



Application of Image Processing and Artificial Neural Networks for Detection of Adulteration in Persian Black Cumin

Majid Dowlati¹ | Atefe Nekoei² | Iman Golpour³ | Atefe Malekian⁴

1. Department of Food Science and Technology, Tuyserkan Faculty of Engineering and Natural Resources, Bu-Ali Sina

University, Hamedan, Iran. E-mail: m.dowlati@basu.ac.ir

2. Department of Mechanical engineering of Biosystems, University of Jiroft, Jiroft, Iran. E-mail: nekoiatefe@gmail.com

3. Department of Energy Engineering, National University of Distance Education, Madrid, Spain E-mail:

igolpour@ind.uned.es

4. Corresponding Author, Department of Agriculture and Medicinal Plants, Nahavand Higher Education Complex, Bu-Ali

Sina University, Hamedan, Iran. E-mail: a.malekian@basu.ac.ir

Article Info

Article type: Research Article

Article history:

Received: Feb. 7, 2025

Revised: Feb. 26, 2025

Accepted: March. 5, 2025

Published online: Winter 2025

Keywords:

**Black cumin,
Artificial neural networks,
Computer vision technology,
Texture and color features.**

ABSTRACT

Persian cumin plays a significant role in both exports and domestic industries of Iran. Today, due to the widespread availability of counterfeit cumin in the market, identifying authentic Persian cumin from its counterfeit counterparts has become increasingly essential. Among the various criteria for identification, color and texture indices are particularly notable. Traditional methods, such as manual and visual inspections, are not only time-consuming but also prone to a high degree of human error. In this study, in order to propose a new, precise, and rapid method, machine vision technology was utilized to extract the color and texture features of cumin from its images. Subsequently, a multi-layer perceptron artificial neural network with a backpropagation algorithm and a hidden layer was employed, evaluating different neurons in this layer to perform the process of distinguishing authentic Persian cumin from counterfeit varieties in the market. In this study, five samples of authentic Persian cumin and four samples of counterfeit cumin, were evaluated. The results showed that the highest average classification and identification accuracy of authentic cumin from counterfeit cumin, using a neural network with one hidden layer and employing a sigmoid transfer function in this layer and a linear function in the output layer with the Levenberg-Marquardt learning algorithm, were 93.51% for color features, 95.86% for texture features, and 95.59% for the combination of these two features (color-texture). However, the findings showed that machine vision technology and artificial neural networks have a high capability in accurately identifying authentic Persian cumin from counterfeit samples.

Cite this article: Dowlati, M., Nekoei, A., Golpour, I., & Malekian, A. (2025). Application of Image Processing and Artificial Neural Networks for Detection of Adulteration in Persian Black Cumin, *Iranian Journal of Biosystem Engineering*, 55 (4), 1-20. <https://doi.org/10.22059/ijbse.2025.390091.665588>

© The Author(s).

Publisher: The University of Tehran Press.

DOI: <https://doi.org/10.22059/ijbse.2025.390091.665588>



EXTENDED ABSTRACT

Introduction

Medicinal plants have gained considerable attention as valuable natural resources in scientific and industrial communities. Iran, with its high diversity of medicinal plants, particularly *Bunium persicum* (Persian cumin), holds a significant position in this field. *Bunium persicum*, a herbaceous plant, grows in various regions of Asia and Europe. One of the main challenges in the cumin market is fraud, where authentic cumin is often mixed with lower-value species. Therefore, there is an increasing need for precise methods to distinguish genuine cumin from counterfeit ones. Image processing, as a non-destructive and innovative method, has been widely used in the food industry for quality evaluation and product differentiation. Color and texture features play a crucial role in food quality assessment, and artificial neural networks (ANNs) are suitable tools for classifying these complex features due to their capacity for data analysis.

Materials and Methods

In this study, nine cumin samples were collected from the local market of Kerman, consisting of five authentic *Bunium persicum* samples and four counterfeit samples (including European black cumin, artificially colored green cumin, and two types of low-quality mixed cumin). The images of the samples were captured using a digital camera, fluorescent light source, computer, and image processing software in a controlled environment. After image acquisition, the samples were converted into different color spaces (RGB, HSI, HSV), and their color and texture features were extracted. The color features included the mean, variance, standard deviation, and range of color components. The texture features were extracted using the Gray-Level Co-occurrence Matrix (GLCM) and included contrast, homogeneity, correlation, energy, and entropy. A total of 36 color features and 108 texture features were considered for analysis. To reduce complexity and enhance model accuracy, important features were selected using factor analysis. Then, a Multilayer Perceptron (MLP) neural network with the Levenberg-Marquardt backpropagation method in MATLAB software was used for classification and recognition. The data were divided into three subsets: training (60%), validation (20%), and testing (20%).

Results and Discussion

The classification accuracy using color features varied. The highest accuracy (93.51%) was achieved using the sigmoid transfer function in the hidden layer and a linear output function. The reduced color features, selected using factor analysis, resulted in improved classification accuracy. For texture features, the highest classification accuracy (95.86%) was achieved with a network using 108 texture features. The network with the sigmoid transfer function in the hidden layer and a linear output function showed the best performance. Texture features outperformed color features in classification accuracy. The combination of color and texture features resulted in better performance, with the classification accuracy reaching 95.95%. The reduced combined features, obtained through factor analysis, provided greater accuracy than using color or texture features alone. Factor analysis was employed at all stages to reduce the number of features and eliminate redundant features, which not only reduced computational complexity but also improved model accuracy.

Conclusion

This study evaluated the use of a combination of image processing and artificial neural networks (ANNs) for the identification and classification of authentic and counterfeit *Bunium persicum*. The results demonstrated that texture features provided the highest accuracy in distinguishing the two types of cumin, with overall classification accuracies of 93.51%, 95.86%, and 95.59% for color, texture, and combined features, respectively. Additionally, after feature selection using factor analysis, the best average classification accuracy with color, texture, and combined features was 93.81%, 95.65%, and 94.67%, respectively. The classification accuracy increased with the reduction of color features, while a decrease in texture and combined features led to a reduction in classification accuracy. These findings highlight the significant potential of image processing and ANNs in identifying and classifying genuine cumin from counterfeit ones. The application of these methods in the design of intelligent systems for identifying authentic and counterfeit cumin in the food industry could be a valuable step towards improving food quality and safety.

Author Contributions

Conceptualization, M.D., I.G. A.N.; methodology, M.D. and A.N.; software, I.G. and A.M.; validation, A.N., M.D., I.G. and A.M.; formal analysis, I.G.; investigation, A.N. and M.D.; resources, M.D. and A.M.; data curation, M.D. and A.M.; writing-original draft preparation, A.M. and M.D.; writing-review and editing, A.M. and M.D.; visualization, A.M. and I.G.; supervision, M.D.; project administration, M.D.

All authors have read and agreed to the published version of the manuscript." All authors contributed

equally to the conceptualization of the article and writing of the original and subsequent drafts.

Data Availability Statement

All data generated or analyzed during this study are available from the corresponding author on request

Acknowledgements

The authors would like to extend their sincere appreciations for financial support provided by the University of Jiroft. The authors avoided data fabrication, falsification, plagiarism, and misconduct.

Conflict of interest

The author declares no conflict of interest.

استفاده از پردازش تصویر و شبکه‌های عصبی مصنوعی به منظور تشخیص تقلب در زیره سیاه پاریسی

مجیددولتی^۱ | عاطفه نکویی^۲ | ایمان گلپور^۳ | عاطفه ملکیان^۴ ✉

۱. گروه علوم و مهندسی صنایع غذایی، دانشکده فنی و منابع طبیعی تویسرکان، دانشگاه بوعلی سینا، همدان، ایران. رایانامه:

m.dowlati@basu.ac.ir۲. گروه مهندسی مکانیک بیوسیستم، دانشگاه جیرفت، جیرفت، ایران. رایانامه: nekoiyatefe@gmail.com۳. گروه مهندسی انرژی، دانشگاه ملی آموزش از راه دور، مادرید، اسپانیا. رایانامه: igolpour@ind.uned.es

۴. نویسنده مسئول، گروه کشاورزی و گیاهان دارویی، مجتمع آموزش عالی فاطمیه نهاوند، دانشگاه بوعلی سینا، همدان، ایران. رایانامه:

a.malekian@basu.ac.ir

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی	زیره ^۱ پاریسی ایران نقش ویژه‌ای در صادرات و صنایع داخلی دارد. امروزه، با توجه به عرضه گسترده انواع زیره تقلبی در بازار، شناسایی زیره ^۲ پاریسی اصیل از نمونه‌های تقلبی آن ضروری است. از میان معیارهای مختلف شناسایی، می‌توان به شاخص‌های رنگ و بافت اشاره نمود. روش‌های سنتی مانند بازرسی دستی و بصری، علاوه بر زمان‌بر بودن، با احتمال بالای خطای انسانی همراه هستند. در این پژوهش، بمنظور ارائه روشی نوین، دقیق و سریع، از فناوری ماشین بینایی برای استخراج ویژگی‌های رنگی و بافتی زیره از تصاویر آن استفاده شد. سپس، با به‌کارگیری شبکه عصبی مصنوعی پرسپترون چندلایه با الگوریتم پس‌انتشار با یک لایه پنهان و ارزیابی نرون‌های مختلف در این لایه، فرآیند تشخیص زیره پاریسی اصیل از انواع تقلبی انجام گرفت. پنج نمونه از زیره پاریسی و چهار نمونه از زیره تقلبی با بیشترین فراوانی در بازار مورد ارزیابی قرار گرفتند. نتایج نشان داد بهترین میانگین دقت شناسایی زیره اصیل از تقلبی، با استفاده از شبکه عصبی با یک لایه پنهان با بکارگیری تابع انتقال لگاریتم سیگموئید در این لایه و تابع خطی در لایه خروجی و الگوریتم یادگیری لونیبرگ مارکوات، به ترتیب ۹۳/۵۱ درصد برای ویژگی‌های رنگی، ۹۵/۸۶ درصد برای ویژگی‌های بافتی و ۹۵/۵۹ درصد برای ترکیب این دو ویژگی (رنگی-بافتی) به دست آمد که نتایج شبکه عصبی با استفاده از ویژگی‌های بافتی عملکرد بهتری داشت. نتایج این تحقیق نشان داد که فن آوری ماشین بینایی و شبکه‌های عصبی مصنوعی، قابلیت بالایی در شناسایی زیره اصیل پاریسی از نمونه‌های تقلبی با دقت بالا دارد.
واژه‌های کلیدی: زیره سیاه، شبکه‌های عصبی مصنوعی، فن آوری کامپیوتر بینایی، ویژگی‌های بافتی و رنگی.	

استناد: دولتی، مجید؛ نکویی، عاطفه؛ گلپور، ایمان؛ و ملکیان، عاطفه (۱۴۰۳). استفاده از پردازش تصویر و شبکه‌های عصبی مصنوعی به منظور تشخیص تقلب در زیره سیاه

پاریسی، مجله مهندسی بیوسیستم ایران/ ایران، ۵۵ (۴)، ۲۰-۱. <https://doi.org/10.22059/ijbse.2025.390091.665588>

© نویسندگان.

ناشر: مؤسسه انتشارات دانشگاه تهران.

DOI: <https://doi.org/10.22059/ijbse.2025.390091.665588>

مقدمه

گیاهان دارویی از منابع طبیعی ارزشمندی به‌شمار می‌روند که امروزه در کشورهای پیشرفته جهان مورد توجه قرار گرفته‌اند و به عنوان مواد اولیه برای تولید داروهای ایمن در صنعت داروسازی استفاده می‌شود (Burdock, 2022). در این زمینه، ایران یکی از غنی‌ترین مناطق از نظر تنوع گیاهان دارویی در جهان به‌شمار می‌رود (Azimzadeh et al., 2012). زیره پارس، گیاهی علفی و چند ساله دارای ارتفاعی بین ۳۰ تا ۶۰ سانتی‌متر است که دارای ساقه توخالی و شیاردار بوده و از قاعده منشعب می‌شود (Agnihotri et al., 2024). این گیاه، دارای نام‌های دیگری مانند «زیره کرمانی» و «زیره کوهی» شناخته شده و نام علمی آن *Bunium Persicum Boiss* است (دینانی توکلی و معصومی، ۱۳۸۸). زیستگاه اصلی این گیاه در سطح جهان، مرکز و غرب آسیا و جنوب شرقی اروپا می‌باشد (عظیم زاده و همکاران، ۱۳۹۳). در ارزیابی کیفیت مواد غذایی، روش‌های سنتی مبتنی بر ارزیابی حسی کاربرد گسترده‌ای دارند، اما این روش‌ها، علاوه بر زمان‌بر و پرهزینه بودن، از دقت پایینی نیز برخوردارند. بنابراین، توسعه روش‌های نوین که ویژگی‌های کلیدی محصول را در زمان کوتاه‌تر و با دقت بالایی ارزیابی کنند، ضروری به نظر می‌رسد (صفری امیری و همکاران، ۱۳۹۷). بازار زیره سیاه پارس یکی از بخش‌های مهم صادراتی و تجاری است که با چالش‌هایی نظیر ورود محصولات ناخالص و تقلبی مواجه است. این امر نه تنها موجب کاهش اعتماد مصرف‌کنندگان و تاجران به کیفیت محصول می‌شود، بلکه می‌تواند به افت قیمت و کاهش رقابت‌پذیری این محصول در بازارهای بین‌المللی منجر شود. همچنین، مصرف‌کنندگان انتظار دارند محصولی با کیفیت بالا دریافت کنند و ورود محصولات تقلبی به بازار، سلامت و اعتماد آن‌ها را تحت تأثیر قرار می‌دهد. علاوه بر این، نظارت دقیق‌تر بر کیفیت محصول می‌تواند نقش مهمی در اجرای استانداردهای قانونی و بهبود مقررات تجاری داشته باشد، که در نهایت به ارتقای اعتبار و ارزش اقتصادی این صنعت کمک می‌کند. پردازش تصویر یکی از این روش‌های نوین است که برای استخراج ویژگی‌های بصری محصولات مختلف بکار برده می‌شود. تحقیقات نشان داده‌اند که این فن‌آوری در اندازه‌گیری خصوصیات کیفی مواد غذایی، یکی از امیدبخش‌ترین حوزه‌های تحقیقاتی محسوب می‌شود (Zheng et al., 2006). این روش به دلیل سرعت بالا، قابلیت اتوماسیون و همچنین به دلیل غیر مخرب بودن آن در صنایع غذایی به طور فزاینده‌ای مورد توجه قرار گرفته است. تاکنون از این فن‌آوری در درجه بندی دانه‌های غلات، ذرت، پسته، بازرسی کیفی محصولات پخته شده، بررسی سلامت سیب، شناسایی بادام‌های آسیب دیده و اندازه‌گیری ابعاد دانه‌ها استفاده شده است (Razavi et al., 2010). در میان ویژگی‌های فیزیکی مواد غذایی، رنگ یکی از مهمترین ویژگی‌های ظاهری در تعیین کیفیت محسوب می‌شود. مصرف‌کنندگان اغلب رنگ را با عواملی مانند طعم، ایمنی، ماندگاری و ارزش تغذیه‌ای مرتبط می‌دانند (Banasal, 2023) و (Navidshad, et al., 2024). از آنجا که کیفیت مواد غذایی ارتباط مستقیمی با ارزیابی فیزیکی، شیمیایی و حسی دارد، میزان رضایت‌مندی مصرف‌کنندگان به شدت تحت تأثیر رنگ محصول قرار می‌گیرد (Saldana et al., 2013). بافت به عنوان یک الگوی اطلاعات یا نظم ساختاری در یک تصویر تعریف می‌شود و در تحلیل ویژگی‌ها و تفسیر تصاویر استفاده می‌شود. در پردازش تصویر، بافت ویژگی‌ای است که نحوه توزیع سطوح خاکستری پیکسل‌ها را در بخش‌های مختلف تصویر نشان می‌دهد و یکی از عناصر کلیدی در شناسایی اشیاء یا نواحی مورد نظر در یک تصویر به‌شمار می‌رود. از دیدگاه بصری، بافت یک الگوی منظم و یکپارچه است که از ترکیب بیش از یک رنگ یا درجه‌ی خاکستری حاصل می‌شود (Long et al., 2003). از سوی دیگر، تحلیل بافت بر اساس ویژگی‌های ماتریس هم‌رخدادی، روشی قدرتمند برای پردازش و تحلیل تصاویر محسوب می‌شود (فیاضی و همکاران، ۱۳۹۲). شبکه‌های عصبی مصنوعی از جمله روش‌های محاسباتی هستند که از طریق فرآیند یادگیری و با استفاده از پردازنده‌هایی موسوم به نرون، سعی در کشف روابط درونی بین داده‌ها دارند و می‌توانند نگاشتی میان فضای ورودی (لایه ورودی) و فضای مطلوب (لایه خروجی) ارائه دهند. در این ساختار، لایه‌های پنهان داده‌های دریافتی از لایه ورودی را پردازش کرده و به لایه خروجی منتقل می‌کند. هر شبکه از طریق دریافت نمونه‌های آموزشی، یادگیری خود را تکمیل می‌کند. این یادگیری شبکه زمانی اتفاق می‌افتد که وزن‌های ارتباطی بین لایه‌ها به گونه‌ای تنظیم شوند که اختلاف بین مقادیر پیش‌بینی شده و مقادیر واقعی به حداقل برسد. در واقع این وزن‌ها، حافظه و دانش شبکه را تشکیل می‌دهند. شبکه عصبی آموزش دیده، قادر است برای پیش‌بینی خروجی‌های متناسب با مجموعه جدید داده‌ها به کار رود (Heistev, 1998).

به دلیل وجود گزارشاتی مبنی بر فروش زیره سیاه اروپایی به جای زیره پارس، همچنین ترکیب گونه پر محصول اما کم ارزش تر زیره سیاه اروپایی با انواع گران قیمت و با کیفیت زیره ی پارس و عرضه آن با قیمت بالا، و حتی رنگ آمیزی زیره سبز و فروش آن تحت

عنوان زیره پارسی، نیاز به روشی دقیق برای شناسایی زیره اصیل از انواع تقلبی ضروری به نظر می‌رسد. بررسی و تأیید خلوص نمونه‌های زیره پیش از ورود به بازار امری ضروری است (شریف زاده، ۱۳۸۲). برای این منظور، استفاده از تکنیک‌ها و روش‌هایی که توانایی شناسایی گونه‌های مختلف را داشته باشند، اهمیت زیادی دارد. اگر چه در حال حاضر نیز امکان تفکیک نمونه‌های اصل و تقلبی وجود دارد، اما این فرآیند عمدتاً به صورت دستی و با استفاده از نیروی انسانی صورت می‌گیرد، که علاوه بر زمان‌بر بودن، احتمال خطای انسانی در آن بالاست و از نقطه نظر اقتصادی مقرون به صرفه نیست. بنابراین توسعه روش‌های غیر دستی و نیمه خودکار که وابستگی کمتری به نیروی انسانی داشته باشد، می‌تواند نقش مهمی در کنترل و ارزیابی نمونه‌های موجود در بازار ایفا کند (Choudhary et al., 2022).

پیشینه پژوهش

مطالعات انجام‌شده در زمینه‌ی تکنیک‌های پردازش تصویر نشان می‌دهند که ترکیب این روش‌ها با تکنیک‌های طبقه‌بندی مانند شبکه‌های عصبی مصنوعی، ظرفیت بالایی برای کاربرد در چنین مواردی دارد (موسوی‌راد، ۱۳۹۲). تحقیقات زیادی تاکنون برای شناسایی محصولات کشاورزی بر اساس ویژگی‌های بافتی و رنگی و همچنین استفاده از تکنیک ماشین بینایی برای تشخیص تقلب در محصولات کشاورزی صورت گرفته است.

چاکرال‌حسینی و اسمعیلی زینی (۱۳۹۶) به بررسی تشخیص تقلبی بودن محصول کلاله زعفران بر اساس رنگ و ساختار فرم این محصول با استفاده از پردازش تصویر پرداختند. صفری امیری و همکاران (۱۳۹۷) به تشخیص زیره‌های کوهی تقلبی با استفاده از ماشین بویایی پرداختند و در این مطالعه میزان موفقیت تشخیص زیره تقلبی ۹۰ درصد گزارش شد. اکبری آدرگانی و همکاران (۱۴۰۰) با استفاده از بینایی کامپیوتر در تشخیص غیرمخرب زعفران واقعی و تقلبی گام برداشتند. در مطالعه‌ای دیگر، (موسوی راد و همکاران، ۱۳۹۲) پس از استخراج ویژگی‌های دانه‌های برنج، ۲۲ ویژگی که بیشترین تأثیر را در دسته‌بندی داشتند با استفاده از روش‌های آماری انتخاب کردند و از شبکه عصبی پس انتشار برای دسته‌بندی واریته‌ها استفاده نمودند، که در این تحقیق میانگین دقت طبقه‌بندی در این تحقیق ۹۶/۶۷ درصد گزارش شد. ۲۰۰۰ (فیاضی و همکاران، ۱۳۹۲) پس از استخراج ۴۱ ویژگی بافتی از ماتریس‌های سطوح خاکستری، ماتریس هم‌رخدادی و الگوی دودویی محلی تصاویر مقیاس خاکستری دانه‌ها، به شناسایی و تفکیک سه رقم برنج ایرانی در توده‌های مخلوط شده با استفاده از ویژگی‌های بافتی و شبکه عصبی پرداختند که دقت طبقه‌بندی به ترتیب برای سه رقم با استفاده از ویژگی‌های ماتریس سطوح خاکستری ۹۷/۹۶، ۱۰۰ و ۸۳ درصد، با ماتریس هم‌رخدادی ۹۶/۲۳، ۱۰۰ و ۱۰۰ درصد با ماتریس الگوی دودویی محلی ۱۰۰، ۹۷/۵ و ۱۰۰ درصد و با استفاده از کلیه ویژگی‌های ماتریس‌ها ۹۷/۶۷، ۱۰۰ و ۱۰۰ درصد بدست آمد. (گلپور و همکاران، ۱۳۹۴) براساس استخراج ۱۰۸ ویژگی بافتی و شبکه عصبی پس انتشار به تشخیص توده ارقام شلتوک، برنج قهوه‌ای و سفید پرداختند که پس از ارزیابی شبکه‌های یک لایه با استفاده از ویژگی‌های بافتی، برای این تحقیق بیشترین میانگین دقت طبقه‌بندی برای ارقام شلتوک، برنج قهوه‌ای و سفید به ترتیب ۹۲/۲، ۹۷/۸ و ۹۸/۹ درصد به دست آمد. در مطالعه‌ای دیگر، (انورخواه، ۱۳۹۱) با استفاده از دو ویژگی مورفولوژیکی و شش ویژگی رنگی شامل میانگین‌های رنگ‌های سبز، قرمز و آبی، شدت رنگ، طول موج غالب، رنگ اشباع و دو نوع شبکه عصبی RBF و تشخیص الگو، اقدام به شناسایی بذر ۷۵ گونه گیاه دارویی کردند. نتایج مطالعه نشان داد که دو ترکیب شامل ترکیب شش صفت رنگی با ۹۹ و ۸۸ درصد دقت و نیز ترکیب یک ویژگی مورفولوژی و دو صفت رنگی با ۹۲ و ۸۰ درصد دقت، بالاترین میانگین‌های آموزش و تست شبکه عصبی را دارا بودند.

با این حال، روش‌های سنتی تشخیص تقلب، زمان‌بر و پرهزینه هستند و دقت کافی ندارند. در این پژوهش طی بررسی‌ها و نمونه برداری‌های گسترده که از نمونه‌های زیره کرمان موجود در بازار انجام گرفت، مشخص شد که این محصول کاملاً خالص نبوده و حاوی مقادیر قابل توجهی از زیره نامرغوب هستند. با توجه به اهمیت اقتصادی این محصول، وجود ناخالصی‌ها و تقلب در آن می‌تواند موجب کاهش اعتماد مصرف‌کنندگان، افت قیمت و کاهش رقابت‌پذیری در بازارهای داخلی و خارجی شود. بنابراین، با توجه به این یافته‌ها و به‌منظور بهبود کیفیت زیره عرضه‌شده، چه جهت مصرف داخلی و چه به جهت صادرات توصیه می‌شود از فناوری‌های نوین مانند ماشین بینایی به‌عنوان روشی کارآمد برای ارزیابی کیفیت و تشخیص زیره اصیل از انواع تقلبی استفاده شود که می‌تواند راهکاری دقیق، سریع و مقرون‌به‌صرفه برای تشخیص تقلب ارائه دهد. این اقدام می‌تواند از بروز بی‌نظمی در بازار و سوء استفاده‌های احتمالی در این حوزه جلوگیری کند. بنابراین، هدف اصلی این تحقیق، شناسایی اصالت زیره سیاه ایرانی از نمونه‌های تقلبی آن با استفاده از فناوری ماشین بینایی و شبکه‌های عصبی مصنوعی است. این پژوهش به‌منظور ارائه یک روش نوین و دقیق برای تفکیک و شناسایی زیره پارسی اصل از انواع

تقلبی آن در بازار، به‌کارگیری ویژگی‌های رنگی و بافتی به‌عنوان ابزارهای اصلی شناسایی را مد نظر قرار داده است. در این راستا، شبکه‌های عصبی مصنوعی به‌عنوان یک الگوریتم هوشمند برای تشخیص و طبقه‌بندی دقیق این ویژگی‌ها به‌کار گرفته شده‌اند.

مواد و روش‌ها

در این تحقیق به شناسایی اصالت زیره پارسى از انواع تقلبی موجود در بازار کرمان پرداخته شد. به همین منظور، ویژگی‌های رنگی و بافتی نه نمونه زیره سیاه که بیشترین فراوانی را در بازار داشتند، استخراج شد و جهت شناسایی و طبقه‌بندی به شبکه‌های عصبی داده شد.

جمع‌آوری نمونه‌ها

در این تحقیق، نه نمونه زیره سیاه از بازار محلی تهیه شد که شامل پنج نوع زیره پارسى اصیل که توسط افراد با تجربه تایید شده است از بازار تهیه شد. همچنین، چهار نوع زیره تقلبی شامل زیره سیاه اروپایی، زیره سبز رنگ شده و دو نوع زیره مخلوط بی‌کیفیت از دیگر نمونه‌ها بودند. لازم به ذکر است که در زمان انجام تحقیق، محدودیت‌هایی در دسترسی به تعداد بیشتری از نمونه‌های باکیفیت برای تصویربرداری وجود داشت. با توجه به این چالش، نهایتاً ۹ رقم زیره باکیفیت و استاندارد را برای تصویربرداری تهیه شد تا دقت و اعتبار نتایج حاصل از پردازش تصویر حفظ شود. برای انجام آزمایش، هر یک از نمونه‌ها به مقدار ۵۰ گرم برداشت شده و ناخالصی‌های آن‌ها شامل کاه، کلش و بذر گیاهان دیگر جدا و آماده تصویربرداری شدند. تصاویر مربوط به این نمونه‌ها در شکل ۱ ارائه شده است.



زیره پارسى شماره ۳




زیره پارسى شماره ۲




زیره پارسى شماره ۱



زیره مخلوط بی کیفیت ۱ (تقلبی)



زیره پارسى شماره ۵




زیره پارسى شماره ۴



زیره سبز رنگ شده (تقلبی)



زیره سیاه اروپایی (تقلبی)



زیره مخلوط بی کیفیت ۲ (تقلبی)


شکل ۱: نه نمونه زیره تهیه شده از بازار محلی (شامل: پنج نمونه زیره پارسى و چهار نمونه زیره تقلبی)

روند پیشنهادی برای شناسایی نمونه‌ها

مراحل پردازش تصویر در این تحقیق شامل اکتساب تصویر، پیش پردازش تصویر، استخراج ویژگی و طبقه‌بندی می‌باشد.

تهیه تصاویر نمونه‌های زیره

برای تهیه تصاویر از نمونه‌های زیره، از چیدمان تصویربرداری موجود در کارگاه طراحی و تحقیق گروه مهندسی مکانیک بیوسیستم دانشگاه جیرفت استفاده شد. این چیدمان از سامانه تصویربرداری شامل دوربین (الف)، محفظه نورپردازی، مجموعه رایانه شخصی و متعلقات آن، نرم افزار تصویربرداری خودکار تشکیل شده است. در شکل ۲ نمایی از چیدمان تصویربرداری نشان داده شده است.



شکل ۲: نمایی از چیدمان تصویربرداری (الف) دوربین (ب) منبع نور فلورسنت (پ) صفحه قوسی (ت) رایانه

منبع نور در سیستم تصویربرداری این تحقیق شامل دو عدد لامپ فلورسنت مونوکروم با توان ۲۰ وات بود که در قسمت زیرین محفظه تصویربرداری تعبیه شد. لازم به ذکر است که نور طبیعی متغیر است و برای اطمینان از یکنواختی شرایط نوری، از یک منبع نور کنترل شده استفاده شده است. برای توزیع یکنواخت و متقارن نور روی نمونه‌ها، از یک صفحه قوسی PVC در بالای لامپ‌ها استفاده شد. دوربین مورد استفاده در این مطالعه، Canon EOS kiss x4 ساخت کشور ژاپن با حسگر از نوع CMOS و وضوح ۱۸ مگاپیکسل که امکان تصویربرداری از راه دور را فراهم می‌کرد. در این تحقیق، فاصله‌ی عمودی بین لنز و سطح نمونه حدود ۳۰ سانتی متر در نظر گرفته شد (Dowlati et al., 2012). تمامی مراحل تصویربرداری توسط نرم افزار ZoomBrowser 6.5.1 EX انجام شد و تصاویر در فایل‌های مشخص برای پردازش‌های بعدی ذخیره شدند. تمامی تصاویر در شرایط کاملاً تثبیت شده انجام گرفت و حالت‌های تنظیم خودکار به طور کلی خاموش شده بود (Dowlati et al., 2013). در جدول ۱ تنظیمات دوربین در هنگام تصویربرداری نیز آورده شده است (دولتی، ۱۳۹۲). بنا بر رنگ زیره و سایر ویژگی‌های تکنیکی از رنگ زمینه سفید به عنوان پس زمینه جهت کاهش سایه، نویز و تجانس پس زمینه با محصول برای کاهش خطا استفاده شد. در نهایت، ۶۴۰ تصویر رنگی (معادل ۴۰ تصویر برای هر نمونه) تهیه شد. با استفاده از جعبه ابزار پردازش تصویر در نرم افزار، تصاویر پردازش شدند و سپس پس از استخراج ویژگی‌ها، با استفاده از شبکه عصبی تشخیص و طبقه‌بندی نمونه‌ها انجام گرفت.

پیش پردازش تصاویر نمونه‌های زیره تهیه شده

پس از اکتساب تصاویر، گام بعدی پیش پردازش تصویر و استخراج ویژگی‌ها با استفاده از الگوریتم مورد نظر جهت می باشد. مرحله پیش پردازش شامل عملیاتی مانند بخش بندی تصویر همچون انتقال تصویر از فضای رنگی به فضای خاکستری، تبدیل تصاویر بین فضاهای رنگی می‌باشد. در ابتدا تصاویر رنگی RGB به باینری تبدیل و ذخیره شد و به دلیل اینکه تصاویر گرفته شده توسط دوربین در فضای رنگی (RGB) که یک فضای رنگی وابسته به دستگاه می‌باشد، پس از حذف پس زمینه تصاویر به فضاهای رنگی (HSV, HSI) مستقل از دستگاه منتقل شدند.

عملیات استخراج ویژگی‌های رنگی و بافتی تصاویر نمونه‌های زیره


استخراج ویژگی‌های رنگی نمونه‌ها

پس از اکتساب تصویر و استخراج مولفه‌های رنگی R، G و B مولفه شدت از میانگین مقادیر این سه مولفه با استفاده از معادلات مربوطه

در مطالعه دولتی و همکاران (۱۳۹۵) محاسبه شد. مقادیر ترکیبات رنگی RGB در محدوده (۰، ۱) می باشند و مولفه‌های اصل رنگ و اشباع و شدت نیز از تبدیل هندسی بین مولفه‌های رنگ با استفاده از معادله‌های مشخص موجود در تحقیق دولتی و همکاران (۱۳۹۵) محاسبه شدند.

متغیر	اندازه، مقدار یا حالت
اندازه تصویر	۵۱۸۴×۳۴۵۶ پیکسل
بزرگ نمایی	بدون بزرگ نمایی
حالت فلش	بدون فلاش
حساسیت	ISO-۱۰۰
تراز سفیدی	فلورسنت
حالت کار	دستی
متوسط روزانه	f/0.4
زمان متوسط نوردهی	۱/۳۰ ثانیه
نوع تصویر	JPEG
ماکرو (نمای نزدیک)	روشن
فاصله کانونی	۲۴ میلی‌متر
وضوح	۷۲ dpi

در نهایت، تصاویر رنگی بوسیله تعیین توزیع رنگی از طریق تصاویر، تغییر در رنگ با توجه به میانگین و تفاوت بین بیشترین و کم‌ترین مقادیر رنگی مشخص شدند. این مشخصه بوسیله محاسبه میانگین، واریانس، محدوده تغییرات و انحراف معیار برای تصویر رنگی داده شده با استفاده از معادلات موجود در تحقیق دولتی و همکاران (۱۳۹۵) بدست آمدند. الگوریتم استخراج ویژگی‌های رنگی در شکل ۳ نشان داده شد.



شکل ۳: الگوریتم استخراج ویژگی‌های رنگی

در نهایت ۳۶ ویژگی رنگی در فضاها رنگی RGB، HSI و HSV بدست آمد که در جدول ۲ نشان داده شده است.

استخراج ویژگی بافتی نمونه های زیره


از ماتریس هم رخدادی (GLCM)، نه ویژگی شامل میانگین، واریانس، محدوده دامنه تغییرات، کنتراست، همگنی، ماکزیمم احتمال، همبستگی، انرژی و آنتروپی مطابق با معادلات موجود در تحقیق گلپور و همکاران، (۱۳۹۴) از تصاویر نمونه های زیره استخراج شد. ویژگی‌های بافت استخراج شده به صورت زیر تعریف و بیان می شود:

آنروپی: یک اندازه از پیچیدگی تصویر را نشان می‌دهد. ساختار پیچیده‌تر دارای آنروپی بالاتری می‌باشد. کنتراست: میزان تغییرات محلی رنگ در تصویر را ارائه می‌دهد. مقادیر بالای کنتراست مربوط به تغییرات روشنی در ساختار تصویر می‌باشد.

انرژی: بیانگر میزان نظم و هم‌جنسی در تصویر است. بنابراین این پارامتر یک پارامتر مناسب جهت اندازه‌گیری بی‌نظمی در ساختار تصویر می‌باشد. برای ساختارهای یکنواخت و هم‌جنس مقدار انرژی نسبت به ساختارهای غیر هم‌جنس کمتر است. ماکزیمم احتمال: ماکزیمم همسایگی سطوح خاکستری در جهت مشخص را ارائه می‌دهد. یکنواختی: شباهت پیکسل‌ها را اندازه می‌گیرد. سطح خاکستری قطری ماتریس مجاورت دارای یکنواختی یک می‌باشد. محدوده تغییرات: تفاوت بین بیشترین و کم‌ترین مقادیر شدت سطوح خاکستری را در یک همسایگی مشخص می‌کند. واریانس: مجموع تفاوت بین شدت پیکسل مرکزی با پیکسل همسایه‌اش را نشان می‌دهد. همبستگی: مقیاسی از خطی بودن تصویر را نشان می‌دهد. به همین دلیل تصاویری که ساختار خطی دارند همبستگی بالایی دارند.

جدول ۲: ویژگی رنگی در فضاها رنگی RGB و HSI و HSV

شماره	ویژگی‌ها	شماره	ویژگی‌ها	شماره	ویژگی‌ها
۱	میانگین رنگ قرمز	۱۳	میانگین اصل رنگ (HSI)	۲۵	میانگین اصل رنگ (HSV)
۲	واریانس رنگ قرمز	۱۴	واریانس اصل رنگ (HSI)	۲۶	واریانس اصل رنگ (HSV)
۳	محدوده‌ی تغییرات رنگ قرمز	۱۵	محدوده‌ی تغییرات اصل رنگ (HSI)	۲۷	محدوده‌ی تغییرات اصل رنگ (HSV)
۴	انحراف معیار رنگ قرمز	۱۶	انحراف معیار اصل رنگ (HSI)	۲۸	انحراف معیار اصل رنگ (HSV)
۵	میانگین رنگ سبز	۱۷	میانگین اشباع (HSI)	۲۹	میانگین اشباع (HSV)
۶	واریانس رنگ سبز	۱۸	واریانس اشباع (HSI)	۳۰	واریانس اشباع (HSV)
۷	محدوده‌ی تغییرات رنگ سبز	۱۹	محدوده‌ی تغییرات اشباع (HSI)	۳۱	محدوده‌ی تغییرات اشباع (HSV)
۸	انحراف معیار رنگ سبز	۲۰	انحراف معیار اشباع (HSI)	۳۲	انحراف معیار اشباع (HSV)
۹	میانگین رنگ آبی	۲۱	میانگین شدت	۳۳	میانگین مقدار رنگ
۱۰	واریانس رنگ آبی	۲۲	واریانس شدت	۳۴	واریانس مقدار رنگ
۱۱	محدوده‌ی تغییرات رنگ آبی	۲۳	محدوده‌ی تغییرات شدت	۳۵	محدوده‌ی تغییرات مقدار رنگ
۱۲	انحراف معیار رنگ آبی	۲۴	انحراف معیار شدت	۳۶	انحراف معیار مقدار رنگ



شکل ۵: محاسبه ماتریس هم رخدادی و استخراج ویژگی‌ها بافتی از ماتریس هم رخدادی

بطور کلی، نه ویژگی ساختاری از هر مولفه رنگ و در هر زاویه (۰، ۴۵، ۹۰ و ۱۳۵ درجه) محاسبه شد که با در نظر گرفتن کلیه زاویه‌ها تعداد متغیرها برای هر مولفه رنگ ۳۶ عدد شد. این زوایا بر اساس استانداردهای موجود برای ماتریس هم رخدادی بر اساس تحقیقات مختلف انتخاب شده اند. با در نظر گرفتن هر سه مولفه رنگ، کلیه پارامترهای محاسبه شده ۱۰۸ عدد بود. پارامترهای اندازه‌گیری شده (پارامترهای بافتی و رنگی) در ادامه بصورت پارامترهای آموزشی در شبکه عصبی استفاده شدند تا بدین وسیله نمونه‌های مختلف شناسایی شوند. الگوریتم محاسبه ماتریس هم رخدادی و استخراج ویژگی‌ها بافتی از ماتریس هم رخدادی در شکل ۵ آورده شده است.

قبل از انتقال داده‌های بدست آمده از پردازش تصویر با استفاده از برنامه نویسی در نرم افزار متلب به ورودی شبکه عصبی مصنوعی، ابتدا عملیات نرمال سازی با استفاده از رابطه ۱ انجام شد. در این رابطه B_U و B_L به ترتیب کران بالا و کران پایین X_{min} و X_{max} و X به ترتیب مقادیر مینیمم، ماکزیمم و مقدار واقعی داده‌ها می باشد. در این رابطه X_n مقدار نرمال شده پارامترهای ورودی و خروجی می باشد.

$$X_n = \frac{X_{max}B_LX_{min}B_U + X(B_U - B_L)}{(X_{max} - X_{min})} \quad \text{رابطه ۱}$$


انتخاب ویژگی ها با استفاده از روش تحلیل عاملی

در این پژوهش، خواص بافتی و رنگی محاسبه شده برای هر تصویر با استفاده از نرم افزار آماری SPSS Statistics 21 بررسی شدند و با روش تحلیل عاملی، ویژگی بافتی و رنگی اضافی که تاثیر کمی در تشخیص و طبقه‌بندی نمونه‌های اصلی زیره با نمونه‌های تقلبی داشتند حذف شده و خواصی که بیشترین تاثیر را داشتند برای شناسایی نمونه‌های زیره اصلی در نظر گرفته شدند. در این روش، متغیرهایی که با هیچ متغیری همبستگی معنی‌دار نداشته بودند، از تحلیل حذف می‌شوند. این کاهش خواص بافتی و رنگی باعث کم شدن محاسبات و کاهش پیچیدگی روابط در تشخیص و طبقه‌بندی نمونه‌های زیره سیاه اصلی از نمونه‌های تقلبی می‌شد. براساس این آنالیزها، ویژگی‌های رنگی و بافتی موثر برای تشخیص ارقام مد نظر زیره مشخص شدند و در نهایت به عنوان ورودی شبکه عصبی جهت طبقه‌بندی و تشخیص نمونه‌های تقلبی از اصل زیره استفاده شدند.

شبکه‌های عصبی مصنوعی پرسپترون چندلایه با الگوریتم پس انتشار (BPMLP)

در این تحقیق، ویژگی‌های استخراج شده از پردازش تصاویر به عنوان ورودی شبکه عصبی پرسپترون چند لایه^۱ (MLP) در نرم افزار MATLAB با روش یادگیری پس انتشار با تابع آموزشی لونیبرگ-مارکوارت برای آموزش شبکه استفاده شد. این شبکه عصبی یکی از مدل‌های پرکاربرد در یادگیری ماشین است که برای مسائل طبقه‌بندی و پیش‌بینی استفاده می‌شود. در این نوع شبکه، لایه‌های مختلفی از نورون‌ها وجود دارد که به صورت پیوسته به هم متصل هستند. فرآیند یادگیری در BPMLP با استفاده از الگوریتم پس انتشار خطا (Backpropagation) انجام می‌شود. در این روش، خطای پیش‌بینی مدل از خروجی به ورودی شبکه منتقل شده و وزن‌های اتصالات بر اساس آن اصلاح می‌شود تا دقت شبکه افزایش یابد.

ورودی‌های شبکه، خواص رنگی و بافتی بدست آمده از تصاویر نمونه‌های زیره و خروجی‌های آن، نمونه‌های زیره بودند. ساختار شبکه عصبی MLP در شکل ۶ شامل یک لایه ورودی، یک لایه پنهان و یک لایه خروجی نشان داده شد. ۶۴۰ الگو (۴۰ تصویر به ازای هر نمونه) برای آموزش، اعتبار سنجی و ارزیابی شبکه استفاده شدند (۶۰ درصد جهت آموزش، ۲۰ درصد اعتبارسنجی و ۲۰ درصد برای ارزیابی شبکه). لازم به ذکر است فاز یادگیری آموزش شبکه با ۲۰۰ تکرار انجام گرفت و در نهایت چرخه آموزش نهایی در پایان آموزش و ارزیابی شبکه مورد ارزیابی قرار گرفت. این تعداد تکرار مربوط به قبل از توقف فرآیند آموزش شبکه و رسیدن به مرحله بیش آموزش می‌باشد. برای دستیابی به بهترین شبکه با بالاترین دقت در تشخیص ارقام، از روش تغییر دادن توابع انتقال، تعداد نرون‌ها در لایه‌های پنهان و نوع لایه‌های پنهان استفاده شد.



شکل ۶: ساختار شبکه عصبی MLP استفاده شده

تشخیص نمونه های زیره اصل و تقلبی با استفاده از ویژگی های رنگی، بافتی و ترکیب آن ها در شبکه عصبی BPMLP پس از عملیات پردازش تصویر، تعداد چهار ویژگی رنگی از هریک از مولفه ها در سه فضای رنگی RGB، HSI و HSV بدست آمد و در حالت کلی ۳۶ ویژگی رنگی (برای هر مولفه رنگی) از هریک از نمونه ها بدست آمد. تعداد ویژگی های بافت بدست آمده از تصاویر نمونه های زیره نیز ۱۰۸ بود. در نهایت، ۳۶ ویژگی رنگی و ۱۰۸ ویژگی بافتی به عنوان ورودی شبکه عصبی پس انتشار برای شناسایی نمونه های زیره استفاده شد. همچنین ارزیابی شبکه عصبی با استفاده از کل داده های رنگی و بافتی (۱۴۴ ویژگی) و داده های کاهش یافته از تحلیل عاملی به صورت جداگانه انجام شد.

نتایج و بحث

تصاویر نمونه های پیش پردازش شده

پس از پیش پردازش، تصاویر نهایی مطابق شکل ۷ نشان داده شدند. در این شکل به ترتیب از سمت راست به چپ ابتدا تصاویر رنگی به تصاویر باینری با حد آستانه ۵ تبدیل شدند. سپس، نویز و پس زمینه ای که دقت را کاهش می دادند، حذف و اجزای کوچک تر از حد مشخصی پاک شدند. در نهایت، تصویر توده زیره به ابعاد 440×420 برش داده شد.



شکل ۷: تصاویر خروجی زیره ها پس از فرآیند پیش پردازش

شناسایی زیره پاریسی از میان نه نمونه ی زیره تهیه شده با استفاده شبکه عصبی BPMLP

طبقه بندی و شناسایی نمونه های زیره پاریسی با استفاده از ویژگی های رنگی

همان طور که در جدول ۳ مشاهده می شود پس از ارزیابی شبکه با یک لایه پنهان با تعداد نرون ها و توابع انتقال مختلف، بیشترین میانگین دقت طبقه بندی ۹۳/۵۱ درصد با استفاده از تابع خطی در خروجی و تابع لگاریتم سیگموئید در لایه پنهان با توپولوژی ۹-۱۴-۳۶ با تعداد چرخه آموزش ۲۴ بدست آمد که بهترین ساختار را در تابع یادگیری لونیگ مارکوارت داشت. همچنین، کمترین مقدار میانگین دقت طبقه بندی با هفت نرون در لایه پنهان با تابع انتقال تانژانت سیگموئید در لایه پنهان و تابع انتقال خطی در لایه خروجی برابر ۸۹/۱۰ درصد حاصل شد (جدول ۳).

جدول ۳: بررسی تاثیر توابع انتقال مختلف لایه پنهان و خروجی بر میانگین دقت تشخیص نمونه‌ها (۳۶ ویژگی رنگی)

توابع انتقال (لایه پنهان-لایه خروجی)	توپولوژی	تعداد چرخه آموزش	میانگین دقت طبقه بندی (درصد)
تانزانانت سیگموئید - خطی	۳۶-۷-۹	۳۱	۸۹/۱۰
تانزانانت سیگموئید - تانزانانت سیگموئید	۳۶-۸-۹	۱۱	۹۳/۰۱
لگاریتم سیگموئید - تانزانانت سیگموئید	۳۶-۲۳-۹	۴۸	۹۲/۱۷
لگاریتم سیگموئید - خطی	۳۶-۱۴-۹	۲۴	۹۳/۵۱

انتخاب ویژگی‌های رنگی نمونه‌های زیره با استفاده از تحلیل عاملی

براساس بررسی‌های بعمل آمده، ویژگی‌های رنگی زیادی با یکدیگر همبستگی داشتند و اگر یکی از ویژگی‌ها برای شناسایی ارقام انتخاب شود، ویژگی‌های دیگر تاثیر معنی داری در بهبود نتایج شناسایی نمونه‌های زیره نخواهد داشت. بنابراین نیاز بود تعدادی از این ویژگی‌ها به دلیل همبستگی زیاد بین آن‌ها، کاهش داده شود. برای بدست آوردن سطوح توزیع از روش تحلیلی عاملی برای انتخاب خواص استفاده شد. با توجه به ماتریس همبستگی حاصل از تحلیل عاملی برای نمونه‌های زیره، ۱۳ ویژگی رنگی برای طبقه بندی نمونه‌های استخراج شده، بدست آمده که این ویژگی‌ها در جدول ۴ آورده شده اند.

جدول ۴: ویژگی‌های رنگی انتخاب شده با استفاده از روش تحلیلی عاملی

شماره	ویژگی‌های رنگی	شماره	ویژگی‌های رنگی	شماره	ویژگی‌های رنگی
۱	میانگین رنگ قرمز	۶	انحراف معیار رنگ سبز	۱۱	میانگین رنگ سبز
۲	واریانس رنگ قرمز	۷	میانگین رنگ آبی	۱۲	واریانس رنگ سبز
۳	محدوده‌ی تغییرات رنگ قرمز	۸	واریانس رنگ آبی	۱۳	واریانس اصل رنگ (HSV)
۴	انحراف معیار رنگ قرمز	۹	انحراف معیار رنگ آبی		
۵	محدوده‌ی تغییرات رنگ آبی	۱۰	محدوده‌ی تغییرات رنگ سبز		

ارزیابی شبکه عصبی با کاهش ویژگی‌های رنگی نمونه‌ها

پس از انتخاب و کاهش ویژگی‌های رنگی، در نهایت شبکه با ۱۳ نرون ورودی و نه نرون خروجی با توابع انتقال مختلف مورد ارزیابی قرار گرفت و پس از آموزش و ارزیابی شبکه با توجه به نتایج بدست آمده مطابق جدول ۵ تابع تانزانانت سیگموئید در خروجی و تابع تانزانانت سیگموئید در لایه پنهان با توپولوژی ۱۳-۲۳-۹ بهترین ساختار در الگوریتم آموزشی لونبرگ مارکوارت با بیشترین میانگین دقت طبقه بندی ۹۳/۸۱ درصد بعنوان بهترین شبکه انتخاب شد. این نتایج با نتایج بدست آمده در پژوهش گلپور و همکاران (۲۰۱۴) برای طبقه بندی ارقام مختلف شلتوک با دقت تقریباً مشابه در طبقه بندی مطابقت داشت. همچنین شبکه با تابع خروجی خطی و ورودی تانزانانت سیگموئید با میانگین دقت طبقه بندی ۸۸/۰۸ درصد با تعداد چرخه آموزش ۱۸۶ و تعداد نرون ۱۶ در لایه پنهان کمترین میانگین دقت طبقه بندی را داشت (جدول ۵). لازم به ذکر است که بهترین نتایج شبکه عصبی در این جدول آورده شد و نتایج شبکه عصبی با توابع خطی و نرون‌های متفاوت دیگر که کمتر از دقت طبقه بندی ۸۸/۰۸ درصد بودند در این جدول ذکر نشده است.

جدول ۵: بررسی تاثیر توابع انتقال مختلف لایه پنهان و خروجی بر میانگین دقت تشخیص نمونه‌ها (۱۳ ویژگی رنگی)

توابع انتقال (لایه پنهان-لایه خروجی)	توپولوژی	تعداد چرخه آموزش	میانگین دقت طبقه بندی (درصد)
تانزانانت سیگموئید - خطی	۹-۱۶-۱۳	۱۸۶	۸۸/۰۸
تانزانانت سیگموئید - تانزانانت سیگموئید	۹-۲۳-۱۳	۴۰	۹۳/۸۱
لگاریتم سیگموئید - تانزانانت سیگموئید	۹-۲۴-۱۳	۷۷	۹۰/۴۴
لگاریتم سیگموئید - خطی	۹-۲۶-۱۳	۵۱	۸۹/۸۹

طبقه بندی و شناسایی نمونه‌های زیره با استفاده از ویژگی‌های بافتی

در این بخش، ابتدا طبقه بندی نه نمونه‌ی زیره (پنج نمونه زیره پاریسی و چهار نمونه زیره تقلبی) با استفاده از ۱۰۸ ویژگی بافتی مورد

بررسی قرار گرفت و سپس به منظور افزایش سرعت و دقت طبقه بندی با استفاده از کاهش تعداد ویژگی‌ها از ۱۰۸ به ۹۶ ویژگی به طبقه بندی نمونه‌های زیره پرداخته شد. نتایج آموزش و ارزیابی شبکه پس انتشار با یک لایه پنهان و توابع انتقال مختلف در این لایه و لایه خروجی شبکه، میانگین دقت‌های طبقه بندی برای شناسایی نه نمونه‌ی زیره با ۱۰۸ ویژگی بافتی که به عنوان ورودی شبکه و نه نمونه‌ی زیره که به عنوان خروجی شبکه محسوب می‌شوند، در جدول ۶ ارائه شده است. براساس نتایج بدست آمده، شبکه با نه نرون در لایه پنهان اول با تابع انتقال لگاریتم سیگموئید در لایه پنهان و تابع خطی در لایه خروجی و تعداد ۲۸ چرخه آموزش بیشترین میانگین دقت طبقه بندی ۹۵/۸۶ درصد را داشت و به عنوان مطلوب‌ترین شبکه انتخاب شد. به طور کلی، با توجه به نتایج حاصل از شبکه های عصبی با ورودی های مربوط به ویژگی‌های بافتی، نسبت به شبکه‌های عصبی با ورودی‌های مربوط به ویژگی‌های رنگی (با میانگین دقت طبقه بندی ۹۳/۵۱ درصد) دارای میزان دقت طبقه بندی بالاتری بود.

جدول ۶: بررسی تاثیر توابع انتقال مختلف لایه پنهان و خروجی بر میانگین دقت تشخیص نمونه ها (۱۰۸ ویژگی بافتی)

توابع انتقال (لایه پنهان-لایه خروجی)	توپولوژی	تعداد چرخه آموزش	میانگین دقت طبقه بندی (درصد)
تانژانت سیگموئید - خطی	۱۰۸-۹-۹	۳۲	۹۳/۳۵
تانژانت سیگموئید - تانژانت سیگموئید	۱۰۸-۶-۹	۲۷	۹۴/۱۴
لگاریتم سیگموئید - تانژانت سیگموئید	۱۰۸-۶-۹	۳۰	۹۲/۱۲
لگاریتم سیگموئید - خطی	۱۰۸-۹-۹	۲۸	۹۵/۸۶

انتخاب ویژگی‌های بافتی برای نمونه‌های زیره با استفاده از تحلیل عاملی

بسیاری از ویژگی‌ها اگر با هم به صورت همزمان برای طبقه بندی استفاده شوند به علت داشتن همبستگی زیاد با یکدیگر برای طبقه بندی و تشخیص واریته ها مناسب نخواهند بود و در افزایش دقت طبقه بندی نقش زیادی نخواهند داشت (گلپور، ۱۳۹۱). با توجه به ماتریس همبستگی حاصل از تحلیلی عاملی ۹۶ ویژگی از کل ۱۰۸ ویژگی بافتی پس از انجام عملیات انتخاب ویژگی حاصل شد که این ویژگی‌ها در جدول ۷ آورده شده اند.

ارزیابی شبکه با کاهش ویژگی‌های بافتی نمونه‌ها

پس از انتخاب ویژگی‌های بافتی، شبکه عصبی با ۹۶ نرون ورودی و نه نرون خروجی مورد ارزیابی قرار گرفت. شبکه عصبی با یک لایه پنهان با در نظر گرفتن نرون های متفاوت به صورت تصادفی و سه تابع انتقال خطی، لگاریتم سیگموئید و تانژانت سیگموئید مورد ارزیابی قرار گرفت. در نهایت، همان طور که در جدول ۸ مشاهده می‌شود شبکه با تابع تانژانت سیگموئید در خروجی و تابع لگاریتم سیگموئید در لایه پنهان با توپولوژی ۹-۸-۹۶ و با تعداد چرخه آموزش ۵۲ بهترین ساختار در تابع یادگیری لونبرگ مارکوارت با بیشترین میانگین دقت طبقه بندی (۹۵/۶۵ درصد) را داشت. نتایج این تحقیق با نتایج گلپور و همکاران (۱۳۹۴) در جهت تشخیص ارقام شلتوک، برنج قهوه‌ای و سفید براساس ویژگی‌های بافتی مطابقت داشت.

تشخیص و طبقه بندی نمونه‌های اصل زیره با استفاده از ویژگی‌های ترکیبی (بافت-رنگ)

از ترکیب ویژگی‌های مربوط به بافت (۱۰۸ ویژگی) و ویژگی‌های مربوط به رنگ (۳۶ ویژگی)، ۱۴۴ ویژگی حاصل شد و به عنوان ورودی شبکه عصبی پس انتشار استفاده شد و همچنین نه نمونه زیره (پنج نمونه زیره پاریسی و چهار نمونه زیره تقلبی) به عنوان خروجی شبکه برای تشخیص و طبقه بندی نمونه‌های زیره در نظر گرفته شد. جدول ۸، میانگین دقت طبقه بندی با استفاده از ترکیب ویژگی‌های بافت و رنگ را نشان می‌دهد. شبکه با یک لایه پنهان و با تعداد نرون‌های مختلف در این لایه مورد بررسی قرار گرفت و بهترین ساختار توپولوژی ۹-۱۱-۱۴۴ با تعداد چرخه آموزش ۲۰ و تابع انتقال لگاریتم سیگموئید در لایه پنهان و تابع تانژانت سیگموئید در لایه خروجی با بیشترین دقت طبقه‌بندی برابر ۹۵/۵۹ درصد بدست آمد. کمترین میانگین دقت طبقه بندی نیز در شبکه ای با توپولوژی ۹-۱۹-۱۴۴ با تابع انتقال خطی در لایه خروجی حاصل شد (جدول ۹).

انتخاب ویژگی‌های ترکیبی (رنگی-بافتی) برای نمونه‌ها

با توجه به ماتریس همبستگی از میان ۱۴۴ ویژگی ترکیبی، تعداد ۱۱۰ ویژگی با استفاده از روش تحلیل عاملی استخراج شدند که این ویژگی‌ها در جدول ۱۰ آورده شده است.

جدول ۷: ویژگی‌های بافتی انتخاب شده با استفاده از روش تحلیل عاملی

شماره	ویژگی - زاویه	شماره	ویژگی - زاویه	شماره	ویژگی - زاویه
۱	ماکزیمم احتمال رنگ سبز ۰	۳۳	انرژی رنگ آبی ۰	۶۵	همبستگی رنگ قرمز ۰
۲	ماکزیمم احتمال رنگ سبز ۴۵	۳۴	انرژی رنگ آبی ۴۵	۶۶	همبستگی رنگ قرمز ۴۵
۳	ماکزیمم احتمال رنگ سبز ۹۰	۳۵	انرژی رنگ آبی ۹۰	۶۷	همبستگی رنگ قرمز ۹۰
۴	ماکزیمم احتمال رنگ سبز ۱۳۵	۳۶	انرژی رنگ آبی ۱۳۵	۶۸	همبستگی رنگ قرمز ۱۳۵
۵	ماکزیمم احتمال رنگ آبی ۰	۳۷	انرژی رنگ قرمز ۰	۶۹	همبستگی رنگ سبز ۰
۶	ماکزیمم احتمال رنگ آبی ۴۵	۳۸	انرژی رنگ قرمز ۴۵	۷۰	همبستگی رنگ سبز ۴۵
۷	ماکزیمم احتمال رنگ آبی ۹۰	۳۹	انرژی رنگ قرمز ۹۰	۷۱	همبستگی رنگ سبز ۹۰
۸	ماکزیمم احتمال رنگ آبی ۱۳۵	۴۰	انرژی رنگ قرمز ۱۳۵	۷۲	همبستگی رنگ سبز ۱۳۵
۹	دامنه تغییرات رنگ قرمز ۰	۴۱	انرژی رنگ سبز ۰	۷۳	همبستگی رنگ آبی ۰
۱۰	دامنه تغییرات رنگ قرمز ۴۵	۴۲	انرژی رنگ سبز ۴۵	۷۴	همبستگی رنگ آبی ۴۵
۱۱	دامنه تغییرات رنگ قرمز ۹۰	۴۳	انرژی رنگ سبز ۹۰	۷۵	همبستگی رنگ آبی ۹۰
۱۲	دامنه تغییرات رنگ قرمز ۱۳۵	۴۴	انرژی رنگ سبز ۱۳۵	۷۶	همبستگی رنگ آبی ۱۳۵
۱۳	دامنه تغییرات رنگ سبز ۰	۴۵	انرژی رنگ آبی ۰	۷۷	همبستگی رنگ قرمز ۰
۱۴	دامنه تغییرات رنگ سبز ۴۵	۴۶	انرژی رنگ آبی ۴۵	۷۸	همبستگی رنگ قرمز ۴۵
۱۵	دامنه تغییرات رنگ سبز ۹۰	۴۷	انرژی رنگ آبی ۹۰	۷۹	همبستگی رنگ قرمز ۹۰
۱۶	دامنه تغییرات رنگ سبز ۱۳۵	۴۸	انرژی رنگ آبی ۱۳۵	۸۰	همبستگی رنگ قرمز ۱۳۵
۱۷	دامنه تغییرات رنگ آبی ۰	۴۹	میانگین رنگ قرمز ۰	۸۱	همبستگی رنگ سبز ۰
۱۸	دامنه تغییرات رنگ آبی ۴۵	۵۰	میانگین رنگ قرمز ۴۵	۸۲	همبستگی رنگ سبز ۴۵
۱۹	دامنه تغییرات رنگ آبی ۹۰	۵۱	میانگین رنگ قرمز ۹۰	۸۳	همبستگی رنگ سبز ۹۰
۲۰	دامنه تغییرات رنگ آبی ۱۳۵	۵۲	میانگین رنگ قرمز ۱۳۵	۸۴	همبستگی رنگ سبز ۱۳۵
۲۱	یکنواختی رنگ قرمز ۰	۵۳	میانگین رنگ سبز ۰	۸۵	همبستگی رنگ آبی ۰
۲۲	یکنواختی رنگ قرمز ۴۵	۵۴	میانگین رنگ سبز ۴۵	۸۶	همبستگی رنگ آبی ۴۵
۲۳	یکنواختی رنگ قرمز ۹۰	۵۵	میانگین رنگ سبز ۹۰	۸۷	همبستگی رنگ آبی ۹۰
۲۴	یکنواختی رنگ قرمز ۱۳۵	۵۶	میانگین رنگ سبز ۱۳۵	۸۸	همبستگی رنگ آبی ۱۳۵
۲۵	یکنواختی رنگ سبز ۰	۵۷	میانگین رنگ آبی ۰	۸۹	انرژی رنگ قرمز ۰
۲۶	یکنواختی رنگ سبز ۴۵	۵۸	میانگین رنگ آبی ۴۵	۹۰	انرژی رنگ قرمز ۴۵
۲۷	یکنواختی رنگ سبز ۹۰	۵۹	میانگین رنگ آبی ۹۰	۹۱	انرژی رنگ قرمز ۹۰
۲۸	یکنواختی رنگ سبز ۱۳۵	۶۰	میانگین رنگ آبی ۱۳۵	۹۲	انرژی رنگ قرمز ۱۳۵
۲۹	یکنواختی رنگ آبی ۰	۶۱	ماکزیمم احتمال رنگ قرمز ۰	۹۳	انرژی رنگ سبز ۰
۳۰	یکنواختی رنگ آبی ۴۵	۶۲	ماکزیمم احتمال رنگ قرمز ۴۵	۹۴	انرژی رنگ سبز ۴۵
۳۱	یکنواختی رنگ آبی ۹۰	۶۳	ماکزیمم احتمال رنگ قرمز ۹۰	۹۵	انرژی رنگ سبز ۹۰
۳۲	یکنواختی رنگ آبی ۱۳۵	۶۴	ماکزیمم احتمال رنگ قرمز ۱۳۵	۹۶	انرژی رنگ سبز ۱۳۵

جدول ۸: بررسی تاثیر توابع انتقال مختلف لایه پنهان و خروجی بر میانگین دقت تشخیص نمونه‌ها (۹۶ ویژگی بافتی)

توابع انتقال (لایه پنهان - لایه خروجی)	توپولوژی	تعداد چرخه آموزش	میانگین دقت طبقه بندی (درصد)
تانزانت سیگموئید - خطی	۹-۲۴-۹۶	۴۷	۹۰/۷۸
تانزانت سیگموئید - تانزانت سیگموئید	۹-۹-۹۶	۳۶	۹۵/۲۳
لگاریتم سیگموئید - تانزانت سیگموئید	۹-۸-۹۶	۵۲	۹۵/۶۵
لگاریتم سیگموئید - خطی	۹-۲۶-۹۶	۷۶	۹۱/۵۷

جدول ۹: بررسی تاثیر توابع انتقال مختلف لایه پنهان و خروجی بر میانگین دقت تشخیص نمونه‌ها (۱۴۴ ویژگی ترکیبی)

توابع انتقال (لایه پنهان، لایه خروجی)	توپولوژی	تعداد چرخه آموزش	میانگین دقت طبقه بندی (درصد)
تانزانت سیگموئید - خطی	۱۴۴-۱۹-۹	۲۶	۹۵/۴
تانزانت سیگموئید - تانزانت سیگموئید	۱۴۴-۱۶-۹	۱۶	۹۵/۴۲
لگاریتم سیگموئید - تانزانت سیگموئید	۱۴۴-۱۱-۹	۲۰	۹۵/۵۹
لگاریتم سیگموئید - خطی	۱۴۴-۲۲-۹	۶۵	۹۵/۴



جدول ۱۰: ویژگی‌های ترکیبی (رنگی - بافتی) انتخاب شده با استفاده از روش تحلیل عاملی

شماره	ویژگی - زاویه	شماره	ویژگی - زاویه	شماره	ویژگی - زاویه
۱	ماکزیم احتمال رنگ سبز	۳۸	انرژی رنگ آبی ۰	۷۵	همبستگی رنگ قرمز ۰
۲	ماکزیم احتمال رنگ سبز ۴۵	۳۹	انرژی رنگ آبی ۴۵	۷۶	همبستگی رنگ قرمز ۴۵
۳	ماکزیم احتمال رنگ سبز ۹۰	۴۰	انرژی رنگ آبی ۹۰	۷۷	همبستگی رنگ قرمز ۹۰
۴	ماکزیم احتمال رنگ سبز ۱۳۵	۴۱	انرژی رنگ آبی ۱۳۵	۷۸	همبستگی رنگ قرمز ۱۳۵
۵	ماکزیم احتمال رنگ آبی ۰	۴۲	آنتروپی رنگ قرمز ۰	۷۹	همبستگی رنگ سبز ۰
۶	ماکزیم احتمال رنگ آبی ۴۵	۴۳	آنتروپی رنگ قرمز ۴۵	۸۰	همبستگی رنگ سبز ۴۵
۷	ماکزیم احتمال رنگ آبی ۹۰	۴۴	آنتروپی رنگ قرمز ۹۰	۸۱	همبستگی رنگ سبز ۹۰
۸	ماکزیم احتمال رنگ آبی ۱۳۵	۴۵	آنتروپی رنگ قرمز ۱۳۵	۸۲	همبستگی رنگ سبز ۱۳۵
۹	دامنه تغییرات رنگ قرمز ۰	۴۶	آنتروپی رنگ سبز ۰	۸۳	همبستگی رنگ آبی ۰
۱۰	دامنه تغییرات رنگ قرمز ۴۵	۴۷	آنتروپی رنگ سبز ۴۵	۸۴	همبستگی رنگ آبی ۴۵
۱۱	دامنه تغییرات رنگ قرمز ۹۰	۴۸	آنتروپی رنگ سبز ۹۰	۸۵	همبستگی رنگ آبی ۹۰
۱۲	دامنه تغییرات رنگ قرمز ۱۳۵	۴۹	آنتروپی رنگ سبز ۱۳۵	۸۶	همبستگی رنگ آبی ۱۳۵
۱۳	دامنه تغییرات رنگ سبز ۰	۵۰	آنتروپی رنگ آبی ۰	۸۷	همبستگی رنگ قرمز ۰
۱۴	دامنه تغییرات رنگ سبز ۴۵	۵۱	آنتروپی رنگ آبی ۴۵	۸۸	همبستگی رنگ قرمز ۴۵
۱۵	دامنه تغییرات رنگ سبز ۹۰	۵۲	آنتروپی رنگ آبی ۹۰	۸۹	همبستگی رنگ قرمز ۹۰
۱۶	دامنه تغییرات رنگ سبز ۱۳۵	۵۳	آنتروپی رنگ آبی ۱۳۵	۹۰	همبستگی رنگ قرمز ۱۳۵
۱۷	دامنه تغییرات رنگ آبی ۰	۵۴	میانگین رنگ قرمز ۰	۹۱	همبستگی رنگ سبز ۰
۱۸	دامنه تغییرات رنگ آبی ۴۵	۵۵	میانگین رنگ قرمز ۴۵	۹۲	همبستگی رنگ سبز ۴۵
۱۹	دامنه تغییرات رنگ آبی ۹۰	۵۶	میانگین رنگ قرمز ۹۰	۹۳	همبستگی رنگ سبز ۹۰
۲۰	دامنه تغییرات رنگ آبی ۱۳۵	۵۷	میانگین رنگ قرمز ۱۳۵	۹۴	همبستگی رنگ سبز ۱۳۵
۲۱	یکنواختی رنگ قرمز ۰	۵۸	میانگین رنگ سبز ۰	۹۵	همبستگی رنگ آبی ۰
۲۲	یکنواختی رنگ قرمز ۴۵	۵۹	میانگین رنگ سبز ۴۵	۹۶	همبستگی رنگ آبی ۴۵
۲۳	یکنواختی رنگ قرمز ۹۰	۶۰	میانگین رنگ سبز ۹۰	۹۷	همبستگی رنگ آبی ۹۰
۲۴	یکنواختی رنگ قرمز ۱۳۵	۶۱	میانگین رنگ سبز ۱۳۵	۹۸	همبستگی رنگ آبی ۱۳۵
۲۵	یکنواختی رنگ سبز ۰	۶۲	میانگین رنگ آبی ۰	۹۹	انرژی رنگ قرمز ۰
۲۶	یکنواختی رنگ سبز ۴۵	۶۳	میانگین رنگ آبی ۴۵	۱۰۰	انرژی رنگ قرمز ۴۵
۲۷	یکنواختی رنگ سبز ۹۰	۶۴	میانگین رنگ آبی ۹۰	۱۰۱	انرژی رنگ قرمز ۹۰
۲۸	یکنواختی رنگ سبز ۱۳۵	۶۵	میانگین رنگ آبی ۱۳۵	۱۰۲	انرژی رنگ قرمز ۱۳۵
۲۹	یکنواختی رنگ آبی ۰	۶۶	ماکزیم احتمال رنگ قرمز ۰	۱۰۳	انرژی رنگ سبز ۰
۳۰	یکنواختی رنگ آبی ۴۵	۶۷	ماکزیم احتمال رنگ قرمز ۴۵	۱۰۴	انرژی رنگ سبز ۴۵
۳۱	یکنواختی رنگ آبی ۹۰	۶۸	ماکزیم احتمال رنگ قرمز ۹۰	۱۰۵	انرژی رنگ سبز ۹۰
۳۲	یکنواختی رنگ آبی ۱۳۵	۶۹	ماکزیم احتمال رنگ قرمز ۱۳۵	۱۰۶	انرژی رنگ سبز ۱۳۵
۳۳	میانگین رنگ قرمز	۷۰	میانگین شدت (HSI)	۱۰۷	واریانس اشباع (HSI)
۳۴	میانگین رنگ سبز	۷۱	میانگین اشباع (HSV)	۱۰۸	واریانس اشباع (HSV)
۳۵	میانگین رنگ آبی	۷۲	میانگین مقدار رنگ	۱۰۹	انحراف معیار مقدار رنگ
۳۶	میانگین اصل رنگ (HSI)	۷۳	واریانس رنگ قرمز	۱۱۰	انحراف معیار اصل رنگ (HSV)
۳۷	میانگین اشباع (HSI)	۷۴	واریانس رنگ سبز		


ارزیابی شبکه با کاهش ویژگی‌های ترکیبی نمونه‌ها

نتایج این بخش نشان داد که ۱۱۰ ویژگی ترکیبی انتخاب شده به عنوان ورودی به شبکه داده شد. همان طور که در جدول ۱۱ مشاهده می‌شود با توجه به انواع مختلفی از توابع انتقال که برای لایه پنهان در نظر گرفته شد با استفاده از تابع تانژانت سیگموئید در لایه خروجی و تابع تانژانت سیگموئید در لایه پنهان با توپولوژی ۹-۶-۱۱۰ بهترین ساختار در تابع یادگیری لونبرگ مارکوارت با بیشترین میانگین دقت طبقه بندی برابر ۹۴/۶۷ درصد بدست آمد (جدول ۱۱).

جدول ۱۱: بررسی تاثیر توابع انتقال مختلف لایه پنهان و خروجی بر میانگین دقت تشخیص نمونه‌ها (۱۱۰ ویژگی ترکیبی)

توابع انتقال (لایه پنهان-لایه خروجی)	توپولوژی	تعداد چرخه آموزش	میانگین دقت طبقه بندی (درصد)
تانژانت سیگموئید - خطی	۹-۲۴-۱۱۰	۴۸	۸۹/۸۲
تانژانت سیگموئید - تانژانت سیگموئید	۹-۶-۱۱۰	۲۵	۹۴/۶۷
لگاریتم سیگموئید - تانژانت سیگموئید	۹-۲۲-۱۱۰	۴۲	۸۹/۴۷
لگاریتم سیگموئید - خطی	۹-۱۲-۱۱۰	۳۰	۸۷/۳۹

پس از ارزیابی شبکه پس انتشار بیشترین میانگین دقت طبقه بندی برای نه نمونه‌های زیره تهیه شده از بازار (پنج نمونه زیره پارسی و چهار نمونه زیره تقلبی) با استفاده از کلیه ویژگی‌های بافتی برابر ۹۵/۸۶ درصد حاصل شد. (پوررضا، ۱۳۹۰) از ویژگی بافتی برای شناسایی ۹ رقم گندم ایرانی استفاده کرد و بالاترین دقت شناسایی را با استفاده از کلیه ویژگی‌های بافتی بدست آورد. همچنین (Zapotoczný, 2011) از دسته بندی تحلیل تصویر بر مبنای ویژگی‌های بافتی و شبکه‌های عصبی برای تفکیک ارقام گندم استفاده کرد. میانگین دقت طبقه بندی ۱۰۰ درصد را برای ۱۱ رقم گندم بدست آورد که با نتایج این تحقیق مطابقت دارد. نتایج نشان داد که به دلیل شباهت‌های رنگی نزدیک نمونه‌ها، ویژگی‌های بافتی میانگین دقت طبقه بندی بهتری نسبت به ویژگی‌های رنگی داشتند. همانطور که شکل ۸ نشان می‌دهد با کاهش تعداد ویژگی‌ها از ۳۶ به ۱۳ ویژگی رنگی، میانگین دقت طبقه بندی افزایش داشت است. (گلپور و همکاران، ۲۰۱۴) نیز با کاهش تعداد ویژگی‌های رنگی به دقت طبقه بندی بالاتر برای شناسایی ارقام شلتوک برنج دست یافتند که با نتایج این تحقیق مطابقت داشت. مقایسه دقت طبقه بندی نمونه‌ها با استفاده از ویژگی‌های بافتی و ترکیبی نشان داد که با کاهش تعداد ویژگی‌ها از ۱۰۸ به ۹۶ ویژگی بافتی و ۱۴۴ به ۱۱۰ ویژگی ترکیبی (بافتی - رنگی) دقت طبقه بندی کاهش یافت که به دلیل اثر متقابل ویژگی‌ها حذف شده، بر ویژگی‌های انتخاب شده می‌باشد. (فیاضی و همکاران، ۱۳۹۲) به این نتیجه رسیدند که کاهش ویژگی‌های بافتی در شناسایی رقم طارم باعث کاهش دقت طبقه بندی می‌گردد که با نتایج این تحقیق همخوانی دارد. در مجموع تشخیص تقلبی بودن زیره‌ها با استفاده از تکنیک ماشین بینایی و شبکه عصبی مصنوعی دارای دقتی بالاتر از نتایج به دست آمده از تحقیق صفری امیری و همکاران (۱۳۹۷) که به تشخیص زیره های کوهی تقلبی با استفاده از ماشین بویایی پرداختند، می باشد.



شکل ۸: مقایسه میانگین دقت طبقه بندی نمونه‌ها با استفاده از ویژگی‌های ترکیبی (بافتی-رنگی) با ویژگی‌های بافتی و رنگی به صورت مجزا

ماتریس اغتشاش

ماتریس اغتشاش یکی از روش‌هایی است که دقت طبقه بندی هر نمونه را به صورت درصدی و مجزا نشان می‌دهد. در ماتریس اغتشاش نمایش داده شده در شکل ۹ اعداد درج شده در سلول‌های قطری نشانگر تعداد نمونه‌هایی است که به درستی طبقه بندی شدند. آخرین سلول در سمت راست و پایین هر ماتریس نمایانگر درصد کل نمونه‌هایی است که به طور صحیح دسته بندی شده‌اند. اعداد درون سلول‌های هر ردیف از ماتریس، نشان دهنده نمونه‌هایی است که به عنوان یک رقم شناسایی شده‌اند. ستون آخر در هر ماتریس نشان دهنده درصد دسته بندی صحیح (به رنگ سبز) و درصد دسته بندی غلط (به رنگ قرمز) در هر رقم است که در شکل ۹، درصد طبقه بندی مربوط به داده های حاصل از تست هریک از نمونه‌ها، دیده می شود. به طوری که درصد دقت طبقه بندی برای ردیف اول تا نهم که به ترتیب پنج نمونه زیره پارسی و چهار نمونه زیره تقلبی می‌باشند به ترتیب: ۸۸/۹، ۱۰۰، ۱۰۰، ۱۰۰، ۱۰۰، ۱۰۰ و ۱۰۰ درصد بدست آمد.

test set Confusion Matrix

Output Class \ Target Class	1	2	3	4	5	6	7	8	9	
1	8 11.6%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 1.4%	0 0.0%	88.9% 11.1%
2	0 0.0%	7 10.1%	0 0.0%	0 0.0%	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%	8 11.6%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
4	0 0.0%	0 0.0%	0 0.0%	6 8.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
5	0 0.0%	0 0.0%	1 1.4%	1 1.4%	8 11.6%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	80.0% 20.0%
6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	7 10.1%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
7	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	8 11.6%	0 0.0%	0 0.0%	100% 0.0%
8	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	6 8.7%	0 0.0%	100% 0.0%
9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	8 11.6%	100% 0.0%
	100% 0.0%	100% 0.0%	88.9% 11.1%	85.7% 14.3%	100% 0.0%	100% 0.0%	100% 0.0%	85.7% 14.3%	100% 0.0%	95.7% 4.3%

شکل ۹: ماتریس اغتشاش نمونه های زیره

نتیجه گیری

در مطالعه حاضر، ترکیب پردازش تصویر و شبکه های عصبی مصنوعی در جهت تشخیص و طبقه بندی زیره پارسی اصل و تقلبی مورد ارزیابی قرار گرفت. در این تحقیق، پنج نمونه زیره پارسی و چهار نمونه زیره تقلبی تهیه شده از شهر کرمان مورد استفاده قرار گرفت. با استفاده از شبکه های عصبی پس انتشار با الگوریتم آموزشی لونبرگ مارکوارت و ارزیابی یک لایه پنهان با نرون های مختلف، بهترین میانگین دقت طبقه بندی بر اساس ویژگی های رنگی، بافتی و ترکیبی به ترتیب ۹۳/۵۱، ۹۵/۸۶ و ۹۵/۵۹ درصد بدست آمد که بیشترین دقت مربوط به ویژگی های بافتی با دقت ۹۵/۸۶ درصد بود. همچنین پس از انتخاب به کمک روش تحلیل عاملی، بهترین میانگین دقت طبقه بندی با استفاده از ویژگی های رنگی، بافتی و ترکیبی نمونه ها به ترتیب ۹۳/۸۱، ۹۵/۶۵ و ۹۴/۶۷ درصد بدست آمد که میانگین دقت طبقه بندی با کاهش ویژگی های رنگی افزایش یافت اما با کاهش ویژگی های بافتی و ترکیبی میانگین دقت طبقه بندی کاهش یافت. با این حال، با پیاده سازی اطلاعات بدست آمده از این تحقیق و همچنین با استفاده ویژگی های مورفولوژی و ارزیابی شبکه های عصبی دیگر در تحقیقات آینده می توان در جهت طراحی دستگاه هوشمند در صنعت غذا برای شناسایی زیره اصل از تقلبی، گام موثری را برداشت. نتایج این تحقیق می تواند در بازارهای مختلف برای تشخیص تقلب در زیره سیاه پارسی به کار گرفته شود. با استفاده از فناوری پردازش تصویر و شبکه های عصبی مصنوعی، امکان شناسایی سریع و دقیق زیره های اصیل از تقلبی فراهم می شود که این امر به نظارت بر کیفیت محصولات و جلوگیری از تقلب در بازار کمک می کند. علاوه بر این، نتایج این تحقیق می توانند به گسترش این تکنیک ها به سایر محصولات غذایی نیز کمک کنند. به ویژه در صنایعی که کیفیت و اصالت محصولات اهمیت زیادی دارد، مانند ادویه ها، خشکبار، و مواد غذایی فرآوری شده، استفاده از این روش ها می تواند به ارتقاء کیفیت، کاهش تقلب، و افزایش اعتماد مصرف کنندگان منجر شود.

سپاسگزاری

نویسندگان این مقاله، مراتب تشکر و قدردانی خود را از دانشگاه جیرفت به جهت حمایت های مادی و معنوی از این پژوهش اعلام می دارند.

منابع

- اکبری آدرگانی، بهروز، محمدزاده مقدم، مرتضی، کریمی نوقابی، مهدی، محمدپور، مجتبی، خلیلیان موحد، محمد. (۱۴۰۰). استفاده از بینایی کامپیوتر در تشخیص غیرمخرب زعفران واقعی و تقلبی. نشریه زراعت و فناوری زعفران، ۹ (۴).
- انورخواه، سپیده. (۱۳۹۱). شناسایی بذر گونه های گیاهان دارویی با استفاده از روش های پیشرفته. پایان نامه کارشناسی ارشد زراعت-اکولوژی گیاهان زراعی، دانشکده کشاورزی، دانشگاه فردوسی مشهد.
- چاکرالاحسینی، محمد. و اسمعیلی زینی، علی محمد (۱۳۹۶). ارائه روشی برای تشخیص تقلبی بودن محصول کلاله زعفران با استفاده از پردازش

تصویر. پایان‌نامه کارشناسی ارشد دانشکده فنی. مؤسسه‌های آموزش عالی غیردولتی-غیرانتفاعی - دانشگاه علم و هنر یزد.

پوررضا، علی‌رضا. (۱۳۹۰). تعیین رقم و تشخیص ناخالصی در بذر گندم با استفاده از پردازش تصویر. پایان‌نامه کارشناسی ارشد ماشین‌های کشاورزی، دانشکده کشاورزی، دانشگاه فردوسی مشهد.

دولتی، مجید. (۱۳۹۲). تشخیص کیفیت و درجه‌بندی ماهی سفید با تلفیق تکنیک‌های ماشین بینایی و شبکه‌های عصبی مصنوعی. پایان‌نامه دکتری، رشته مهندسی مکانیک ماشین‌های کشاورزی، دانشکده مهندسی و فناوری کشاورزی، پردیس کشاورزی و منابع طبیعی، دانشگاه تهران.

دولتی، مجید؛ نکویی، عاطفه و گلپور، ایمان. (۱۳۹۵). شناسایی و طبقه‌بندی توده‌های زیره پارس (Bunium persicum Boiss) با روش پردازش تصویر در ترکیب با شبکه‌های عصبی مصنوعی. پژوهش‌های مکانیک ماشین‌های کشاورزی، ۵ (۱)، ۳۷-۴۶.

شریف‌زاده، سردار. (۱۳۸۲). بررسی تقلبات در زیره سیاه گیاه (Bunium persicum). پایان‌نامه دکتری، رشته داروسازی، دانشکده داروسازی، دانشگاه تهران.

فیاضی، سعیده؛ عباسپور فرد، محمد حسین؛ منجمی، سید امیر حسن؛ صدرنیا، حسن و روحانی، عباس. (۱۳۹۲). شناسایی و تفکیک سه رقم برنج ایرانی در توده‌های مخلوط‌شده با استفاده از ویژگی‌های بافتی و شبکه عصبی LVQ. نشریه مکانیزاسیون کشاورزی، ۱۱ (۱)، ۳۵-۴۳.

گلپور، ایمان؛ امیری پریان، جعفر؛ امیری چایجان، رضا و خزائی، جواد. (۱۳۹۴). تشخیص ارقام شلتوک، برنج قهوه‌ای و سفید براساس ویژگی‌های بافتی تصویر و شبکه عصبی مصنوعی. نشریه ماشین‌های کشاورزی، ۵ (۱)، ۷۳-۸۱.

گلپور، ایمان. (۱۳۹۱). پیش‌بینی، تشخیص و بررسی سینتیک خشک کردن ارقام برنج با استفاده از پردازش تصویر و شبکه‌های عصبی مصنوعی. پایان‌نامه کارشناسی ارشد ماشین‌های کشاورزی، دانشکده کشاورزی، دانشگاه بوعلی سینا.

صفری امیری، زهرا؛ قاسمی ورنامخواستی، مهدی؛ توحیدی، محتسبی، سید سعید و دولتی، مجید. (۱۳۹۷). استفاده از سامانه ماشین بویایی به‌منظور تشخیص تقلب در زیره کوهی. فناوری‌های جدید در صنعت غذا، ۵ (۱)، ۵۲۷-۵۴۱.

موسوی‌راد، سید جلال الدین. (۱۳۹۲). طراحی یک سیستم خبره برای تشخیص اصالت ارقام برنج با استفاده از ترکیب ویژگی‌های بافتی تصاویر توده‌ی برنج. مجله ماشین بینایی و پردازش تصویر، ۱۱ (۱)، ۱۱-۱۸.

REFERENCES

- Akbari Adergani, B., MohammadzadehMoghadam, M., KarimiNoghabi, M., Mohammadpour, M., KhalilianMovahhed, M.2022. Application of Computer Vision on Non-Destructive Detection of the Authentic and Adulterated Saffron. *Saffron Agronomy & Technology*, 9(4): 409-429.
- Agnihotri, V., Shashni, S., & Tripathi, M. (2024). Morphological, phytochemical and pharmacological properties of *Carum carvi* (caraway) and *Bunium persicum* (black caraway) seeds: A review. *Journal of Food Engineering and Technology*, 13(1), 25-31.
- Anvarkhah, S. (2012). Identification of medicinal plant seeds using advanced methods (Master's thesis, Faculty of Agriculture, Ferdowsi University of Mashhad). (in Persian)
- Azimzadeh, M., & Amiri, R. (2012). Genetic diversity of Iranian *Bunium persicum* germplasm by morphological markers and essential oil components. *Journal of Medicinal Plants Research*, 6(7), 1119-1129.
- Bansal, S., Sharma, K., Gautam, V., Lone, A. A., Malhotra, E. V., Kumar, S., & Singh, R. (2023). A comprehensive review of *Bunium persicum*: A valuable medicinal spice. *Food Reviews International*, 39(2), 1184-1202.
- Burdock, G. A. (2022). Assessment of black cumin (*Nigella sativa* L.) as a food ingredient and putative therapeutic agent. *Regulatory Toxicology and Pharmacology*, 128, 105088.
- Chaker Al-Hosseini, M. & Esmaeili Zeini, A. M., (2017). Presenting a method for detecting the counterfeit of saffron stigma product using image processing. Master's thesis, Faculty of Technology. Yazd University of Science and Art.
- Choudhary, P., Seth, A., & Lata Verma, K. (2022). Identification of adulterants and contaminants in black pepper, cumin, fennel, coriander, and turmeric using GC-MS technique for forensic investigation. *Journal of Food Science and Industry Research*, 18(3), 31-51. (In Persian)
- Dowlati, M. (2013). Quality detection and grading of *Rutilus frisii kutum* using a combination of machine vision techniques and artificial neural networks (Doctoral dissertation, Faculty of Agricultural Engineering and Technology, University of Tehran). (in Persian)
- Dowlati, M., Nekouei, A., & Golpour, I. (2016). Identification and classification of Persian cumin (*Bunium persicum* Boiss) populations using image processing combined with artificial neural networks. *Agricultural Machinery Research*, 5(1), 37-46. (in Persian)
- Dowlati, M., Mohtasebi, S. S., & de la Guardia, M. (2012). Application of machine-vision techniques to fish-



- quality assessment. *Trends in Analytical Chemistry*, 40, 168-179.
- Dowlati, M., Mohtasebi, S. S., Omid, M., Razavi, S. H., Jamzad, M., & de la Guardia, M. (2013). Freshness assessment of gilthead sea bream (*Sparus aurata*) by machine vision based on gill and eye color changes. *Journal of Food Engineering*, 119(2), 277-287.
- Fayazi, S., Abbaspour Fard, M. H., Monjami, S. A. H., Sadrnia, H., & Rouhani, A. (2013). Identification and differentiation of three Iranian rice varieties in mixed populations using texture features and LVQ neural network. *Agricultural Mechanization Journal*, 1(1), 35-43. (in Persian)
- Golpour, A. (2012). Prediction, detection, and kinetic study of rice drying varieties using image processing and artificial neural networks (Master's thesis, Faculty of Agriculture, Bu-Ali Sina University). (in Persian)
- Golpour, A., Amiri Paryan, J., Amiri Chayjan, R., & Khazaei, J. (2015). Identification of paddy, brown, and white rice varieties based on texture features and artificial neural network. *Agricultural Machinery Journal*, 5(1), 73-81. (in Persian)
- Golpour, I., Amiri Parian, J., & Amiri Chayjan, R. (2014). Identification and classification of bulk paddy, brown, and white rice cultivars with colour features extraction using image analysis and neural network. *Czech Journal of Food Science*, 32(3), 280-287.
- Heistev, R. M. (1998). *The ANN book*. Boston.
- Long, F., Zhang, H., & Feng, D. D. (2003). Fundamentals of content-based image retrieval. In *Multimedia Information Retrieval and Management - Technological Fundamentals and Applications* (pp. 1-26). Springer-Verlag.
- Mousavi Rad, S. J. (2013). Design of an expert system for rice variety authentication using a combination of texture features in rice bulk images. *Journal of Machine Vision and Image Processing*, 1(1), 11-18. (in Persian)
- Navidshad, B., Dadashi Orang, A., & Royan, M. (2024). The potential of black cumin (*Nigella sativa*) as a natural feed additive for poultry: An update. *World's Poultry Science Journal*, 1-15.
- Pourreza, A. R. (2011). Determination of variety and impurity detection in wheat seeds using image processing (Master's thesis, Faculty of Agriculture, Ferdowsi University of Mashhad). (in Persian)
- Razavi, S. M., Bostan, A., & Rahbari, R. (2010). Computer image analysis and physico-mechanical properties of wild sage seed (*Salvia macrosiphon*). *International Journal of Food Properties*, 13(2), 308-316.
- Safari Amiri, Gh., Ghasemi Varnamkhasti, T., Mohtasebi, S. S., & Dolati, M. (2018). Application of an electronic nose system for fraud detection in wild cumin. *New Technologies in Food Industry*, 5(1), 527-541. (in Persian)
- Saldana, E., Siche, R., Huamán, R., Luján, M., Castro, W., & Quevedo, R. (2013). Computer vision system in real-time for color determination on flat surface food. *Scientia Agropecuaria*, 4(1), 55-63.
- Sharifzadeh, Y. (2003). Investigation of fraud in black cumin (*Bunium persicum*) (Doctoral dissertation, Faculty of Pharmacy, University of Tehran). (in Persian)
- Zapotoczny, P. (2011). Discrimination of wheat grain varieties using image analysis and neural networks. Part I. Single kernel texture. *Journal of Cereal Science*, 54(1), 60-68.
- Zheng, C., Sun, D. W., & Zheng, L. (2006). Recent developments and applications of image features for food quality evaluation and inspection – A review. *Trends in Food Science & Technology*, 17(12), 642-655.