



Development of general software for clustering rice cultivars using image processing and a self-organizing map to assess morphological diversity

Sayed Javad Sajadi 

*Corresponding Author: Assistant Professor, Department of Plant Production, College of Agriculture Science and Natural Resources, Gonbad Kavous University, Gonbad, Golestan, Iran.
Email address: sajadi@gonbad.ac.ir

Hossein Sabouri 

Professor, Department of Plant Production, College of Agriculture Science and Natural Resources, Gonbad Kavous University, Gonbad, Golestan, Iran. Email address: hossein.sabouri@gonbad.ac.ir

Mahdi Tarashi 

MSc Graduate, Department of Plant Production, College of Agriculture Science and Natural Resources, Gonbad Kavous University, Gonbad, Golestan, Iran. Email address: mahditarashi@gmail.com

Mohsen Rezaei 

MSc Graduate, Department of Plant Production, College of Agriculture Science and Natural Resources, Gonbad Kavous University, Gonbad, Golestan, Iran. Email address: Mohsenrezaei.gku@gmail.com

Abstract

Objective

This study was conducted to evaluate the potential of digital image processing and artificial neural networks in identifying and classifying rice cultivars based on grain morphological characteristics and also to introduce an applied software in this field. Rice cultivars included Gil3, IR362542/2, Restore50, Domsiah, MusaTarom, GHARIB3, Gharibsiahryhani, IR50maz, Line304, LINE229-2, Nemat, KMP41, DCL, Lebant, IR67017, DomsiahSolymandarab, Dashtisard, Hashemi, Dolar, IR24, IR50, line831, IR3441, AnbarboElam, CY, Mehr, Line213, Fujiminuri, Hasani, Ghasraldashti, TE, Sangtarom, Dasht, line216, Vad, IR662320, Canhopatra and Usen rice lines

and 17 lines resulting from crossing Azucin and Bala. Evaluation of morphological diversity is considered an essential step in breeding programs and conservation of plant genetic resources.

Materials and Methods

Rice grains used in this study were cultivated during the 2015–2016 growing season at the research farm of Gonbad Kavous University. After harvest, digital images of paddy grains were captured using a standard imaging chamber equipped with a CCD camera. Using MATLAB R2015a software and image processing algorithms, grain characteristics such as length, width, perimeter, area, roundness, and aspect ratio were extracted. A Self-Organizing Map (SOM) neural network was then applied to cluster the grains based on these morphological features under both normal and drought stress conditions.

Results

The image processing results demonstrated the capability of this method to extract the geometric features of rice grains accurately. The developed software also performed effectively in measuring these characteristics. The SOM neural network successfully clustered grains into distinct groups based on morphological traits, particularly length and width. The SOM visualization maps illustrated both the morphological differences among samples and the influence of drought stress on these traits.

Conclusion

The combination of digital image processing and a Self-Organizing Map neural network provides an efficient, non-destructive approach for assessing morphological diversity and classifying rice cultivars. This method has valuable applications in breeding programs, germplasm management, and seed quality assessment. Moreover, the developed software serves as a valuable tool for researchers in the field. Future studies are recommended to include a broader range of morphological, color, and textural traits in SOM modeling and to explore their relationships with genetic and agronomic characteristics of diverse rice cultivars.

Keywords: Classification, Drought stress, Machine vision, Phenotypic traits.

Paper Type: Research Paper.

Citation: Sajadi SJ, Sabouri H, Tarashi M, Rezaei M (2024) Development of general software for clustering rice cultivars using image processing and a self-organizing map to assess morphological diversity. *Journal of Genetics and Plant Breeding* 1 (2), 1-24.

Journal of Genetics and Plant Breeding 1 (2), 1-24.

DOI: 10.22103/gpb.2024.4985

Received: September 29, 2024.

Received in revised form: December 7, 2024.

Accepted: December 8, 2024.

Published online: December 25, 2024.


Publisher: Research and Technology Institute of Plant Production,
Afzalipour Research Institute, Shahid Bahonar University of Kerman and
Iranian Genetics Society.



© the authors




توسعه نرم افزار عمومی برای خوشه بندی ژنوتیپ های برنج با استفاده از پردازش تصویر و شبکه خودسازمانده (SOM) به منظور ارزیابی تنوع ریخت شناسی

 سید جواد سجادی


*نویسنده مسئول: استادیار، گروه تولیدات گیاهی، دانشکده کشاورزی و منابع طبیعی، دانشگاه گنبد کاووس، گنبد کاووس، ایران.

رایانامه: sajadi@gonbad.ac.ir

 حسین صبوری

استاد، گروه تولیدات گیاهی، دانشکده کشاورزی و منابع طبیعی، دانشگاه گنبد کاووس، گنبد کاووس، ایران. رایانامه:

hossein.sabouri@gonbad.ac.ir

 مهدی تراشی

دانش آموخته کارشناسی ارشد، گروه تولیدات گیاهی، دانشکده کشاورزی و منابع طبیعی، دانشگاه گنبد کاووس، گنبد کاووس، ایران.

رایانامه: mahditarashi@gmail.com

 محسن رضایی

دانش آموخته کارشناسی ارشد، گروه تولیدات گیاهی، دانشکده کشاورزی و منابع طبیعی، دانشگاه گنبد کاووس، گنبد کاووس، ایران.

رایانامه: Mohsenrezaei.gku@gmail.com

تاریخ دریافت: ۱۴۰۳/۰۷/۰۸ تاریخ دریافت فایل اصلاح شده نهایی: ۱۴۰۳/۰۹/۱۷ تاریخ پذیرش: ۱۴۰۳/۰۹/۱۸

چکیده

هدف: این پژوهش با هدف ارزیابی پتانسیل پردازش تصویر دیجیتال و شبکه های عصبی مصنوعی در شناسایی و طبقه بندی

ژنوتیپ های برنج بر اساس خصوصیات ریخت شناسی دانه و همچنین معرفی یک نرم افزار کاربردی در این زمینه انجام شد. ژنوتیپ های

برنج شامل لاین های IR362542/2, Restore50, Domsiah, MusaTarom, GHARIB3, Gil3,

Gharibsiyahryhani, IR50maz, Line304, LINE229-2, Nemat, KMP41, DCL, Lebant, IR67017,

DomsiahSolymandarab, Dashtisard, Hashemi, Dolar, IR24, IR50, line831, IR3441,

AnbarboElam, CY, Mehr, Line213, Fujiminuri, Hasani, Ghasraldashti, TE, Sangtarom, Dasht, line216, Vad, IR662320, Canhopatra, Usen و ۱۷ لاین حاصل از تلاقی Azucina و Bala بود. ارزیابی تنوع

ریخت‌شناسی گامی اساسی در برنامه‌های به‌نژادی و حفظ ذخایر ژنتیکی گیاهی محسوب می‌شود.

مواد و روش‌ها: دانه‌های برنج مورد استفاده در این پژوهش در مزرعه تحقیقاتی دانشگاه گنبد کاووس کشت شدند. پس از برداشت، تصاویر دیجیتال از دانه‌های شلتوک با استفاده از یک اتاقک تصویربرداری استاندارد و دوربین دیجیتال تهیه گردید. سپس با استفاده از نرم‌افزار MATLAB و الگوریتم‌های پردازش تصویر، خصوصیات نظیر طول، عرض، محیط، مساحت، ضریب گردی و نسبت طول به عرض برای هر دانه استخراج شد. در ادامه، از شبکه عصبی خودسازمانده برای خوشه‌بندی دانه‌ها بر اساس این خصوصیات در دو شرایط نرمال و تنش خشکی استفاده گردید.

نتایج: نتایج پردازش تصویر نشان داد که این روش قادر به استخراج دقیق خصوصیات هندسی دانه‌های برنج است. نرم‌افزار توسعه‌یافته نیز عملکرد مطلوبی در اندازه‌گیری این خصوصیات از خود نشان داد. شبکه عصبی خودسازمانده توانست دانه‌ها را بر اساس ویژگی‌های ریخت‌شناسی طول و عرض در گروه‌های مجزا خوشه‌بندی نماید. نقشه‌های خودسازمانده تفاوت‌های ریخت‌شناسی بین نمونه‌های مختلف و همچنین تأثیر شرایط تنش خشکی بر این خصوصیات را به تصویر کشیدند.

نتیجه‌گیری: استفاده از پردازش تصویر به‌همراه شبکه عصبی خودسازمانده ابزاری کارآمد و غیرمخرب برای ارزیابی تنوع ریخت‌شناسی و طبقه‌بندی ژنوتیپ‌های برنج می‌باشد. این روش می‌تواند در برنامه‌های به‌نژادی، مدیریت ژرم‌پلاسما و کنترل کیفیت بذر مورد استفاده قرار گیرد. این رویکرد پتانسیل بالایی برای استفاده در ارزیابی تنوع ژنتیکی، شناسایی ژنوتیپ‌ها، مطالعات مرتبط با تنش‌های محیطی و برنامه‌های به‌نژادی برنج دارد. نرم‌افزار توسعه‌یافته نیز می‌تواند به‌عنوان یک ابزار کمکی برای محققان در این زمینه مورد استفاده قرار گیرد. پیشنهاد می‌شود در تحقیقات آینده، تعداد بیشتری از ویژگی‌های ریخت‌شناسی و همچنین ویژگی‌های رنگی و بافتی در مدل‌سازی توسط شبکه عصبی خودسازمانده لحاظ شده و ارتباط آن‌ها با خصوصیات ژنتیکی و زراعی ژنوتیپ‌های مختلف برنج بررسی گردد.

کلیدواژه‌ها: بینایی ماشین، تنش خشکی، طبقه‌بندی، ویژگی‌های فنوتیپی.

نوع مقاله: پژوهشی.

استناد: سجادی سید جواد، صبوری حسین، تراشی مهدی، رضایی محسن (۱۴۰۳) توسعه نرم‌افزار عمومی برای خوشه‌بندی ژنوتیپ‌های برنج با استفاده از پردازش تصویر و شبکه خودسازمانده (SOM) به‌منظور ارزیابی تنوع ریخت‌شناسی. *مجله ژنتیک و به‌نژادی گیاهی*، (۲) ۱، ۲۴-۱.



Publisher: Research and Technology Institute of Plant Production, Afzalipour Research Institute, Shahid Bahonar University of Kerman and Iranian Genetics Society

© the authors

برنج (*Oryza sativa L.*) یکی از مهم‌ترین غلات در جهان است که غذای اصلی بیش از نیمی از جمعیت کره زمین را تشکیل می‌دهد. شناسایی و طبقه‌بندی ژنوتیپ‌های مختلف برنج و ارزیابی تنوع ژنتیکی موجود در آن‌ها برای برنامه‌های به‌نژادی، حفظ ذخایر ژنتیکی و تولید پایدار این محصول از اهمیت بالایی برخوردار است (Cinar & koklu 2022). خصوصیات ریخت‌شناسی دانه، از جمله اندازه، شکل و بافت، از معیارهای مهم در تعیین کیفیت، بازارپسندی و طبقه‌بندی ژنوتیپ‌های برنج هستند. اندازه‌گیری سنتی این خصوصیات اغلب زمان‌بر، خسته‌کننده و همراه با خطای انسانی است (Sultana et al. 2022).

در سال‌های اخیر، فناوری پردازش تصویر دیجیتال به‌عنوان یک روش سریع، دقیق، غیرمخرب و کم‌هزینه برای اندازه‌گیری و تجزیه و تحلیل خصوصیات فیزیکی و ریخت‌شناسی محصولات کشاورزی، از جمله دانه‌های غلات، مورد توجه قرار گرفته است (Himmelboe et al. 2025). این فناوری امکان استخراج طیف وسیعی از ویژگی‌ها مانند ابعاد، شکل، رنگ و بافت را از تصاویر دیجیتال فراهم می‌کند. محققان در آزمایشی از ترکیب ویژگی‌های مورفولوژی، رنگ و بافت برای طبقه‌بندی ژنوتیپ‌های گندم با دقت بالا استفاده کردند (Khan et al. 2024). همچنین، موزز و همکاران (Moses et al. 2022) با استفاده از الگوریتم‌های پردازش تصویر، ویژگی‌های رنگی و بافتی دانه‌های برنج را استخراج و آن‌ها را طبقه‌بندی نمود. به‌طور مشابه، مطالعات متعدد دیگری نیز بر طبقه‌بندی واریته‌های برنج با استفاده از روش‌های یادگیری ماشین و یادگیری عمیق تمرکز کرده‌اند (Sheng et al. 2022; Razavi et al. 2024; Saxena et al. 2022; Jeyaraj et al. 2022; Din et al. 2024; Rajalakshmi et al. 2024).

شبکه‌های عصبی مصنوعی، به‌ویژه شبکه‌های عصبی SOM¹، ابزارهای قدرتمندی برای تحلیل داده‌های پیچیده و چندبعدی، شناسایی الگوها و خوشه‌بندی هستند (Deshai et al. 2024; Farahnakian et al. 2024; Felizardo et al. 2024). این شبکه‌ها قادرند بدون نیاز به اطلاعات پیشین در مورد کلاس‌ها، داده‌ها را بر اساس شباهت‌های ذاتی آن‌ها گروه‌بندی کنند. از این رو، شبکه عصبی SOM می‌تواند در شناسایی گروه‌های مختلف ژنوتیپ‌های برنج بر اساس ویژگی‌های ریخت‌شناسی استخراج‌شده از پردازش تصویر، مفید واقع شود (Makmuang et al. 2021; Weerakoon et al. 2021). در مطالعه‌ای محققان از تکنیک‌های محاسبات نرم، از جمله شبکه‌های عصبی، برای تخمین عملکرد و خوشه‌بندی ژنوتیپ‌های نخود استفاده کردند (Das et al. 2023).

برای تحلیل داده‌های ریخت‌شناسی و شناسایی الگوهای تنوع، می‌توان از الگوریتم‌های مختلف هوش مصنوعی بهره برد. این الگوریتم‌ها عمدتاً به دو دسته یادگیری نظارت‌شده² و نظارت‌نشده³ تقسیم می‌شوند. الگوریتم‌های نظارت‌شده مانند ماشین بردار

¹ Self-Organizing Maps (SOM)

² Supervised

³ Unsupervised

پشتیبان، جنگل تصادفی و شبکه‌های عصبی کانولوشنی، برای طبقه‌بندی نمونه‌ها در کلاس‌های از پیش تعریف‌شده بسیار قدرتمند هستند، اما نیازمند داده‌های برجسپ‌دار می‌باشند. در مقابل، هدف این پژوهش، طبقه‌بندی در کلاس‌های مشخص نبود، بلکه کشف گروه‌های ریخت‌شناسی طبیعی و ناشناخته در میان ژنوتیپ‌ها و درک روابط بین این گروه‌ها بود (Liakos et al. 2018; Bishop et al. 2006).


از این رو، استفاده از الگوریتم‌های یادگیری نظارت‌نشده مانند خوشه‌بندی K-Means، خوشه‌بندی سلسله‌مراتبی و شبکه عصبی SOM مناسب‌تر است. در حالی که الگوریتم K-Means داده‌ها را به تعداد K خوشه مجزا تقسیم می‌کند، اما ساختار یا ارتباط توپولوژیکی بین خوشه‌ها را نشان نمی‌دهد. شبکه عصبی SOM یک نمایش توپولوژیکی دوبعدی از فضای ویژگی‌های چندبعدی ارائه می‌دهد. در این نقشه، خوشه‌هایی که از نظر ریخت‌شناسی به یکدیگر شبیه‌تر هستند، در همسایگی یکدیگر قرار می‌گیرند. این ویژگی بصری‌سازی قدرتمند، شبکه عصبی SOM را به ابزاری ایده‌آل برای ارزیابی تنوع ژنتیکی، شناسایی گرادیان‌های ریخت‌شناسی و درک چگونگی تأثیر تنش بر ساختار جمعیت تبدیل می‌کند. به همین دلیل، با توجه به هدف اصلی پژوهش که ارزیابی تنوع و ساختار آن بود، الگوریتم SOM به‌عنوان رویکرد اصلی انتخاب گردید.

هدف از این پژوهش، بررسی کارایی ترکیب پردازش تصویر و شبکه عصبی SOM برای استخراج خصوصیات ریخت‌شناسی دانه‌های برنج و خوشه‌بندی آن‌ها به‌منظور ارزیابی تنوع و همچنین معرفی یک نرم‌افزار کاربردی برای اندازه‌گیری این خصوصیات بوده است. این تحقیق می‌تواند به درک بهتر تنوع ریخت‌شناسی در ژنوتیپ‌های برنج و شناسایی ژنوتیپ‌های با ویژگی‌های مطلوب برای برنامه‌های به‌نژادی کمک نماید.

مواد و روش‌ها

این پژوهش در دانشگاه گنبد کاووس انجام شد. دانه‌های برنج مورد استفاده در مزرعه تحقیقاتی دانشکده کشاورزی و منابع طبیعی این دانشگاه کشت شدند. ژنوتیپ‌های برنج شامل لاین‌های Domsiah, Restore50, IR362542/2, Gil3, MusaTarom, GHARIB3, Gharibsiyahryhani, IR50maz, Line304, LINE229-2, Nemat, KMP41, DCL, Lebant, IR67017, DomsiahSolymandarab, Dashtisard, Hashemi, Dolar, IR24, IR50, line831, IR3441, AnbarboElam, CY, Mehr, Line213, Fujiminuri, Hasani, Ghasraldashti, TE, و Azucina و Sangtarom, Dasht, line216, Vad, IR662320, Canhopatra, Usen Bala بود. پس از برداشت، دانه‌ها از غلاف جدا شده و برای تصویربرداری آماده گردیدند. تصاویر رنگی دانه‌های برنج با استفاده از یک دوربین CCD (Sony, DSC-W100) با رزولوشن ۴ مگاپیکسل از فاصله ثابت ۱۰ سانتی‌متری گرفته شدند. برای ثبت عکس با کمترین میزان نویز، از یک سیستم نورپردازی فلورسنت با لامپ مدور در یک اتاقک تصویربرداری استفاده شد. تصاویر در فضای رنگی RGB با فرمت JPG در رایانه ذخیره شدند. در مجموع ۱۰۱۷ تصویر، که در هر تصویر ۵ دانه شلتوک قرار داشت، تهیه گردید.

عملیات پیش‌پردازش شامل انتقال تصاویر از فضای RGB به فضای HSV بود. در فضای HSV، با استفاده از مقادیر آستانه، نویز ناشی از ذرات غلاف، ریشک و سایر اضافات تصویر حذف شد. سپس با استفاده از الگوریتم تشخیص لبه، موقعیت دانه‌های برنج در هر تصویر با دقت تعیین گردید. پس از قطعه‌بندی تصویر، خصوصیات هندسی موردنظر از هر کدام از دانه‌ها استخراج و ذخیره شدند. این خصوصیات شامل طول، عرض، محیط، مساحت، ضریب گردی، ضریب کرویت، مرکز هندسی، نسبت طول به عرض، قطر حسابی، قطر هندسی، حجم و سطح جانبی^۸ بود. برای این تحقیق، از داده‌های مربوط به ۱۲۷۹۷ دانه در شرایط نرمال و ۹۷۵ دانه در شرایط تنش خشکی استفاده شد و تمرکز بر روی ویژگی‌های طول و عرض برای خوشه‌بندی قرار گرفت. شایان ذکر است که تفاوت قابل توجه در تعداد کل دانه‌های به‌دست‌آمده بین دو شرایط، یک خطای نمونه‌برداری نبوده، بلکه نتیجه مستقیم و مورد انتظار تأثیر بیولوژیکی تنش خشکی بر کاهش تعداد و عملکرد دانه در ژنوتیپ‌های مورد مطالعه است. از آنجا که تحلیل خوشه‌بندی برای هر یک از دو شرایط به‌صورت مستقل انجام گرفته است، این تفاوت تأثیری بر اعتبار الگوهای شناسایی شده در هر گروه ندارد. ابعاد یک محصول شامل طول، عرض و ضخامت می‌شوند. طول یا قطر بزرگ به بزرگترین اندازه یک محصول روی بزرگترین سطح تصویر شده یا ترسیم شده آن اطلاق می‌شود. به‌همین ترتیب، عرض یا قطر متوسط به بزرگترین اندازه محصول روی بزرگترین سطح تصویر شده که عمود بر محور طولی آن باشد، گفته می‌شود. همچنین، ضخامت یا قطر کوچک به بزرگترین طول روی سطح تصویر شده کوچکتر که عمود بر طول و عرض آن محصول باشد، اشاره دارد (Sheng et al. 2022).



شکل ۱. خصوصیات هندسی استخراج شده از دانه برنج (الف) طول و عرض، (ب) محیط و (ج) مساحت
Figure 1. Geometric properties extracted from rice grain (a) length and width, (b) perimeter, and (c) area.

1. Roundness
2. Sphericity
3. Centroid
4. Aspect Ratio
5. Arithmetic Mean Diameter
6. Geometric Mean Diameter
7. Volume
8. Surface Area

از آنجا که شکل دانه‌ها و سایر مواد کشاورزی گرانولی معمولاً نامنظم هستند اندازه دانه‌ها را با قطرهندسی بیان می‌کنند. قطر هندسی را می‌توان با استفاده از رابطه زیر محاسبه کرد (رابطه ۱). در این رابطه L, W, T به‌عنوان ابعاد سه گانه دانه به ترتیب پهنا، عرض و طول دانه هستند که دو به دو بر هم عمودند:

$$d_G = (TWL)^{1/3} \quad \text{رابطه (۱)}$$

قطر حسابی دانه‌های شلتوک دیگر شاخصی است که جهت بررسی خصوصیات فیزیکی دانه‌ها اندازه‌گیری شد. قطر حسابی مطابق رابطه ۲ محاسبه شد:

$$D_a = \left(\frac{1}{3}\right) (T + W + L) \quad \text{رابطه (۲)}$$

اگر حجم دانه برابر حجم یک بیضی گون سه محوری با محورهای L, W, T در نظر گرفته شود به طوری که قطر کره محیطی بزرگترین محور بیضی (L) راداشته باشد، آنگاه ضریب کرویت را می‌توان به صورت زیر تعریف کرد:

$$S_p = \frac{d_G}{L} \quad \text{رابطه (۳)}$$

هر چه قدر مقدار کرویت به ۱ نزدیک‌تر باشد شکل محصول به کره شبیه‌تر است. زمانی شکل محصول کره کامل است که مقادیر a, b و c هم برابر باشند. یکی دیگر از شاخص‌هایی که ممکن است برای توصیف اندازه مواد کشاورزی گرانولی اندازه‌گیری شود، حجم دانه می‌باشد که در محاسبات خواص مکانیکی مورد استفاده قرار می‌گیرد:

$$V_s = \frac{\pi d^3}{6} \quad \text{رابطه (۴)}$$

سطح جانبی دانه‌ها با استفاده از روابط زیر محاسبه شد:

$$A = \frac{\pi.B.L^2}{2L-B} \quad \text{رابطه (۵)}$$

$$B = (W.T)^{1/2} \quad \text{رابطه (۶)}$$

شبکه عصبی SOM: عملیات خوشه‌بندی با استفاده از شبکه عصبی SOM در نرم‌افزار MATLAB R2015a انجام


شد. الگوریتم یادگیری شبکه عصبی خودسازمانده به شرح ذیل است (Makmuang et al. 2021). ابتدا وزن هر نرون به صورت یک عدد تصادفی قرار داده می‌شود، سپس یک الگوی ورودی $X = (x_1, x_2, \dots, x_d)$ به شبکه اعمال می‌گردد. سپس بر اساس معیار تشابه شبکه، نرون برنده مشخص می‌گردد. معیارهای تشابه مختلفی را می‌توان در شبکه عصبی خودسازمانده به کار گرفت، اما معمول‌ترین معیاری که در این‌گونه از شبکه‌ها به کار گرفته می‌شود، فاصله اقلیدسی است. رابطه معیار تشابه اقلیدسی مطابق رابطه (۷) می‌باشد.

$$\|X - W\| = \left(\sum_{i=1}^d (X_i - w_i)^2 \right)^{1/2} \quad \text{رابطه (۷)}$$

حال به‌صورت هم‌زمان ورودی $X = (x_1, x_2, \dots, x_d)$ با تمامی عناصر موجود در شبکه مقایسه می‌گردد. نرون برنده، نرونی با فاصله کمینه در میان تمامی الگوهای مرجع از داده ورودی می‌باشد.

$$\|X - m_c\| = \min_i \{ \|X - m_r\| \} \quad \text{رابطه (۸)}$$

که m_c نرون برنده و m_r بردارهای مرجع می‌باشند. نمونه‌ای از انتخاب نرون برنده از میان الگوهای مرجع در شکل (۲) آورده شده است.



شکل ۲. انتخاب نرون برنده از میان الگوهای مرجع.

Figure 2. Selecting the winning neuron from among the reference patterns.

هنگامی که نرون برنده شناسایی شد، گام بعدی شناسایی مجموعه‌ای از نرون‌های همسایه است که مقادیر آن‌ها باید تغییر کند. دو رویکرد اصلی برای این مشکل وجود دارد. یکی شامل انتخاب یک شعاع همسایگی در اطراف سلول برنده است، جایی که همه نرون‌های درون آن شعاع با یک ضریب ثابت به سمت ورودی حرکت می‌کنند. دیگری شامل جابجایی همه نرون‌های درون شبکه با ضریب نابرابر است، جایی که ضریب دارای حداکثر مقدار در نرون برنده و مقدار کاهشی با دور شدن از نرون برنده است. در نهایت، وزن نرون برنده و همسایگان آن باید طبق دو روش تنظیم شوند.

$$m_r(t+1) = m_r(t) + \alpha(t) \cdot h_{cr}(t) [x(t) - m_r(t)] \quad \text{رابطه (۹)}$$

که $x(t)$ بردار ورودی در زمان t ، $m_r(t)$ الگوی مرجع m_r در زمان t ، $\alpha(t)$ نرخ یادگیری در زمان t و $h_{cr}(t)$ تابع همسایگی است که بر اساس تابع کرنل مطابق زیر تعریف می‌گردد.

$$h_{cr}(t) = \exp\left(-\frac{\|k_c - k_r\|^2}{2\sigma(t)^2}\right) \quad \text{رابطه (۱۰)}$$

در این رابطه، $k_c, k_r \in \mathbb{R}^d$ به ترتیب بیانگر نرون برنده و الگوهای مرجع همسایه آن بوده و $\delta(t)$ شعاع تابع کرنل در زمان t می‌باشد. نتیجه موارد فوق اصلاح اوزان و حرکت نرون‌های مذکور بسوی نمونه آموزشی است. $\alpha(t)$ پارامتری است که به منظور کنترل همگرایی الگوریتم بکارگرفته می‌شود و وابسته به تکرار می‌باشد. به منظور پایداری شبکه می‌بایست $0 < \alpha(t) < 1$ بوده و لزوماً بر حسب t بصورت کاهشی یکنواخت باشد. آموزش بدون نظارت در حالت کلی به صورت اجتناب ناپذیری از حالت نظارتی پیچیده‌تر بوده و به همین دلیل نیز به زمان بیشتری جهت یادگیری الگوهای آموزشی نیاز دارد. در این پژوهش، شبکه عصبی SOM با دو نرون در لایه ورودی (متناظر با طول و عرض دانه‌ها) و یک نقشه دوبعدی از نرون‌ها در لایه خروجی، با استفاده از الگوریتم یادگیری دسته‌ای بدون ناظر (trainbu) و با ۲۰۰ تکرار آموزش داده شد.

نتایج و بحث

نتایج پردازش تصویر و نرم‌افزار: پردازش تصاویر دیجیتال دانه‌های برنج امکان استخراج دقیق و سریع مجموعه‌ای

از خصوصیات ریخت‌شناسی را فراهم آورد. شکل ۳ - الف نمونه‌ای از تصویر اولیه دانه‌های برنج در فضای RGB و شکل ۳-ب نتیجه تبدیل این تصویر به فضای HSV را نمایش می‌دهد که برای کاهش نویز و بهبود تفکیک‌پذیری دانه از پس‌زمینه مفید بود. الگوریتم‌های تشخیص لبه و قطعه‌بندی (شکل ۳-ج و د) با موفقیت موقعیت دانه‌ها را در تصویر مشخص کردند و امکان استخراج ویژگی‌های فردی هر دانه را فراهم نمودند.


نرم‌افزار توسعه‌یافته در محیط MATLAB (شکل ۴) نیز قابلیت کالیبراسیون، فراخوانی تصاویر و محاسبه خصوصیات هندسی دانه‌ها را به طور کاربرپسند ارائه داد. این ابزار می‌تواند برای محققین و دانشجویان علوم زراعی و به‌نژادی گیاهی در اندازه‌گیری سریع و دقیق خصوصیات دانه‌های غلات مفید باشد.

نتایج خوشه‌بندی توسط شبکه عصبی SOM: شبکه عصبی SOM برای خوشه‌بندی دانه‌های برنج بر اساس دو

ویژگی کلیدی طول و عرض آموزش داده شد. در شکل ۵ آموزش شبکه عصبی SOM در نرم‌افزار MATLAB نشان داده شده است.

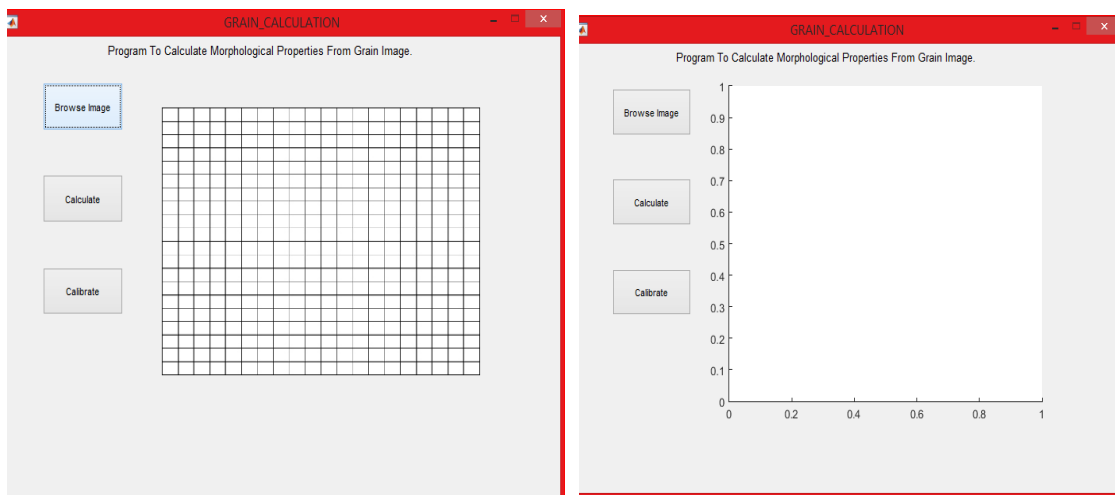
نمودار نشان داده شده در شکل ۶، کیفیت و اعتبار خوشه‌بندی‌های انجام شده توسط شبکه عصبی SOM با ابعاد متفاوت را با استفاده از شاخص سیلوئت مقایسه می‌کند. شاخص سیلوئت معیاری برای سنجش فشردگی و جدایی خوشه‌ها است و مقادیر بالاتر (نزدیک به ۱) نشان‌دهنده خوشه‌بندی بهتر و معتبرتر می‌باشد. به این معنی که اعضای هر خوشه شباهت زیادی به یکدیگر و تفاوت قابل توجهی با اعضای خوشه‌های دیگر دارند. همانطور که در نمودار مشاهده می‌شود، برای هر دو شرایط نرمال و تنش، شبکه با ساختار ۶ خوشه بالاترین امتیاز سیلوئت را به خود اختصاص داده است. این نتیجه حاکی از آن است که تقسیم‌بندی لاین‌های برنج به ۶ گروه ریخت‌شناسی، بهترین توازن را بین شباهت درون‌گروهی و تفاوت بین‌گروهی ایجاد می‌کند و از نظر ساختاری، معتبرترین

مدل برای توصیف تنوع ریخت‌شناسی داده‌های حاضر است. اگرچه شبکه‌های با ۴ و ۸ خوشه نیز عملکرد قابل قبولی دارند، اما انتخاب ساختار با ۶ خوشه از نظر آماری انتخاب بهینه‌تری برای تحلیل‌های بعدی محسوب می‌شود. همچنین، امتیازات بالاتر در شرایط نرمال در مقایسه با شرایط تنش می‌تواند بیانگر این باشد که تنوع ریخت‌شناسی در شرایط نرمال دارای ساختار واضح‌تری بوده و تنش خشکی ممکن است با ایجاد تغییرات ناهمگون در ابعاد دانه، مرز بین گروه‌های ریخت‌شناسی را تا حدی کمتر مشخص نماید.



شکل ۳. (الف) تصویر اولیه دانه‌های برنج در فضای RGB، (ب) نتیجه تبدیل تصویر دانه‌های برنج از فضای RGB به فضای HSV، (ج) تشخیص موقعیت دانه‌ها در تصویر، (د) قطعه‌بندی تصویر دانه‌های برنج.

Figure 3. (a) Initial image of paddy rice grains in RGB color space, (b) Result of converting paddy rice image from RGB to HSV color space, (c) Detection of grain positions in the image, (d) Segmentation of paddy rice image.

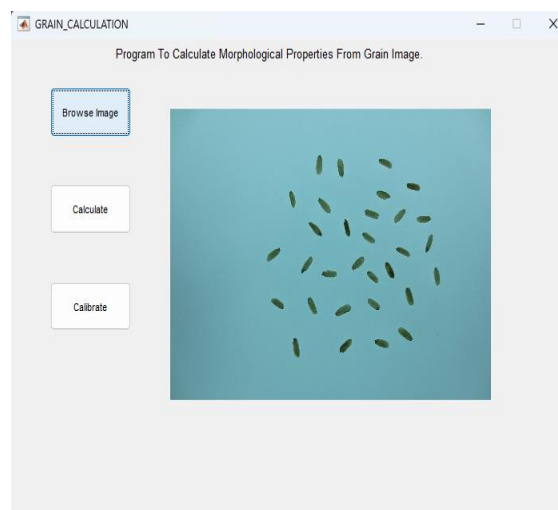


(ب) (ب)

(الف) (ا)

	A	B	C	D	E	F	G
1	length	width	primeter	area	round	L/W	equadial
2	0.11547	0.05774	0.098	0.005	0.15293	2	0.07981
3	0.05774	0.05774	0	0.0025	0	1	0.05643
4	0.22433	0.14174	0.4499	0.02	0.80577	1.58265	0.15962
5	0.05774	0.05774	0	0.0025	0	1	0.05643
6	0.46188	0.05774	0.686	0.02	1.87339	8	0.15962
7	0.11547	0.05774	0.098	0.005	0.15293	2	0.07981
8	0.05774	0.05774	0	0.0025	0	1	0.05643
9	0.11547	0.05774	0.098	0.005	0.15293	2	0.07981
10	0.1291	0.08819	0.15465	0.0075	0.25389	1.46385	0.09775
11	0.11547	0.05774	0.098	0.005	0.15293	2	0.07981
12	0.15275	0.10408	0.2295	0.01	0.41935	1.4676	0.11287
13	0.05774	0.05774	0	0.0025	0	1	0.05643
14	0.18257	0.09129	0.25265	0.01	0.50822	2	0.11287
15	0.11547	0.05774	0.098	0.005	0.15293	2	0.07981
16	0.05774	0.05774	0	0.0025	0	1	0.05643
17	0.23094	0.05774	0.294	0.01	0.68818	4	0.11287
18	0.05774	0.05774	0	0.0025	0	1	0.05643


(د) (د)



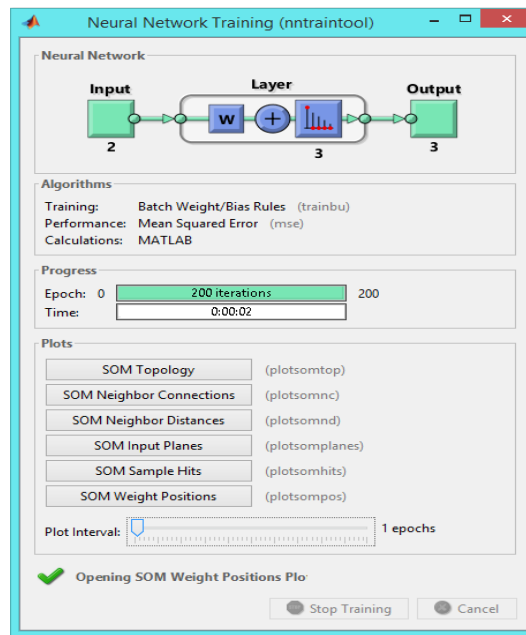
(ج) (ج)

شکل ۴. (الف) نمایی از نرم‌افزار اندازه‌گیری خصوصیات هندسی دانه، (ب) انجام عملیات کالیبره کردن نرم‌افزار، (ج) فراخوانی تصویر دانه‌های برنج در نرم‌افزار (د) خروجی نرم‌افزار به صورت فایل اکسل.

Figure 4. (a) View of the software for measuring grain geometric properties, (b) performing the software calibration operation, (c) calling up the image of rice grains in the software, (d) software output as an Excel file.



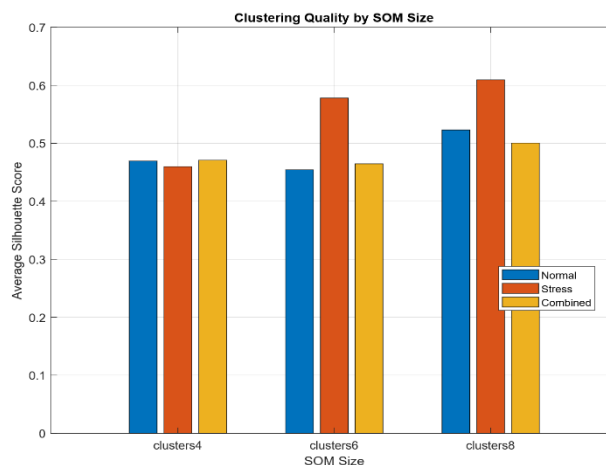
ب ب



الف

شکل ۵. آموزش شبکه عصبی SOM (الف) ابزار آموزش و آزمایش شبکه در نرم‌افزار MATLAB (ب) ساختار شبکه عصبی SOM ایجاد شده.

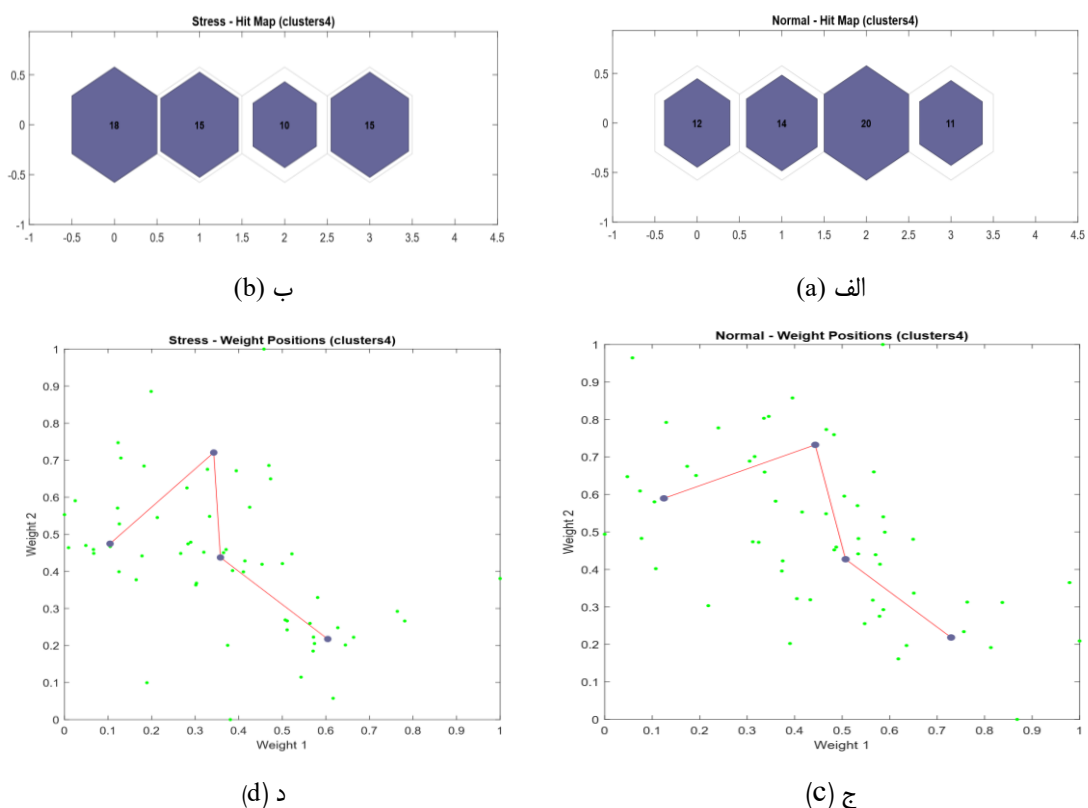
Figure 5. Training of the Self-Organizing Map neural network (a) The SOM toolbox App in MATLAB and (b) the SOM topology.



شکل ۶. مقایسه میانگین شاخص سیلوئت برای ارزیابی کیفیت خوشه‌بندی شبکه عصبی SOM با سه ساختار مختلف (۴، ۶ و ۸ نرون) در شرایط نرمال، تنش خشکی و حالت ترکیبی داده‌ها.

Figure 6. Comparison of the average Silhouette Score for evaluating the clustering quality of self-organizing network (SOM) with three different structures (4, 6, and 8 neurons) in normal, drought stress, and mixed data conditions.

مجموعه نمودارهای نشان داده شده در شکل ۷، نتایج خوشه‌بندی با استفاده از یک شبکه عصبی SOM با ۴ نرون (خوشه) را به تصویر می‌کشد. نقشه همسایگی (U-Matrix) (شکل‌های ۷-الف و ۷-ب) فاصله اقلیدسی بین بردارهای وزن نرون‌های همسایه را نشان می‌دهد. رنگ‌های روشن نشان‌دهنده فاصله زیاد و مرز بین خوشه‌ها هستند، درحالی‌که رنگ‌های تیره نشان‌دهنده نزدیکی نرون‌ها و مرکز خوشه‌ها می‌باشند. در هر دو شرایط نرمال و تنش، مرزهای مشخصی بین خوشه‌ها قابل مشاهده است که نشان‌دهنده تشکیل گروه‌های ریخت‌شناسی متمایز بر اساس ویژگی‌های طول و عرض دانه است. نقشه فراوانی داده‌ها (Hit Map) (شکل‌های ۷-ج و ۷-د) نشان می‌دهد که چه تعداد از نمونه‌های ورودی (دانه‌های برنج) به هر نرون (خوشه) نگاشت شده‌اند. هر نرون متناسب با تعداد داده‌های اختصاص یافته به آن است.



شکل ۷. نقشه‌های خروجی شبکه عصبی SOM با ساختار ۴ نرون برای داده‌های ریخت‌شناسی برنج. (الف) نقشه همسایگی نرون‌ها در شرایط نرمال، (ب) نقشه همسایگی نرون‌ها در شرایط تنش خشکی (ج) نقشه فراوانی داده‌ها در شرایط نرمال، (د) نقشه فراوانی داده‌ها در شرایط تنش خشکی.

Figure 7. Output maps of the [1x4] SOM network for rice morphological data. a) Neighborhood map of neurons (U-Matrix) under normal conditions, b) Neighborhood map of neurons (U-Matrix) under drought stress conditions, c) Hit map under normal conditions, and d) Hit map under drought stress conditions.

در شرایط نرمال (شکل ۷-ج)، توزیع داده‌ها در میان خوشه‌ها نسبتاً متوازن است. اما در شرایط تنش (شکل ۷-د)، مشاهده می‌شود که یکی از خوشه‌ها (نرون سمت راست) تعداد بسیار بیشتری از نمونه‌ها را به خود اختصاص داده است. این امر می‌تواند نشان‌دهنده آن باشد که تحت تأثیر تنش خشکی، بخش قابل توجهی از لاین‌های برنج از نظر ریخت‌شناسی به یکدیگر شبیه‌تر شده و در یک گروه غالب قرار گرفته‌اند که احتمالاً بیانگر کاهش عمومی ابعاد دانه در پاسخ به تنش است.

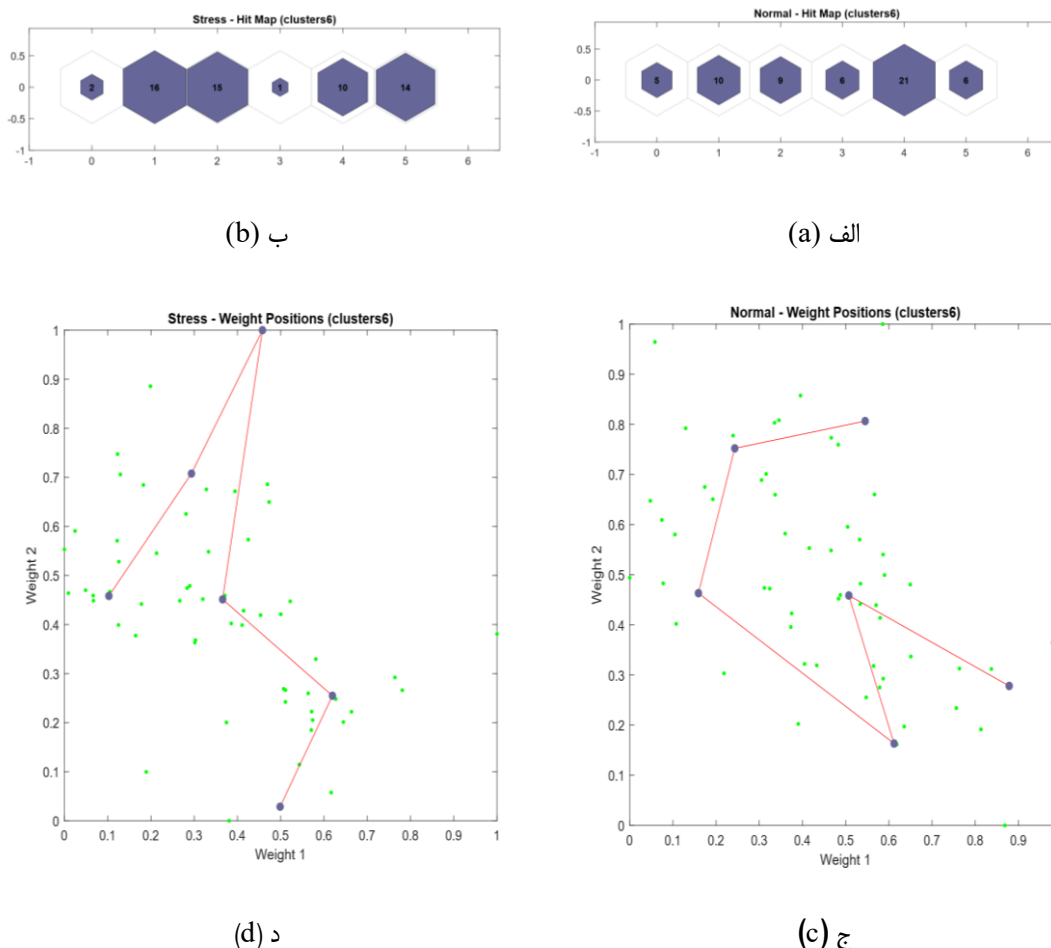
نمودارهای شکل ۸ نتایج مدل بهینه بر اساس شاخص سیلوئت با ۶ خوشه را نمایش می‌دهند که امکان تفکیک دقیق‌تری از تنوع ریخت‌شناسی را فراهم می‌کند. در شکل‌های ۸-الف و ۸-ب، مرزبندی بین ۶ خوشه به وضوح دیده می‌شود. این تفکیک‌پذیری بالاتر امکان می‌دهد تا گروه‌های ریخت‌شناسی میانی را که ممکن است در مدل با ۴ خوشه ادغام شده باشند، شناسایی شود. این مدل می‌تواند تنوع ژنتیکی موجود در ژرم‌پلاسم را با جزئیات بیشتری به تصویر بکشد. توزیع داده‌ها در شرایط نرمال (شکل ۸-ج) در بین ۶ خوشه، وجود زیرگروه‌های متعدد با اندازه‌های مختلف را نشان می‌دهد. در شرایط تنش (شکل ۸-د)، مجدداً الگوی تجمع داده‌ها در خوشه‌های خاصی مشاهده می‌شود که تاییدی بر یافته‌های مدل قبلی است؛ یعنی تنش خشکی منجر به همگرایی فنوتیپی در بخش بزرگی از لاین‌ها شده است. مقایسه این دو نقشه فراوانی به وضوح نشان می‌دهد که کدام گروه‌های ریخت‌شناسی در شرایط نرمال، تحت تأثیر تنش به کدام گروه‌های جدید منتقل شده‌اند.

استفاده از ۸ خوشه (شکل ۹) باعث تقسیم‌بندی بیش از حد داده‌ها شده است، به طوری که برخی خوشه‌ها (نرون‌ها) در نقشه فراوانی (شکل‌های ۹-ج و ۹-د) هیچ داده‌ای را به خود اختصاص نداده‌اند یا تعداد بسیار کمی را شامل می‌شوند. اگرچه نقشه همسایگی (شکل‌های ۹-الف و ۹-ب) همچنان مرزهایی را نشان می‌دهد، اما کاهش امتیاز سیلوئت (در شکل ۶) و وجود خوشه‌های خالی نشان می‌دهد که این مدل پیچیده‌تر از حد نیاز بوده و لزوماً توصیف بهتری از ساختار واقعی داده‌ها ارائه نمی‌دهد. با این حال، این تحلیل می‌تواند برای شناسایی لاین‌های بسیار خاص یا پرت که در خوشه‌های مجزا و کم‌جمعیت قرار می‌گیرند، مفید باشد.

استفاده از ۸ خوشه (شکل ۹) باعث تقسیم‌بندی بیش از حد داده‌ها شده است، به طوری که برخی خوشه‌ها (نرون‌ها) در نقشه فراوانی (شکل‌های ۹-ج و ۹-د) هیچ داده‌ای را به خود اختصاص نداده‌اند یا تعداد بسیار کمی را شامل می‌شوند. اگرچه نقشه همسایگی (شکل‌های ۹-الف و ۹-ب) همچنان مرزهایی را نشان می‌دهد، اما کاهش امتیاز سیلوئت (در شکل ۶) و وجود خوشه‌های خالی نشان می‌دهد که این مدل پیچیده‌تر از حد نیاز بوده و لزوماً توصیف بهتری از ساختار واقعی داده‌ها ارائه نمی‌دهد. با این حال، این تحلیل می‌تواند برای شناسایی لاین‌های بسیار خاص یا پرت که در خوشه‌های مجزا و کم‌جمعیت قرار می‌گیرند، مفید باشد.

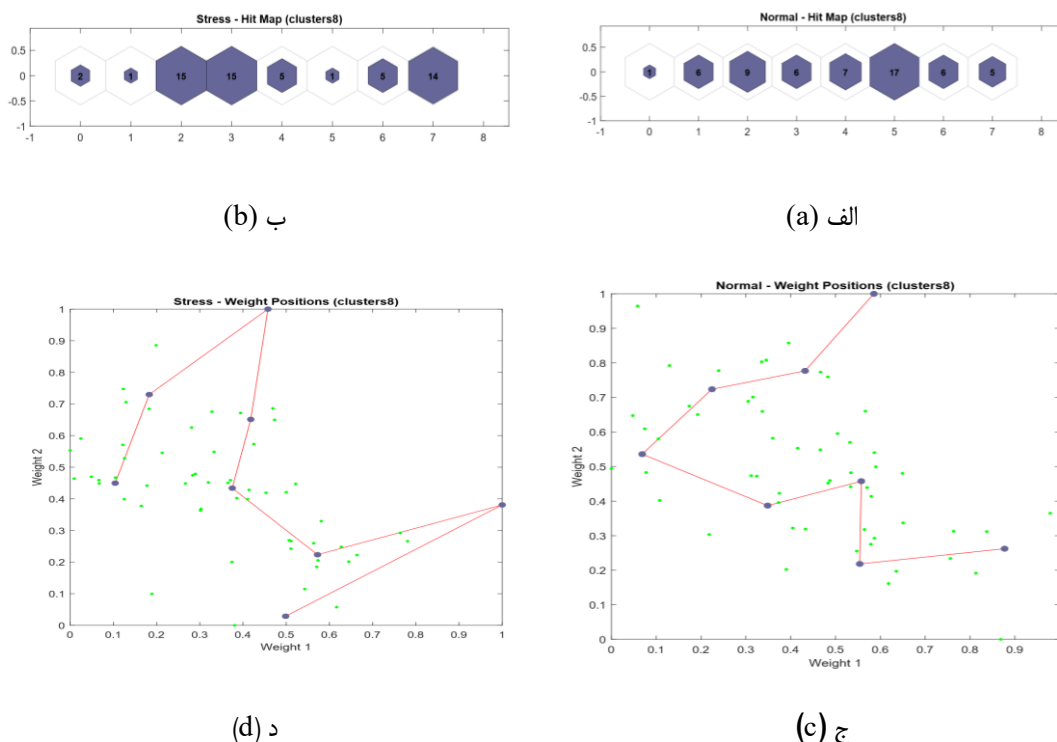
نتایج این پژوهش با یافته‌های Cinar and koklu (2022) که از شبکه عصبی برای خوشه‌بندی واریته‌های برنج بر اساس ویژگی‌های مورفولوژی و رنگ استفاده کردند، هم‌خوانی دارد. آن‌ها نیز نشان دادند که شبکه‌های عصبی می‌توانند ابزار مؤثری در طبقه‌بندی ژنوتیپ‌ها باشند. همچنین Singh et al. (2022) کاربرد موفقیت‌آمیز پردازش تصویر را در طبقه‌بندی دانه‌های برنج گزارش کرده‌اند. استفاده از شبکه عصبی SOM در این پژوهش امکان بصری‌سازی داده‌های چندبعدی را در فضای دوبعدی فراهم

کرد و به شناسایی الگوهای پنهان در داده‌ها کمک نمود. این روش می‌تواند برای ارزیابی سریع تنوع ژرمپلاسم برنج و شناسایی ژنوتیپ‌ها با ویژگی‌های خاص ریخت‌شناسی در برنامه‌های به‌نژادی مفید باشد. به‌عنوان مثال، می‌توان ژنوتیپ‌های مقاوم به تنش خشکی را که تغییرات ریخت‌شناسی کمتری در دانه نشان می‌دهند، شناسایی کرد.



شکل ۸. نقشه‌های خروجی شبکه عصبی SOM با ساختار $[1 \times 6]$ برای داده‌های ریخت‌شناسی برنج. الف) نقشه همسایگی نرون‌ها در شرایط نرمال، ب) نقشه همسایگی نرون‌ها در شرایط تنش خشکی ج) نقشه فراوانی داده‌ها در شرایط نرمال د) نقشه فراوانی داده‌ها در شرایط تنش خشکی.

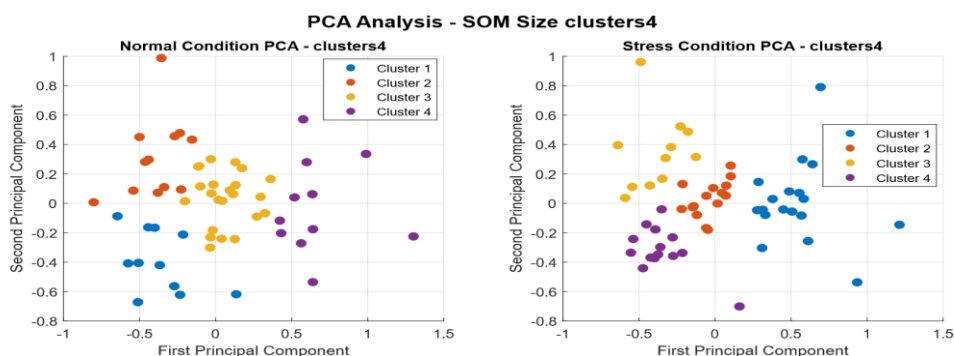
Figure 8. Output maps of the SOM network with $[1 \times 6]$ structure for rice morphological data. a) Neighborhood map of neurons (U-Matrix) under normal conditions, b) Neighborhood map of neurons (U-Matrix) under drought stress conditions, c) Hit Map under normal conditions, and d) Hit Map under drought stress conditions.



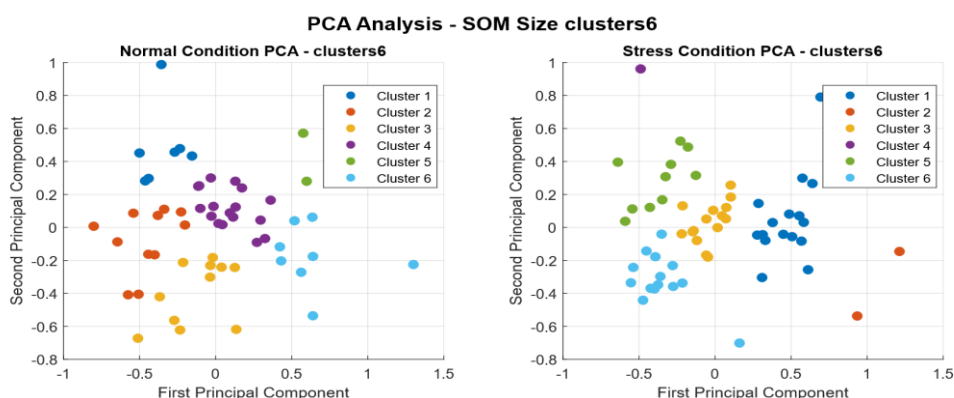
شکل ۹. نقشه‌های خروجی شبکه عصبی SOM با ساختار $[8 \times 1]$ برای داده‌های ریخت‌شناسی برنج. الف) نقشه همسایگی نرون‌ها در شرایط نرمال، ب) نقشه همسایگی نرون‌ها در شرایط تنش خشکی ج) نقشه فراوانی داده‌ها در شرایط نرمال، د) نقشه فراوانی داده‌ها در شرایط تنش خشکی.

Figure 9. Output maps of the SOM network with $[1 \times 8]$ structure for rice morphological data. A) Neighborhood map of neurons (U-Matrix) under normal conditions, b) Neighborhood map of neurons (U-Matrix) under drought stress conditions, c) Hit Map under normal conditions, and d) Hit Map under drought stress conditions.


تحلیل مؤلفه‌های اصلی روشی برای کاهش ابعاد است که به ما امکان می‌دهد داده‌های چندبعدی را در یک فضای دو یا سه بعدی نمایش دهیم. نمودار شکل ۱۰، نتایج خوشه‌بندی توسط شبکه عصبی SOM را در فضای دو مؤلفه اصلی اول، که بیشترین واریانس داده‌ها را توصیف می‌کنند، به تصویر می‌کشد. همانطور که در شکل مشاهده می‌شود، خوشه‌های شناسایی شده توسط شبکه عصبی SOM در فضای دو بعدی PCA نیز به خوبی از یکدیگر تفکیک شده‌اند. این همپوشانی کم بین گروه‌ها، صحت و اعتبار خوشه‌بندی انجام شده توسط الگوریتم شبکه عصبی SOM را به صورت بصری تأیید می‌کند و نشان می‌دهد که گروه‌های شناسایی شده، الگوهای واقعی و متمایزی در داده‌ها هستند. افزایش تعداد خوشه‌ها به ۶ گروه، منجر به شناسایی زیرگروه‌های جدیدی شده است که در این نمودار نیز به صورت ابرهای نقطه‌ای مجزا و قابل تفکیک دیده می‌شوند.



(الف) الف



(ب) ب



(ج) ج

شکل ۱۰. نمودار تحلیل مؤلفه‌های اصلی برای بصری‌سازی تفکیک خوشه‌های شناسایی شده توسط شبکه عصبی SOM با ساختار $[1 \times 4]$ در فضای دو بعدی (الف)، با ساختار بهینه $[1 \times 6]$ (ب)، با ساختار بهینه $[1 \times 8]$ (ج) مربوط به لاین‌های برنج در شرایط نرمال و خشکی. هر رنگ نمایانگر یک خوشه مجزا است.

Figure 10. Principal component analysis (PCA) plot to visualize the separation of clusters identified by the SOM network with $[1 \times 4]$ structure in 2D space (a), with the optimal structure $[1 \times 6]$ (b), with the optimal miner $[1 \times 8]$ (c) for rice lines under normal and drought conditions. Each color represents a separate cluster.

این سطح از جزئیات در خوشه‌بندی، برای برنامه‌های به‌نژادی که نیازمند شناسایی لاین‌هایی با ویژگی‌های ریخت‌شناسی بسیار خاص هستند، از اهمیت بالایی برخوردار است. تفکیک‌پذیری واضح این شش گروه در فضای PCA، بار دیگر برتری و اعتبار مدل با ۶ خوشه را که پیش‌تر توسط شاخص سیلوئت پیشنهاد شده بود، تأیید می‌کند. تحلیل نتایج خوشه‌بندی بهینه با ۶ خوشه که در جداول ۱ و ۲ ارائه شده است، امکان تفسیر دقیق‌تری از ساختار تنوع ریخت‌شناسی ژنوتیپ‌ها و واکنش آن‌ها به تنش خشکی را فراهم می‌آورد. از آنجا که خوشه‌بندی بر مبنای ویژگی‌های طول و عرض دانه صورت گرفته، تفاوت اصلی میان خوشه‌ها به گرایان این دو ویژگی بازمی‌گردد. در شرایط نرمال (جدول ۱)، ژنوتیپ‌ها در شش گروه ریخت‌شناسی متمایز توزیع شده‌اند که نشان‌دهنده تنوع قابل توجه در ژرم‌پلاسم مورد مطالعه است. خوشه‌های ۱ و ۲ به ترتیب شامل ۴ و ۱۰ لاین هستند که ویژگی مشترک آن‌ها، داشتن دانه‌هایی با ابعاد کوچکتر (کوتاه‌تر و باریک‌تر) نسبت به سایر گروه‌ها است. خوشه‌های ۳ و ۴ نماینده ژنوتیپ‌هایی با دانه‌هایی با ابعاد متوسط هستند. دو خوشه ۵ و ۶ ژنوتیپ‌های با دانه‌های درشت‌تر را در خود جای داده‌اند. به‌طور مشخص، خوشه ۵ با در برگرفتن ۲۰ لاین، بزرگترین گروه را تشکیل داده و نماینده ژنوتیپ‌هایی با دانه‌های بلند و کشیده است که از نظر بازارپسندی مطلوب محسوب می‌شوند. خوشه ۶ نیز شامل ۶ لاین با درشت‌ترین و کشیده‌ترین دانه‌ها می‌باشد. این توزیع، طیف کاملی از مورفولوژی دانه، از کوتاه و گرد تا بسیار بلند و کشیده را به تصویر می‌کشد.

جدول ۱. توزیع ژنوتیپ‌های برنج تحت شرایط نرمال بر اساس مدل بهینه SOM با ۶ خوشه

Table 1. Distribution of rice genotypes under normal conditions based on the SOM model with 6 clusters

تعداد لاین Number of lines	لاین‌های قرار گرفته در خوشه Lines located in the cluster	شماره خوشه Cluster number
4	Gil3, (Azucina × Bala)294, (Azucina × Bala)200, IR362542/2	1
10	(Azucina × Bala)150, (Azucina × Bala)145, (Azucina × Bala)64, Restore50, Domsiah, MusaTarom, GHARIB3, Gharibsiyahryhani, IR50maz, Line304	2
9	LINE229-2, (Azucina × Bala)217, (Azucina × Bala)108, (Azucina × Bala)292, (Azucina × Bala)261, Nemat, KMP41, DCL, Lebant	3
6	IR67017, DomsiahSolymandarab, Dashtisard, Hashemi, Dolar, IR24,	4
20	IR50, line831, IR3441, AnbarboElam, CY, Mehr, Line213, Fujiminuri, Hasani, Ghasraldashti, TE, (Azucina × Bala)105, (Azucina × Bala)34, (Azucina × Bala)72, (Azucina × Bala)73, (Azucina × Bala)84, (Azucina × Bala)104, (Azucina × Bala)151, (Azucina × Bala)274, Sangtarom	5
6	Dasht, line216, Vad, IR662320, Canhopatra, Usen	6

اعمال تنش خشکی، ساختار خوشه‌بندی را به شکل معناداری تغییر داد (جدول ۲). تفاوت اصلی میان دو محیط، همگرایی فنوتیپی و جابجایی ژنوتیپ‌ها به سمت خوشه‌های با ابعاد کوچکتر است. برخلاف شرایط نرمال که توزیع نسبتاً متوازی داشتیم، در شرایط تنش، اکثر ژنوتیپ‌ها در خوشه‌های ۲، ۳ و ۶ متمرکز شده‌اند. این نشان می‌دهد که تنش خشکی باعث کاهش عمومی در ابعاد دانه در بسیاری از لاین‌ها شده و آن‌ها را از نظر ریخت‌شناسی به یکدیگر شبیه‌تر کرده است. خوشه ۱ و ۲ (مجموعاً ۱۷ لاین) نماینده ژنوتیپ‌هایی هستند که تحت تنش، دانه‌های بسیار کوچکی تولید کرده‌اند. بسیاری از لاین‌هایی که در شرایط نرمال در خوشه‌های با ابعاد متوسط بودند، به این گروه‌ها منتقل شده‌اند که نشان‌دهنده حساسیت آن‌ها به تنش است. خوشه‌های ۴ و ۱ که به ترتیب تنها یک و دو لاین را شامل می‌شوند، ممکن است نماینده ژنوتیپ‌هایی با پاسخ شدید و خاص به تنش باشند که از الگوی عمومی جمعیت جدا شده‌اند.

خوشه ۶ شامل ۱۳ لاین است که با وجود تنش، همچنان دانه‌هایی با ابعاد نسبتاً بزرگتر تولید کرده‌اند. این ژنوتیپ‌ها کاندیداهای بالقوه برای تحمل به خشکی محسوب می‌شوند، زیرا توانسته‌اند ویژگی مطلوب اندازه دانه را تا حد زیادی حفظ کنند. در مجموع، مقایسه دو محیط نشان می‌دهد که شبکه SOM نه تنها قادر به گروه‌بندی ژنوتیپ‌ها بر اساس تنوع ذاتی آن‌هاست، بلکه ابزاری قدرتمند برای بصری‌سازی و کمی‌سازی تأثیر تنش محیطی بر فنوتیپ و شناسایی واکنش‌های متفاوت ژنوتیپ‌ها می‌باشد.

جدول ۲. توزیع ژنوتیپ‌های برنج تحت شرایط تنش خشکی بر اساس مدل SOM با ۶ خوشه

Table 2. Distribution of rice genotypes in morphological clusters under drought stress conditions based on the SOM model with 6 clusters

شماره خوشه Cluster number	لاین‌های قرار گرفته در خوشه Lines located in the cluster	تعداد لاین Number of lines
1	Taromamiri, IR58	2
2	Alikazemi, Mirtarom, Domsefeid, Salari, P77, IR74720, P96, Ahmalitarom, Domzard, fajr2, IR64, IR28, IR66232, Tarompakotah, Sangjo	15
3	IR30, (Azucina × Bala)182, (Azucina × Bala)51, (Azucina × Bala)42, (Azucina × Bala)5, (Azucina × Bala)234, (Azucina × Bala)85, Binam, (Azucina × Bala)307, MohammadiChparsar, DomsiahSolymandarab7, Anbarbouu, Ghashangeh, IR67715, Arjantin	15
4	(Azucina × Bala)257	1
5	(Azucina × Bala)218, (Azucina × Bala)159, (Azucina × Bala)116, line30amol, (Azucina × Bala)302, (Azucina × Bala)305, (Azucina × Bala)204, (Azucina × Bala)169, Hasansaraei, Neda	10
6	(Azucina × Bala)270, (Azucina × Bala)265, (Azucina × Bala)286, (Azucina × Bala)141, (Azucina × Bala)123, (Azucina × Bala)93, (Azucina × Bala)241, (Azucina × Bala)224, (Azucina × Bala)114, NP125, IR4491, Norin, Zerehbandpzi	13

نتیجه‌گیری: این پژوهش نشان داد که تلفیق پردازش تصویر دیجیتال با شبکه عصبی خودسازمانده (SOM)، یک متدولوژی کارآمد، سریع و غیرمخرب برای ارزیابی کمی و طبقه‌بندی تنوع ریخت‌شناسی در دانه‌های برنج است. این رویکرد با فراهم آوردن معیارهای عینی، ابزاری قدرتمند برای شناسایی و انتخاب ژنوتیپ‌های برتر در برنامه‌های به‌نژادی محسوب می‌شود. نتایج به‌طور مشخص نشان داد که این سیستم قادر است ژنوتیپ‌های با پتانسیل بازارپسندی بالا (بر اساس ابعاد دانه) را در شرایط نرمال تفکیک کرده و همچنین ژنوتیپ‌های متحمل به تنش خشکی را بر اساس پایداری فنوتیپی صفات دانه شناسایی نماید. بنابراین، این متدولوژی نه تنها به‌عنوان یک ابزار طبقه‌بندی، بلکه به‌عنوان یک سیستم حمایتی تصمیم‌گیری برای به‌نژادی گزینشی در شرایط محیطی مختلف، پتانسیل کاربردی بالایی دارد. پیشنهاد می‌شود در مطالعات آتی، با گسترش مجموعه ویژگی‌ها و ادغام این داده‌های فنوتیپی با اطلاعات ژنومیکی، ارتباط میان خصوصیات ریخت‌شناسی و مبانی ژنتیکی آن‌ها مورد بررسی عمیق‌تری قرار گیرد.

سپاسگزاری: بدین وسیله از مدیریت محترم پژوهش و فناوری دانشگاه گنبد کاووس به‌دلیل حمایت‌های مالی این طرح در قالب گرنت پژوهشی و همچنین از مدیریت محترم گروه تولیدات گیاهی و سایر همکاران گروه به‌خاطر همکاری و همراهی در انجام این تحقیق، سپاسگزاری می‌شود.

References

- Bishop, C. M., & Nasrabadi, N. M. (2006). Pattern recognition and machine learning (Vol. 4, No. 4, p. 738). New York: springer.
- Cinar, I., & Koklu, M. (2022). Identification of rice varieties using machine learning algorithms. *Journal of Agricultural Sciences*, 28(2): 307–325.
<https://doi.org/10.15832/ankutbd.862482>
- Das, P., Jha, G. K., Lama, A., & Parsad, R. (2023). Crop yield prediction using hybrid machine learning approach: a case study of lentil (*Lens culinaris Medik.*). *Agriculture*, 13(3), 596.
<https://doi.org/10.3390/agriculture13030596>
- Deshai, N., Ambikapathy, A., & Kumar, R. (2024). Deep Learning and Its Applications. Cipher Publisher.
- Din, N. M. U., Assad, A., Dar, R. A., Rasool, M., Sabha, S. U., Majeed, T., ... & 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>

- Farahnakian, F., Sheikh, J., Farahnakian, F., & Heikkonen, J. (2024). A comparative study of state-of-the-art deep learning architectures for rice grain classification. *Journal of Agriculture and Food Research*, *15*, 100890. <https://doi.org/10.1016/j.jafr.2023.100890>
- Felizardo, K. B., Paredes, A. M. C., & Arboleda, E. R. (2024). Advancements in Artificial Intelligence (AI) for enhanced insights and automation in rice agriculture: A systematic review. *International Journal of Science and Research Archive*, *11*(1), 444-463. <https://doi.org/10.30574/ijrsra.2024.11.1.0092>
- Himmelboe, M., Jørgensen, J. R., Gislum, R., & Boelt, B. (2025). Seed identification using machine vision: Machine learning features and model performance. *Computers and Electronics in Agriculture*, *231*, 109884. <https://doi.org/10.1016/j.compag.2024.109884>
- Jeyaraj, P. R., Asokan, S. P., & Nadar, E. R. S. (2022). Computer-assisted real-time rice variety learning using deep learning network. *Rice Science*, *29*(5), 489-498. <https://doi.org/10.1016/j.rsci.2022.02.003>
- Khan, M., Hooda, B. K., Gaur, A., Singh, V., Jindal, Y., Tanwar, H., ... & Yadav, K. K. (2024). Ensemble and optimization algorithm in support vector machines for classification of wheat genotypes. *Scientific Reports*, *14*(1), 22728. <https://doi.org/10.1038/s41598-024-72056-0>
- Liakos, K. G., Busato, P., Moshou, D., Pearson, S., & Bochtis, D. (2018). Machine learning in agriculture: A review. *Sensors*, *18*(8), 2674. <https://doi.org/10.3390/s18082674>
- Makmuang, S., Nootchanat, S., Ekgasit, S., & Wongravee, K. (2021). Non-destructive method for discrimination of weedy rice using near infrared spectroscopy and modified self-organizing maps (SOMs). *Computers and Electronics in Agriculture*, *191*, 106522. <https://doi.org/10.1016/j.compag.2021.106522>
- Moses, K., Miglani, A., & Kankar, P. K. (2022). Deep CNN-based damage classification of milled rice grains using a high-magnification image dataset. *Computers and Electronics in Agriculture*, *195*, 106811. <https://doi.org/10.1016/j.compag.2022.106811>
- Rajalakshmi, R., Faizal, S., Sivasankaran, S., & Geetha, R. (2024). RiceSeedNet: Rice seed variety identification using deep neural network. *Journal of Agriculture and Food Research*, *16*, 101062. <https://doi.org/10.1016/j.jafr.2024.101062>
- Razavi, M., Mavaddati, S., & Koohi, H. (2024). ResNet deep models and transfer learning technique for classification and quality detection of rice cultivars. *Expert Systems with Applications*, *247*, 123276. <https://doi.org/10.1016/j.eswa.2024.123276>

- Saxena, P., Priya, K., Goel, S., Aggarwal, P. K., Sinha, A., & Jain, P. (2022). Rice varieties classification using machine learning algorithms. *Journal of Pharmaceutical Negative Results*, 13(7), 3762-3772. <https://doi.org/10.47750/pnr.2022.13.S07.479>
- Sheng, R. T. C., Huang, Y. H., Chan, P. C., Bhat, S. A., Wu, Y. C., & Huang, N. F. (2022). Rice growth stage classification via RF-based machine learning and image processing. *Agriculture*, 12(12), 2137. <https://doi.org/10.3390/agriculture12122137>
- Singh, K. R., Chaudhury, S., Datta, S., & Deb, S. (2022). Gray level size zone matrix for rice grain classification using back propagation neural network: a comparative study. *International Journal of System Assurance Engineering and Management*, 13(5), 2683-2697. <https://doi.org/10.1007/s13198-022-01739-6>
- Sultana, S., Faruque, M., & Islam, M. R. (2022). Rice grain quality parameters and determination tools: a review on the current developments and future prospects. *International Journal of Food Properties*, 25(1), 1063-1078. <https://doi.org/10.1080/10942912.2022.2071295>
- Weerakoon, S., & Somaratne, S. (2021). Genetic diversity of weedy rice (*Oryza sativa* f. *spontanea*) populations in Sri Lanka: An application of Self Organizing Map (SOM). *Asian Journal of Agriculture*, 5(1), 35-43. <https://doi.org/10.13057/asianjagric/g050106>