

Research Article

Development of an intelligent machine vision system for online quality measurement of rice paddy

Fatemeh Sadeghi¹, Davood Kalantari^{2*}, Sajad Kiani³

1. M.Sc., Department of Biosystem Engineering, Sari Agricultural Sciences and Natural Resources University
2. Associate Professor, Department of Biosystems Engineering, Sari Agricultural Sciences and Natural Resources University
3. Assistant Professor, Department of Biosystems Engineering, Sari Agricultural Sciences and Natural Resources University

(Received 13 May 2023, Received in revised form 7 October 2023, Accepted 7 October 2023)

Introduction: Farmers use the traditional method (unaided eye and dimensional examination of the seeds) to determine the percentage of healthy rice paddies after harvesting and drying. In recent years, however, machine vision has grown significantly and many researchers have used this system to classify and measure the quality of agricultural and food products, identify different varieties of products, determine the geographical origin of products, identify losses, estimate effective substances, and other related subjects. For example, in one study, the mixing percentage of wheat grains and the determination of grain hardness were performed with the help of machine vision (Fazaeli and Afkari-Sayah, 2009). In order to calculate the hardness of seeds, they used the weight percentage and to measure the mixing percentage, they used the color characteristics of the samples. The classification accuracy obtained in this research was 93%. In another research, artificial neural networks (ANN) and some statistical techniques were used to identify and classify 5 varieties of Iranian rice (Hatami et al., 2010). In their study, samples of 300 seeds were randomly selected from each cultivar, and images of the samples were captured using a digital camera. Then, using the thresholding process, the images were segmented and the features of the area, length of major and minor axis, perimeter, convexity level, strength, extent, and equivalent diameter were extracted. In the created regression model, the highest detection percentage was obtained in Garde and Ramadani cultivars equal to 93.6 and 91.48%, respectively.

According to the previous studies, it was found that determining the percentage of crop loss and the percentage of paddy harvested from the field before the bleaching stage is very important so that the percentage of paddy harvested from the field shows the yield of the crop per hectare. Therefore, in the current research, an intelligent machine vision system was developed and evaluated to quickly detect and determine the percentage of healthy paddy seeds.

Materials and methods: First, five varieties of rice paddy were prepared. The samples included devoid and healthy seeds. In order to determine the moisture content of the samples, the samples were placed in an oven with a temperature of 70°C for 24 hours. Next, the images were captured online with the help of a 16-megapixel camera that was placed perpendicular to the surface of the samples in the chamber of the imaging system. The distance between the camera and the samples was fixed at 30 cm. In addition to the imaging camera, the system includes a cubic enclosure made of stainless steel and a lighting unit system. Two projector light sources were installed in the upper half of the chamber so that proper and completely uniform lighting (using optical filters) was guaranteed. To prepare pictures, 250 seeds were randomly selected from healthy samples and pictures were taken. Then the images containing the devoid seeds were taken according to the previous settings and under the same lighting conditions. Moreover, in order to evaluate the algorithm, samples were taken and stored as a combination of healthy and devoid rice with 5%, 10%, and 15% devoid percentages. Next, the machine vision system algorithm was designed and coded in MATLAB software. In the order that the images were read first in

* Corresponding author: dkalantari2000@yahoo.com

the software, pre-processing was applied to the images and finally, their color and shape characteristics were extracted. Finally, a multilayer perceptron (MLP) artificial neural network with the Levenberg-Marquardt algorithm was used for clustering and separating full and devoid seeds. The input layer of MLP had the number of neurons equal to the number of features considered in each stage of training. In the present study, a neural network with a hidden layer was used, the number of neurons of which was selected as 10 by trial and error.

Results and discussion: First, the color characteristics of healthy and devoid rice were extracted. Due to the non-uniformity of the results obtained from the analysis of color channels, PCA analysis was used to check the discriminating power of color features. For example, in the Binam cultivar, R color channels related to healthy and devoid seeds overlapped and it was not suitable for separating and clustering the seeds. For this variety, color channel B was chosen as a suitable option for separating or distinguishing between healthy and devoid seeds. For the Neda variety, the R color channel was very clearly separated for healthy and infected samples. In the second stage, the PCA analysis method was used to determine the more effective features that play a more important role in identifying healthy seeds from devoid ones. The results of the PCA analysis showed that by using all the shape and color features, a high percentage of mixing between healthy and devoid samples was created and it is not possible to use all the features to separate healthy and devoid samples in this way. Due to the fact that it is not possible to recognize the shape characteristics of rice grains when they are moved by volume on the conveyor belt, PCA analysis was performed using 3 extracted color features, where it is possible to check the image data pixel-by-pixel and to evaluate the operational usability of the system in online conditions. PCA analysis graphs, considering only 3 color characteristics of healthy and devoid rice samples, show that in the PCA score diagrams, healthy and devoid data can be separated to an acceptable extent and are separated in a certain range. Also, in the PCA loading diagrams, it can be seen that in all the tested samples, the color features are located at the farthest position from the center. This shows the ability of high resolution by all color features. The results of the training, validation, and testing of the perceptron neural network model created with 8 input neurons, one hidden layer with 10 hidden neurons, and two output linear layers were used to distinguish between devoid and healthy samples for different varieties of rice. According to the obtained results, the R^2 coefficient in training and final evaluation for the Roshan variety was equal to 0.86. In the same way, the highest R^2 coefficient in the final evaluation of the models created based on color characteristics was obtained for the Neda cultivar equal to 0.96.

Conclusion: In this research, an intelligent system based on image processing methods and artificial neural networks was implemented and evaluated to identify the devoid rice seeds from five newly improved rice cultivars. The system proposed in this research has high accuracy and speed compared to conventional experimental methods and scientific methods that have been used so far. PCA method was used for a more detailed examination of the effective components in distinguishing between healthy and devoid seeds. Due to the need for the system to be online and the quality measurement of rice grains in piles, three color features were selected from among the features and modeled using MLP artificial neural networks. The final results, based on the statistical parameters, showed that the implemented system can be used as an online, fast, and cheap system for measuring the quality of paddy in the stages of entering the lines of rice bleaching factories.

Keywords: *Image processing, Artificial neural network, MATLAB, Non-destructive testing*

How to cite this article:

Sadeghi, F., Kalantari, D., Sajad Kiani, S., (2023). Development of an intelligent machine vision system for online quality measurement of rice paddy. *Innov. Food Technol.*, 10(4), 335-357.
DOI: <http://dx.doi.org/10.22104/IFT.2023.6268.2141>

مقاله پژوهشی

توسعه یک سامانه بینایی ماشین هوشمند به منظور کیفیت‌سنجی برخط شلتوک

فاطمه صادقی^۱، داود کلانتری^{۲*}، سجاد کیانی^۳

۱. دانشجوی کارشناسی ارشد، گروه مهندسی بیوسیستم، دانشگاه علوم کشاورزی و منابع طبیعی ساری

۲. دانشیار، گروه مهندسی بیوسیستم، دانشگاه علوم کشاورزی و منابع طبیعی ساری

۳. استادیار، گروه مهندسی بیوسیستم، دانشگاه علوم کشاورزی و منابع طبیعی ساری

(تاریخ ارسال: ۱۴۰۲/۰۲/۲۳، تاریخ آخرین بازنگری: ۱۴۰۲/۰۷/۱۵، تاریخ پذیرش: ۱۴۰۲/۰۷/۱۵)

چکیده

روش‌هایی که به‌طور معمول برای شناسایی شلتوک‌های پوک از سالم مورد استفاده قرار می‌گیرند، اغلب زمان‌بر و هزینه‌بر هستند. به همین دلیل، در پژوهش حاضر روشی هوشمند و سریع مبتنی بر بینایی ماشین و شبکه‌های عصبی مصنوعی جهت تشخیص دانه‌های شلتوک پوک از سالم ارائه شد. تصاویر دیجیتالی پنج رقم شلتوک در سه وضعیت سالم، پوک و مخلوط و در دو حالت پراکنده و کپه‌ای تهیه شدند. پس از انجام پیش‌پردازش و قطعه‌بندی، برای هر دانه شلتوک ۳ ویژگی رنگی و ۵ ویژگی شکلی استخراج گردید. به‌منظور تشخیص تأثیرگذارترین ویژگی‌ها در تشخیص شلتوک‌های سالم از پوک، روش تحلیل مؤلفه‌های اصلی (PCA) بکار گرفته شد. سپس برای ایجاد مدل شناسایی و دسته‌بندی نمونه‌ها از شبکه‌های عصبی مصنوعی پرسپترون چندلایه (MLP) که بر اساس مؤلفه‌های اصلی حاصل از روش PCA به دست آمده بودند، استفاده گردید. برای بررسی قابلیت مدل‌سازی و اعتبارسنجی هر الگوریتم از پارامترهای آماری ویژگی، حساسیت، ریشه میانگین مربعات خطا (RMSE) و ضریب همبستگی (R^2) استفاده شد. نتایج نشان داد که روش هوشمند طراحی شده می‌تواند با دقت قابل قبول در تمامی ارقام ($R^2_p > 0.85$, $RMSE_p < 0.130$, $Sensitivity > 0.8$ & $Specificity > 0.98$) دانه‌های سالم و پوک را تشخیص دهد؛ بنابراین از روش بینایی ماشین در ترکیب با شبکه‌های عصبی مصنوعی می‌توان به‌عنوان روشی هوشمند و سریع در ورودی کارخانه‌های سفیدکن شلتوک برای ارزیابی کیفیت شلتوک و تشخیص شلتوک‌های سالم از پوک استفاده کرد.

واژه‌های کلیدی: پردازش تصویر، شبکه عصبی مصنوعی، متلب، آزمون غیر مخرب

۱. مقدمه

خوشه‌های برنج رسیده شامل دانه‌های پر و پرنشده است. تعداد دانه‌های پر شده در خوشه با عملکرد محصول نسبت مستقیم دارد و تعیین میزان عملکرد از اهمیت بالایی برخوردار است [۱]. محصول برنج همانند سایر محصولات کشاورزی دارای ارقام مختلفی می‌باشند که هر رقم خود دارای قیمت و کاربردهای مختلف در صنعت غذا می‌باشد. شناسایی و تعیین رقم برنج توسط کشاورزان و افراد خبیره به صورت تجربی و با بررسی ویژگی‌های هندسی مانند ابعاد، ویژگی‌های بویایی و رنگی مثل میزان تیرگی یا روشنی و نیز نحوه‌ی استقرار دانه‌ها در کنار هم در یک توده انجام می‌گیرد. همچنین کشاورزان با روش سنتی (چشم غیرمسلح و با بررسی ابعادی دانه‌ها) اقدام به تعیین درصد پوک و پر بودن شلتوک‌ها پس از مراحل برداشت و خشک کردن می‌کنند. بینایی ماشین در قرن اخیر در صنایع مختلف کشاورزی و غذایی اهمیت چشمگیری پیدا کرده است و پژوهشگران متعددی برای کاربردهای متفاوت از جمله طبقه‌بندی و کیفیت‌سنجی محصولات کشاورزی و غذایی، تشخیص ارقام مختلف محصولات، تعیین منشأ جغرافیایی محصولات، شناسایی افت، برآورد ماده مؤثره و... از این سامانه استفاده کرده‌اند [۲-۹]. بینایی ماشین از جمله تکنولوژی‌ها است که می‌تواند برای درجه‌بندی محصولات کشاورزی به صورت غیر تخریبی مورد استفاده قرار گیرد. این روش برای تعیین ویژگی‌های ظاهری محصولات کشاورزی با استفاده از اندازه‌گیری خصوصیات فیزیکی و مکانیکی آنها شامل اندازه ابعاد، رنگ و بافت به کار برده می‌شود. استخراج و اندازه‌گیری سریع این ویژگی‌ها با تکرارپذیری قابل قبول به کمک شیوه‌های بینایی رایانه‌ای روشی نسبتاً ارزان قیمت برای کیفیت‌سنجی و طبقه‌بندی محصولات با درجه‌های مختلف می‌باشد [۱۰].

در پژوهشی ماشینی بر اساس جداکننده بادی (بر اساس وزن) و تجزیه و تحلیل تصویر دانه‌های جداشده برای کیفیت‌سنجی دانه‌های شلتوک طراحی و تولید شد [۱۱]. این روش با وجود دقت قابل قبول در تشخیص دانه‌های پوک، به لیل وجود ساز و کار مکانیکی، پیچیده و پرهزینه بود. در پژوهشی دیگر روشی مبتنی بر پردازش تصویر برای تخمین

عملکرد برنج بر اساس ناحیه خوشه پیشنهاد شد [۱۲]. در این روش ناحیه پانیکول با گرفتن تصاویر از زوایای مختلف محاسبه می‌شد ولی تبعیض دانه‌های پر و پوک را در طول اندازه‌گیری مساحت خوشه در نظر نمی‌گیرد که این امر از معایب روش ارائه شده است. به طور مشابه، روشی مبتنی بر سایه، برای شمارش دانه‌های پر استفاده شد [۱۳] در این روش از چهار نور برای ایجاد سایه در اطراف دانه‌ها استفاده شد. دانه‌های پر بر اساس نسبت خصوصیات شکلی^۱ سایه به خصوصیات دانه شمارش شدند. یکی از محدودیت‌های اصلی این روش این بود که دانه‌ها باید در یک الگوی مناسب چیده شوند تا سایه روشن و مشخصی از هر دانه به دست آید. همچنین حفظ فاصله مناسب برای هر دانه در طی فرآیند کامل تمایز و شمارش دانه‌های پر و پوک دشوار است.

در پژوهشی مشابه درصد اختلاط دانه‌های گندم و تشخیص سختی دانه‌ها به کمک بینایی ماشین انجام شد [۱۴]. این پژوهش از جهت شناسایی خصوصیات آسیابی دانه‌های گندم و نحوه‌ی اختلاط گندم نرم و سخت از اهمیت بالایی برخوردار است. آنها به منظور محاسبه میزان سختی دانه‌ها از درصد وزنی و برای اندازه‌گیری درصد اختلاط از ویژگی‌های رنگی نمونه‌ها استفاده نمودند. دقت طبقه‌بندی به دست آمده در این پژوهش ۹۳٪ به دست آمده آمد. در پژوهشی دیگر به منظور شناسایی و دسته‌بندی ۵ رقم برنج ایرانی شامل: طارم، فریدونکنار، هاشمی، رضانی و گرده از شبکه‌های عصبی مصنوعی (ANN) و چند تکنیک آماری استفاده شد [۱۵]. نمونه‌ها (۳۰۰ دانه) به صورت تصادفی از هر رقم انتخاب و با استفاده از دوربین دیجیتال مدل Canon تصاویر نمونه‌ها جمع‌آوری شد. سپس با استفاده از فرآیند آستانه‌یابی، تصاویر را قطعه‌بندی و ویژگی‌های مساحت، طول محور بزرگ و کوچک، محیط، سطح تحدب، استحکام، وسعت و قطر معادل استخراج کردند. در مدل رگرسیونی ایجادشده بالاترین درصد تشخیص در ارقام گرده و رضانی به ترتیب برابر ۹۳/۶ و ۹۱/۴۸٪ به دست آمد.

در پژوهشی دیگر بینایی ماشین برای شناسایی اصالت برنج رقم هاشمی و تشخیص درصد اختلاط آن با برنج باسماتی

کلیدی برای ارزیابی کیفیت تغذیه‌ای گندم هستند. در این مطالعه، بازتاب طیفی هسته گندم و آرد در محدوده VNIR به دست آمد. سپس محتوای ریزمغذی گندم اندازه‌گیری و ارتباط آنها با طیف‌ها مدل‌سازی شد. نتایج نشان داد که مدل ایجادشده با بازتاب طیفی از دانه‌های گندم پیش‌بینی‌های خوبی برای کلسیم، منیزیم، مولیبدن و روی را داشته است ($R^2 > 0.70$).

یک سامانه بینایی ماشینی دیگر برای بررسی دانه‌های برنج قرمز ایندیکا^۱ معیوب شامل شکسته، گچی، آسیب‌دیده یا لکه‌دار بکار گرفته شد [۲۰]. در این سامانه از یک طبقه‌بندی‌کننده ماشین بردار پشتیبان^۲ (SVM) برای شناسایی هسته‌های شکسته برنج در تصاویر استفاده شد. همچنین با استفاده از روش لبه‌یابی و ریخت‌شناسی، نقاط آسیب‌دیده و لکه‌دار روی هسته برنج شناسایی شدند. دقت تشخیص برای دانه‌های شکسته، گچی و مناطق آسیب‌دیده و لکه‌دار به ترتیب ۹۹/۳، ۹۶/۳ و ۹۳/۶٪ رسید و بیان کردند روش پیشنهادی پتانسیل قابل‌توجهی برای استفاده برای تشخیص سریع و دقیق کیفیت برنج قرمز ایندیکا و درجه‌بندی خودکار آن دارد.

در جدیدترین پژوهش [۲۱] یک سامانه خودکار و سریع تشخیص کیفیت ظاهری برنج بر اساس فناوری بینایی ماشین با معرفی یک شبکه عصبی کانولوشن^۳ و فناوری پردازش تصویر ارائه شد. در این مطالعه، تصاویر NIR و RGB به داده‌های تصویری پنج کانالی توسط تابع برهم‌نهی تولید شدند و تصاویر با ترکیب یک الگوریتم و با تابع آستانه تطبیقی پیش پردازش شدند. دانه‌های مختلف در نمونه‌ها برچسب‌گذاری شدند و برای آموزش در شبکه عصبی کانولوشن قرار گرفتند. نتایج تجربی نشان داد که قدرت تفکیک سامانه می‌تواند به ۹۲/۳٪ برسد. همچنین بیان کردند که در فرآیند تشخیص به‌وسیله این سامانه نه تنها مشکلات خطاهای بازرسی سنتی برای حجم نمونه بزرگ کاهش می‌دهد، بلکه زمان و دقت تشخیص را به میزان قابل

به‌کار گرفته شد [۱۶]. آنها بر این باور بودند مخلوط چند برنج با هم نسبت به ترکیب یک نوع برنج بافت متفاوتی را شامل می‌شود. در این پژوهش با سه روش هیستوگرام تصویر، ماتریس هم‌رخداد^۱ و الگوی دودویی محلی اقدام به شناسایی ویژگی‌های بافتی دانه‌ها نمودند. ابتدا ۱۰۰ تصویر از رقم هاشمی به‌عنوان برنج اصلی تهیه و در مراحل بعد برنج باسماتی را به‌صورت تدریجی و به مقدار ۵٪ از کل به برنج اصلی اضافه شد. این عمل تا جایی که میزان هر دو رقم به برابری رسید ادامه پیدا کرد و در هر مرتبه ۱۰۰ تصویر تهیه شد. نتایج نشان داد الگوی دودویی محلی با خطای ۴/۹۲ و ضریب همبستگی با خطای ۰/۹۱۵۳ بهترین کارایی را برای مدل پیشنهادی دارا است. همچنین به‌منظور تشخیص ۱۵ رقم مختلف شلتوک از بینایی ماشین و شبکه‌های عصبی مصنوعی استفاده شد [۱۷]. نمونه‌ها از ایستگاه تحقیقاتی کشاورزی تهیه، تصاویر با استفاده از دوربین رنگی ۱۴ مگاپیکسلی Pentax استخراج و از هر رقم شلتوک ۲۰۰ تصویر برداشت شد. با استفاده از ماتریس هم‌رخداد ۵ ویژگی بافتی شامل انرژی، همگنی، آنتروپی، کنتراست و همبستگی برای آموزش و آزمون شبکه‌ی عصبی چند لایه انتخاب شد. نتایج نشان داد طبقه‌بندی با دقت ۹۲/۳۳٪ صورت گرفته است.

در مطالعه‌های دیگر [۱۸] یک سامانه بینایی رایانه‌ای متشکل از یک سینی برنج ویژه، اسکنر و نرم‌افزار پردازشگر برای ارزیابی کیفیت ظاهری چهار رقم برنج توسعه داده شد و بیان کردند که تکنیک پردازش تصویر پتانسیل قابل توجهی برای استفاده برای ارزیابی کیفیت ظاهری هسته برنج دارد. دانه‌های هر چهار رقم مورد مطالعه با توجه به ویژگی‌های ابعادی آنها با دقت طبقه‌بندی قابل قبول (>98%) و ضرایب $R^2 > 0.98$ و $RMSE > 0.08$ به گروه‌های دانه‌های کامل و شکسته طبقه‌بندی شدند. همچنین آنها برای تفکیک لکه‌های قرمز و سیاه دانه برنج از آستانه‌گذاری بر روی تفاوت رنگ قرمز و اجزای مقیاس خاکستری به‌طور دقیق استفاده کردند. همچنین در پژوهشی دیگر برای پیش‌بینی محتوای ریزمغذی گندم به کار گرفته شد [۱۹]. ریزمغذی‌ها عوامل

2. Red Indica Rice

3. Support Vector Machine

4. Convolutional Neural Network

1. Co-occurrence matrix

قرار داده شدند. میزان رطوبت شلتوک‌ها بر اساس معیار وزن خشک ($M_{d,b}$) آنها محاسبه شد.

۲.۲ سامانه بینایی ماشین

برای اکتساب تصاویر و همچنین تشخیص آنها از یکدیگر یک سامانه بینایی ماشینی توسعه داده شد. سامانه بینایی ماشین از قسمت‌های زیر تشکیل شده است.

۱.۲.۲ سامانه تصویربرداری

در این پژوهش تصاویر به کمک یک دوربین ۱۶Mp که به صورت کاملاً عمود و موازی با سطح نمونه‌ها در محفظه سامانه تصویربرداری قرار داده شده بود، به صورت بر خط تهیه شدند. فاصله دوربین تا نمونه‌ها ۳۰cm به طور ثابت در نظر گرفته شد (شکل ۱). سامانه علاوه بر دوربین تصویربرداری شامل یک محفظه مکعبی از جنس فولاد زنگ نزن و سیستم واحد نورپردازی است. دو عدد منبع نور پرژکتوری در نیمه بالایی محفظه تعبیه شد به گونه‌ای که نورپردازی مناسب و کاملاً یکنواخت (با استفاده از فیلترهای نوری) انجام شود. نورپردازی مناسب و زاویه قرارگیری منابع نوری باعث ایجاد نور یکنواخت و در نتیجه کاهش سایه در تصاویر می‌شود که این امر در ادامه باعث افزایش کیفیت بصری تصویر و کاهش نوفه در تصاویر می‌شود.

توجهی بهبود می‌بخشد که این امر اهمیت بالای برای توسعه صنعت برنج دارد.

تعیین درصد افت محصول و درصد پوکی شلتوک برداشت‌شده از سطح مزرعه قبل از مرحله سفید کردن از اهمیت زیادی برخوردار است. در فرآیند فرآوری و تبدیل شلتوک به برنج سفید ممکن است برخی از دانه‌ها پوک بوده و تعیین درصد پوکی محصول قبل از مرحله شالی‌کوبی دارای اهمیت ویژه‌ای است. به طوری که درصد پوک بودن شلتوک‌های برداشت‌شده از سطح مزرعه نشان‌دهنده عملکرد محصول در هکتار می‌باشد. در این پژوهش یک سامانه بینایی‌ماشین هوشمند به منظور تشخیص سریع و تعیین درصد دانه‌های شلتوک پوک توسعه و ارزیابی شد.

۲. مواد و روش‌ها

۱.۲ تهیه نمونه‌ها

پنج رقم شلتوک برنج (از هر رقم ۵۰۰g) از پژوهشکده برنج دانشگاه علوم کشاورزی و منابع طبیعی ساری تهیه شد. ابتدا ناخالصی‌ها شامل کاه و کلش، بذر گیاهان دیگر و بذرهای شکسته برای کلیه ارقام از بذرهای سالم جدا شد. نمونه‌ها شامل دانه‌های پوک و سالم بودند. به منظور تعیین میزان رطوبت نمونه‌ها، نمونه‌ها به مدت ۲۴h در آون با دمای ۷۰°C



شکل (۱) سامانه تصویربرداری مرئی ایجادشده

Fig 1. Created visible imaging system

قرار گرفت و تصاویر اخذ شدند. سپس تصاویر حاوی دانه‌های پوک طبق تنظیمات قبل و با همان شرایط گرفته شدند. همچنین به منظور ارزیابی الگوریتم، نمونه‌ها به صورت ترکیبی


برای تهیه تصاویر ابتدا تعداد ۲۵۰ دانه به صورت تصادفی از نمونه‌های سالم انتخاب شد. پس‌زمینه به همراه دانه‌ها در زیر محفظه به طوری که در مرکز دید دوربین قرار داشته باشند،

از شلتوک‌های سالم و پوک با درصدهای ۵٪، ۱۰٪ و ۱۵٪. پوک نیز گرفته و ذخیره شد.

های رنگی و شکلی آن‌ها استخراج می‌شد. پیش‌پردازش شامل عملیاتی مانند بخش‌بندی، انتقال از فضای رنگی به باینری با استفاده از روش آستانه‌گذاری و حذف پس‌زمینه می‌باشد. سپس تصاویر آماده برای استخراج ویژگی‌های رنگی و شکلی شد. فرآیند استخراج ویژگی‌های رنگی و شکلی تصاویر مطابق نمودار روند نمای نشان داده‌شده در شکل (۲) صورت گرفت.

۲.۲.۲ پردازش تصاویر و استخراج ویژگی‌ها

الگوریتم سامانه بینایی ماشین در نرم‌افزار MATLAB طراحی و کد نویسی شد. به ترتیبی که تصاویر ابتدا فراخوانی شده، پیش‌پردازش بر روی تصاویر اعمال و در نهایت ویژگی‌



شکل (۲) نمودار روند نمای استخراج ویژگی‌های رنگی و شکلی

Fig 2. Diagram of the extraction process of color and shape features

- استخراج ویژگی‌ها

برچسب‌گذاری شده، ویژگی‌های آورده شده در جدول (۱) را برای هر دانه به‌طور مجزا محاسبه نمود.

یک الگوریتم ترکیبی برای محاسبه ویژگی‌های شکلی و رنگی در برنامه اصلی بعد از انجام مراحل پیش‌پردازش طراحی و استفاده شد. این الگوریتم با دریافت تصویر باینری و

جدول (۱) ویژگی‌های رنگی و شکلی استخراج شده برای هر دانه شلتوک

Table 1. Color and shape features extracted for each rice grain

Morphological features خصوصیات شکلی	Color features خصوصیات رنگی
Area سطح	R
Eccentricity خارج از مرکزیت	
Perimeter محیط	G
MajorAxisLength طول محور اصلی	
MinorAxisLength طول محور فرعی	B

بندی^۲ آنها بکار می‌رود. توضیحات تکمیلی این روش در منابع متعدد آورده شده است [۲۲].

الگوریتم ریاضی برای محاسبه PCs بر پایه محاسبه بردارهای ویژه و مقادیر ویژه یک ماتریس عمل می‌کند. مدل ریاضی متناظر با PCA بر پایه تجزیه ماتریس X به ماتریس $n \times A$ ، امتیازها^۳ (T) و ماتریس $N \times A$ بارگذاریها^۴ (P) طبق رابطه (۱) به دست می‌آید.

$$X = TP' + F = \sum_{a=1}^A t_a p'_a + F \quad (1)$$

که در این رابطه، X ماتریس ویژگی‌های اندازه‌گیری شده، T ماتریس امتیازها برای Y، P معکوس ماتریس بارگذاریها برای Y، F ماتریس خطاها برای X در مدل، بردار امتیاز نمونه‌ها روی هر PC برای Y و بردار بارگذاری متغیرها روی هر PC برای Y.

- شبکه‌های عصبی مصنوعی (ANN)

از ANN به منظور ارتباط دادن ویژگی‌های استخراج شده از نمونه‌های سالم و پوک به طبقه هر کدام استفاده شد. برای این منظور از شبکه عصبی مصنوعی پرسپترون چند لایه (MLP) با الگوریتم Levenberg-Marquardt استفاده شد. لایه ورودی MLP دارای تعداد نرون برابر با تعداد

۳.۲.۲ داده‌کاوی و مدل‌سازی

- تحلیل مؤلفه‌های اصلی (PCA)

مؤلفه‌های اصلی PCA ارتباط موجود میان داده‌ها (ویژگی‌های استخراج شده محصولات/نمونه‌ها) و خصوصیات/صفات حسی آنها را به طور واضح مشخص می‌کند؛ لذا در پژوهش حاضر از روش PCA برای تعیین مناسب‌ترین ویژگی‌های استخراج شده و مشخص نمودن ارتباط بین آنها و نمونه‌های سالم و پوک به کار گرفته شد.

از دیدگاه ریاضی این روش به تبدیل خطی متعامدی گفته می‌شود که داده‌های موجود را به دستگاه مختصاتی جدیدی انتقال می‌دهد که محورهای آن مؤلفه‌های اصلی (PCs) هستند. این انتقال به گونه‌ای است که بزرگ‌ترین واریانس داده بر روی نخستین مؤلفه اصلی (PC1)، دومین بزرگ‌ترین واریانس بر روی دومین مؤلفه اصلی (PC2) قرار می‌گیرد و به همین ترتیب برای باقیمانده. نخستین مؤلفه اصلی استخراج شده یا PC1، بیشترین مقدار پراکندگی داده‌ها را در کل مجموعه در بر می‌گیرد. دومین مؤلفه استخراج شده یا PC2 بیشترین مجموعه داده‌هایی که توسط مؤلفه اول محاسبه نشده است را در نظر می‌گیرد. این روش در مواردی که تعداد متغیرها و ابعاد آنها زیاد باشد، برای کاهش^۱ ابعاد و خوشه-

2. Cluster Analysis
3. Scores Matrix
4. Loading Matrix

1. Data Reduction

که در آن مثبت حقیقی (*real positive*) شامل مواردی است که به‌وسیله‌ی سامانه به‌درستی پوک تشخیص داده شده‌اند، مثبت کاذب (*false positive*) مواردی است که به‌وسیله سامانه به‌اشتباه پوک تشخیص داده شده‌اند، منفی حقیقی (*real negative*) به مواردی اطلاق می‌شود که به‌وسیله سامانه به‌درستی سالم تشخیص داده شده‌اند و در نهایت منفی کاذب (*false negative*) مواردی است که به‌وسیله سامانه به‌اشتباه سالم تشخیص داده شده‌اند.

۳. نتایج و بحث

۱.۳ ویژگی‌های رنگی و شکلی استخراج شده

تصاویر اخذشده از نمونه‌ها توسط سامانه بینایی ماشین در شکل (۳) و خصوصیات رنگی مربوط به شلتوک‌های سالم و پوک مورد آزمون در شکل (۴) آورده شده‌اند. به‌طور نمونه، در رقم بینام، کانال‌های رنگی R مربوط به دانه‌های سالم و پوک هم‌پوشانی داشته و برای مدل تشخیصی مناسب به نظر نمی‌رسد. برای همین رقم، کانال رنگی B می‌تواند بهترین گزینه برای تفکیک یا تشخیص دانه‌های سالم و پوک از هم باشد. در صورتی که برای رقم ندا، کانال رنگی R به‌صورت خیلی واضح برای نمونه‌های سالم و پوک از هم تفکیک شده‌اند. کانال رنگی B می‌تواند برای ارقام دیگر مورد استفاده قرار گیرد. با توجه به یکسان نبودن نتایج به‌دست‌آمده از تحلیل کانال‌های رنگی از تحلیل PCA برای بررسی قدرت تفکیک‌کنندگی ویژگی‌های رنگی استفاده شد.

ویژگی‌های در نظر گرفته‌شده در هر مرحله از آموزش بود. تعیین تعداد لایه‌ها و تعداد نورون‌های موجود در لایه‌های پنهان میانی برای دریافت نتیجه مناسب بسیار حائز اهمیت است. به تجربه ثابت‌شده که شبکه عصبی با یک لایه پنهان میانی با تابع سیگموئید و تابع خطی در لایه خروجی قادر به پاسخگویی اکثر نیازهای روزمره مهندسی می‌باشد، به شرطی که تعداد کافی از نورون‌ها در لایه پنهان موجود باشد. نورون‌های لایه میانی به‌عنوان تشخیص‌دهنده الگو عمل می‌کنند، لذا کم بودن تعداد آن‌ها قدرت پیشگویی شبکه را کاهش داده و تعداد بیش از حد لزوم آن‌ها باعث تولید نگاهت بسیار پیچیده بین ورودی و خروجی شده که در نهایت برای داده‌های آموزش بسیار دقیق عمل کرده و برای داده‌های ارزیابی عملکرد پایینی نشان خواهد داد. به همین دلیل، در مطالعه حاضر از شبکه عصبی با یک لایه پنهان استفاده شد که تعداد نورون‌های آن با آزمون و خطا برابر با ۱۰ انتخاب گردید.

از معیارهای ضریب رگرسیون (R^2)، ریشه میانگین مربعات خطا (RMSE)، حساسیت^۱ و ویژگی^۲ برای اعتبارسنجی هر الگوریتم استفاده شد. حساسیت و ویژگی از لحاظ ریاضی دقت آزمونی را که وجود یا عدم وجود یک وضعیت را گزارش می‌کند، توصیف می‌کند. توانایی سامانه برای پیدا کردن موارد پوک را حساسیت می‌گویند. برای محاسبه حساسیت باید نسبت موارد مثبت حقیقی را به مجموع موارد مثبت حقیقی و منفی کاذب به دست آورد (رابطه ۲). توانایی سامانه برای پیدا کردن موارد سالم را ویژگی می‌گویند. برای محاسبه ویژگی باید نسبت موارد منفی حقیقی را به مجموع موارد منفی حقیقی و مثبت کاذب به دست آورد (رابطه ۳)


$$Sensitivity = \frac{real\ positive}{real\ positive + false\ negative} \times 100 \quad (2)$$

$$Specificity = \frac{real\ negative}{real\ negative + false\ positive} \times 100 \quad (3)$$

1. Sensitivity
2. Specificity



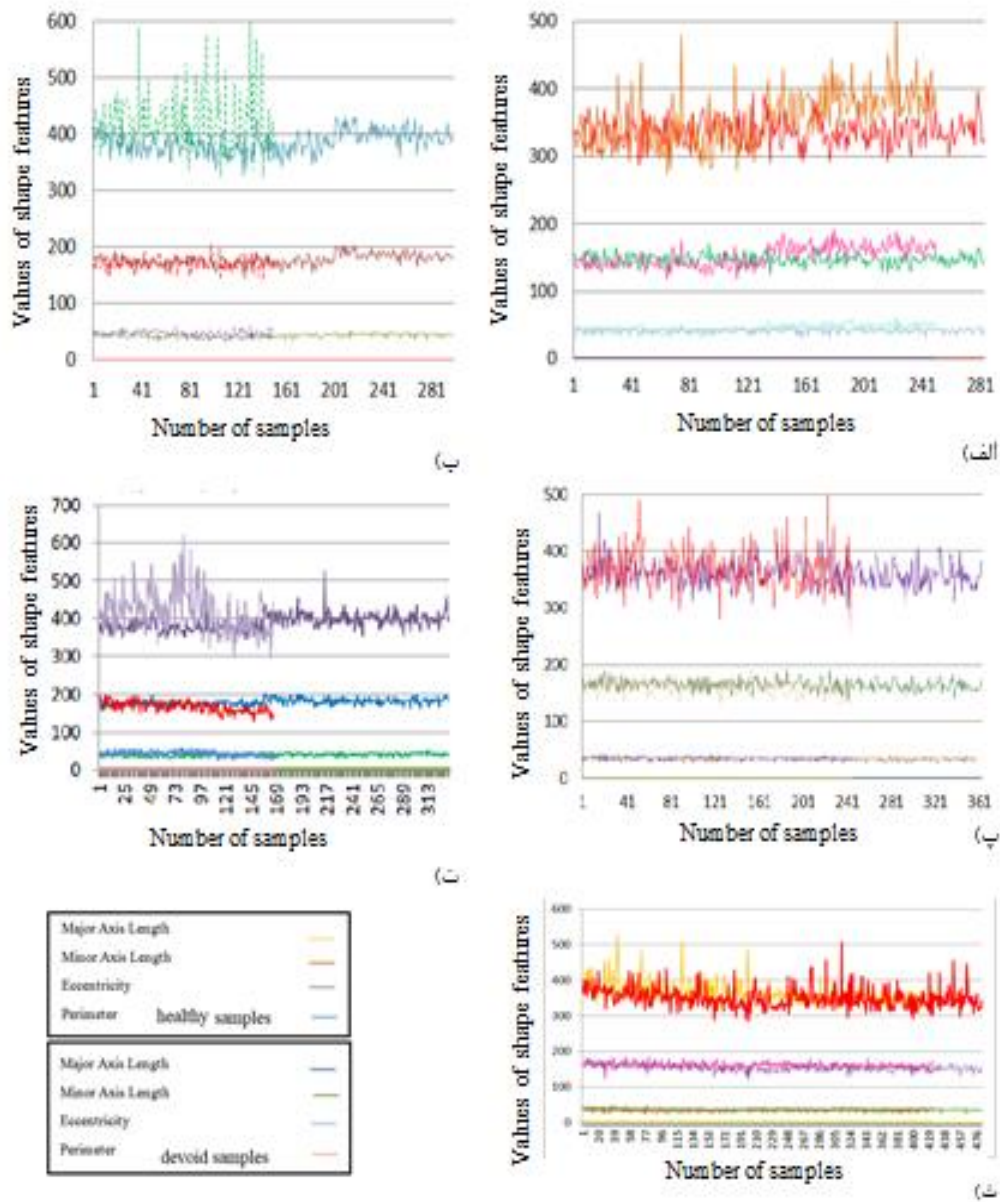
شکل (۳) تصاویر نمونه‌های شلتوک (a) روشن (b) ندا (c) بینام (d) شهریار و (e) شیرودی
 Fig 3. Pictures of rice samples a) Roshan b) Nada c) Binam d) Shahriari and e) Shiroudi



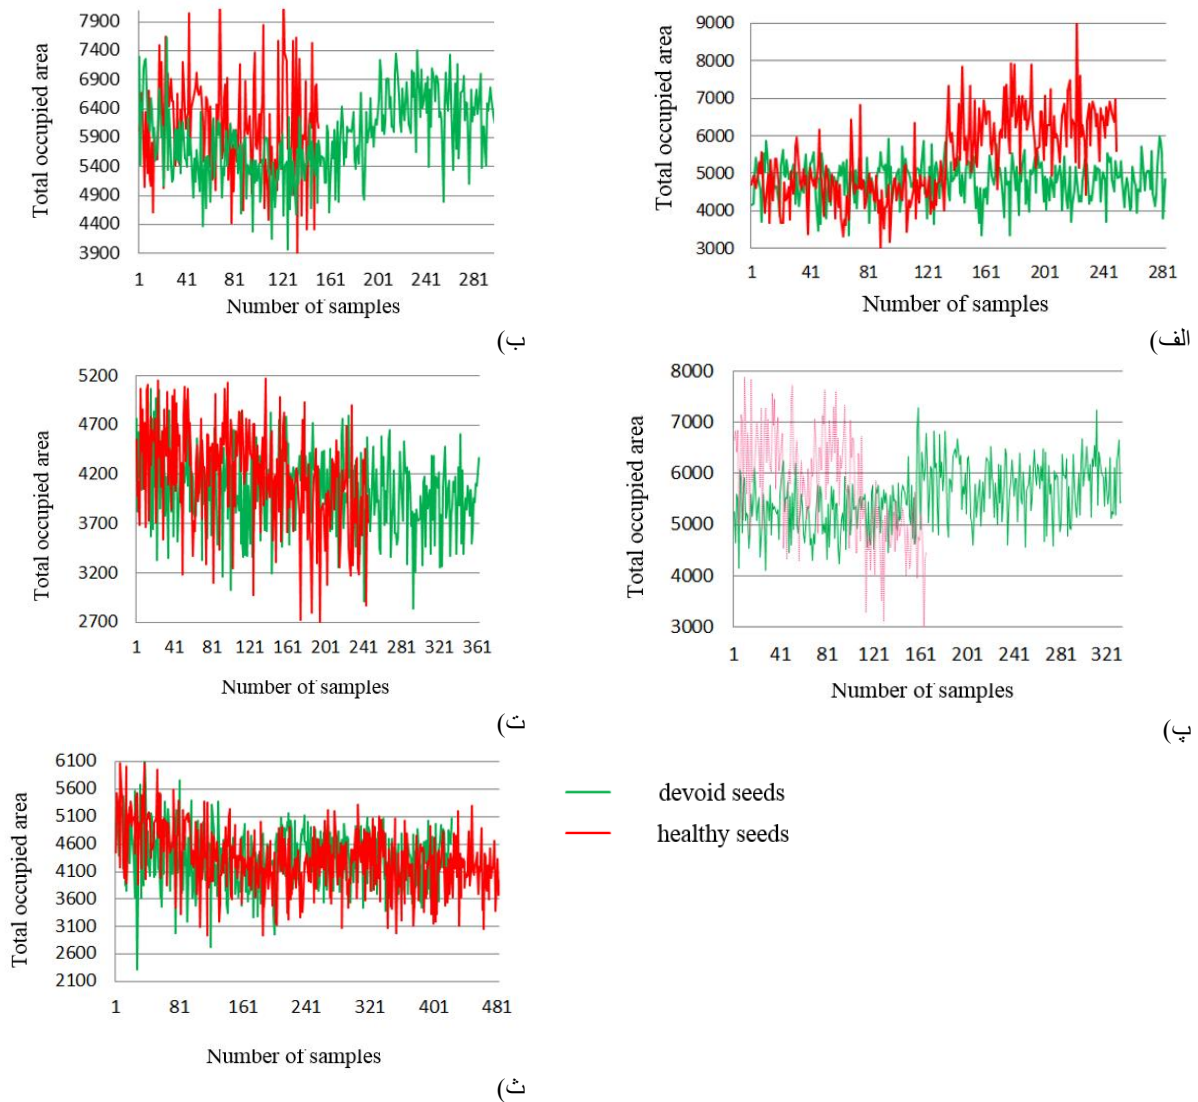
شکل (۴) ویژگی‌های رنگی نمونه‌های سالم و پوک
 Fig 4. Color characteristics of healthy and devoid samples

پوک به‌صورت قابل توجهی هم‌پوشانی داشته و تفکیک دانه‌ها به‌صورت بصری امکان‌پذیر نبود.

در مرحله دوم ویژگی‌های شکلی استخراج‌شده برای هر یک از ارقام مورد بررسی قرار گرفت (شکل‌های ۵ و ۶). با توجه به تصاویر نشان داده شده، ویژگی‌های شکلی دانه‌های سالم و



شکل (۵) ویژگی‌های شکلی نمونه‌های سالم و پوک، الف) بینام، ب) نداء، پ) روشن، ت) شیرودی و ث) شهریاری
 Fig 5. Shape characteristics of healthy and devoid samples, a) Binam, b) Neda, c) Roshan, d) Shiroudi and d) Shahriari



شکل (۶) ویژگی هندسی مساحت احاطه‌شده توسط دانه‌های پوک و سالم برای ارقام مختلف الف) بینام، ب) ندا، پ) روشن، ت) شیرودی و ث) شهریاری


Fig 6. Geometric characteristics of the area surrounded by healthy and devoid seeds for different cultivars a) Binam, b) Neda, c) Roshan, d) Shiroudi, and d) Shahriari

شکلی و ۳ ویژگی رنگی برای ارقام مورد بررسی در شکل (۷) آورده شده‌اند. در نمودارهای امتیازها به ازای هر کدام از تشخیص‌ها (سالم و پوک) نتایج به صورت جداگانه آورده شده‌اند.



۲.۳ تحلیل PCA و انتخاب ویژگی‌های مؤثر در

شناسایی دانه‌ها



از روش تحلیل PCA به منظور تعیین ویژگی‌های مؤثرتر که نقش مهم‌تری در شناسایی دانه‌های سالم از پوک دارند، استفاده شد. نمودارهای امتیازها و نمودار بارگذاری ۵ ویژگی



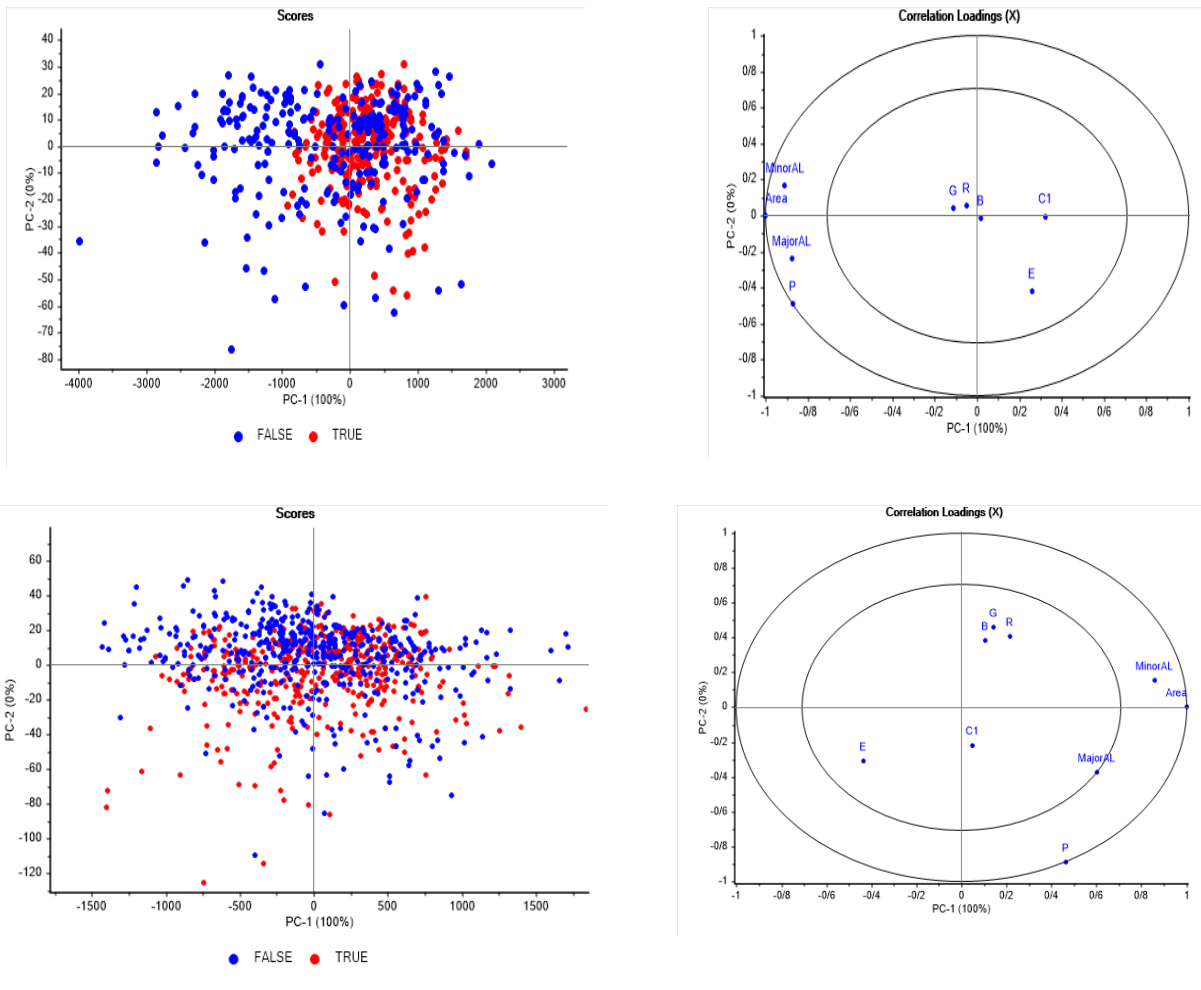
(الف)



(ب)



(پ)



(ت)

(ث)

شکل (۷) نمودار PCA با در نظر گرفتن ویژگی‌های شکلی و رنگی، نمودار امتیازدهی (راست) و بارگذاری صفات (چپ) برای رقم‌های الف (ندا، ب) شیرویدی، پ (بینام، ت) روشن و ث (شهریاری



Fig 7. PCA diagram taking into account shape and color features, scoring diagram (right) and attribute loading (left) for figures a) Neda, b) Shiroudi, c) Binam, d) Roshan and d) Shahriari

عمل مشابه و یا بسیار نزدیک به دانه‌های پوک هستند؛ بنابراین امکان به‌کارگیری کلیه ویژگی‌ها برای جداسازی نمونه‌های سالم و پوک به این صورت میسر نیست. ممکن است با افزودن ویژگی‌های بافتی به ویژگی‌های شکلی و رنگی نتایج بهتری در جداسازی نمونه‌ها حاصل شود. همچنین با توجه به اینکه تشخیص خصوصیات شکلی دانه‌های شلتوک در زمانی که به‌صورت حجمی بر روی نوار نقاله حرکت داده می‌شوند نیز امکان‌پذیر نیست، عملاً به‌کارگیری ویژگی‌های شکلی کارایی ندارند؛ بنابراین تحلیل PCA با استفاده از ۳ ویژگی رنگی استخراج‌شده انجام شد تا امکان بررسی داده‌های تصویر به‌صورت نقطه‌ای (پیکسل) فراهم‌شده

نمودارهای بارگذاری تحلیل PCA (شکل ۷- ستون راست) ویژگی‌های شکلی و رنگی نمونه‌های شلتوک را نشان می‌دهد. ویژگی‌های شکلی نسبت به ویژگی‌های رنگی درصد بالایی از واریانس بین داده‌ها (سهام هر ویژگی بر روی محور PC1 و PC2 یا مؤلفه اول و دوم) را به خود اختصاص داده است ولی همان‌طور که مشخص شده است در عمل با به‌کارگیری کلیه ویژگی‌های شکلی و رنگی درصد اختلاط و همپوشانی بالای بین نمونه‌های سالم و پوک در نمودارهای امتیازها (شکل ۷- ستون چپ) ایجاد شده است. می‌توان به این صورت تفسیر کرد که نمونه‌های سالم خود به دلیل داشتن دانه‌ها با ویژگی‌های شکلی و اندازه‌های مختلف (ریز تا درشت)، در

رنگی جهت تفکیک دانه‌های سالم از پوک مورد استفاده قرار گرفته است (شکل ۸).

و قابلیت کاربرد عملیاتی سامانه در شرایط برخط ارزیابی شود. در ادامه نمودار PCA با در نظر گرفتن ویژگی‌های




(الف)

(ب)

(پ)

(ت)



شکل (۸) نمودار PCA با در نظر گرفتن ویژگی‌های رنگی: نمودار امتیازدهی (راست) و بارگذاری صفات برای رقم‌های مختلف (چپ): الف) ندا، ب) شیرودی، پ) روشن، ت) بینام، ث) شهریار
Fig 8. PCA diagram considering color features: scoring diagram (right) and attribute loading for different cultivars (left) a) Nada, b) Shiroudi, c) Roshan, d) Binam, d) Shahriari

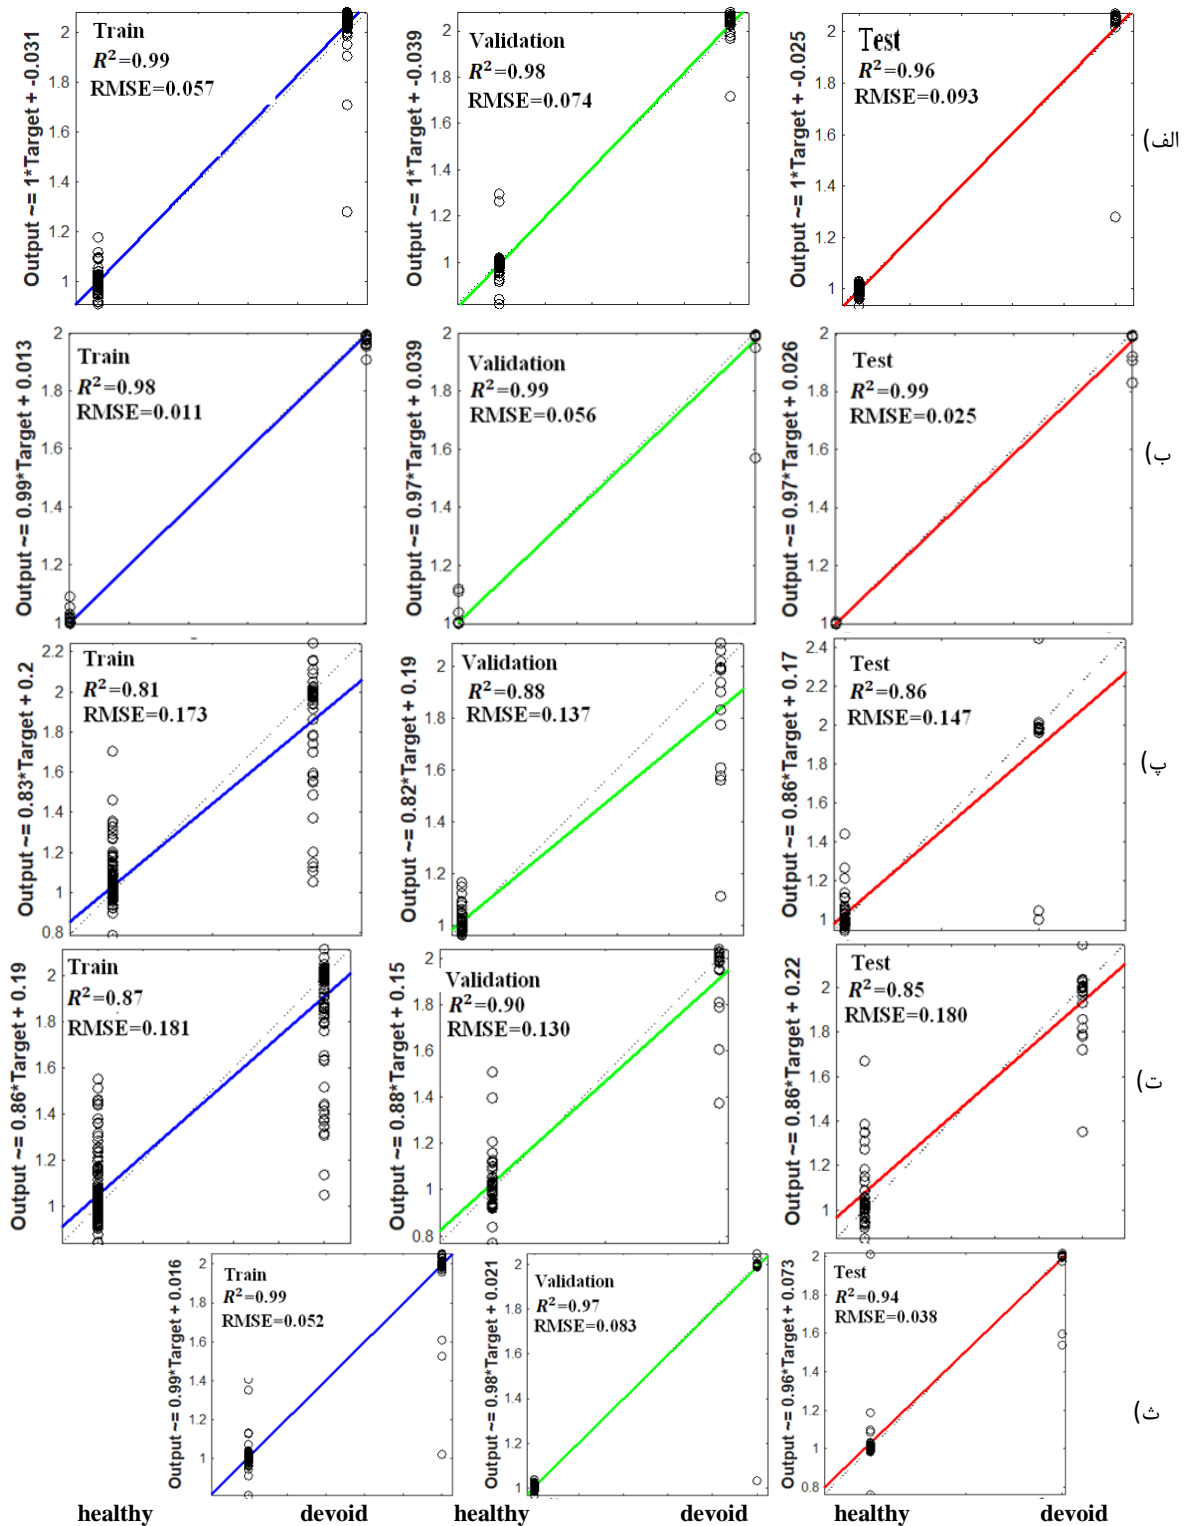
بر است، فقط از ویژگی‌های رنگی به‌عنوان مؤلفه‌های اصلی شناسایی در مدل‌سازی استفاده شد.

۳.۳ مدل‌سازی و تشخیص دانه‌های پوک به‌وسیله شبکه‌های عصبی مصنوعی

نتایج آموزش، اعتبارسنجی و آزمون مدل شبکه عصبی پرسپترون ایجاد شده با ۳ نورون ورودی، یک لایه پنهان با ۱۰ نورون مخفی و دو لایه خطی خروجی برای تشخیص نمونه‌های پوک از سالم برای رقم‌های مختلف برنج در شکل (۹) آورده شده است. مقادیر R^2 و RMSE برای مدل‌های هوشمند ایجادشده برای ارقام مختلف مورد آزمون در جدول (۲) ارائه شده است. با توجه به نتایج نشان داده شده، کمترین مقدار R^2 بر اساس خصوصیات رنگی، برای شناسایی ارقام پوک و سالم رقم روشن به دست آمد. این ضریب در آموزش و ارزیابی نهایی برای رقم روشن به ترتیب برابر با ۰/۸۱ و ۰/۸۶ به دست آمد. به همین ترتیب بالاترین ضریب R^2 در ارزیابی نهایی مدل‌های ایجادشده بر اساس خصوصیات رنگی برای رقم ندا برابر با ۰/۹۶ به دست آمد.

تحلیل PCA با در نظر گرفتن تنها ۳ ویژگی رنگی از نمونه‌های شلتوک‌های سالم و پوک نشان می‌دهد که در نمودارهای امتیازها (شکل ۸- ستون چپ) نمونه‌های سالم و پوک در حد قابل قبولی در محدوده مشخص جداشده از هم قرار گرفته‌اند. همچنین در نمودارهای بارگذاری PCA (شکل ۸- ستون راست) می‌توان مشاهده کرد که در تمامی نمونه‌های مورد آزمایش ویژگی‌های رنگی در دورترین موقعیت از مرکز قرار گرفته‌اند. بدین معنی که ویژگی‌های رنگی در جداسازی این دو گروه از هم بسیار تأثیرگذار هستند.

نتایج به‌دست‌آمده در این بخش این امکان را فراهم می‌سازد که در تصاویر کپه‌ای گرفته‌شده از نمونه‌ها، امکان تشخیص نمونه‌های پوک از سالم وجود داشته باشد. به دلیل اینکه دانه‌های شلتوک در حالت واقعی و عملی در ورودی کارخانه‌های فرآوری شلتوک به‌صورت درهم ریخته و توده‌ای بر روی نوار نقاله قرار می‌گیرند و قبل از آن هم به‌صورت توده‌ای داخل کیسه‌های حمل وجود دارند و امکان جداسازی آنها برای تصویربرداری و استفاده از خصوصیات شکلی دانه زمان-



شکل (۹) نتایج شبکه‌های ANN ایجادشده برای شناسایی داده‌های سالم از پوک، آموزش شبکه عصبی مصنوعی (چپ)، اعتبار سنجی (وسط) و آزمون (راست) برای رقم‌های الف (بینام، ب) ندا، پ) روشن، ت) شیرودی، ث) شهریار

Fig 9. Results of ANN networks created to identify healthy data from devoid, artificial neural network training (left), validation (middle) and test (right) for digits a) Binam, b) Neda, c) Roshan, T) Shiroudi, C) Shahriari


جدول (۲) مقادیر واریانس و جذر میانگین مربعات خطا برای ویژگی‌های رنگی

Table 2. Values of variance and root mean square error for color features

RMSE	R ²	Variety رقم	
0.201	0.83	Training آموزش	Binam بی نام
0.126	0.93	Validation ارزیابی	
0.219	0.81	Test تست	
0.052	0.99	Training آموزش	Shahriari شهریاری
0.083	0.90	Validation ارزیابی	
0.038	0.9	Test تست	
0.173	0.81	Training آموزش	Roshan روشن
0.130	0.90	Validation ارزیابی	
0.147	0.86	Test تست	
0.181	0.87	Training آموزش	Shiroudi شیروودی
0.137	0.88	Validation ارزیابی	
0.093	0.85	Test تست	
0.052	0.99	Training آموزش	Neda ندا
0.083	0.98	Validation ارزیابی	
0.038	0.96	Test تست	

خروجی به رنگ سبز و دانه‌های پوک با رنگ قرمز مشخص شده‌اند. تصاویر آزمون شامل ۱۰۰ نمونه با درصد‌های پوکی ۵٪ تا ۱۵٪ بود. نتایج به دست آمده از دانه‌های پوک تخمین زده شده توسط نرم‌افزار در مقابل دانه‌های پوک واقعی شمارش شده به روش دستی در جدول (۳) آورده شده است. در این بخش به دلیل خالی بودن لبه‌هایی برخی از دانه‌های سالم و یا نیمه‌پر بودن برخی از دانه‌ها، بازه پیکسلی (سطح مقطع) مشخصی برای تعیین دانه‌های پوک در نظر گرفته شد. هم‌چنین مقادیر حساسیت و ویژگی نتایج مدل‌ها در تشخیص دانه‌های پوک ۵ رقم شلتوک در جدول (۳) آورده شده است.

در ادامه به منظور ارزیابی مدل‌های عصبی مصنوعی ایجاد شده در حالتی که دانه‌ها به صورت مخلوط در کنار یکدیگر قرار گرفته بودند اقدام شد. آزمون‌های شبکه‌های ایجاد شده در دو صورت نمونه‌های مجزا از هم و در مرحله بعد به صورت کپه-ای انجام شد. محصول در این بخش به صورت مخلوط دانه-های سالم و پوک با درصد پوکی ۵٪، ۱۰٪ و ۱۵٪ برای هر رقم به صورت مجزا گرفته شد. مدل‌های که برای هر رقم آموزش داده شده بود، مورد آزمون قرار گرفت تا دقت و عملکرد آن بر روی تصاویر حاوی درصد مشخصی از دانه‌های پوک مشخص شود. نمونه‌ای از تصاویر اخذ شده و نتایج حاصل برای رقم ندا در شکل (۱۰) نشان داده شده است. همان طور که در تصاویر نشان داده شده دانه‌های سالم در



شکل (۱۰) تصاویر تشخیص و شمارش دانه‌های پوک در رقم ندا، الف) ۵ دانه پوک، ب) ۱۰ دانه پوک، پ) ۱۵ دانه پوک

Fig 10. Images of detection and counting of devoid seeds in Neda variety, a) 5 seeds, b) 10 seeds, c) 15 seeds


جدول (۳) نتایج مدل‌های ایجادشده در شناسایی و تشخیص دانه‌های پوک در آزمون واقعی در حالت دانه‌های مجزا و غیر متراکم

Table 3. The results of the models created in the identification and recognition of devoid seeds in the real test in the case of separate and non-dense seeds.

Specificity ویژگی	Sensitivity حساسیت	Number of detected devoid seeds تعداد نمونه های پوک تشخیص داده شده	Number of actual devoid seeds تعداد واقعی دانه های پوک	Total number of samples تعداد کل نمونه ها	Variety رقم
0.989	1	6	5	100	Binam بی نام
1	1	10	10		
1	1	15	15		
1	1	5	5	100	Neda ندا
1	1	10	10		
1	0.93	14	15		
1	0.8	3	5	100	Roshan روشن
1	0.8	8	10		
1	1	16	15		
1	0.8	4	5	100	Shahriari شهریاری
1	0.8	8	10		
1	0.93	14	15		
1	0.8	4	5	100	Shiroudi شیرودی
1	1	10	10		
0.988	1	16	15		

شده است. از نتایج جدول (۳) و (۴) مشخص است که در حالت جدا بودن دانه‌ها از یک دیگر رقم روشن و در حالت همپوشانی دانه‌ها، رقم ندا بیش‌ترین خطا را در شمارش داشته است.

در بخش نهایی پژوهش، به‌منظور شبیه‌سازی کاربرد سامانه در بخش صنعت، سامانه برای کیفیت‌سنجی نمونه‌ها به‌صورت کپه‌ای در حالی که دانه‌ها با یک دیگر همپوشانی داشتند، بکار گرفته شد. نتایج سامانه برای رقم روشن در شکل (۱۱) و خلاصه نتایج آماری برای همه ارقام در جدول (۴) آورده



شکل (۱۱) نتایج به‌دست‌آمده از آزمون نهایی سامانه در تشخیص دانه‌های پوک رقم روشن: ۱۰ دانه پوک (راست) و ۵ دانه پوک (چپ)
Fig 11. The results obtained from the final test of the system in the detection of devoid Roshan seeds: 10 seeds (right) and 5 seeds (left)

جدول (۴) نتایج به‌کارگیری سامانه پیاده‌سازی شده در کیفیت‌سنجی نمونه‌های کپه‌ای شلتوک

Table 4. The results of using the system implemented in the quality measurement of rice in pile condition

Specificity ویژگی	Sensitivity حساسیت	Number of detected devoid seeds تعداد نمونه های پوک تشخیص داده شده	Number of actual devoid seeds تعداد واقعی نمونه های پوک	Variety رقم
1	1	5	5	Binam
11	1	10	10	بی نام
0.989	0.83	6	5	Roshan
0.966	0.83	13	10	روشن
1	1	5	5	Shahriari
0.988	0.9	11	10	شهریاری
1	0.71	5	5	Shiroudi
0.988	0.76	11	10	شیرودی
1	1	5	5	Neda
0.95	0.66	11	10	ندا

آن انعکاس نور بیشتری از روی پوسته شلتوک اتفاق می‌افتد که باعث تغییرات رنگی بین دو گروه پوک و سالم می‌شود. همچنین بر اساس نتایج نمودار بارگذاری تحلیل PCA، ابتدا کانال رنگی B، سپس کانال رنگی G و بعد از آنها کانال رنگی R بیشترین تأثیر در طبقه‌بندی شلتوک‌های پوک از سالم در همه ارقام را داشته است.

با بررسی نتایج می‌توان بیان کرد که در ۵ رقم مورد مطالعه، تغییرات رنگی در هر سه کانال رنگی R، G و B برای دانه‌های پوک شلتوک نسبت به دانه‌های پر و سالم وجود داشته است. این تغییرات رنگی به‌دلیل ضعیف‌بودن یا لاغر‌بودن و یا عدم وجود هسته دانه برنج داخل پوسته شلتوک ایجاد می‌شود. هرچه هسته شلتوک بزرگ‌تر و سفیدتر باشد، در نتیجه

شلتوک استخراج شد. برای بررسی دقیق‌تر مؤلفه‌های مؤثر در تشخیص دانه‌های پوک و سالم از روش PCA استفاده شد. به دلیل نیاز به برخط‌بودن سامانه و کیفیت‌سنجی دانه‌های شلتوک به‌صورت کپه‌ای سه ویژگی رنگی از میان ویژگی‌ها انتخاب و با استفاده از شبکه‌های عصبی مصنوعی MLP مدل‌سازی شدند. نتایج نهایی بر اساس پارامترهای آماری نشان داد سامانه پیاده‌سازی شده با دقت قابل قبولی قابلیت استفاده به‌عنوان یک سامانه برخط و سریع برای کیفیت‌سنجی شلتوک در مراحل ورود به خطوط کارخانه‌های سفیدکن برنج را دارد. سامانه پیشنهادشده در این پژوهش نسبت به روش‌های مرسوم تجربی و روش‌های علمی که تاکنون استفاده می‌شد از دقت و سرعت عمل بالاتری برخوردار می‌باشد. همچنین این روش نیازی به امکانات آزمایشگاهی گران‌قیمت ندارد و هزینه‌های پیاده‌سازی این سامانه نیز برای فرآوری‌کنندگان شلتوک کم و مقرون به‌صرفه می‌باشد. به‌منظور افزایش دقت سامانه ویژگی‌های بافتی پوسته‌های شلتوک پوک و سالم در کنار ویژگی‌های رنگی نیز می‌توانند در مطالعات بعدی مورد آزمون قرار گیرند.

تقدیر و تشکر

بدین وسیله نویسندگان مقاله مراتب تقدیر و تشکر خود را از دانشگاه علوم کشاورزی و منابع طبیعی ساری که مطالعه حاضر را در قالب پایان‌نامه کارشناسی ارشد از نظر مالی حمایت نمودند، اعلام می‌نمایند.

در مطالعات پیشین پژوهشی به‌منظور کیفیت‌سنجی شلتوک با استفاده از بینایی ماشین یافت نشد ولی پژوهش‌های متعددی کاربرد موفق این سامانه را برای کیفیت‌سنجی دانه‌های برنج نشان داده‌اند. به‌عنوان مثال در پژوهشی به‌منظور کیفیت‌سنجی و طبقه‌بندی چهار گونه برنج هندی از سامانه بینایی ماشین در ترکیب با یک شبکه عصبی مصنوعی و با استفاده از ویژگی‌های شکل، رنگ و بافت اقدام شد [۲۳]. آنها زمانی که از کلیه ویژگی‌های دانه‌ها استفاده کردند، دقت سامانه ۹۶٪ حاصل شد. در مطالعه‌ای دیگر چهار نوع برنج با استفاده از تکنیک‌های مختلف یادگیری ماشینی و با استفاده از ویژگی‌های رنگی و بافت طبقه‌بندی و دقت متوسط ۸۹/۱٪ به دست آمد [۲۴]. همچنین محققان دیگری [۲۵] دریافته‌اند که سه نوع دانه برنج تایوانی که ظاهر بسیار مشابهی دارند، می‌توانند با دقت تا ۹۷/۳۵٪ با استفاده از یک سامانه بینایی ماشین و شبکه عصبی مصنوعی طبقه‌بندی شوند. آنها در این تحقیق، از ویژگی‌های شکلی و رنگی استفاده کردند. در پژوهشی دیگر [۲۶] از سامانه بینایی ماشین و طبقه‌بند ماشین بردار پشتیبان^۱ و شبکه عصبی مصنوعی برای تعیین تقلب یک نمونه برنج با استفاده از ویژگی‌های بافت و رنگ اقدام شد و دقت طبقه‌بندی متوسط ۹۷/۲۶٪ به دست آمد. در جدیدترین پژوهش سامانه بینایی ماشین برای طبقه‌بندی انواع بذر برنج هرز و بذر برنج اصلی بکار گرفته شد [۲۷]. در این تحقیق، شصت و هفت ویژگی شکل، رنگ و بافت استخراج و به‌عنوان ورودی برای یادگیری ماشین استفاده شد. آن‌ها در این پژوهش بیان کردند که ویژگی‌های رنگی انتخاب‌شده، حساسیت و دقت بالاتری در شناسایی دو گروه داشته‌اند.

۴. نتیجه‌گیری

در این پژوهش یک سامانه هوشمند بر پایه روش‌های پردازش‌تصویر و شبکه‌های عصبی مصنوعی برای شناسایی دانه‌های شلتوک پوک از سالم پنج رقم شلتوک تازه اصلاح‌شده در پژوهشکده دانشکده کشاورزی و منابع طبیعی ساری پیاده‌سازی و ارزیابی شد. هشت ویژگی شامل سه ویژگی رنگی و پنج ویژگی شکلی از تصاویر دیجیتالی هر دانه

1. Support Vector Machine

منابع

- [1] Wang, E., Wang, J., Zhu, X., Hao, W., Wang, L., Li, Q., Zhang, L., He, W., Lu, B., & Lin, H. (2008). Control of rice grain-filling and yield by a gene with a potential signature of domestication. *Nat. Gene.*, 40, 1370-1374.
- [2] Sapirstein, H.D., Neuman, M., Wright, E.H., Shwedyk, E., & Bushuk, W. (1987). An instrumental system for cereal grain classification using digital image analysis. *J. Cereal Sci.*, 6, 3-14.
- [3] Neuman, M., Sapirstein, H., Shwedyk, E., & Bushuk, W. (1989). Wheat grain color analysis by digital image processing ii. Wheat class discrimination. *J. Cereal Sci.*, 10(3), 183-188.
- [4] Walker, C.K., & Panozzo, J.F. (2012). Measuring volume and density of a barley grain using ellipsoid approximation from a 2-d digital image. *J. Cereal Sci.*, 55, 61-68.
- [5] Manickavasagan, A., Sathya, G., Jayas, D., & White, N. (2008). Wheat class identification using monochrome images. *J. Cereal Sci.*, 47, 518-527.
- [6] Kiani, S., Azimifar, Z., & Kamgar, S. (2010). Wavelet-based crop detection and classification. *18th Iranian Conf. on Elect. Engineering. IEEE.*, 587-591.
- [7] Kiani, S; Minaei, S., Ghasemi-Varnamkhashti, M., & Ayyari, M. (2017). An original approach for the quantitative characterization of saffron aroma strength using electronic nose. *Int. j. Food Properties.*, 20, 673-683.
- [8] Zapotoczny, P. (2011). Discrimination of wheat grain varieties using image analysis and neural networks. Part i. single kernel texture. *J. Cereal Sci.*, 54, 60-68.
- [9] Minaei, S., Kiani, S., Ayyari, M., & Ghasemi-Varnamkhashti, M. (2017). A portable computer-vision-based expert system for saffron color quality characterization. *J. Applied Research on Medicinal and Aromatic Plants.*, 7, 124-130.
- [10] Patil, K., and R. & Kumar. (2011). Advances In Image Processing for Detection Of Plant. *Adv. Bioinf. Appl. And Research.*, 2, 135-141.
- [11] Duan, L., Yang, W., Bi, K., Chen, S., Luo, Q., & Liu, Q. (2011a). Fast discrimination and counting of filled/unfilled rice spikelet based on bi-modal imaging. *Comp. and Electronics in Agric.*, 75, 196-203.
- [12] Duan, L., Huang, C., Chen, G., Xiong, L., Liu, Q., & Yang, W. (2014). High-throughput estimation of yield for individual rice plant using multi-angle RGB imaging. *Int. Conf. on Computer and Computing Tech. in Agriculture*. Springer., 1-12
- [13] Liu, T., Wu, W., Chen, W., Sun, C., Chen, C., Wang, R., Zhu, X., & Guo, W. (2016). A shadow-based method to calculate the percentage of filled rice grains. *Biosys. Eng.*, 150, 78-88.
- [14] Fazaeli Bagh Dolabi, H., & Afkari Sayah, A. (2008). Mixing percentage of hard and soft wheat in the grain mass by machine vision method. *National Conf. of Water, Soil, Plant and Agricultural Mechanization Sciences*, Dezful. <https://civilica.com/doc/140183T>.
- [15] Hatami, M., Rahmani Didar, A., & Khazaei, J. (2010). Identification of Iranian rice varieties using machine vision techniques. *6th National Cong. Of Agr. Machinery Eng. And Mechanization*, Tehran, 65-60.
- [16] Mousavi Rad, S. J., & Akhlikian Tab, F. (2012). Designing an expert system for recognizing the authenticity of rice cultivars using the combination of textural features of rice mass images. *Machine Vision and Image Processing.*, 1, 68-74.
- [17] Næs T, Brockhoff PB, & Tomic, O. (2010). *Statistics for Sensory and Consumer Science*. John Wiley & Sons Ltd. UK.
- [18] Payman, S.H., Bakhshipour A., Zareiforoush, H. (2018). Development of an expert vision-based system for inspecting rice quality indices. *Quality Assurance and Safety of Crops & Foods.*, 10 (1): 103-114.
- [19] Reza, M.N., Na, I.S., Baek, S.W., & Lee, K.H. (2019). Rice yield estimation based on k-means clustering with graph-cut segmentation using low-altitude UAV images. *J. Biosys. Eng.*, 177, 109-121.
- [20] Chen, S., Xiong, J., Guo, W., Bu, R., Zheng, Z., Chen, Y., Yang, Z, Lin. (2019). Colored rice quality inspection system using machine vision. *Journal of Cereal Science.*, 88, 87-95.
- [21] He Y, Fan B, Sun L, Fan X, Zhang J, Li Y and Suo X. (2023). Rapid appearance quality of rice based on machine vision and convolutional neural network research on automatic detection system. *Front. Plant Sci.*, 14:1190591. Doi: 10.3389/fpls.2023.1190591
- [22] Duan, L., Yang, W., Huang, C., & Liu, Q. (2011b). A novel machine-vision-based facility for the automatic evaluation of yield-related traits in rice. *Nat. J. of Signal Processing, Image Processing, and Pattern Recognition.*, 8, 19-30.
- [23] Singh, K.R., Chaudhury, S. (2016). Efficient Technique for Rice Grain Classification Using Back-Propagation Neural Network and Wavelet Decomposition. *IET Comput. Vis.*, 10, 780-787.
- [24] Kuo, T.Y., Chung, C.L., Chen, S.Y., Lin, H.A., Kuo, Y.F. (2016). Identifying Rice Grains Using Image Analysis and Sparse-Representation-Based Classification. *Comput. Electron. Agric.*, 127, 716-725.

- [25] Cinar, I., Koklu, M. (2019). Classification of Rice Varieties Using Artificial Intelligence Methods. *Int. J. Intell. Syst. Appl. Eng.*, 7, 188–194.
- [26] Anami, B.S., Malvade, N.N., Palaiah, S. (2019). Automated Recognition and Classification of Adulteration Levels from Bulk Paddy Grain Samples. *Inf. Process. Agric.*, 6, 47–60.
- [27] Ruslan, R., Khairunniza-Bejo, S., Jahari, M., Ibrahim, M.F. (2022). Weedy Rice Classification Using Image Processing and a Machine Learning Approach. *Agriculture.*, 12(5), 645.