده است، طبقه‌بند قادر بوده است از بین ۱۸ نمونه مربوط به طبقه اول، دوم و هفتم تمامی نمونه‌ها را به درستی شناسایی کند. در طبقه سوم و چهارم تعداد سه نمونه را به اشتباه تشخیص داده است و همچنین در طبقه پنجم تعداد شانزده نمونه را از بین هجده نمونه به درستی طبقه‌بندی کرده است. در طبقه ششم تنها یک نمونه را به اشتباه در طبقه هفتم قرار داده است. می‌توان گفت مدل طبقه‌بند به روش شبکه عصبی مصنوعی توانسته است با نرخ طبقه‌بندی ۹۲/۹ درصد نمونه‌ها را طبقه‌بندی نماید.


Confusion Matrix

1	18 14.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
2	0 0.0%	18 14.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
3	0 0.0%	0 0.0%	15 11.9%	3 2.4%	0 0.0%	0 0.0%	0 0.0%	83.3% 16.7%
4	0 0.0%	0 0.0%	3 2.4%	15 11.9%	0 0.0%	0 0.0%	0 0.0%	83.3% 16.7%
5	0 0.0%	0 0.0%	0 0.0%	2 1.6%	16 12.7%	0 0.0%	0 0.0%	88.9% 11.1%
6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	17 13.5%	1 0.8%	94.4% 5.6%
7	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	18 14.3%	100% 0.0%
	100% 0.0%	100% 0.0%	83.3% 16.7%	75.0% 25.0%	100% 0.0%	100% 0.0%	94.7% 5.3%	92.9% 7.1%
	1	2	3	4	5	6	7	
	Target Class							
	Output Class							

شکل ۶. ماتریس اغتشاش شبکه عصبی بهینه در تشخیص درصدهای مختلف K_2O بر اساس تمام ویژگی‌های استخراج شده.

طبقه‌بندی بر اساس ویژگی‌های کارا


نمونه‌های مختلف کود پتاس با درصدهای متفاوت K_2O با استفاده از روش شبکه عصبی مصنوعی طبقه‌بندی شدند. در مدل بهینه طبقه‌بندی ارائه شده بر اساس رویکرد انتخاب ویژگی کارا، تعداد نورون‌ها در لایه ورودی برابر با ۷ (تعداد ویژگی‌های کارا)، در لایه خروجی نیز برابر با ۷ (سطوح مختلف K_2O) و در تعداد نورون‌ها در لایه پنهان ۱۲ نظر گرفته شد (شکل ۷). در این مدل، تابع فعال‌سازی لایه ورودی از نوع tansig و برای لایه خروجی از نوع purelin انتخاب شد.



شکل ۷. ساختار شبکه عصبی بهینه در تشخیص درصدهای مختلف K_2O بر اساس ویژگی‌های کارا.


عملکرد شبکه در مرحله اعتبارسنجی برای دوره‌های مختلف در شکل ۸ نشان داده شده است. کمترین خطای اعتبارسنجی در

تکرار ۴۴ برابر با ۰/۰۵۸۹ به دست آمد.



شکل ۸. نمودار عملکرد شبکه عصبی مصنوعی بهینه در تشخیص درصدهای مختلف K_2O بر اساس ویژگی‌های کارا.

در شکل ۹ ضرایب همبستگی شبکه بهینه نشان داده شده است. ضریب همبستگی شبکه بهینه برای داده‌های آموزش، اعتبارسنجی، آزمون و کل به ترتیب برابر ۹۶/۹۵، ۷۸/۷۱، ۶۵/۵۵ و ۸۵/۲۳ بود.



شکل ۹. نمودارهای رگرسیون شبکه عصبی مصنوعی بهینه در تشخیص درصدهای مختلف K_2O بر اساس ویژگی‌های کارا.

در شکل ۱۰ ماتریس اغتشاش طبقه‌بند بهینه مبتنی بر روش شبکه عصبی مصنوعی برای تشخیص درصد‌های متفاوت K_2O در کود پتاس نشان داده شده است. در این ماتریس اغتشاش، طبقه ۱، ۲، ۳، ۴، ۵، ۶ و ۷ به معنی کود پتاس با سطح ۵۰، ۵۰/۱، ۵۰/۲، ۵۰/۴، ۵۰/۵، ۵۰/۶ و ۵۰/۷ درصد است. در طبقه اول و هفتم، طبقه‌بند تمام نمونه‌ها را به درستی تشخیص داده است. در طبقه دوم، طبقه‌بند تنها یک نمونه را به اشتباه در طبقه چهارم قرار داده است و همچنین برای طبقه سوم تنها پنج نمونه را به اشتباه در طبقه چهارم طبقه‌بندی کرده است. در طبقه چهارم طبقه سه نمونه را به اشتباه طبقه‌بندی کرده است که تعداد یک نمونه را در طبقه پنجم و تعداد دو نمونه را در طبقه سوم طبقه‌بندی کرده است. در طبقه پنجم و ششم طبقه‌بندی تنها یک نمونه را به اشتباه طبقه‌بندی کرده است. بنابراین، از تعداد کل ۱۲۶ نمونه با درصد‌های مختلف K_2O ، تعداد ۱۱۸ نمونه‌ها به درستی تشخیص داده شده‌اند که می‌توان گفت مدل طبقه‌بند بر اساس روش شبکه عصبی مصنوعی توانسته است با نرخ طبقه‌بندی صحیح ۹۱/۳ درصد نمونه‌ها را طبقه‌بندی نموده است.

Confusion Matrix

Output Class	1	18 14.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	2	0 0.0%	17 13.5%	0 0.0%	1 0.8%	0 0.0%	0 0.0%	0 0.0%	94.4% 5.6%
	3	0 0.0%	0 0.0%	13 10.3%	5 4.0%	0 0.0%	0 0.0%	0 0.0%	72.2% 27.8%
	4	0 0.0%	0 0.0%	2 1.6%	15 11.9%	1 0.8%	0 0.0%	0 0.0%	83.3% 16.7%
	5	0 0.0%	0 0.0%	1 0.8%	0 0.0%	17 13.5%	0 0.0%	0 0.0%	94.4% 5.6%
	6	0 0.0%	1 0.8%	0 0.0%	0 0.0%	0 0.0%	17 13.5%	0 0.0%	94.4% 5.6%
	7	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	18 14.3%	100% 0.0%
		100% 0.0%	94.4% 5.6%	81.3% 18.8%	71.4% 28.6%	94.4% 5.6%	100% 0.0%	100% 0.0%	91.3% 8.7%
		Target Class							
		1	2	3	4	5	6	7	

شکل ۱۰. ماتریس اغتشاش شبکه عصبی بهینه در تشخیص درصد‌های مختلف K_2O بر اساس ویژگی‌های کارا.

نتایج این تحقیق با یافته‌های مطالعات پیشین قابل مقایسه است. به عنوان مثال، گیلی و همکاران (۱۴۰۱) در پژوهشی به طبقه‌بندی محصولات کشاورزی با استفاده از شبکه کانولوشنی عمیق مبتنی بر شاخص محصول پرداختند. در مرحله نخست، سری

زمانی باندها به عنوان ورودی شبکه کانولوشنی عمیق در نظر گرفته شد. این شبکه در ناحیه آموزش با استفاده از اطلاعات طیفی- زمانی باندها به عنوان کانال‌های ورودی و نمونه‌های زمینی محصولات به عنوان برچسب، آموزش داده شد. به دلیل همپوشانی طیفی محصولات در برخی دوره‌های زمانی، فرآیند آموزش شبکه با خطای نسبتاً بالایی همراه بود. در نتیجه، در مرحله آزمون، دقت کلی طبقه‌بندی ۶۹ درصد به دست آمد. در مرحله دوم، توابعی که به عنوان شاخص‌های فنولوژیک برای هر محصول توسعه یافته بودند، بر روی سری زمانی باندها اعمال شدند و برای هر محصول، یک کانال ویژگی منحصر به فرد به عنوان شاخص اختصاصی آن محصول استخراج گردید. سپس الگوریتم با استفاده از این کانال‌های ویژگی در ناحیه آزمون اجرا شد که منجر به افزایش دقت کلی به ۸۶ درصد شد. این نتایج نشان دهنده بهبود چشمگیر دقت و کیفیت طبقه‌بندی در مقایسه با حالت اولیه است.

نتیجه‌گیری

در این مطالعه به بررسی تشخیص درصدهای مختلف K_2O در کود پتاس با استفاده از روش پردازش تصویر فراطیفی پرداخته شد. که هفت سطح از درصدهای مختلف K_2O در کود پتاس با روش شبکه عصبی مصنوعی طبقه‌بندی شد. طبقه‌بندی تصاویر فراطیفی بر اساس دو راهبرد با و بدون انتخاب ویژگی صورت گرفت. در راهبرد بدون انتخاب ویژگی تمام ویژگی‌های استخراج شده از تصاویر فراطیفی در کانال‌های موثر به عنوان ورودی مدل‌های طبقه‌بند مورد استفاده قرار گرفتند. در راهبرد با انتخاب ویژگی، تنها ویژگی‌های کارا برای طبقه‌بندی استفاده شدند. نرخ طبقه‌بندی صحیح مدل طبقه‌بند شبکه عصبی مصنوعی با راهبرد انتخاب ویژگی کارا درصدهای مختلف K_2O در کود پتاس برابر ۹۱/۳ درصد و دقت آن با راهبرد تمام ویژگی‌های استخراج شده برابر ۹۲/۹ درصد بود. روش پیشنهادی در این پژوهش علاوه بر داشتن دقت تشخیص بالا، از قابلیت اطمینان بالایی نیز برخوردار است. در مقایسه با روش‌های مبتنی بر آزمایشگاه، این روش دارای مزایای متعددی از جمله غیرمخرب بودن، سرعت بالا، سادگی در اجرا و هزینه کمتر است که آن را به گزینه‌ای کارآمد و مقرون به صرفه تبدیل می‌کند. از آنجا که تشخیص سریع و دقیق عناصر شیمیایی در صنایع مختلف، به ویژه در حوزه کشاورزی و تولید کودهای شیمیایی، از اهمیت بالایی برخوردار است، استفاده از این روش می‌تواند به بهبود فرآیندهای کنترل کیفیت و افزایش بهره‌وری کمک کند. علاوه بر این، این روش پتانسیل بالایی برای توسعه و به کارگیری در شناسایی سایر عناصر شیمیایی موجود در کود پتاس را دارد و می‌تواند در آینده به عنوان یک ابزار موثر در تجزیه و تحلیل ترکیبات کودهای شیمیایی مورد استفاده قرار گیرد.

تشکر و قدر دانی

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

تعارض منافع

منابع

- 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.
- Patiluna, V., Owen, J., Jr., Maja, J.M., Neupane, J., Behmann, J., Bohnenkamp, D., Borra-Serrano, I., Peña, J.M., Robbins, J., & de Castro, A. (2025). Using Hyperspectral Imaging and Principal Component Analysis to Detect and Monitor Water Stress in Ornamental Plants. *Remote Sens*, 17, 285. <https://doi.org/10.3390/rs17020285>.
- 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>.
- Arjomandi, H.R., Kheiralipour, K., & Amarloei, A. (2022). Estimation of dust concentration by a novel machine vision system. *Scientific Reports*, 12(1), 1-8.
- Azadnia, R., & Kheiralipour, K. (2022). Evaluation of hawthorns maturity level by developing an automated machine learning-based algorithm. *Ecological Informatics*, 71, 101804. <https://doi.org/10.1016/j.ecoinf.2022.101804>.
- Barbosa, M.C., Fernandes, G.C., Lima, B.H., Rosa, L.G.P., Ito, W.C.N., Souza, L.F.R.d., Jalal, A., Nogueira, T.A.R., Oliveira, C.E.d.S., & Ghaley, B.B. (2025). The Effects of Potassium Dose, Timing, and Source in Soybean Crops in Brazilian Savannah Oxisol. *Sustainability*, 17, 934. <https://doi.org/10.3390/su17030934>.
- Brunetto, G., Marques, A., Martins, A., Miotto, A., Tiecher, T., Tiecher, T., Pias, O., Ambrosini, V., Ferreira, P., & Souza da Silva, L. (2022). Fertilidade do solo e nutric.º para cultura da soja. In *Tecnologias Aplicadas para o Manejo Rentavel e Eficiente da Cultura da Soja*; GR: Santa Maria, CA, USA, pp. 11–46. ISBN 9786589469575.

Efraim, I., Holdengraber, C., & Lampert, S. (1996). U. S. Patent No. 5552126, Washington, D.C.: U.S. Patent and Trademark Office.

ElMasry, G., Kamruzzaman, M., Sun, D. W., & Allen, P. (2012). Principles and applications of hyperspectral imaging in quality evaluation of agro food products: a review. *Crit. Rev. Food Sci. Nutr.*, 52(11), 999-1023.

Esa, N., Masarudin, M.F., Saad, M.M., & Misman, S.N. (2025). Determine the Balance of Nitrogen, Potassium, and Silicon Fertilization for the Control of Rice Tungro Disease Using Response Surface Methodology. *Natural and Life Sciences Communications*. 24(1): e2025002.

Farokhzad, S., Modares Motlagh, A., Ahmadi Moghadam, P., Jalali Honarmand, S., & Kheiralipour, K. (2020). Application of infrared thermal imaging technique and discriminant analysis methods for non-destructive identification of fungal infection of potato tubers. *Journal of Food Measurement and Characterization*. 14(1): 88-94.

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, no. 8: 1314–1319. <https://doi.org/10.4315/0362-028X.JFP-18-567>.

Giambra, M.A. (2005). Application of ion chromatography to qualitative and quantitative determination of the main inorganic ionic components of samples from a production process of potassium sulphate, *Analytica Chimica Acta*, 530, 41–48, <https://doi.org/10.1016/J.ACA.2004.08.047>.

Gili, M., Ashourloo, D., Aghighi, H., Motakan, A., & Shakiba, A. (2021). Classification of agricultural products with deep convolutional network based on product index. *Quarterly Journal of Environmental Sciences*, Volume 20, Issue 4, 37-52. <http://dx.doi.org/10.48308/envs.2022.1126>.

Gomez-Sanchis, J., Gomez-Chova, L., Aleixos, N., Camps-Valls, G., Montesinos-Herrero, C., Molto, E., & Blasco, J. (2008). Hyperspectral system for early detection of rotteness caused by *Penicillium digitatum* in mandarins. *Journal of Food Engineering*, 89, 80-86.

- 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.
- 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 Eng. Rev.* 15, 41–55. <https://doi.org/10.1007/s12393-022-09327-x>.
- 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 Res.*, 65, 1-22.
- 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*, Nova Science Publishers, Hauppauge, New York, USA. ISBN 979-8-88697-208-5.
- 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.
- Kheiralipour, K., Ahmadi, H., Rajabipour, A., & Rafiee, S. (2018). *Thermal Imaging, Principles, Methods and Applications*. 1st Ed. Ilam University Publication, Ilam, Iran.
- Kheiralipour, K., Ahmadi, H., Rajabipour, A., Rafiee, S., & Javan-Nikkhah, M. (2014). Classifying healthy and fungal infected-pistachio kernel by thermal imaging technology. *International Journal of Food Properties*, 18 (1), 93-99.
- Kheiralipour, K., Ahmadi, H., Rajabipour, A., Rafiee, S., Javan-Nikkhah, M., & Jayas, D.S. (2013). Development of a new threshold-based classification model for analyzing thermal

- imaging data to detect fungal infection of pistachio kernel. *Agricultural Research*, 2, 127-131.
- Kheiralipour, K., Ahmadi, H., Rajabipour, A., Rafiee, S., Javan-Nikkhah, M., Jayas, D. S. and Siliveru K. (2015). 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.
- 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*.
- Kumar, A., Bharti, V., Kumar, V., Kumar, U., & Meena, P.D. (2016). Hyperspectral imaging: A potential tool for monitoring crop infestation, crop yield and macronutrient analysis, with special emphasis to Oilseed Brassica. *Journal of Oilseed Brassica*, 7(2), 113-12.
- Kheiralipour, K., & Jayas D.S. (2023b). 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.
- Kheiralipour, K., & Jayas, D.S. (2023a). Advances in image processing applications for assessing leafy materials. *International Journal of Tropical Agriculture*. 41(1-2), 31-47.
- Kheiralipour, K., & Jayas, D.S. (2023c). Image Processing for the Quality Assessment of Flour and Flour-Based Baked Products. In *Image Processing: Advances in Applications and Research*. Edited by Jayas, D.S. New York, USA: *Nova Science Publishers*.
- 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.
- Kheiralipour, K., Kazemi, A. (2020) A new method to determine morphological properties of fruits and vegetables by image processing technique and nonlinear multivariate modeling. *International Journal of Food Properties* 23(1), 368-374.

- Kheiralipour, K., & Marzbani, F. (2016). Pomegranate quality sorting by image processing and artificial neural network. 10th *Iranian National Congress on AGR Machi Eng (Biosystems) and Mechanization*, 29-31 August, Mashhad, Iran.
- Kheiralipour, K., & Nargesi, M.H. (2024). Classification of wheat flour levels in powdered spices using visual imaging. *Journal of Agriculture and Food Research*. 18, Pages, 101408. <https://doi.org/10.1016/j.jafr.2024.101408>.
- Kheiralipour, K., Nadimi, M., & Paliwal, J. (2022). Development of an Intelligent Imaging System for Ripeness Determination of Wild Pistachios. *Sensors*. 22(19), 7134.
- Kheiralipour, K., Singh, C. B., & Jayas, D. S. (2023b). Applications of Visible, Thermal, and Hyperspectral Imaging Techniques in the Assessment of Fruits and Vegetables. In *Image Processing: Advances in Applications and Research*. Edited by Jayas, D.S. New York, USA: *Nova Science Publishers*.
- Li, Ch., Xu, F., Cao, Ch., Shang, M.Y., Zhang, C.Y., Yu, J., Liu, G.X., Wang, X. & Cai, SH.C. (2013). Comparative analysis of two species of *Asari Radix et Rhizoma* by electronic nose, headspace GC–MS and chemometrics, *Journal of Pharmaceutical and Biomedical Analysis*, 85, 231-238.
- Li, Norman & Bailey, J. & Kenrick, Douglas & Linsenmeier, Joan. (2002). The Necessities and Luxuries of Mate Preferences: Testing the Tradeoffs. *Journal of personality and social psychology*. 82. 947-55. [10.1037/0022-3514.82.6.947](https://doi.org/10.1037/0022-3514.82.6.947).
- Malavi, D., Nikkhah, A., Alighaleh, P., Einafshar, S., Raes, K., & Haute, S. V. (2024). Detection of saffron adulteration with *Crocus sativus* style using NIR-hyperspectral imaging and chemometrics. *Food Control*, 157 (2024) 110189.
- Manzoor, N., Akbar, N., Ahmad Anjum, S., Ali, I., Shahid, M., Shakoor, A., Waseem Abbas, M., Hayat, K., Hamid, W., & Rashid, M. A. (2017). Interactive effect of different nitrogen and potash levels on the incidence of bacterial leaf blight of rice (*Oryza sativa* L.). *Agricultural Sciences*. 8: 56–63.
- Mientka, A., Grzmil, B., & Tomaszewska, M. (2007). Production of potassium sulfate from potassium hydrosulfate solutions using alcohols. Institute of Chemical and Environment

Engineering, Szczecin University of Technology, ul. Pulaskiego 10, 70-322 Szczecin, Poland. 62 (1) 123–126.

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>.

Moosavian, A. (2012). Fault Diagnosis and Classification of Journal Bearings by Using Support Vector Machine, M. Sc. dissertation, University of Tehran, Karaj.

Nargesi, M. H., & Kheiralipour, K. (2024). Ability of visible imaging and machine learning in detection of chickpea flour adulterant in original cinnamon and pepper powders. *Heliyon*. Volume 10, ISSUE 16, e35944, August 30, 2024.

Nargesi, M. H., & Kheiralipour, K. (2024). Visible feature engineering to detect adulteration in black and red peppers. *Scientific Reports*. volume 14, Article number: 25417. <https://doi.org/10.1038/s41598-024-76617-1>.

Nargesi, M. H., Amiri parian, J., & Kheiralipour, K. (2024). Determination of the purity of black pepper powder using hyperspectral imaging and support vector machine methods., *Innov. Food Technol*, 11(4), 295-312., DOI: <https://doi.org/10.22104/ift2024.6934.2174>.

Nargesi, M. H., Amiriparian, J., Bagherpour, H., & Kheiralipour, K. (2024). Detection of different adulteration in cinnamon powder using hyperspectral imaging and artificial neural network method. *Results in Chemistry*. Volume 9, July 2024, 101644.

Nargesi, M. H., Heidarbeigi, K., Moradi, Z., & Abdolahi, S. (2024). Detection of chlorine in potassium chloride and potassium sulfate using chemical imaging and artificial neural network. *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy*. Volume 326, 125253. <https://doi.org/10.1016/j.saa.2024.125253>.

Nargesi, M. H., Kheiralipour, K., & Jayas, D. S. (2024a). Classification of different wheat flour types using hyperspectral imaging and machine learning techniques. *Infrared Physics & Technology*. Volume 142, 105520.

- 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.
- Nobari Moghaddam, H., Tamiji, Z., Akbari Lakeh, M., Khoshayand, M. R., & Haji & Mahmoodi, M. (2022). Multivariate analysis of food fraud: A review of NIR based instruments in tandem with chemometrics. *Journal of Food Composition and Analysis*, 107. <https://doi.org/10.1016/j.jfca.2021.104343>.
- Qin, J., Chao, K., Kim, M.S., Lu, R., & Burks, T.F. (2013). Hyperspectral and multispectral imaging for evaluating food safety and quality, *J. Food Eng.* 118, 157–171, <https://doi.org/10.1016/j.jfoodeng.2013.04.001>.
- Rodrigues, M.A.D.C., Buzetti, S., Teixeira Filho, M.C.M., Garcia, C.M.P., & Andreotti, M. (2014). Adubac.o com KCl revestido na cultura do milho no Cerrado. R. Bras. *Eng. Agric. Ambient*, 18, 127–133.
- Salam, S., & Kheiralipour, K. (2022). Development and evaluation of chickpea classification system based on visible image processing technology and artificial neural network. *Innovative Food Technologies*. 9(2), 181-163.
- Salam, S., & Kheiralipour, K., & Jian, F. (2022). Detection of unripe kernels and foreign materials in chickpea mixtures using image processing. *Agriculture*, 12(7), 995.
- 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>.
- Shrestha, J., Kandel, M., Subedi, S., & Shah, K. K. (2020). Role of nutrients in rice (*Oryza sativa* L.): A review. *Agrica*, 9: 53–62.
- Singh, C.B. (2009). Detection of insect and fungal damage and incidence of sprouting in stored wheat using near-infrared hyperspectral and digital color imaging. Ph.D. Dissertation. University of Manitoba, Winnipeg, Canada.

- Siripatrawan, U., & Makino, Y. (2015). Monitoring fungal growth on brown rice grains using rapid and nondestructive hyperspectral imaging. *International Journal of Food Microbiology*, 199, 93-100.
- Sun, J., Yang, F., Cheng, J., Wang, S., & Fu, L. (2024b). Nondestructive identification of soybean protein in minced chicken meat based on hyperspectral imaging and VGG16-SVM. *J. Food Compos. Anal.* 125, 105713. <https://doi.org/10.1016/j.jfca.2023.105713>.
- Taboada, M.E., Palma, P. A., & Graber, T.A. (2003). Crystallization of potassium sulfate by cooling and potassium chloride in-out using 1-propanol in a calorimetric reactor, *Crystal Research and Technology*. 21–29, <https://doi.org/10.1002/crat.200310002>.
- Wu, D. & Sun, W.D. (2013). Colour measurements by computer vision for food quality control – A review, *Trends in Food Science & Technology*, Volume 29, Issue 1, Pages 5-20.
- Xu, X., Du, X., Wang, F., Sha, J., Chen, Q., Tian, G., Zhu, Z., Ge, S., & Jiang, Y. (2020). Effects of potassium levels on plant growth, accumulation and distribution of carbon, and nitrate metabolism in apple dwarf rootstock seedlings. *Frontiers in Plant Science*. 11: 904.
- Zhang, J., Tong, T., Potcho, P. M., Huang, S., Ma, L., & Tang, X. (2020). Nitrogen effects on yield, quality and physiological characteristics of giant rice. *Agronomy*. 10: 1816.
- Zisner, T., Holdengraber, C., & Lampert, S. (1996). U. S. Patent No. 5549876. Washington, D.C.: U.S. Patent and Trademark Office.

Estimation of Potassium Oxide Content in Potash Fertilizer Using Hyperspectral Image Processing and Machine Learning Methods

Abstract

To enhance agricultural productivity, managing soil fertility and ensuring the availability of essential nutrients such as potassium is of great importance. Potassium plays a vital role in plant growth and physiological processes; however, its unbalanced application can lead to soil degradation or nutrient loss. Conventional methods for measuring potassium oxide content are often expensive and time-consuming, highlighting the need for rapid, accurate, and cost-effective alternatives. This study aims to detect the amount of potassium oxide in potash fertilizer based on hyperspectral imaging. After acquiring and processing the hyperspectral images, artificial neural networks were employed for classification using two approaches: with and without feature selection. In the first approach, all extracted features from the effective hyperspectral bands were directly used as inputs to the classification models. In the second approach, only selected features were used for classification. The results showed that the artificial neural network model using all extracted features achieved a higher accuracy (92.9%) compared to the model based on selected features (91.3%). The proposed method in this study can potentially be used in the future to detect other chemical elements in potash fertilizers. This approach offers an efficient, rapid, and non-destructive tool for assessing fertilizer composition.

Keywords: Chemical fertilizer, hyperspectral imaging, image processing, machine learning, artificial neural network.