

بازشناسی انواع پسته بر پایه بینایی ماشین، فیلترهای گابور و الگوریتم وراثتی

چکیده

در این پژوهش، روشی نوین و کارآمد برای بازشناسی انواع پسته با بهره‌گیری از فیلترهای گابور و الگوریتم وراثتی ارائه شده است که هدف آن افزایش سرعت و دقت در فرآیند طبقه‌بندی می‌باشد. برخلاف روش‌های پیشین که عمدتاً بر پردازش جداگانه دانه‌های منفرد پسته تکیه داشته‌اند و از این رو با وجود دقت مناسب، از نظر زمانی و محاسباتی پرهزینه بوده‌اند، روش پیشنهادی از پردازش کل‌نگر تصاویر مجموعه‌ای از پسته‌ها بهره می‌گیرد و بدین وسیله فرآیند بازشناسی را تسریع و بهینه‌سازی می‌کند. در این چارچوب، ابتدا ویژگی‌های بافتی و شکلی برجسته از تصاویر با استفاده از فیلترهای گابور استخراج می‌گردد. سپس، الگوریتم وراثتی به منظور انتخاب ویژگی‌های بهینه و حذف داده‌های زائد به کار گرفته می‌شود. ویژگی‌های منتخب نهایتاً به کمک همسایه نزدیک‌ترین (KNN) منتقل شده تا طبقه‌بندی نهایی صورت گیرد. ارزیابی روش پیشنهادی بر روی پایگاه داده‌ای شامل ۱۰۰۰ زیرتصویر متعلق به پنج نوع رایج پسته (اکبری، احمدآقایی، کله‌قوچی، فندق‌چی و بادامی) انجام شد و نتایج حاکی از نرخ طبقه‌بندی صحیح ۹۹/۵ درصد می‌باشد. در مقایسه با روش‌های یادگیری عمیق، روش پیشنهادی با وجود عدم نیاز به آموزش عمیق و منابع پردازشی سنگین، دقتی قابل رقابت با آن را ارائه داده و سرعت پیاده‌سازی بسیار بالاتری دارد. این ویژگی‌ها روش پیشنهادی را به گزینه‌ای مناسب برای کاربردهای صنعتی، به‌ویژه در خطوط تولید و بسته‌بندی هوشمند پسته بدل می‌سازد و گامی مؤثر در جهت خودکارسازی فرآیندهای کشاورزی و کاهش هزینه‌های زمانی و انسانی تلقی می‌شود.

کلیدواژه‌ها: الگوریتم وراثتی، بازشناسی پسته، طبقه‌بندی تصویر، همسایه نزدیک‌ترین، فیلتر گابور.

Recognition of Pistachio Varieties Based on Machine Vision, Gabor Filters, and Genetic Algorithm

ABSTRACT

This study proposes an efficient and novel method for recognizing pistachio varieties by leveraging Gabor filters for feature extraction and a genetic algorithm for feature selection, aiming to enhance classification accuracy and speed. Unlike conventional approaches that focus on individual processing of pistachio kernels—which, despite high accuracy, are time-consuming and computationally demanding—the proposed method employs holistic processing of images containing multiple pistachios, thereby significantly accelerating the recognition process. Key textural and shape-based features are initially extracted using Gabor filters. Subsequently, the genetic algorithm is applied to select optimal features and reduce data redundancy. The refined feature set is then classified using the K-Nearest Neighbor (KNN) algorithm. Experiments conducted on a dataset of 1,000 sub-images covering five common pistachio types (Akbari, Ahmad Aghaei, Kaleh Ghouchi, Fandoghi, and Badami) yielded an average classification accuracy of 99.5%. In comparison with deep learning models, the proposed method demonstrates competitive performance while requiring no extensive training phase or high computational resources. This results in a faster and more resource-efficient implementation, making it particularly suitable for industrial applications, especially in automated pistachio processing and packaging systems. The proposed method contributes to the automation of agricultural workflows, reducing both processing time and labor costs, and offers a practical solution for real-time classification in resource-constrained environments.

Keywords: Gabor Filter, Genetic Algorithm, Image Classification, K-Nearest Neighbor Classifier (KNN), Pistachio Recognition.

Introduction

Pistachio is one of Iran's most significant non-oil export products, contributing substantially to the country's economy. Iran ranks among the top global pistachio producers, with several varieties, including Ahmad Aghaei, Fandoghi, Akbari, Badami, and Kalleh Chouchi, dominating the market. Given the economic and industrial importance of pistachios, accurate classification of different types is crucial for improving quality control, optimizing processing efficiency, and minimizing waste. Traditional classification methods face challenges in identifying pistachio types with high accuracy. Therefore, leveraging advanced image processing, deep learning, and machine vision techniques has become a promising research direction. Among various texture analysis techniques, Gabor filters have proven effective in extracting meaningful patterns from images, offering a computationally efficient alternative to deep learning-based approaches.

Methods

This study proposes a machine vision-based method for pistachio classification using texture analysis. The approach consists of several steps:

1. Image Acquisition & Preprocessing: High-resolution color images of bulk pistachios (3498×2542 pixels) were acquired using a scanner at 300 dpi. Images were converted to grayscale, and sub-images (512×512 pixels) were extracted for analysis.
2. Feature Extraction: A Gabor filter bank with five scales and four orientations (total of 20 filters) was applied to the sub-images. The mean and standard deviation of filtered images were computed, resulting in a 40-dimensional feature vector.
3. Feature Selection: A genetic algorithm (GA) was employed to optimize feature selection, reducing the initial 40 features to 18 while preserving classification performance.
4. Classification: The selected features were input to a K-nearest neighbor (KNN) classifier using the χ^2 distance metric. A dataset comprising 1000 sub-images from five pistachio varieties was used for evaluation.

Results

The proposed method achieved an overall classification accuracy of 99.5%, significantly outperforming a reference method (Shamsi-Goshki et al., 2013) with 94.8% accuracy. The genetic algorithm effectively reduced computational complexity while maintaining classification performance. Performance metrics, including precision, recall, and F1-score,

confirmed the superiority of the proposed approach over previous methods. Additionally, the proposed bulk classification approach is more suitable for industrial applications compared to conventional methods that classify individual pistachios.

Conclusions

This study demonstrates the effectiveness of combining Gabor filters, genetic algorithms, and KNN classification for pistachio type recognition. The approach achieves high accuracy with significantly lower computational costs than deep learning models, making it suitable for large-scale industrial applications. Future research can explore integrating deep learning with texture-based methods for further improvements.

Author Contributions

Conceptualization, methodology, software, validation, formal analysis, investigation, resources, data curation, writing—original draft preparation, writing—review and editing, visualization, supervision, and project administration by Asma Shams-Kermani. Author has read and agreed to the published version of the manuscript.

Data Availability Statement

Data available on request from the authors

Acknowledgments

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

Ethical considerations

Ethical approval was not required for this study as it did not involve human or animal participants, or any sensitive personal data.

Conflict of interest

The author declares no conflict of interest.

Formatted: Font: (Default) Times New Roman, 12 pt, Bold, Font color: Auto, Complex Script Font: B Lotus, 12 pt, Bold, Pattern: Clear

Formatted: Indent: First line: 0.19"

Formatted: Indent: First line: 0"

Formatted: Font: (Default) Times New Roman, 12 pt, Font color: Auto, Complex Script Font: B Lotus, 12 pt

Formatted: Font: (Default) Times New Roman, 12 pt, Bold, Font color: Auto, Complex Script Font: B Lotus, 12 pt, Bold, Pattern: Clear

Formatted: Font: Bold, Complex Script Font: Bold

Formatted: Font: (Default) Times New Roman, 12 pt, Font color: Auto, Complex Script Font: B Lotus, 12 pt, Pattern: Clear

Formatted: Indent: First line: 0"

Formatted: Font: (Default) Times New Roman, 12 pt, Bold, Font color: Auto, Complex Script Font: B Lotus, 12 pt, Bold, Pattern: Clear

Formatted: Indent: First line: 0.19"

Formatted: Font: Bold, Complex Script Font: Bold

Formatted: Font: 12 pt, Not Bold, Complex Script Font: B Lotus, 12 pt, Not Bold

Formatted: Font: 12 pt, Not Bold, Complex Script Font: B Lotus, 12 pt, Not Bold

Formatted: Indent: First line: 0"

Formatted: Font: (Default) Times New Roman, 12 pt, Bold, Font color: Auto, Complex Script Font: B Lotus, 12 pt, Bold, Pattern: Clear

Formatted: Indent: First line: 0.19"

Formatted: Font: Bold, Complex Script Font: Bold

Formatted: Font: (Default) Times New Roman, 12 pt, Font color: Auto, Complex Script Font: B Lotus, 12 pt, Pattern: Clear

Formatted: Indent: First line: 0"

مقدمه

پسته به عنوان یکی از مهم‌ترین محصولات صادراتی غیرنفتی، نقش به سزایی در اقتصاد ایران ایفا می‌کند. ایران با تولید هزاران تن پسته در سال، یکی از پیشروترین عرضه‌کنندگان این محصول در بازارهای جهانی است. انواع مختلفی از پسته، مانند احمدآقایی، فندق، اکبری، بادامی و کله‌قوچی، بخش قابل توجهی از این بازار را تشکیل می‌دهند. به دلیل اهمیت این محصول، بازشناسی دقیق انواع مختلف پسته و طبقه‌بندی آن‌ها به منظور بهبود کیفیت، افزایش دقت در فرآیندها، ارتقاء ارزش افزوده و کاهش ضایعات، بسیار حیاتی است. با توجه به چالش‌های موجود در تشخیص کیفیت و انواع پسته، استفاده از روش‌های پیشرفته پردازش تصویر، یادگیری عمیق و بینایی ماشین برای بازشناسی پسته مورد توجه قرار گرفته است (امام و همکاران، ۱۳۹۸؛ عبدالله‌نژاد باروق و همکاران، ۱۳۹۸).

بافت که توصیف‌کننده ویژگی سطح است، نقش بسیار مهمی را در بسیاری از کاربردهای پردازش تصویر و بینایی ماشین ایفا می‌کند. علاوه بر روش‌های یادگیری عمیق و بینایی ماشین، روش‌های تحلیل بافت تصویر نیز سهم قابل توجهی در بهبود فرآیند طبقه‌بندی پسته داشته‌اند. این روش‌ها با استخراج ویژگی‌های دقیق مرتبط با ساختار و بافت تصاویر، امکان طبقه‌بندی دقیق‌تر و کارآمدتر را فراهم کرده‌اند. تحلیل بافت در سایر محصولات کشاورزی نیز استفاده شده است. در مرجع (Indra et al., 2021)، فرایند تحلیل بافت با استفاده از روش ماتریس هم‌رخدادی سطح خاکستری بر روی تصاویر برنج انجام شده است، به گونه‌ای که تصاویر برنج به صورت گروهی (و نه به صورت دانه‌ای) تحلیل شده‌اند. نتایج این تحقیق برای طبقه‌بندی بافت تصویر برنج سالم و آسیب‌دیده مورد استفاده قرار گرفته است.

شکل ۱ چند نمونه از تصاویر بافت را نشان می‌دهد. در ردیف اول شکل ۱، سه تصویر نمونه از بافت‌های مختلف از پایگاه داده پروداتز^۱ نشان داده شده است. این پایگاه داده یکی از منابع استاندارد در تحلیل بافت در پردازش تصویر محسوب می‌شود. ردیف دوم سمت چپ تصویر مجموعه‌ای از دانه‌های برنج است که در مرجع (Indra et al., 2021) به عنوان بافت در نظر گرفته شده است و تصویر سمت راست مجموعه‌ای از دانه‌های پسته را نشان می‌دهد که به دلیل ساختار منظم و الگوی تکرارشونده، مشابه تصاویر مذکور، می‌تواند به عنوان یک تصویر بافت در نظر گرفته شود.



شکل ۱. چند تصویر نمونه از بافت، ردیف اول: چند نمونه تصویر بافت استخراج شده از پایگاه داده پروداتز. ردیف دوم: تصویر مجموعه‌ای از دانه‌های برنج مرجع (Indra et al., 2021) و تصویر مجموعه‌ای از دانه‌های پسته.

¹Brodatz

یکی از ابزارهای مؤثر در زمینه تحلیل بافت، فیلترهای گابور هستند که برای تحلیل الگوهای متناوب و ویژگی‌های بافتی تصاویر مورد استفاده قرار می‌گیرد. این فیلترها با شناسایی بسامدها و جهت‌های مختلف در تصویر، ویژگی‌های معناداری را برای طبقه‌بندی فراهم می‌کنند. مطالعات نشان داده‌اند که این روش به‌ویژه در شناسایی تفاوت‌های ظریف میان گونه‌های مختلف پسته مفید است (شمسی گوشکی و همکاران، ۱۳۹۱). این رویکردها علاوه بر دقت بالا، به دلیل کاهش پیچیدگی محاسباتی، گزینه‌ای مناسب برای کاربردهای صنعتی هستند.

هدف این تحقیق، توسعه روشی برای تشخیص نوع پسته با استفاده از بینایی ماشین است که از ویژگی‌های بافت تصاویر پسته برای طبقه‌بندی انواع آن بهره می‌برد. این روش با استفاده از فیلترهای گابور ویژگی‌های بافت تصاویر پسته را استخراج کرده و از الگوریتم وراثتی برای انتخاب ویژگی‌های مناسب استفاده می‌کند. به منظور ارزیابی روش پیشنهادی، این روش روی مجموعه‌ای شامل ۱۰۰۰ تصویر از ۵ نوع متداول پسته آزمایش شده است و برای طبقه‌بندی از طبقه‌بند k همسایه نزدیک‌تر استفاده شده است.

اکثر روش‌های ارائه شده در مقالات که در بخش بعد مورد بررسی قرار می‌گیرند از پردازش تک تک دانه‌های پسته استفاده می‌کنند. در این روش‌ها برای دسته‌بندی پسته از یک دانه‌ی آن، تصویر تهیه کرده و پردازش می‌کنند. اما از آنجا که نوع پسته یکی از معیارهای اصلی قیمت‌گذاری است و با توجه به اینکه ۸۰ درصد از پسته ایران به صورت انبوه و فله‌ای به بازار عرضه می‌شود، تشخیص نوع پسته در حجم‌های وسیع، ضرورتی حیاتی برای صنایع کشاورزی و صادراتی است. نویسنده این مقاله و همکاران در مرجع (شمسی گوشکی و همکاران، ۱۳۹۱) از پردازش تصاویر مجموعه‌ای از پسته‌ها برای طبقه‌بندی آن‌ها به ۵ طبقه با استفاده از فیلتر گابور و طبقه‌بند k همسایه نزدیک‌تر استفاده کرده‌اند. در این پژوهش از پایگاه داده مرجع (شمسی گوشکی و همکاران، ۱۳۹۱) استفاده شده است و نتایج روش پیشنهادی با نتایج آن مرجع مقایسه شده‌اند. سازمان‌دهی این مقاله به گونه‌ای است که در فصل دوم، سوم و چهارم به ترتیب پیشینه پژوهش، روش‌شناسی پژوهش و یافته‌های پژوهش بیان شده و در بخش‌های پنجم و ششم به بحث، نتیجه‌گیری پرداخته می‌شود.

پیشینه پژوهش

در این بخش به مرور مهم‌ترین تحقیقات و روش‌های موجود در زمینه شناسایی و طبقه‌بندی انواع پسته پرداخته می‌شود. از جمله فناوری‌هایی که برای این منظور به کار گرفته شده‌اند، می‌توان به پردازش تصویر، بینایی ماشین، و مدل‌های یادگیری عمیق اشاره کرد. در سال‌های اخیر، این فناوری در بخش کشاورزی، به ویژه در طبقه‌بندی محصولات ارزشمندی مانند پسته، به‌طور گسترده‌ای مورد استفاده قرار گرفته است. مدل‌های شناخته‌شده‌ای نظیر VGG16 و VGG19 که ساختارهای شبکه عصبی عمیق آن‌ها الهام گرفته از شبکه‌های پیچشی چندلایه است، توانسته‌اند در شناسایی انواع پسته با دقت بالا موفق عمل کنند و به دقت ۹۸/۸۴ درصد در طبقه‌بندی تصاویر پسته به دو طبقه برسند (Singh et al., 2022, Avuçlu, 2023 a, Avuçlu, 2023 b). علاوه بر این، الگوریتم‌های یادگیری ماشین کوچک‌مقیاس نیز نتایج موفقیت‌آمیزی داشته‌اند (Kumar et al., 2024).

افزون بر این، انتقال یادگیری به‌عنوان رویکردی نوین، امکان بهره‌برداری از مدل‌های پیش‌آموزش‌یافته را فراهم کرده است و توانسته است زمان و منابع مورد نیاز برای آموزش شبکه‌ها را به طور چشمگیری کاهش دهد. این روش در مراجع (Patel et al., 2023) و (Farazi et al., 2017)، عملکرد موفقیت‌آمیزی در شناسایی گونه‌های پسته نشان داده است. از سوی دیگر، مدل‌های پیشرفته‌تری مانند EfficientNet به دلیل بهینه‌سازی‌های انجام‌شده در ساختار معماری‌شان، توجه بسیاری را به خود جلب کرده‌اند. این مدل‌ها توانسته‌اند تعادلی میان دقت بالا و استفاده بهینه از منابع محاسباتی برقرار کنند. پژوهش‌ها نشان می‌دهند که مدل EfficientNet با دقت ۹۷/۲ درصد در شناسایی گونه‌های مختلف درخت پسته، یکی از انتخاب‌های برتر برای کاربردهای کشاورزی هوشمند است (Heidary-Sharifabad et al., 2021).

علاوه بر شناسایی انواع و گونه‌های پسته، روش‌های بینایی ماشین در طبقه‌بندی دانه‌های پسته به طبقه‌بندی‌های دیگر مثل پسته‌های سالم و بیمار، خندان و ناخندان، با پوست و بدون پوست و ... نیز استفاده شده‌اند. در مرجع (Abbaszadeh et al., 2019)، یک الگوریتم تصویربرداری مبتنی بر یادگیری عمیق برای بهبود مرتب‌سازی آجیل‌ها با نقص پوسته و هسته که نشان‌دهنده خطر آلودگی آفاتوکسین است، مانند لکه‌های تیره، لکه‌های روغنی، پوسته چسبنده، پوسیدگی قارچی و کپک‌های آسپرژیلوس توسعه داده شده است. این مقاله یک روش یادگیری بدون نظارت را برای طبقه‌بندی پسته‌های معیوب و ناخوشایند بر اساس شبکه‌های عصبی خودکار رمزگذار عمیق ارائه می‌کند. آزمایش شبکه عصبی طراحی شده بر روی یک مجموعه داده اعتبارسنجی نشان داد که آجیل‌هایی که دارای لکه تیره، لکه روغنی یا بدنه چسبنده هستند با دقت ۸۰/۳ درصد از دانه‌های معمولی قابل تشخیص هستند. در پژوهش دیگری، سامانه‌ای بر پایه ماشین‌های بردار پشتیبان (SVM) برای جداسازی پسته‌های پوست‌کنده توسعه داده شده است. این سامانه توانسته با دقت بالای ۹۹/۱۷ درصد، کارایی بسیار خوبی در فرآیندهای طبقه‌بندی صنعتی ارائه دهد (Nouri-Ahmadaabadi et al., 2017). در مرجع (Subbarao et al., 2023) نیز سامانه چند سطحی پیشنهادی با استفاده از ماشین‌های بردار پشتیبان به طور مؤثر گونه‌های پسته را با نرخ ۹۳/۹ درصد طبقه‌بندی می‌کند. در تحقیق دیگری به تشخیص پسته خندان، کم خندان و ناخندان با استفاده از بینایی ماشین پرداخته شده است (Kasiri & Safabakhsh, 2007). در مقاله مذکور، روشی مبتنی بر تفاضل مؤلفه رنگی تصویر پسته ارائه شده است. در این روش، ویژگی‌های استخراج شده برای دسته‌بندی به شبکه عصبی و درخت تصمیم سپرده شده‌اند.

روش‌های نوآورانه دیگری نیز در زمینه شناسایی و طبقه‌بندی پسته مورد استفاده قرار گرفته‌اند. از جمله این روش‌ها می‌توان به سامانه‌های مبتنی بر تحلیل صوت اشاره کرد. این روش‌ها با بهره‌گیری از داده‌های صوتی تولیدشده در اثر برخورد پسته به سطوح مختلف، اطلاعات جامعی را برای شناسایی و طبقه‌بندی فراهم می‌کنند. در مرجع (Mahdavi-Jafari et al., 2008) از شبکه‌های عصبی مصنوعی برای تحلیل صداهای ناشی از برخورد پسته‌ها به سطوح فلزی استفاده شده است. این سامانه توانست با دقت ۹۹/۸۹ درصد، گونه‌های مختلف پسته را شناسایی کند. چنین دقت بالایی نشان‌دهنده قابلیت بسیار زیاد تحلیل صوت در کاربردهای صنعتی و کشاورزی هوشمند است.

در مرجع (Omid et al., 2009) سامانه‌ای بر پایه تحلیل صوت همراه با روش کاهش ابعاد تحلیل مؤلفه اصلی (PCA) ارائه کردند. در این پژوهش، از ۴۰ ویژگی کلیدی استخراج‌شده از داده‌های صوتی برای طبقه‌بندی انواع مختلف پسته استفاده شده است. این روش نه تنها موجب افزایش دقت طبقه‌بندی شد، بلکه با کاهش تعداد ویژگی‌ها، سرعت و کارایی سامانه را نیز بهبود بخشید. افزون بر این، ترکیب تحلیل صوت با دیگر فناوری‌ها مانند شبکه‌های عصبی و روش‌های کاهش ابعاد امکان بهبود بیشتر دقت و سرعت این سامانه‌ها را فراهم کرده است.

روش‌شناسی پژوهش

فیلترهای گابور

استخراج ویژگی‌های تصویر، یک مرحله اجتناب‌ناپذیر در بسیاری از زمینه‌های پردازش تصویر است. از آنجایی که خصوصیات مورد نظر در یک تصویر، مقیاس و جهت‌های گوناگونی دارند، استخراج اطلاعات و ویژگی‌های جهت‌دار در مقیاس‌های مختلف یکی از گام‌های اساسی است. فیلترهای گابور به علت خواص مناسبی که دارند برای رسیدن به این منظور به طور وسیع در زمینه‌هایی هم چون تحلیل بافت (Wang et al., 2019)، طبقه‌بندی تصویر (Liang et al., 2023)، بازبینی تصویر (Madhavi et al., 2019)، تشخیص فونت (Ha et al., 2005) و ... مورد استفاده قرار می‌گیرند. از جمله این خواص می‌توان به سادگی و امکان انتخاب جهت و بسامد برای استخراج اطلاعات تصویر اشاره کرد. فرمول تابع گابور و تبدیل فوریه آن طبق روابط ۱ و ۲ است:

$$g(x, y) = \frac{1}{2\pi\sigma_x\sigma_y} \exp\left(-\frac{1}{2}\left(\frac{x^2}{\sigma_x^2} + \frac{y^2}{\sigma_y^2}\right)\right) \times \exp(j2\pi u_0 x) \quad \text{رابطه ۱}$$

$$G(u, v) = \exp\left(-\frac{1}{2}\left(\frac{(u - u_0)^2}{\sigma_u^2} + \frac{v^2}{\sigma_v^2}\right)\right) \quad \text{رابطه ۲}$$

که در آن u_0 ، بسامد مرکزی موج سینوسی را در راستای محور x ، چنان چه جهت صفر درجه انتخاب شده باشد، است. σ_x و σ_y به ترتیب انحراف معیار تابع پوش گاوسی در راستای محورهای x و y و $\sigma_u = \frac{1}{2\pi\sigma_x}$ و $\sigma_v = \frac{1}{2\pi\sigma_y}$ به ترتیب انحراف معیار تابع گاوسی در راستای محورهای u و v هستند. در برخی از تحقیقات تنها از بخش حقیقی (زوج) یا موهومی (فرد) توابع گابور مختلط استفاده شده است. قسمت حقیقی تابع گابور مختلط، زوج است که روابط حوزه مکان و بسامد آن مطابق روابط ۳ و ۴ به دست می‌آیند و از آن برای تحلیل بافت استفاده می‌شود.

$$g(x, y) = \frac{1}{2\pi\sigma_x\sigma_y} \exp\left(-\frac{1}{2}\left(\frac{x^2}{\sigma_x^2} + \frac{y^2}{\sigma_y^2}\right)\right) \times \cos(2\pi u_0 x) \quad \text{رابطه ۳}$$

$$G(u, v) = \exp\left(-\frac{1}{2}\left(\frac{(u - u_0)^2}{\sigma_u^2} + \frac{v^2}{\sigma_v^2}\right)\right) + \exp\left(-\frac{1}{2}\left(\frac{(u + u_0)^2}{\sigma_u^2} + \frac{v^2}{\sigma_v^2}\right)\right) \quad \text{رابطه ۴}$$

در این تحقیق نیز از قسمت حقیقی تابع گابور مختلط استفاده شده است. موجک‌های گابور را می‌توان از طریق گسترش و چرخش موجک مادر یا تابع مولد $g(x, y)$ در حوزه مکان به صورت رابطه ۵ بدست آورد:

$$\begin{aligned} g_{m,n}(x, y) &= a^{-m} g(\hat{x}, \hat{y}), \quad a > 1 \\ \hat{x} &= a^{-m}(x \cos(\theta) + y \sin(\theta)) \\ \hat{y} &= a^{-m}(-x \sin(\theta) + y \cos(\theta)), \quad \theta = \frac{n\pi}{k} \\ m &= 0, 1, \dots, s-1, \quad n = 0, 1, \dots, k-1 \end{aligned} \quad \text{رابطه ۵}$$

که در آن $g_{m,n}$ مقیاس شده و چرخش یافته‌ای از فیلتر مادر $g(x, y)$ ، a عامل مقیاس، k تعداد کل جهت‌ها، s تعداد کل مقیاس‌ها و m و n به ترتیب مشخص کننده مقیاس و جهت هر فیلتر هستند. x و y نیز مختصات مقیاس شده و چرخش یافته هستند. ضریب a^{-m} برای اطمینان از عدم وابستگی انرژی فیلتر به m است. با استفاده از این فیلترها هر تصویر ورودی به تعدادی تصویر فیلتر شده تجزیه می‌شود که هر تصویر فیلتر شده شامل تغییرات شدت روشنایی در یک محدوده باریک از بسامد و جهت است. اگر فرض کنیم u_l و u_h به ترتیب برای نمایش حداقل و حداکثر بسامد مرکزی مجمع فیلتر به کار روند، در این صورت عامل‌های مجمع فیلتر با توجه به روابط ۶ محاسبه می‌شوند (Manjanath & Ma, 1996).

$$a = \left(\frac{u_h}{u_l}\right)^{\frac{1}{s-1}} \quad \text{رابطه ۶}$$

$$\sigma_v = \frac{\tan\left(\frac{\pi}{2k}\right)\left(u_h - 2 \ln\left(\frac{u_h}{u_l}\right)\right)}{\sqrt{2 \ln 2 - (2 \ln 2)^2 \left(\frac{u_h}{u_l}\right)^2}}$$

$$\sigma_u = \frac{(a-1)u_h}{(a+1)\sqrt{2 \ln 2}}$$

در این تحقیق به فیلترهایی با ابعاد 512×512 نیاز است. بنابر پیشنهاد (Jain & Bhattacharjee, 1992)، u_h برابر $128\sqrt{2}$ دوره بر پهنای تصویر و u_l برابر $8\sqrt{2}$ دوره بر پهنای تصویر انتخاب شده‌اند. بنابراین مقدار a برابر ۲ خواهد بود. برای تصویر $I(x, y)$ تبدیل موجک گابور با استفاده از رابطه ۷ محاسبه می‌شود.

$$I_{m,n}(x, y) = \iint I(x_1, x_2) g^*(x - x_1, y - y_1) dx_1 dx_2 \quad \text{رابطه ۷}$$

از آنجا که به دست آوردن زیرتصویرهای $I_{m,n}$ با استفاده از رابطه ۷ به دلیل زمان‌بر بودن عملیات پیچش در حوزه مکان وقت‌گیر است، این زیرتصویرها با استفاده از رابطه ۸ در فضای تبدیل فوریه محاسبه می‌شوند.

$$I_{m,n}(x, y) = f^{-1}[I(u, v) G_{m,n}(u, v)] \quad \text{رابطه ۸}$$

که در آن $I(u, v)$ تبدیل فوریه تصویر $I(x, y)$ و $G_{m,n}(u, v)$ تبدیل فوریه $g_{m,n}(x, y)$ است. به طور کلی برای کاهش حساسیت فیلترها به مقدار قدرمطلق شدت روشنایی تصویر، $G_{m,n}(0,0)$ یعنی مقدار dc تصویر، برابر صفر در نظر گرفته می‌شود.

الگوریتم وراثتی

الگوریتم‌های ژنتیکی روش‌هایی برای جستجوی تصادفی هستند که بر اساس اصول وراثت و انتخاب طبیعی عمل می‌کنند. این الگوریتم‌ها برای نخستین بار توسط گلدبرگ به صورت مدون معرفی شدند (Goldberg, 1989). الگوریتم‌های ژنتیکی با یک مجموعه اولیه از راه‌حل‌های تصادفی که «جمعیت» نام دارند شروع می‌شوند. هر عنصر از این جمعیت که به عنوان «کروموزوم» شناخته می‌شود، نماینده یک راه‌حل مسئله است. طی فرایندهای متوالی که «نسل» نامیده می‌شوند، کروموزوم‌ها دستخوش تغییر و تحول می‌گردند. در هر نسل، عملکرد کروموزوم‌ها با استفاده از یک تابع برازش سنجیده می‌شود.

برای تولید نسل بعدی، کروموزوم‌های جدید که «فرزندان» نامیده می‌شوند، از طریق دو عملگر اصلی، یعنی جابجایی و جهش ژنی ایجاد می‌شوند. نسل جدید با استفاده از انتخاب بر اساس مقادیر تابع برازش والدین و فرزندان و حذف دیگر کروموزوم‌ها به منظور ثابت نگه‌داشتن اندازه جمعیت شکل می‌گیرد. با گذشت چندین نسل، این الگوریتم به سمت یک کروموزوم بهینه هدایت می‌شود که معمولاً پاسخی نزدیک به بهترین جواب ممکن برای مسئله ارائه می‌دهد.


معمولاً انتخاب اولیه به صورت تصادفی انجام می‌شود. در این انتخاب تصادفی، تعداد واقعی کروموزوم‌هایی که تکثیر می‌شوند، بر اساس احتمال بقا تعیین می‌گردد. از میان روش‌های شناخته‌شده برای این انتخاب، روش «چرخ رولت» رایج‌ترین است. در این روش، احتمال بقای هر کروموزوم بر اساس مقدار تابع برازش آن تعیین می‌شود. احتمال انتخاب کروموزوم k با تابع برازش f_k ، احتمال انتخاب یا p_k از رابطه ۹ محاسبه می‌شود.

$$p_k = \frac{f_k}{\sum f_i} \quad \text{رابطه ۹}$$

جابجایی با احتمال p_c ، یکی از مهم‌ترین عملگرهای الگوریتم‌های ژنتیکی است که برای ترکیب کروموزوم‌های والد و تولید فرزندان جدید استفاده می‌شود. روش‌های رایج جابجایی شامل برش تک‌قطعه‌ای، دوتقطه‌ای، چندنقطه‌ای و جابجایی یکنواخت هستند. جهش ژنی با احتمال p_m نیز عملگر دیگری است که می‌تواند تغییراتی در یک یا چند ژن از یک کروموزوم ایجاد کند.

روش پیشنهادی

در شکل ۲، نمای روش پیشنهادی قابل مشاهده است. تصویر ورودی، یک تصویر رنگی از پسته‌ها با ابعاد 3498×2542 تصادف (پیکسل) است. برای ثبت این تصویر، پسته‌ها درون یک ظرف شیشه‌ای که ابعاد آن با صفحه پوشش‌گر مطابقت دارد، قرار داده شده و سپس با استفاده از پوششگری با دقت $300dpi$ ، تصویری رنگی از آن‌ها تهیه شده است. نمودار از این تصویر اسکن شده در شکل ۳ نشان داده شده است.



شکل ۲. روش پیشنهادی برای بازشناسی تصاویر پسته.

تصویر ورودی پس از دریافت، پیش‌پردازش می‌شود. در مرحله بعد، ویژگی‌های بافت از تصویر پیش‌پردازش شده با استفاده از بانک فیلتر گابور استخراج می‌شوند. در مرحله بعد توسط الگوریتم وراثتی ویژگی‌های مناسب انتخاب می‌شوند. در نهایت به منظور بازشناسی نوع پسته، ویژگی‌های استخراج شده به طبقه‌بند k همسایه نزدیک‌تر سپرده می‌شوند. خروجی طبقه‌بند، نوع پسته ورودی را مشخص می‌کند. در ادامه قسمت‌های مختلف روش پیشنهادی تشریح می‌شوند.

در مرحله پیش‌پردازش به دلیل استفاده از ویژگی بافت، ابتدا تصویر رنگی به خاکستری تبدیل می‌شود. سپس به صورت اتفاقی زیرتصویرهایی به ابعاد 2048×2048 از تصویر خاکستری بریده شده و به ابعاد 512×512 تغییر اندازه می‌دهند. از هر نوع پسته ۱۵ عکس اسکن شده و از آن‌ها ۴۰۰ زیرتصویر 512×512 استخراج می‌شود. در مجموع ۲۰۰۰ زیرتصویر 512×512 (۴۰۰ زیرتصویر برای هر نوع پسته) تهیه که از مجموع آن‌ها ۱۰۰۰ زیرتصویر (۲۰۰ زیرتصویر برای هر نوع پسته)، برای یادگیری و ۱۰۰۰ زیرتصویر برای آزمون استفاده شده است. برای مستقل بودن مجموعه‌های یادگیری و آزمایش، برای هر نوع پسته از ۸ تصویر اول ۲۰۰ زیرتصویر 512×512 به صورت اتفاقی برای یادگیری و از ۷ تصویر دوم ۲۰۰ زیرتصویر 512×512 به صورت اتفاقی برای آزمون تهیه شده است.

در مرحله بعد زیرتصاویر 512×512 به مرحله استخراج ویژگی ارسال می‌شوند. برای تعیین اندازه زیرتصویر، باید دو مسئله را در نظر گرفت. نخست آنکه انتخاب زیرتصویر کوچک باعث می‌شود اطلاعات زیادی در یک پنجره قرار نگیرد و دیگری اینکه انتخاب زیرتصویر بزرگ، موجب پایین آمدن کارایی برنامه از نظر صرف زمان می‌شود. بر اساس نتایج تجربی، اندازه زیرتصویر 2048×2048 انتخاب مناسبی است.



شکل ۳. یک نمونه از تصویر اسکن شده.

در مرحله استخراج ویژگی از فیلترهای گابور استفاده شده است. برای انتخاب مناسب مقیاس و جهت، آزمایش‌هایی با مقیاس‌ها و جهت‌های مختلف انجام شد که با توجه به نتایج، استفاده از ۵ مقیاس و ۶ جهت ($s = 5$ و $k = 6$) انتخاب مناسبی است و در مجموع ۳۰ فیلتر گابور تشکیل شد. همچنین به دلیل تصادفی بودن جهت پسته‌ها در تصویر، میانگین و انحراف معیار به دست آمده از زیرتصویرهای فیلتر شده، در دو جهت $\theta = 15^\circ$ و $\theta = 120^\circ$ به ترتیب به مقادیر حاصل از جهت‌های $\theta = 60^\circ$ و $\theta = 30^\circ$ نزدیک هستند. برای حذف این اطلاعات اضافی، دو جهت $\theta = 150^\circ$ و $\theta = 120^\circ$ حذف و در نهایت از پنج مقیاس و چهار جهت ($\theta = 0^\circ, 30^\circ, 60^\circ, 90^\circ$) که در مجموع ۲۰ فیلتر را تشکیل می‌دهند استفاده شد.

این فیلترها در ابعاد 512×512 تصدانه طراحی شدند. زیرتصویر 512×512 انتخاب شده از تصویر پیش‌پردازش شده، از ۲۰ کانال فیلتر گابور عبور کرده و زیرتصویرهای فیلتر شده آن از رابطه ۸ محاسبه شدند؛ سپس از هر تصویر دو عامل میانگین و انحراف معیار، مطابق رابطه ۱۰ به عنوان ویژگی استخراج شدند.

$$\sigma_{m,n} = \sqrt{\iint (g_{m,n}(x,y) - \mu_{m,n})^2 dx dy} \quad \text{رابطه ۱۰}$$

$$\mu_{m,n} = \iint |g_{m,n}(x,y)| dx dy$$

در نهایت یک بردار ویژگی با استفاده از $\sigma_{m,n}$ و $\mu_{m,n}$ ساخته شد که در این تحقیق ۴۰ بعدی و مطابق رابطه ۱۱ است.

$$\bar{f} = [\mu_{0,0}, \sigma_{0,0}, \mu_{0,1}, \sigma_{0,1}, \dots, \mu_{4,3}, \sigma_{4,3}] \quad \text{رابطه ۱۱}$$

خروجی مرحله استخراج ویژگی، یک بردار ۴۰ بعدی متناظر با تصویر ورودی است که برای انتخاب ویژگی‌های مناسب به الگوریتم وراثتی سپرده می‌شود.

در الگوریتم وراثتی استفاده‌شده، میزان برازندگی هر کروموزوم برابر با نرخ طبقه‌بندی صحیح پسته‌ها با در نظر گرفتن آن کروموزوم به عنوان بردار وزن محاسبه می‌شود. در الگوریتم وراثتی از اندازه جمعیت اولیه ۵۰ کروموزوم (هر کروموزوم شامل ۴۰ ژن)، $p_m = 0.05$ و $p_c = 0.9$ با ۱۰۰ تکرار استفاده شده است. برای به دست آوردن میزان برازندگی یک کروموزوم، هر ژن در آن کروموزوم به عنوان وزن در مؤلفه متناظر بردار ویژگی ضرب می‌شود.

برای طبقه‌بندی از روش k همسایه نزدیک‌تر استفاده شده است. در این روش، بردار ویژگی زیرتصویر ورودی با بردارهای ویژگی مربوط به تصاویر برچسب خورده، در مجموع یادگیری مقایسه شده و تعداد k همسایه نزدیک‌تر به بردار ورودی، مشخص می‌شوند (k عددی فرد انتخاب می‌شود). تصویر ورودی به طبقه‌ای تعلق می‌گیرد که از بین k همسایه نزدیک‌تر، تعداد بیش‌تری را به خود نسبت داده باشد. در این تحقیق برای تعیین فاصله بین بردارهای ویژگی از فاصله χ^2 استفاده شده است. این فاصله برای دو بردار n بعدی $X = (x_1, x_2, \dots, x_n)$ و $Y = (y_1, y_2, \dots, y_n)$ مطابق رابطه ۱۲ تعریف می‌شود.

$$D(X, Y) = \sum_{i=1}^n \left(\frac{x_i - y_i}{x_i + y_i} \right)^2 \quad \text{رابطه ۱۲}$$

بعد از استفاده از الگوریتم وراثتی با ۱۰۰ بار تکرار، نرخ بازیابی با استفاده از بردار ویژگی رابطه ۱۳، بالاترین نرخ طبقه‌بندی را دارا است.

$$f = [\sigma_{00}, \mu_{02}, \sigma_{02}, \mu_{03}, \sigma_{10}, \sigma_{12}, \mu_{13}, \sigma_{20}, \sigma_{21}, \sigma_{23}, \mu_{32}, \sigma_{32}, \mu_{33}, \sigma_{40}, \sigma_{41}, \mu_{43}, \sigma_{43}] \quad \text{رابطه ۱۳}$$

بنابراین در نهایت از مجموع ۴۰ ویژگی، ۱۸ ویژگی مناسب در بازیابی استفاده می‌شود.

یافته‌های پژوهش

نتایج حاصل از طبقه‌بندی برای مجموعه آزمون با روش پیشنهادی در جدول ۱ آمده است. در این جدول، تعداد زیرتصاویری که در هر گروه به درستی یا اشتباه بازشناسی شده‌اند در قسمت سبزرنگ و درصد طبقه‌بندی درست و اشتباه در هر طبقه، در قسمت ابی رنگ نشان داده شده است. نتایج بخش‌بندی با روش مرجع (شمسی گوشکی و همکاران، ۱۳۹۱) روی پایگاه داده مشابه در جدول ۲ آورده شده است. در طبقه‌بندی، تعداد همسایه‌ها ۷ در نظر گرفته شده است.

جدول ۱. نتایج طبقه‌بندی تصاویر ورودی در مجموعه آزمون با روش پیشنهادی.

نوع پسته واقعی					
اکبری	احمد آقایی	کله قوچی	فندق	بادامی	
۰	۰	۰	۰	۲۰۰	بادامی
۰	۰	۰	۲۰۰	۰	فندق
۰	۲	۱۹۹	۰	۰	کله قوچی
۲	۱۹۸	۱	۰	۰	احمد آقایی
۱۹۸	۰	۰	۰	۰	اکبری
۹۹	۹۹	۹۹/۵	۱۰۰	۱۰۰	درصد طبقه‌بندی درست

درصد طبقه‌بندی اشتباه	۰	۰	۰/۵	۱	۱
-----------------------	---	---	-----	---	---

جدول ۲. نتایج طبقه‌بندی تصاویر ورودی در مجموعه آزمون با روش مرجع (شمسی گوشکی و همکاران، ۱۳۹۱).

		نوع بسته واقعی				
		اکبری	احمد آقایی	کله قوچی	فندقی	بادامی
نوع بسته نسبت داده شده	بادامی	۰	۰	۰	۰	۲۰۰
	فندقی	۳	۰	۰	۲۰۰	۰
	کله قوچی	۰	۳۱	۱۸۴	۰	۰
	احمد آقایی	۱	۱۶۸	۶	۰	۰
	اکبری	۱۹۶	۱	۱۰	۰	۰
درصد طبقه‌بندی درست		۹۸	۸۴	۹۲	۱۰۰	۱۰۰
درصد طبقه‌بندی اشتباه		۲	۱۶	۸	۰	۰

به منظور مقایسه معنادارتر روش پیشنهادی و روش مورد مقایسه از معیارهای ارزیابی دقت، صحت، حساسیت^۳ و معیار F1^۴ استفاده شده است که روابط آن‌ها به ترتیب در روابط ۱۴ تا ۱۷ آورده شده است.

$$Precision = \frac{TP}{TP + FP} \quad \text{رابطه ۱۴}$$

$$accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad \text{رابطه ۱۵}$$

$$Sensitivity = \frac{TP}{TP + FN} \quad \text{رابطه ۱۶}$$

$$F1 - score = \frac{2 \times Precision \times Sensitivity}{Precision + Sensitivity} \quad \text{رابطه ۱۷}$$

1. Precision
2. Accuracy
3. Sensitivity
4. F-score

در این روابط، TP نشان دهنده‌ی تعداد تصاویری است که به یک طبقه تعلق داشته‌اند و به درستی در آن طبقه انتخاب شده‌اند. TN نشان دهنده‌ی تعداد تصاویری است که متعلق به یک طبقه نبودند و به درستی به آن طبقه تعلق نگرفته‌اند. FP نشان دهنده‌ی تعداد تصاویری است که به یک طبقه تعلق نداشته‌اند اما به اشتباه به آن طبقه طبقه‌بندی شده‌اند و FN نشان دهنده‌ی تعدادی از تصاویر است که به یک طبقه تعلق داشته‌اند اما به اشتباه در آن طبقه طبقه‌بندی نشده‌اند. ارزیابی نتایج به دست‌آمده بین روش پیشنهادی و روش مورد مقایسه با معیارهای ارزیابی ارائه‌شده، به ترتیب در جدول‌های ۳ و ۴ آورده شده است.

جدول ۳. معیارهای ارزیابی برای طبقه‌بندی تصاویر پسته با روش پیشنهادی

	Precision	Accuracy	Sensitivity	F1-score
بادامی	۱	۱	۱	۱
فندق	۱	۱	۱	۱
کله‌قوچی	۰/۹۹	۰/۹۹۷	۰/۹۹۵	۰/۹۹۳
احمدآقایی	۰/۹۸۵	۰/۹۹۵	۰/۹۹	۰/۹۸۷
اکبری	۱	۰/۹۹۸	۰/۹۹	۰/۹۹۵
همه طبقه‌ها	۰/۹۹۵	۰/۹۹۸	۰/۹۹۵	۰/۹۹۵

جدول ۴. معیارهای ارزیابی برای طبقه‌بندی تصاویر پسته با روش مرجع (شمسی گوشکی و همکاران، ۱۳۹۱).

	Precision	Accuracy	Sensitivity	F1-score
بادامی	۱	۱	۱	۱
فندق	۰/۹۸۵	۰/۹۹۷	۱	۰/۹۹۳
کله‌قوچی	۰/۸۵۶	۰/۸۵۲	۰/۹۲	۰/۸۸۶
احمدآقایی	۰/۹۶	۰/۹۶۱	۰/۸۴	۰/۸۹۶
اکبری	۰/۹۴۷	۰/۹۸۵	۰/۹۸	۰/۹۶۳
همه طبقه‌ها	۰/۹۴۸	۰/۹۷۹	۰/۹۴۸	۰/۹۴۸

معیار دقت (Precision) نشان می‌دهد که چه مقدار از پیش‌بینی‌های مثبت مدل درست هستند؛ مقادیر بالاتر به معنای تعداد کمتر موارد مثبت اشتباه است. همان‌طور که در جداول ۳ و ۴ دیده می‌شود روش پیشنهادی در سه مورد از پنج رقم پسته، دقت کامل داشته و تنها در رقم کله‌قوچی و احمدآقایی اندکی کاهش مشاهده شده است که نشان دهنده‌ی میزان بسیار کم خطای طبقه‌بندی است. در مقابل، روش ارائه‌شده در مرجع (شمسی گوشکی و همکاران، ۱۳۹۱) عملکرد متفتری داشته و پایین‌ترین دقت مربوط به رقم کله‌قوچی (۰/۸۵۹) است که بیانگر تعداد بیشتر پیش‌بینی اشتباه سایر طبقه‌ها در این طبقه می‌باشد. در مجموع، روش پیشنهادی با دقت ۰/۹۹۸ عملکرد بسیار بهتری دارد، در حالی که دقت روش مرجع (شمسی گوشکی و همکاران، ۱۳۹۱) ۰/۹۴۸ است. معیار صحت (Accuracy) میزان پیش‌بینی‌های صحیح را نسبت به کل نمونه‌ها نشان می‌دهد. طبق جداول ۳ و ۴ هر دو روش برای پسته بادامی به صحت کامل ۱ دست یافته‌اند. روش پیشنهادی در سایر طبقه‌ها عملکرد بهتری دارد. در مجموع، روش پیشنهادی با صحت ۰/۹۹۸ نسبت به ۰/۹۷۹ روش مرجع (شمسی گوشکی و همکاران، ۱۳۹۱)، عملکرد برتری در طبقه‌بندی پسته‌ها نشان می‌دهد.

معیار حساسیت (Sensitivity)، توانایی یک مدل در شناسایی صحیح نمونه‌های مثبت از هر طبقه را ارزیابی می‌کند. حساسیت بالا نشان دهنده‌ی اثربخشی مدل در شناسایی نمونه‌های مرتبط با یک طبقه خاص است. همان‌طور که در جداول ۳ و ۴ نشان داده شده است روش پیشنهادی به‌طور کلی حساسیت بسیار بالایی را به دست می‌آورد (۰/۹۹۵). در مقایسه، روش ارائه‌شده در مرجع (شمسی گوشکی و همکاران، ۱۳۹۱) برای برخی کلاس‌ها حساسیت کمتری دارد. حساسیت برای کلاس احمد آقایی تنها ۰/۸۴ است، به این معنی که ۱۶ درصد از پسته‌های این کلاس به‌درستی شناسایی نمی‌شوند. به‌طور مشابه، کلاس کله قوچی دارای

حساسیت ۰/۹۲ است، که نشان‌دهنده نرخ عدم شناسایی ۸ درصد است. حساسیت کلی برای هر پنج کلاس پسته با روش پیشنهادی ۰/۹۹۸ است، در حالی که این مقدار برای روش ارائه‌شده در مرجع (شمسی گوشکی و همکاران، ۱۳۹۱). برابر با ۰/۹۴۸ است. این موضوع نشان‌دهنده استحکام روش پیشنهادی در به حداقل رساندن عدم شناسایی‌ها در میان تمام کلاس‌ها است و عملکرد قابل اطمینان‌تری را در طبقه‌بندی پسته نسبت به روش مورد مقایسه ارائه می‌دهد.

معیار F1 تعادلی بین دقت (Precision) و حساسیت (Sensitivity) ایجاد می‌کند و به‌ویژه در مجموعه داده‌های نامتوازن یا زمانی که هم مثبت‌های کاذب و هم منفی‌های کاذب اهمیت دارند، مفید است. همان‌طور که در جدول ۳ و ۴ نشان داده شده است روش پیشنهادی برای بادامی و فندق‌ای امتیاز F1 کامل را به دست آورده و در کله‌قوچی، احمدآقایی و اکبری کمی کاهش داشته است، که نشان‌دهنده تعادل قوی در تمام کلاس‌هاست. روش ارائه‌شده در مرجع (شمسی گوشکی و همکاران، ۱۳۹۱) عملکرد ناپایدارتری داشته و در طبقه‌بندی همه انواع پسته به جز بادامی ضعیف‌تر عمل کرده، که نشان‌دهنده مشکل این روش در حفظ تعادل بین دقت و حساسیت است. امتیاز F1 کلی ۰/۹۹۵ در روش پیشنهادی، برتری و تعادل بالای آن را در طبقه‌بندی پسته‌ها تأیید می‌کند، در حالی که روش مرجع (شمسی گوشکی و همکاران، ۱۳۹۱) امتیاز ۰/۹۴۸ را کسب کرده است.

نکته قابل توجه تفاوت کلاس کله‌قوچی و اکبری است. بر طبق جدول ۱، از ۲۰۰ تصویر پسته نوع کله‌قوچی تنها ۱ تصویر به اشتباه برچسب نوع احمدآقایی خورده است و از ۲۰۰ تصویر نوع اکبری، ۲ تصویر به اشتباه برچسب نوع احمدآقایی خورده‌اند. چون تعداد تصاویر اشتباه طبقه‌بندی شده نوع اکبری بیشتر از کله‌قوچی است، معیار حساسیت آن در جدول ۳ کمتر است (۰/۹۹ نسبت به ۰/۹۹۵). در مقابل ۲ تصویر از نوع احمدآقایی به اشتباه برچسب کله‌قوچی خورده‌اند اما هیچ تصویری به اشتباه برچسب اکبری نخورده است به همین دلیل معیار دقت در جدول ۳ برای نوع اکبری بیشتر از کله‌قوچی است (۱ نسبت به ۰/۹۹). از آنجایی که بیشترین تصاویر اشتباه طبقه‌بندی شده به طبقه احمدآقایی تعلق گرفته‌اند (۱ تصویر از طبقه کله‌قوچی و ۲ تصویر از طبقه اکبری)، دقت آن از همه طبقه‌ها کمتر است.

در شکل ۴ از هر نوع پسته موجود در پایگاه داده، یک تصویر نمونه ارائه شده است. همان‌طور که مشاهده می‌شود، ویژگی غالب برای تمایز بین انواع پسته، اندازه دانه‌ها است که متوجه تفاوت در بافت تصاویر شده است. نوع بادامی (شکل ۴-الف) دارای کوچک‌ترین اندازه در بین انواع دیگر است که موجب طبقه‌بندی صحیح آن توسط روش پیشنهادی و روش‌های مقایسه‌ای شده است. اندازه دانه‌ها به ترتیب از شکل ۴-الف تا شکل ۴-ه افزایش یافته و نوع اکبری دارای بزرگ‌ترین دانه‌ها می‌باشد. ترتیب اندازه انواع پسته عبارت است از: بادامی، فندق، کله‌قوچی، احمدآقایی، و اکبری. از آنجا که هر نوع پسته از نظر اندازه، بیشترین شباهت را به نوع همسایه خود دارد، نمونه‌های اشتباه طبقه‌بندی شده نیز عمدتاً به طبقه‌های مجاور تعلق داشته‌اند. به‌ویژه، انواع کله‌قوچی، احمدآقایی و اکبری شباهت ظاهری زیادی داشته و در برخی موارد مانند احمدآقایی و اکبری با چشم غیرمسلح نیز به سختی قابل تمایز هستند. از این‌رو، بیشترین میزان خطا در طبقه احمدآقایی مشاهده شده است. این امر بر ضرورت توسعه روش‌هایی با قدرت تمایز بالا برای انواع بسیار مشابه تأکید دارد.



برای ارزیابی تأثیر الگوریتم وراثتی در کاهش ابعاد بردار ویژگی حاصل از فیلترهای گابور، یک آزمون مقایسه‌ای با استفاده از روش تحلیل مؤلفه‌های اصلی (PCA) انجام شد. در این آزمون، بردار ویژگی رابطه ۱۱ با استفاده از روش تحلیل مؤلفه‌های اصلی کاهش پیدا کرده و بردار ویژگی حاصل با طبقه‌بند k همسایه نزدیک‌تر طبقه‌بندی می‌شود. نتایج این بررسی در جدول ۶ ارائه شده است. همان‌طور که مشاهده می‌شود، درصد دقت طبقه‌بندی برای ابعاد مختلف بردار ویژگی محاسبه شده است. در این میان، بهترین عملکرد مربوط به کاهش ابعاد از ۴۰ به ۶ بوده و میزان دقت ۹۱/۸ درصد به‌دست آمده است. در مقابل، الگوریتم وراثتی در روش پیشنهادی با دقت ۹۹/۵ درصد برتری محسوسی داشته و به‌عنوان رویکردی کارآمد در کاهش ابعاد و بهبود عملکرد طبقه‌بندی معرفی می‌شود.

جدول ۶. کاهش ابعاد بردار ویژگی با استفاده از روش PCA و تأثیر آن بر دقت طبقه‌بندی مدل

۱۰	۷۸/۴	۸۰/۴	۸۲/۱	۹۱/۸	۸۹/۷	۷۷/۲	۷۸/۱	۷۳/۸	۵۱/۸	تعداد ابعاد کاهش‌یافته
۹	۸۰/۴	۸۲/۱	۹۱/۸	۸۹/۷	۷۷/۲	۷۸/۱	۷۳/۸	۵۱/۸	درصد طبقه‌بندی	تعداد ابعاد کاهش‌یافته
۲۰	۶۳/۸	۶۶/۴	۶۶/۲	۶۸/۱	۷۰/۱	۷۰/۶	۷۲/۴	۷۳/۸	۷۵/۸	درصد طبقه‌بندی
۳۰	۵۳	۵۲/۱	۵۳/۱	۵۴	۵۴/۱	۵۵/۵	۵۷/۹	۶۰/۴	۶۱/۲	درصد طبقه‌بندی
۴۰	۴۹/۳	۴۸/۵	۴۸/۳	۴۷/۵	۴۸/۱	۴۹/۱	۵۱/۱	۵۰	۵۱	درصد طبقه‌بندی


به‌منظور ارزیابی دقت و کارایی روش پیشنهادی، عملکرد آن با دو مدل مطرح یادگیری عمیق شامل ResNet-18 و YOLOv8 مقایسه شد. شایان ذکر است که هر سه روش بر روی یک پایگاه داده یکسان مورد آزمون قرار گرفتند تا اعتبار نتایج و قابلیت مقایسه به‌طور کامل حفظ شود. مدل ResNet-18، به‌عنوان یک شبکه عمیق با ساختار Residual، توانست به دقت ۱۰۰ درصد دست یابد، که نشان‌دهنده توانایی بالای آن در استخراج ویژگی‌های پیچیده از داده‌ها است؛ با این حال، این مدل به زمان آموزش قابل توجه و منابع محاسباتی بالا نیاز دارد. مدل YOLOv8 نیز، که برای تشخیص سریع و دقیق طراحی شده است، دقت ۹۹/۸ درصد را حاصل نمود و از نظر سرعت استنتاج در مقایسه با ResNet-18 بسیار بهتر عمل می‌کند و حدود ۱۰۰ برابر سریعتر است. در مقابل، روش پیشنهادی با دقت ۹۹/۵ درصد عملکردی نزدیک به مدل‌های یادگیری عمیق داشت. مهم‌ترین مزیت این روش، حذف کامل فاز آموزش سنگین و زمان‌بر و در نتیجه، کاهش چشمگیر زمان پیاده‌سازی و مصرف منابع محاسباتی است. این ویژگی موجب می‌شود روش پیشنهادی در کاربردهایی نظیر سیستم‌های تعبیه‌شده، پردازش به‌شرایط محدودیت سخت‌افزاری و نیاز به پاسخ‌دهی سریع، گزینه‌ای بهینه تلقی گردد. در نهایت، با وجود اختلاف اندک در دقت، روش پیشنهادی از نظر بهره‌وری محاسباتی و قابلیت استفاده در زمان واقعی برتری نسبی دارد، و می‌تواند به‌عنوان جایگزینی کارآمد برای روش‌های یادگیری عمیق در برخی کاربردها مدنظر قرار گیرد. در جدول ۷ مقایسه‌ای بین روش پیشنهادی و روش‌های یادگیری عمیق انجام شده است.

جدول ۷. مقایسه بین روش پیشنهادی و روش‌های یادگیری عمیق

منابع محاسباتی مورد نیاز	زمان استنتاج	زمان آموزش	دقت بر حسب درصد	مدل مورد استفاده
بالا	متوسط	زیاد	۱۰۰	ResNet-18
متوسط	بسیار کم	زیاد	۹۹/۸	YOLOv8
بسیار پایین	کم	بسیار کم	۹۹/۵	روش پیشنهادی

به‌منظور بررسی مقاومت مدل پیشنهادی در برابر اختلالات محیطی مرتبط با شرایط نوری و زاویه دید، یک مجموعه آزمایش تکمیلی طراحی شد. در این تحلیل، عملکرد مدل در طبقه‌بندی تصاویر تحت پنج شرایط مختلف محیطی شبیه‌سازی شده

شامل تغییرات نور و زاویه بررسی گردید. این حالت‌ها به‌منظور بازتاب بخشی از شرایط واقعی تصویربرداری در محیط واقعی یا خطوط تولید طراحی شده‌اند و شامل نور کم، نور زیاد، تغییرات نوری افقی، تغییرات نوری عمودی و تغییر زاویه دید می‌باشند. یک نمونه تصویر از هر کدام از شرایط شبیه‌سازی شده در شکل ۵ نمایش داده شده است.



شکل ۵. تصاویر نمونه از شرایط مختلف محیطی شبیه‌سازی شده. الف) تصویر اصلی، ب) تصویر با نور کم، ج) تصویر با نور زیاد، د) تصویر با تغییرات نوری افقی، ه) تصویر با تغییرات نوری عمودی و ی) تصویر با تغییر زاویه دید.

در هر شرایط، به ازای هر طبقه (۵ رقم پسته)، ۱۰ تصویر شبیه‌سازی شده از روی تصاویر اصلی که مدل قادر به طبقه‌بندی آن‌ها است تولید و با مدل آموزش دیده، بدون آموزش مجدد، طبقه‌بندی شدند. درصد طبقه‌بندی مدل در جدول ۸ آورده شده است.

جدول ۸. تاثیر شرایط مختلف محیطی شبیه‌سازی شده بر دقت مدل

تغییر زاویه دید	تغییرات نوری عمودی	تغییرات نوری افقی	نور زیاد	نور کم	بدون تغییر	شرایط مختلف شبیه‌سازی شده
۹۹/۸	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	درصد طبقه‌بندی

همان‌طور که در جدول ۸ مشاهده می‌شود، مدل به تغییرات نوری حساس نیست اما به تغییر زاویه دید تا حدی حساس است. از آنجایی که مدل پیشنهادی تنها از ویژگی بافت استفاده می‌کند، تغییرات شدت روشنایی روی عملکرد آن تاثیر زیادی ندارد اما چون تغییر در زاویه دید منجر به تفاوت بین اندازه دانه‌های پسته در جاهای مختلف تصویر می‌شود و مهم‌ترین تفاوت بین طبقه‌های مختلف پسته اندازه آن‌ها است، تغییر در زاویه دید دقت روش را پایین می‌آورد.

بحث

نتایج به‌دست‌آمده در این تحقیق نشان می‌دهد که روش پیشنهادی با ترکیب فیلترهای گابور و الگوریتم وراثتی برای استخراج ویژگی‌های بهینه از تصاویر پسته و استفاده از طبقه‌بند k همسایه نزدیک‌تر (KNN) در بازشناسی انواع مختلف پسته، عملکردی

قابل توجه دارد. در این روش، ویژگی‌های استخراج شده به کمک الگوریتم وراثتی از بین ۴۰ ویژگی اولیه به ۱۸ ویژگی کاهش یافته‌اند که این کاهش مؤثر، پیچیدگی محاسباتی را کاهش داده و درعین حال کارایی سامانه را بهبود بخشیده است. روش پیشنهادی در تشخیص انواعی که از نظر اندازه و ویژگی‌های بصری مشابه هستند، نظیر انواع فندق و کله‌قوچی، به مراتب بهتر عمل کرده است. این یافته نشان‌دهنده تأثیر الگوریتم وراثتی در انتخاب ویژگی‌های تمایزدهنده و تقویت قابلیت طبقه‌بندی برای انواع مشابه است.

با توجه به این که روش پیشنهادی از یک زیرساخت محاسباتی ساده (تصاویر اسکن شده و الگوریتم‌های قدیمی) استفاده کرده است، می‌توان آن را روشی کم‌هزینه و کاربردی دانست که برای سامانه‌های عملی بازناسی محصولات کشاورزی، مانند خط تولید، بسیار مفید خواهد بود. با این حال، این روش دارای محدودیت‌هایی نیز است که از جمله آن‌ها می‌توان به استفاده از یک روبشگر ثابت برای تصویربرداری و عدم بررسی پایداری نتایج در شرایط نوری یا زاویه‌های متفاوت اشاره کرد. مزیت روش پیشنهادی نسبت به روش‌های یادگیری عمیق حجم محاسبات کم است. روش‌های یادگیری عمیق نیاز به مرحله آموزش طولانی و منابع پردازشی قوی برای آموزش شبکه‌ها و همچنین پایگاه داده غنی دارند تا به دقت بالا در طبقه‌بندی برسند. روش پیشنهادی به دقت ۹۹/۵ درصد و قابل رقابت با روش‌های عمیق رسیده است.

نتیجه‌گیری و پیشنهادها

در این پژوهش، یک روش مبتنی بر فیلترهای گابور و الگوریتم وراثتی برای طبقه‌بندی و بازناسی پنج نوع پسته متداول ارائه شد و به دقت ۹۹/۵ درصد دست یافت. دقت بالای این روش بیانگر قابلیت آن برای کاربردهای صنعتی و تجاری در شناسایی و طبقه‌بندی محصولات کشاورزی است. با این وجود، برای ارتقای کارایی و افزایش کاربردپذیری روش پیشنهادی، پیشنهاد می‌شود:

- تنوع در داده‌های تصویری: استفاده از تصاویر با شرایط نوری، پس‌زمینه و زاویه‌های متنوع برای بررسی تأثیر تغییرات محیطی بر دقت مدل و اطمینان از پایداری آن در شرایط واقعی.
- گسترش دامنه انواع محصولات: آزمایش روش پیشنهادی روی سایر محصولات کشاورزی با تنوع‌های ظاهری مشابه برای ارزیابی قابلیت تعمیم‌پذیری روش.
- پیاده‌سازی در زمان واقعی: استفاده از روش‌های بهینه‌سازی کد و پیاده‌سازی روش روی سخت‌افزارهای قابل حمل یا خط تولید برای بررسی سرعت و کارایی آن در شرایط عملی.
- مقایسه با مدل‌های یادگیری عمیق: بررسی عملکرد روش پیشنهادی در مقابل مدل‌های پیشرفته یادگیری عمیق مانند شبکه‌های پیچشی (CNN) به‌عنوان راهکاری برای مقایسه دقت و پیچیدگی محاسباتی.

منابع

- کتیری، سوده و صفابخش، رضا. (۱۳۸۶، آذر). تشخیص پسته خندان، کم‌خندان، ناخندان با استفاده از بینایی ماشین. سومین کنفرانس بین‌المللی فناوری اطلاعات و دانش، مشهد، ایران.
- شمسی گوشکی، اسماء؛ سریزدی، سعید؛ نظام‌آبادی پور، حسین و شمسی گوشکی، حمزه. (۱۳۹۱). بازناسی ارقام پسته بر پایه بینایی ماشین و فیلترهای گابور. مجله مهندسی یو سیستم ایران ۴۳(۲)، ۱۲۲۵-۱۳۱.
- امام، سید محمد؛ رضایی پور، امیرمحمد و فوری‌نژاد، ابوالفضل. (۱۳۹۸). اندازه‌گیری ویژگی‌های هندسی و مورفولوژیکی مغز پسته با استفاده از ماشین بینایی. نشریه علمی پژوهش‌های علوم و صنایع غذایی ایران، ۱۵(۵)، ۵۶۵-۵۷۵.
- عبداله‌نژاد باروق، علیرضا؛ عادلی‌نیا، محمد و محمدی، مجید. (۱۳۹۶). کلاس‌بندی پسته با استفاده از تکنیک‌های پردازش تصویر و شبکه نروفازی تطبیق‌پذیر. نشریه علمی ماشین‌های کشاورزی، ۱۶(۱)، ۱۱-۲۰.

References

Abbaszadeh, M., Rahimifard, A., Eftekhari, M., Ghayoumi Zadeh, H., Fayazi, A., Dini, A., & Danaeian, M. (2019). Deep learning-based classification of defective pistachios via deep autoencoder neural networks. *arXiv preprint, arXiv:1906.11878*. <https://doi.org/10.48550/arXiv.1906.11878>.

Avuçlu, E. (2023). Classification of pistachio images using VGG16 and VGG19 deep learning models. *International Scientific and Vocational Studies Journal*, 7(2), 79–86. <https://doi.org/10.47897/bilmes.1328313>.

Avuçlu, E. (2023). Classification of pistachio images with the ResNet deep learning model. *Selcuk Journal of Agriculture and Food Sciences*, 37(2), 291–300. <https://doi.org/10.15316/SJAFS.2023.029>.

Farazi, M., Abbas-Zadeh, M. J., & Moradi, H. (2017, November). A machine vision-based pistachio sorting using transferred mid-level image representation of convolutional neural network. Paper presented at the 10th Iranian Conference on Machine Vision and Image Processing (MVIP) IEEE, Isfahan, Iran. <https://doi.org/10.1109/IRANIANMVIP.2017.8342335>.

Goldberg, D. E. (1989). *Genetic algorithms in search, optimization, and machine learning*. Addison-Wesley.

Ha, M. H., Tian, X. D., & Zhang, Z. R. (2005, August). Optical font recognition based on Gabor filter. In *International Conference on Machine Learning and Cybernetics (ICMLC)*. Guangzhou, China. <https://doi.org/10.1109/ICMLC.2005.1527799>.

Heidary-Sharifabad, A., Zarchi, M. S., Emadi, S., & Zarei, G. (2021). An efficient deep learning model for cultivar identification of a pistachio tree. *British Food Journal*, 123(14), 3592–3609. <https://doi.org/10.1108/BFJ-12-2020-1100>.

Indra, D., Fadlillah, H. M., Kasman., & Ilmawan, L. B. (2021, December). Rice texture analysis using GLCM features. Paper presented at the 2021 International Conference on Electrical, Computer and Energy Technologies (ICECET), Cape Town, South Africa.

Jain, A. K., & Bhattacharjee, S. K. (1992). Address block location on envelopes using Gabor filters. *Pattern Recognition*, 25(12), 1459–1477. [https://doi.org/10.1016/0031-3203\(92\)90144-O](https://doi.org/10.1016/0031-3203(92)90144-O).

Kumar, S. S., Sigappi, A. N., Thomas, G. A., Robinson, Y. H., & Raja, S. P. (2024). Classification and analysis of pistachio species through neural embedding-based feature extraction and small-scale machine learning techniques. *International Journal of Image and Graphics*, 24(3), 2450032. <https://doi.org/10.1142/s0219467824500323>.

Liang, L., Liu, Y., & Wang, M. (2023, July). Gabor-DCTnet: A simple and efficient method for image classification. In *2023 19th International Conference on Natural Computation, Fuzzy Systems and Knowledge Discovery (ICNC-FSKD)*. Harbin, China. <https://doi.org/10.1109/ICNC-FSKD59587.2023.10281063>.

Madhavi, D., Mohammed, K. M., Jyothi, N., & Patnaik, M. R. (2019). A hybrid content-based image retrieval system using log-Gabor filter banks. *International Journal of Electrical and Computer Engineering*, 9(1), 237–244. <https://doi.org/10.11591/ijece.v9i1.pp237-244>.

Mahdavi-Jafari, S., Salehinejad, H., & Talebi, S. (2008, December). A pistachio nuts classification technique: An ANN-based signal processing scheme. Paper presented at the *International Conference on Computational Intelligence for Modelling, Control and Automation (CIMCA)*, Vienna, Austria. <https://doi.org/10.1109/CIMCA.2008.150>.

Manjunath, B. S., & Ma, W. Y. (1996). Texture features for browsing and retrieval of image data. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 18(8), 837–842. <https://doi.org/10.1109/34.531803>.

Nouri-Ahmadabadi, H., Omid, M., Mohtasebi, S. S., & Firouz, M. S. (2017). Design, development, and evaluation of an online grading system for peeled pistachios equipped with machine vision technology and support vector machine. *Information Processing in Agriculture*, 4(4), 333–341. <https://doi.org/10.1016/j.inpa>.

Omid, M., Mahmoudi, A., & Omid, M. (2009). An intelligent system for sorting pistachio nut varieties. *Expert Systems with Applications*, 36(9), 11528–11535. <https://doi.org/10.1016/j.eswa.2009.03.040>.

Patel, F., Mewada, S., Degadwala, S., & Vyas, D. (2023, October). Recognition of pistachio species with transfer learning models. Paper presented at the International Conference on Self Sustainable Artificial Intelligence Systems (ICSSAS), Erode, India. <https://doi.org/10.1109/ICSSAS57918.2023.10331907>.

Shamsi-Goshki, A., Sariyazdi, S., Nazmabadipour, N., & Shamsi-Goshki, H. (2013). Pistachio varieties recognition based on machine vision and Gabor filters. *Iranian Journal of Biosystems Engineering*, 43(2), 125–131. <https://doi.org/10.22059/ijbse.2013.35214>. (In Persian).

Singh, D., Taspinar, Y. S., Kursun, R., Cinar, I., Koklu, M., Ozkan, I. A., & Lee, H. N. (2022). Classification and analysis of pistachio species with pre-trained deep learning models. *Electronics*, 11(7), 981. <https://doi.org/10.3390/electronics11070981>.

Subbarao, M., Ram, G., & Varma, D. (2023, February). Performance analysis of pistachio species classification using support vector machine and ensemble classifiers. Paper presented at the International Conference on Recent Trends in Electronics and Communication (ICRTEC), Mysore, India. <https://doi.org/10.1109/ICRTEC56977.2023.10111889>.

Wang, M., Gao, L., Huang, X., Jiang, Y., & Gao, X. (2019). A texture classification approach based on the integrated optimization for parameters and features of Gabor filter via hybrid ant lion optimizer. *Applied Sciences*, 9(11), 2173. <https://doi.org/10.3390/app9112173>.