

# Classification of Pistachio Varieties Using MobileNet Deep Learning Model

Sekineh Asadi Amiri<sup>1</sup>, Mohammadsam Andi<sup>2</sup>

<sup>1</sup> Assistant Professor, Dept. of Computer Engineering, Faculty of Engineering and Technology, University of Mazandaran, Babolsar, Iran

[s.asadi@umz.ac.ir](mailto:s.asadi@umz.ac.ir)

<sup>2</sup> MSc. Student, Dept. of Computer Engineering, Faculty of Engineering and Technology, University of Mazandaran, Babolsar, Iran

[m.andi05@umail.umz.ac.ir](mailto:m.andi05@umail.umz.ac.ir)

## Abstract:

Pistachio, a flowering plant from the Anacardiaceae family, is categorized into various types based on its physical characteristics. Due to its high market value and nutritional importance, accurate identification and packaging based on the pistachio variety are essential for addressing export challenges. Pistachio classification is often performed by electromechanical machines, but these machines lack the necessary precision and can damage the pistachio kernels. Therefore, there is a growing demand for new technologies to improve pistachio classification and separation. In this study, we used a modified version of the MobileNetV3 deep learning model to identify different pistachio varieties. Additionally, by leveraging the small version of MobileNet, we can efficiently deploy the trained model on smartphones, as it is optimized for computational efficiency. The research was conducted using a dataset of 2148 images representing the Kirmizi and Siirt pistachio varieties. To increase the number and diversity of images, data augmentation techniques were applied. This helps prevent overfitting and enables the model to generalize better to unseen data. Our modified MobileNetV3 model achieved an accuracy of 99.30% in identifying the two pistachio varieties, outperforming existing classification methods.

**Keywords:** Pistachio classification, Deep learning, Neural network, Image processing.

**Article Type:** Research

---

**Received:** 02. 06. 2024

**Revised:** 27. 08. 2024

**Accepted:** 16. 09. 2024

**Corresponding author:** S. Asadi Amiri

**Corresponding author's address:** Iran – Mazandaran – Babolsar – University of Mazandaran – Faculty of Engineering and Technology



Copyright © 2025 The Authors. Published by Iranian Association of Electrical and Electronics Engineers.

This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International license

(<https://creativecommons.org/licenses/by-nc/4.0/>). Non-commercial uses of the work are permitted, provided the

original work is properly cited.

## 1. Motivation of the work

Accurate classification of pistachio varieties is vital due to their high market value and nutritional benefits, particularly for export markets. Traditional electromechanical sorting machines often lack the precision needed, leading to damaged kernels and inefficiencies in packaging. Misclassification can compromise product quality and hinder meeting export standards, especially for key varieties like Kirmizi and Siirt, which are essential for production and profitability. Manual sorting is time-consuming and prone to human error, underscoring the need for advanced technological solutions. Deep learning models, such as MobileNetV3, offer high accuracy and computational efficiency, making them ideal for automating pistachio classification. Deploying these models on smartphones enhances their practicality and scalability for industrial and commercial applications. This research aims to bridge the gap between current inefficiencies in pistachio sorting and the potential of deep learning technologies, providing a robust, accurate, and efficient classification system to improve quality control and boost the economic viability of pistachio exports.

## 2. Contributions

This study introduces a novel method for classifying pistachio varieties using a modified MobileNetV3 deep learning model optimized for mobile deployment. Key contributions include replacing the Flatten layer with Global Average Pooling and adding Dense layers with 128 and 64 neurons, enhancing feature extraction and classification accuracy while reducing computational complexity. Comprehensive data augmentation techniques—such as rotation, translation, zooming, and mirroring—were employed to expand the training dataset, improving model robustness and preventing overfitting. The proposed method achieved a classification accuracy of 99.30%, outperforming traditional methods like k-NN and deep models such as VGG16 and VGG19. Additionally, a comparative analysis with previous research highlights the superior performance and efficiency of the modified MobileNetV3Small model. This work sets a new benchmark for pistachio classification, offering practical solutions for the agricultural industry to enhance quality control, reduce manual labor, and increase export reliability.

## 3. Procedures

The study utilized a dataset of 2,148 high-resolution images (600x600 pixels) of pistachios from two varieties: Kirmizi (1,232 images) and Siirt (916 images), captured with a Prosilica GT2000C camera under controlled conditions to minimize shadows and damage. Initial preprocessing involved noise reduction to ensure clarity and consistency. The dataset was split into 80% training and 20% testing subsets. Data augmentation techniques, including rotations up to 180 degrees, translations in four

directions by 10%, zooming by 10%, and horizontal mirroring, were applied to increase the training data to 4,051 images, enhancing diversity and preventing overfitting. The core procedure involved modifying the MobileNetV3Small architecture by replacing the Flatten layer with Global Average Pooling and adding two Dense layers with 128 and 64 neurons. ReLU activation functions and Dropout layers were incorporated to improve network performance and reduce overfitting. The model was implemented using Python and trained with transfer learning, leveraging pre-trained weights, the Adam optimizer, and Sparse Categorical Crossentropy loss. Training was conducted on a system with an Intel Core i7-8750H processor and 16 GB RAM, with images resized to 224x224 pixels to match MobileNetV3's input requirements.

## 4. Findings

The modified MobileNetV3Small model achieved an impressive 99.30% accuracy in classifying Kirmizi and Siirt pistachio varieties, correctly identifying 427 out of 430 test images. This performance surpasses traditional methods like k-NN (94.18%) and other deep learning models such as VGG16 and VGG19 (up to 98.84%). The confusion matrix revealed minimal misclassifications, indicating high precision and recall. Additional evaluation metrics, including specificity, F1-Score, and ROC curves, confirmed the model's superior performance. The ROC curve exhibited a high Area Under the Curve (AUC), demonstrating excellent discriminative ability. Data augmentation significantly enhanced model robustness by increasing dataset diversity, allowing better generalization to new data. Compared to previous studies, the proposed method not only provided higher accuracy but also benefited from reduced computational complexity and faster training times, making it a more efficient and effective solution for real-world pistachio classification.

## 5. Conclusion

This research successfully developed a highly accurate method for classifying pistachio varieties using a modified MobileNetV3Small deep learning model, achieving 99.30% accuracy. Architectural enhancements, including Global Average Pooling and additional Dense layers, improved feature extraction and classification performance while reducing computational demands. Comprehensive data augmentation increased dataset diversity and model robustness, effectively preventing overfitting. The optimized MobileNetV3Small model is suitable for deployment on mobile devices, enabling practical applications in industrial and commercial settings for real-time pistachio classification and quality control. The study demonstrates the potential of deep learning and image processing technologies to enhance agricultural practices, providing a reliable and efficient solution to manual and electromechanical sorting challenges. Future work could extend the model to classify additional pistachio varieties and integrate it into

comprehensive quality management systems, further improving the economic viability and operational efficiency of pistachio production and export.

## طبقه‌بندی گونه‌های پسته با به‌کارگیری مدل یادگیری عمیق موبایل نت

سکینه اسدی امیری<sup>۱</sup>، محمدسام اندی<sup>۲</sup>

۱- استادیار- گروه مهندسی کامپیوتر- دانشکده مهندسی و فناوری - دانشگاه مازندران - بابلسر- ایران

[s.asadi@umz.ac.ir](mailto:s.asadi@umz.ac.ir)

۲- دانش آموخته کارشناسی ارشد- گروه مهندسی کامپیوتر- دانشکده مهندسی و فناوری - دانشگاه مازندران - بابلسر- ایران

[m.andi05@umail.umz.ac.ir](mailto:m.andi05@umail.umz.ac.ir)

**چکیده:** پسته، گیاهی گل‌دار از تیره پسته‌ایان است که بسته به شکل ظاهری آن به انواع مختلفی تقسیم می‌شود. این میوه قیمت و ارزش غذایی بالایی دارد و تشخیص دقیق نوع و بسته‌بندی بر اساس آن از چالش‌های صادرات پسته به‌شمار می‌رود. دسته‌بندی پسته اغلب توسط ماشین‌های الکترومکانیکی انجام می‌شود؛ اما این دستگاه‌ها دقت لازم را ندارند و موجب آسیب به مغز پسته می‌شوند. بنابراین نیاز به فناوری‌های جدیدی برای دسته‌بندی و جداسازی انواع پسته محسوس است. در این پژوهش، با استفاده از نسخه اصلاح‌شده مدل یادگیری عمیق MobileNetV3، گونه‌های پسته را شناسایی کردیم. همچنین با به‌کارگیری نسخه Small موبایل‌نت، می‌توانیم مدل یاد گرفته شده را بر روی تلفن‌های هوشمند اجرا کنیم، زیرا این مدل به دلیل بهینگی پردازشی، برای این امر مناسب است. برای این تحقیق، از مجموعه داده‌ای از ۲۱۴۸ تصویر پسته با گونه‌های گرمیزی و سیرت استفاده شد. برای افزایش تعداد و تنوع تصاویر، داده‌افزایی روی تصاویر انجام شد. با افزایش داده‌ها و ایجاد تنوع در مجموعه آموزش، می‌توان از بیش‌برازش جلوگیری کرد و مدل را قادر ساخت تا به نحو بهتری داده‌های جدید را پوشش دهد. سپس از نسخه اصلاح‌شده شبکه MobileNetV3 برای شناسایی گونه‌های پسته استفاده کردیم. روش پیشنهادی ما توانست با دقت ۹۹٫۳۰٪ این دو گونه پسته را شناسایی کند و برتر از روش‌های موجود است.

**کلمات کلیدی:** طبقه‌بندی پسته، یادگیری عمیق، شبکه عصبی، پردازش تصویر

**نوع مقاله:** پژوهشی

دریافت: ۱۴۰۳/۰۳/۱۳

بازنگری: ۱۴۰۳/۰۶/۰۶

پذیرش: ۱۴۰۳/۰۶/۲۶

نام نویسنده‌ی مسئول: دکتر سکینه اسدی امیری

نشانی نویسنده‌ی مسئول: ایران - مازندران - بابلسر - دانشگاه مازندران - دانشکده‌ی مهندسی و فناوری

## ۱- مقدمه

[۹]. سپس از نسخه اصلاح شده شبکه عمیق MobileNetV3 برای طبقه‌بندی دو گونه پسته استفاده شده است. در روش پیشنهادی با اعمال تغییراتی در ساختار مدل MobileNetV3 توانستیم عملکرد مدل را ارتقا ببخشیم.

در ادامه این پژوهش، پیشینه پژوهش در بخش ۲ بیان شده است. مجموعه داده مورد استفاده در بخش ۳ توضیح داده شده است. روش پیشنهادی در بخش ۴ معرفی شده است. در بخش ۵ نتایج حاصل از معیارهای ارزیابی مختلف و ماتریس سردرگمی آورده شده است. در نهایت نتیجه‌گیری در بخش ۶ ارائه شده است.

## ۲- پیشینه پژوهش

اوزکان و همکاران [۳] از تکنیک‌های پردازش تصویر و یادگیری ماشین برای طبقه‌بندی دو نوع مختلف پسته به طور خاص پسته‌های کرمیزی و سیرت، استفاده کردند. دیتاست استفاده شده در این پژوهش مشابه با دیتاستی است که در پژوهش حاضر نیز مورد استفاده قرار گرفته است. آنان با استفاده از طبقه‌بندی  $k$  نزدیک‌ترین همسایه<sup>۵</sup> به دقت تشخیص ۹۴٫۱۸٪ رسیدند. این امر می‌تواند مبنایی برای مقایسه نتایج حاصل از پژوهش ما با نتایج ارائه شده توسط اوزکان و همکاران باشد. امید و همکاران [۱۰] یک سیستم بر مبنای پردازش تصویر و تکنیک‌های یادگیری ماشین برای طبقه‌بندی پسته‌های پوست شده به پنج دسته ارائه کردند. در این پژوهش، الگوریتم‌های جستجوی معماری عصبی<sup>۶</sup> و ماشین بردار پشتیبانی<sup>۷</sup> برای طبقه‌بندی استفاده شد.

سینگ و همکاران [۱۱] در پژوهش خود به بررسی دو نوع پسته کرمیزی و سیرت پرداختند. آن‌ها برای طبقه‌بندی این دو نوع پسته از سه شبکه عصبی عمیق شامل AlexNet، VGG16 و VGG19 استفاده کردند و به ترتیب به دقت ۹۴٫۴۲٪، ۹۸٫۸۴٪ و ۹۸٫۱۴٪ دست یافتند. آن‌ها از دیتاستی مشابه با دیتاست مورد استفاده در پژوهش حاضر استفاده کردند. این موضوع امکان مقایسه مستقیم نتایج حاصل از روش‌های مختلف طبقه‌بندی را فراهم می‌کند و می‌تواند به عنوان معیاری برای ارزیابی عملکرد مدل‌ها و الگوریتم‌های مورد استفاده در پژوهش ما در نظر گرفته شود.

دهیر و همکاران [۱۲] از شبکه‌های عصبی کانولوشنی پیش‌آموزش‌دیده برای طبقه‌بندی انواع مختلفی از مغزها استفاده کردند و دقتی برابر با ۹۸٪ دست یافتند.

عباس‌زاده و همکاران [۱۳] با استفاده از شبکه‌های عصبی عمیق دقت طبقه‌بندی پسته‌های سالم و معیوب را به ۸۰٫۳ درصد رساندند.

دینی و همکاران [۱۴] برای طبقه‌بندی پسته‌های سالم و معیوب از الگوریتمی استفاده کردند که براساس شبکه‌های عصبی کانولوشنی پیش‌آموزش‌دیده بود و دقت طبقه‌بندی‌ها را به ترتیب ۹۵٫۸ و ۹۷٫۲ درصد گزارش کردند.

پسته یک آجیل سرشار از مواد مغذی است که حاوی اسیدهای چرب ضروری برای قلب، پروتئین، فیبر و مواد معدنی مانند پتاسیم، منیزیم و ویتامین‌هاست. رنگ منحصربه‌فرد سبز و بنفش مغز پسته به دلیل وجود لوتئین و آنتوسیانین در آن است [۱]. پسته در مقایسه با سایر آجیل‌ها دارای مشخصات تغذیه‌ای سالم‌تر با محتوای چربی کمتری است. کشت پسته در غرب آسیا آغاز شد؛ سپس از طریق ایران به حوزه مدیترانه گسترش یافت. ایالات متحده بزرگ‌ترین تأمین‌کننده پسته و سپس ترکیه و ایران که روی هم رفته ۹۷٪ پسته جهان را تولید می‌کنند [۲]. این محصول مغذی فواید بسیاری دارد. گونه‌های کرمیزی<sup>۱</sup> و سیرت<sup>۲</sup> گونه‌های ارجح برای افزایش تولید پسته در ترکیه هستند [۳]. هر ۱۰۰ گرم از پسته دارای ۵۶۰ کالری می‌باشد؛ از این رو مغز پسته منبع خوبی از چربی (۵۰ تا ۶۰ درصد) است. علاوه بر آن، به دلیل ویژگی‌های ظاهری، به طور گسترده‌ای در صنایع شیرینی‌پزی و تولید بستنی و انواع خوراکی‌ها استفاده می‌شود [۴، ۵].

از این رو تولید پسته در بسیاری از کشورها در حال گسترش است؛ با این حال تولید تجاری آن تحت تأثیر ویژگی‌های فیزیولوژیکی نامطلوب، انسداد پوسته، دانه‌های خالی، خشکی، شوری و بیماری‌های قارچی قرار گرفته است. در این میان، گونه سیرت به دلیل سرعت بالای ترک خوردن و شکل گرد، ترجیح داده شده است [۶]. شکل ۱ دو گونه پسته کرمیزی و سیرت را نشان می‌دهد.



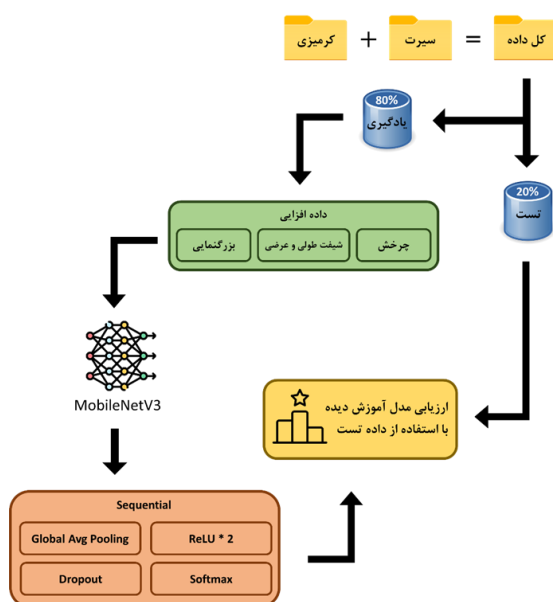
شکل (۱): دو گونه رایج پسته

علاوه بر این به دلیل ارزش اقتصادی، گونه‌های کرمیزی و سیرت تولید بیشتری دارند. برای افزایش سودآوری بازار پسته به جداسازی و طبقه‌بندی انواع مختلف این محصول نیاز است. از طرفی جداسازی پسته اغلب به صورت دستی انجام می‌شود که به دلیل دقت پایین چشم انسان، احتمال خطا در آن زیاد است. همچنین، جداسازی دستی فرآیندی زمان‌بر بوده و اهداف برداشت با سرعت بالا را محقق نمی‌کند. بنابراین لازم است از تکنیک و فناوری‌های جدید برای بهبود طبقه‌بندی انواع مختلف آن استفاده کرد. فناوری مورد استفاده می‌تواند تکنیک‌های پردازش تصویر با شبکه عصبی عمیق و روش‌های مناسب هوش مصنوعی باشد [۷، ۸].

در این پژوهش، مجموعه داده‌ای از ۲۱۴۸ تصویر پسته با گونه‌های کرمیزی و سیرت استفاده شد. برای افزایش تعداد و تنوع تصویر، داده‌افزایی<sup>۳</sup> روی تصاویر انجام شد. افزایش داده، با ایجاد تنوع در داده‌های آموزشی، می‌تواند به جلوگیری از بیش‌برازش<sup>۴</sup> کمک کند و باعث شود مدل بتواند به نحو بهتری داده‌های جدید را پوشش دهد

#### ۴- روش پیشنهادی

در این مقاله، روش جدیدی برای شناسایی گونه‌های پسته ارائه شده است. ابتدا مجموعه داده که شامل دو کلاس کرمیزی و سیرت است به دو بخش آموزش و آزمون با نسبت ۸۰ به ۲۰ تقسیم می‌شود. سپس تعداد و تنوع نمونه‌های آموزشی با فرآیند داده‌افزایی افزایش می‌یابند. این فرآیند به مدل کمک می‌کند تا با تنوع بیشتری از داده‌ها آموزش ببیند و بتواند بهتر عمل کند. در پایان با استفاده از نسخه بهبود یافته شبکه عصبی عمیق MobileNetV3Small، دو گونه کرمیزی و سیرت با دقت بالایی شناسایی می‌شوند. مراحل روش پیشنهادی در شکل ۳ نشان داده شده است.



شکل (۳): طرح کلی مراحل در روش پیشنهادی در شناسایی پسته

#### ۴-۱- پیش‌پردازش

در مرحله پیش‌پردازش، ابتدا مجموعه داده به دو دسته آموزش و آزمون تقسیم می‌شوند. همان‌طور که اشاره شد، مجموعه داده مورد استفاده، ۲۱۴۸ تصویر از دو گونه پسته را در بر می‌گیرد که شامل ۱۲۳۲ تصویر از گونه کرمیزی و ۹۱۶ تصویر از گونه سیرت است. ۸۰ درصد از داده‌ها برای فرآیند یادگیری مدل و ۲۰٪ برای آزمون مدل استفاده می‌شود. از میان داده‌هایی که در فرآیند یادگیری مدل مورد استفاده قرار می‌گیرد، ۲۰٪ آن برای اعتبارسنجی<sup>۱</sup> و مابقی برای آموزش<sup>۱۰</sup> در نظر گرفته می‌شود. برای بهبود فرآیند یادگیری مدل، فرآیند داده‌افزایی روی نمونه‌های آموزش انجام شده است. داده‌افزایی در داده‌کاوی، به سازوکارهایی برای افزایش شمار داده‌ها گفته می‌شود. این داده‌های جدید با ایجاد کپی‌ها و نمونه‌هایی از داده‌های موجود یا ساخت داده‌های جدید با الگوبرداری از داده‌های کنونی، تولید می‌شوند [۱۷]. با انجام داده‌افزایی بر روی تصاویر آموزش، ۴۰۵۱ تصویر به تعداد تصاویر اعتبارسنجی و آموزش اضافه شد. در فرآیند داده‌افزایی، از


کاسانت و همکاران [۱۵] از شبکه عصبی پارتو کوانتومی<sup>۸</sup> در طبقه‌بندی استفاده کردند و در تعیین کیفیت محصول به دقت ۸۸ درصد رسیدند.

چتین و همکاران [۱۶] الگوریتمی ارائه دادند که می‌توانست پسته‌های با پوست باز را از پوست بسته تشخیص دهد. روش تشخیص به این صورت بود که پسته‌ها به صفحه‌ای فولادی برخورد می‌کردند و صدایی تولید می‌شد، که صدای تولید شده در حالت باز و بسته متفاوت بود.

روش‌های قبلی مانند مدل سنتی K-NN و مدل‌های یادگیری عمیق مانند VGG16 و VGG19، با چالش‌هایی مواجه هستند. برای نمونه، این مدل‌های یادگیری عمیق به دلیل تعداد زیاد لایه‌ها و پارامترها، کارایی کمتری دارند. در مقابل، MobileNetV3Small که در این مقاله استفاده شده است، با طراحی سبک‌تر و بهینه‌تر خود، عملکرد بهتری را ارائه داده است. علاوه بر این، در این پژوهش، تغییراتی در معماری MobileNetV3Small اعمال کردیم که شامل استفاده از لایه Global Average Pooling به جای لایه Flatten و افزودن دو لایه Dense به ترتیب با ۱۲۸ و ۶۴ نرون بعد از لایه Global Average Pooling است. این تغییرات باعث شده‌اند تا مدل با پارامترهای کمتر و تنظیمات بهینه‌تر، دقت بالاتری در طبقه‌بندی تصاویر پسته به دست آورد. این ترکیب، تعادلی مناسب بین پیچیدگی و کارایی فراهم کرده و مدل را قادر ساخته تا ویژگی‌ها را بهتر یاد بگیرد و عملکرد طبقه‌بندی بهبود یابد.

#### ۳- مجموعه داده

داده‌های مورد استفاده در این پژوهش شامل تصاویری با وضوح ۶۰۰ در ۶۰۰ پیکسل از پسته‌هایی با دو نوع کرمیزی و سیرت هستند که با دوربین عکاسی Prosilica GT2000C از فاصله ۱۵ سانتی‌متری از پسته‌ها ثبت شده‌اند. برای کاهش سایه‌ها و خرابی، تصاویر در جعبه‌های مخصوص ثبت شده و نویز آن‌ها با استفاده از تکنیک‌های پردازش تصویر حذف شده است. ۲۱۴۸ نمونه تصویر برای این دو نوع پسته وجود دارد که ۱۲۳۲ تصویر از نوع کرمیزی و ۹۱۶ تصویر از نوع سیرت است. چند نمونه از تصاویر این مجموعه داده در شکل ۲ نشان داده شده است.



شکل (۲): نمونه‌ای از تصاویر مجموعه داده برای دو گونه پسته کرمیزی و سیرت

Small، دو مدل بهینه‌شده و جدید هستند که برای استفاده در سناریوهایی با منابع زیاد یا کم طراحی شده‌اند. این مدل‌ها برای شناسایی و دسته‌بندی اشیاء کاربرد دارند. با استفاده از روش‌های پیشرفته مانند Lite Reduced Atrous Spatial Pyramid Pooling (LR-ASPP)، دقت و سرعت این مدل‌ها نسبت به نسخه‌های قبلی بهبود یافته است [۱۹].

در این پژوهش علاوه بر استفاده از مدل پایه موبایل‌نت، لایه‌های بیشتری برای استخراج و طبقه‌بندی ویژگی‌ها به شبکه اضافه شده است. پس از لایه‌های کانولوشن، از یک لایه Global Average Pooling استفاده شده است که جایگزین بهتری برای لایه سنتی Flatten می‌باشد. این لایه با محاسبه میانگین ابعاد فضایی و تبدیل آن‌ها به یک بعد، تشخیص ویژگی‌ها را آسان‌تر می‌کند. سپس، لایه‌های Dense به شبکه اضافه می‌شوند تا ویژگی‌ها طبقه‌بندی شوند. این لایه‌ها برای یادگیری الگوهای پیچیده در ویژگی‌های استخراج شده و برای انجام طبقه‌بندی تصاویر به دسته‌های مختلف استفاده می‌شوند. تابع فعال‌سازی ReLU برای بهبود توانایی شبکه و تبدیل آن به مؤلفه غیرخطی در تحلیل ارتباطات پیچیده در داده‌ها استفاده می‌شود. از یک لایه Dropout نیز استفاده شده است تا به طور تصادفی کسری از واحدهای ورودی را در طول آموزش رها کند و در نتیجه، از بیش‌برازش مدل روی داده‌های موجود جلوگیری کند. معماری شبکه عصبی عمیق موبایل‌نت بهبودیافته در شکل ۵ نشان داده شده است. تغییراتی که در روش پیشنهادی بر روی این معماری انجام شده است، به صورت بلوک سبز رنگ نشان داده شده است.

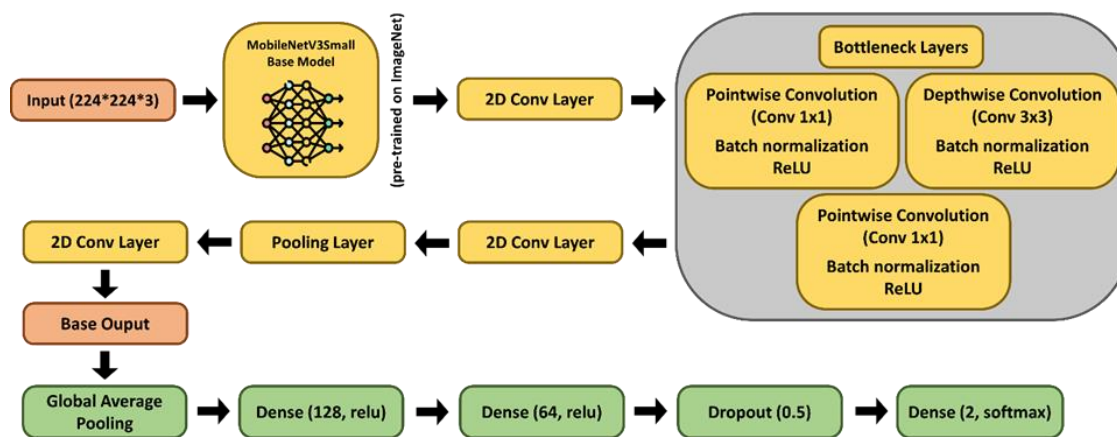
چرخش تصاویر با حداکثر ۱۸۰ درجه، انتقال تصویر به چهار جهت با میزان ۱۰ درصد، بزرگنمایی تصاویر با میزان ۱۰ درصد و همچنین آینه‌سازی تصاویر استفاده شده است. نمونه‌هایی از تصاویری که با داده‌افزایی تولید شده‌اند در شکل ۴ نشان داده شده است.



شکل (۴): تصاویر تولید شده در فرآیند داده‌افزایی

#### ۴-۲- نسخه اصلاح شده شبکه عصبی موبایل‌نت

شبکه عصبی کانولوشن نوعی از شبکه‌های عمیق است که ویژگی‌های تصویر را از طریق لایه‌های کانولوشنی متعدد استخراج می‌کند و به طور گسترده در طبقه‌بندی تصاویر مورد استفاده قرار می‌گیرد. با افزایش تعداد داده‌های تصویری که توسط دستگاه‌های تلفن همراه پردازش می‌شوند، استفاده از شبکه‌های عصبی در تلفن‌های همراه رایج شده است. با این حال، این شبکه‌ها به محاسبات گسترده و سخت‌افزار پیشرفته نیاز دارند که سازگاری آن‌ها با تلفن‌های همراه را دشوار می‌کند. در این میان شبکه یادگیری عمیق MobileNet می‌تواند تعادل مناسبی را بین کارایی و دقت برای کاربردهای واقعی طبقه‌بندی تصویر در تلفن‌های همراه فراهم کند [۱۸]. معماری MobileNetV3 که با استفاده از الگوریتم جستجوی معماری عصبی و روش‌های جدید طراحی شده است، برای بهینه‌سازی و استفاده در دستگاه‌های تلفن همراه به کار می‌رود. MobileNetV3-Large و MobileNetV3-



شکل (۵): فلوجارت معماری نسخه بهبود یافته موبایل‌نت

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (۱)$$

$$\text{Precision} = \frac{TP}{TP + FP} \quad (۲)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (۳)$$

$$F1 - \text{Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (۴)$$

$$\text{Specificity} = \frac{TN}{TN + FP} \quad (۵)$$

## ۵- نتایج پیاده‌سازی

در این مقاله روش جدیدی برای تشخیص دو گونه پسته ارائه شده است. برای سنجش عملکرد روش پیشنهادی، از معیارهای دقت<sup>۱۱</sup>، صحت<sup>۱۲</sup>، یادآوری<sup>۱۳</sup>، تشخیص<sup>۱۴</sup> و F1-Score، نمودار دقت و خطا<sup>۱۵</sup>، و همچنین ماتریس سردرگمی<sup>۱۶</sup> و نمودار ROC<sup>۱۷</sup> استفاده شده است. در پایان نیز نتایج حاصل از روش پیشنهادی را با کارهای پیشین مقایسه نمودیم، که نشان‌دهنده برتری روش پیشنهادی است.

### ۵-۱- ماتریس سردرگمی

ماتریس سردرگمی جدولی است که در یادگیری ماشین و طبقه‌بندی آماری برای ارزیابی عملکرد مدل استفاده می‌شود و با نمایش گرافیکی نتایج، خلاصه‌ای از پیش‌بینی‌ها را در مقایسه با مقادیر واقعی ارائه می‌دهد. این ماتریس از ردیف‌ها و ستون‌ها تشکیل شده است که به ترتیب کلاس‌های پیش‌بینی شده و کلاس‌های واقعی را نشان می‌دهند. قطر اصلی نمایانگر نمونه‌هایی است که به درستی طبقه‌بندی شده‌اند [۲۰]. شکل ۶، شیوه نمایش ماتریس سردرگمی را برای یک مسئله دو کلاسه نشان می‌دهد.

TN	FP
FN	TP

شکل (۶): نمایش ماتریس سردرگمی برای یک مسئله دو کلاسه


در این جدول، TP<sup>۱۸</sup> بیانگر تعداد نمونه‌هایی است که به درستی به عنوان مثبت پیش‌بینی شده‌اند. TN<sup>۱۹</sup> بیانگر تعداد نمونه‌هایی است که به درستی به عنوان منفی پیش‌بینی شده‌اند. FP<sup>۲۰</sup> بیانگر تعداد نمونه‌هایی است که به اشتباه به عنوان مثبت پیش‌بینی شده‌اند. FN<sup>۲۱</sup> بیانگر تعداد نمونه‌هایی است که به اشتباه به عنوان منفی پیش‌بینی شده‌اند.

### ۵-۲- معیارهای ارزیابی

با استفاده از مقادیر موجود در درایه‌های ماتریس سردرگمی، می‌توان به معیارهای ارزیابی مختلف دست یافت. فرمول محاسبه هر معیار ارزیابی در پایین ذکر شده است [۲۱، ۲۲].


### ۵-۳- نتایج روش پیشنهادی

روش پیشنهادی با زبان برنامه‌نویسی پایتون پیاده‌سازی شد. مدل MobileNetV3 با استفاده از یادگیری انتقالی، بهینه‌ساز Adam، و تابع خطای Sparse Categorical Crossentropy آموزش داده شد. آزمایش‌ها بر روی سیستمی با پردازنده Intel Core i7-8750H و ۱۶ گیگابایت حافظه RAM انجام شد. تصاویر که به ابعاد ۶۰۰ در ۶۰۰ پیکسل بودند، تغییر اندازه داده شدند و به ابعاد ۲۲۴ در ۲۲۴ پیکسل کاهش یافتند تا برای آموزش مدل آماده شوند. همچنین تنظیماتی انجام شد تا با استفاده از وزن‌های پیش‌آموزش‌دیده، آموزش بهینه‌تری انجام گیرد. شکل ۷، میزان دقت و خطای مدل در هر دوره از اجرای فرآیند یادگیری را نشان می‌دهد.



شکل (۷): نمودار دقت و خطا در دوره‌های اجرای یادگیری مدل

ماتریس سردرگمی حاصل از روش پیشنهادی برای دو گونه پسته کرمیزی و سیرت در شکل ۸ نشان داده شده است. همان‌طور که از ماتریس سردرگمی مشخص است روش پیشنهادی به خوبی قادر است نمونه‌های هر دو کلاس را با دقت خوبی شناسایی کند.



شکل (۹): نمودار ROC روش پیشنهادی روی مجموعه داده پسته


شکل ۱۰، نتیجه معیارهای ارزیابی روش پیشنهادی را نشان می‌دهد. در این شکل، روش پیشنهادی با بهترین نتیجه پژوهش‌های پیشین مقایسه شده است. همان‌طور که از نتایج مشخص است، روش پیشنهادی عملکرد بهتری در طبقه‌بندی پسته دارد. حداکثر دقت روش پیشنهادی ۹۹٫۳۰٪ به دست آمد که ۴۲۷ تصویر از ۴۳۰ تصویر پسته را به درستی دسته‌بندی کرد.

Pistachio Set Best Confusion Matrix			
TARGET \ OUTPUT	Kirmizi	Siirt	SUM
Kirmizi	244 56.74%	3 0.70%	247 98.79% 1.21%
Siirt	0 0.00%	183 42.56%	183 100.00% 0.00%
SUM	244 100.00% 0.00%	186 98.39% 1.61%	427 / 430 99.30% 0.70%

شکل (۸): ماتریس‌های سردرگمی برای دو کلاس کرمیزی و سیرت

نمودار ROC که در شکل ۹ نمایش داده شده است، توانایی مدل را در تفکیک بین نمونه‌های مثبت و منفی نشان می‌دهد. مساحت زیر منحنی (AUC) نیز به عنوان معیاری جامع برای ارزیابی کلی عملکرد مدل در تشخیص گونه‌های پسته استفاده می‌شود.

معیارهای ارزیابی به دست آمده از نسخه اصلاح شده موبایلنت در این پژوهش  
بهترین نتیجه به دست آمده در پژوهش‌های دیگر [۹]



شکل (۱۰): مقایسه نتیجه معیارهای ارزیابی حاصل از روش پیشنهادی با بهترین مدل پژوهش‌های دیگر

VGG16 به دلیل تعداد زیاد لایه‌ها و پارامترها، نیازمند منابع محاسباتی بیشتری هستند که ممکن است منجر به افزایش خطا و کاهش دقت شود. علاوه بر این، با تغییراتی که در ساختار مدل VGG16 ارائه نمودیم، منجر به بهبود عملکرد آن مدل شدیم. در روش پیشنهادی، از لایه Global Average Pooling به جای لایه Flatten استفاده شده است. همچنین دو لایه Dense به ترتیب با ۱۲۸ و ۶۴ نرون بعد از لایه Global Average Pooling اضافه شده است. این افزایش تعداد لایه‌ها سبب می‌شود تا مدل بتواند ویژگی‌ها را بهتر یاد بگیرد و عملکرد طبقه‌بندی بهبود یابد. همچنین، در این پژوهش از

روش پیشنهادی روی مجموعه داده پسته با سایر پژوهش‌های پیشین نیز مقایسه شده است و نتایج در جدول ۱ نمایش داده شده است. با توجه به نتایج به دست آمده، روش پیشنهادی ما در تشخیص و دسته‌بندی گونه‌های پسته عملکرد بهتری نسبت به روش‌های موجود دارد. این بهبود دقت به چند دلیل اصلی برمی‌گردد: استفاده از معماری MobileNetV3Small که به دلیل طراحی بهینه و سبک خود، توانسته است با کاهش پیچیدگی محاسباتی و تعداد پارامترها، دقت بالاتری را نسبت به مدل‌های سنتی مانند K-NN و مدل‌های پیچیده‌تری مانند VGG16 ارائه دهد. مدل‌های پیچیده‌تر مانند

داشته باشد. این عوامل به طور کلی باعث شده‌اند که روش پیشنهادی ما دقت بالاتری نسبت به روش‌های موجود داشته باشد و بتواند به طور موثرتری گونه‌های پسته را شناسایی و دسته‌بندی کند.

تکنیک داده‌افزایی استفاده شده است که با افزایش تنوع در مجموعه داده‌ها، مدل را قادر ساخته تا با نمونه‌های مختلف و متنوع‌تری آموزش ببیند. این امر به بهبود دقت مدل در تشخیص و دسته‌بندی گونه‌های پسته کمک شایانی کرده است. علاوه بر این، با بهینه‌سازی فرآیند آموزش و تنظیمات هایپرپارامترها، توانستیم مدل را به گونه‌ای آموزش دهیم که بهترین عملکرد را در تشخیص و دسته‌بندی گونه‌های پسته

جدول (۱): مقایسه روش پیشنهادی با پژوهش‌های انجام شده برای دسته‌بندی گونه‌های پسته کرمیزی و سیرت

روش	دسته‌بند	Specificity	F1-Score	Recall	Precision	Accuracy
Ozkan [3]	KNN	۰,۹۳۴۱	۰,۹۴۹۴	۰,۹۴۷۵	۰,۹۵۱۳	۰,۹۴۱۸
Singh [9]	AlexNet	۰,۸۹۵۵	۰,۹۴۹۶	۰,۹۸۶۹	۰,۹۱۵۰	۰,۹۴۴۲
Singh [9]	VGG19	۰,۹۷۰۱	۰,۹۸۲۷	۰,۹۹۱۳	۰,۹۷۴۲	۰,۹۸۱۴
Singh [9]	VGG16	۰,۹۸۰۱	۰,۹۸۸۴	۰,۹۹۵۶	۰,۹۸۲۸	۰,۹۸۸۴
مدل پیشنهادی	MobileNet	۰,۹۸۳۹	۰,۹۹۳۹	۱,۰۰۰۰	۰,۹۸۷۹	۰,۹۹۳۰

## ۶- نتیجه‌گیری

در این مقاله، روش جدیدی برای شناسایی گونه‌های پسته ارائه شده است. در روش پیشنهادی، با تغییراتی که در ساختار مدل MobileNetV3 ایجاد نمودیم، توانستیم قابلیت این مدل را در طبقه‌بندی گونه‌های پسته به ۹۹,۳۰٪ بهبود بخشیم. در روش پیشنهادی، از لایه Global Average Pooling، به جای لایه Flatten استفاده شده است. همچنین دو لایه Dense به ترتیب با ۱۲۸ و ۶۴ نرون بعد از لایه Global Average Pooling اضافه شده است. این افزایش تعداد لایه‌ها سبب می‌شود تا مدل بتواند، ویژگی‌ها را بهتر یاد بگیرد و عملکرد طبقه‌بندی بهبود یابد. همچنین، در این مقاله از نسخه شبکه عصبی عمیق MobileNetV3Small برای طبقه‌بندی دو گونه پسته کرمیزی و سیرت استفاده شده است. این مدل برای یادگیری، بهینه‌سازی شده است. لذا می‌توان از آن علاوه بر دستگاه‌های صنعتی، در دستگاه‌های قابل حمل مانند موبایل یا تلفن‌های هوشمند با کاربری‌های صنعتی یا تجاری، نیز استفاده کرد.

## مراجع

- [1] Dreher, Mark L., "Pistachio nuts: composition and potential health benefits," *Nutrition Reviews*, Vol. 70, No. 4, pp. 234-240, 2012.
- [2] Mateos, Raquel, et al., "Why should pistachio be a regular food in our diet?" *Nutrients*, Vol. 14, No. 15, p. 3207, 2022.
- [3] Ozkan, I.A., Koklu, M., Saraçoğlu, R., "Classification of Pistachio Species Using Improved K-NN Classifier," *Health*, Vol. 23, p. e2021044, 2021.
- [4] Kay, C.D., Gebauer, S.K., West, S.G., Kris-Etherton, P.M., "Pistachios Increase Serum Antioxidants and Lower Serum Oxidized-LDL in Hypercholesterolemic Adults," *The Journal of Nutrition*, Vol. 140, No. 6, pp. 1093-1098, 2010.
- [5] Bonifazi, G., Capobianco, G., Gasbarrone, R., Serranti, S., "Contaminant detection in pistachio nuts by different classification methods applied to short-wave infrared hyperspectral images," *Food Control*, Vol. 130, p. 108202, 2021.
- [6] Sheikhi, Abdollatif, et al., "Pistachio (*Pistacia spp.*) breeding," *Advances in Plant Breeding Strategies: Nut and Beverage Crops: Volume 4*, pp. 353-400, 2019.
- [7] Aghaei N, Akbarizadeh G, Kosarian A. Using ShuffleNet to design a deep semantic segmentation model for oil spill detection in synthetic aperture radar images. *Journal of Iranian Association of Electrical and Electronics Engineers* 2022; 19 (3) :131-144
- [8] Atay, Ü., "The investigation of classification systems used for pistachio and construction of an alternative classification system," Ph.D. Thesis, Harran University, Sanliurfa, 2007.
- [9] Sohrabi M S, Moazzami M. A Hybrid Approach for Probabilistic mid-term Electricity Price Forecasting using deep learning. *Journal of Iranian Association of Electrical and Electronics Engineers* 2023; 20 (4) :123-132
- [10] Omid, M., Firouz, M.S., Nouri-Ahmadabadi, H., Mohtasebi, S.S., "Classification of peeled pistachio kernels using computer vision and color features," *Engineering in Agriculture, Environment and Food*, Vol. 10, pp. 259-265, 2017.

<sup>14</sup> Speceficity

<sup>15</sup> Accuracy & Loss

<sup>16</sup> Confusion Matrix

<sup>17</sup> Receiver operating characteristic

<sup>18</sup> True Positives

<sup>19</sup> True Negatives

<sup>20</sup> False Positives

<sup>21</sup> False Negatives

<sup>22</sup> Area Under Curve

- [11] Singh, Dilbag, et al., "Classification and analysis of pistachio species with pre-trained deep learning models," *Electronics*, Vol. 11, No. 7, p. 981, 2022.
- [12] Dheir, I.M., Mettleq, A.S.A., Elsharif, A.A., "Nuts Types Classification Using Deep Learning," *International Journal of Academic Information Systems Research*, Vol. 3, pp. 12-17, 2020.
- [13] Abbaszadeh, M., Rahimifard, A., Eftekhari, M., Zadeh, H.G., Fayazi, A., Dini, A., Danaeian, M., "Deep Learning-Based Classification of the Defective Pistachios via Deep Autoencoder Neural Networks," *arXiv*, arXiv:1906.11878, 2019.
- [14] Dini, A., Zadeh, H.G., Rahimifard, A., Fayazi, A., Eftekhari, M., Abbaszadeh, M., "Designing a Hardware System to Separate Defective Pistachios From Healthy Ones Using Deep Neural Networks," *Iranian Journal of Biosystems Engineering*, Vol. 51, pp. 149-159, 2020.
- [15] Casasent, D.A., Sipe, M.A., Schatzki, T.F., Keagy, P.M., Lee, L.C., "Neural net classification of X-ray pistachio nut data," *LWT-Food Science and Technology*, Vol. 31, No. 2, pp. 122-128, 1998.
- [16] Cetin, A.E., Pearson, T.C., Tewfik, A.H., "Classification of closed and open shell pistachio nuts using principal component analysis of impact acoustics," *Proceedings of the 2004 IEEE International Conference on Acoustics, Speech, and Signal Processing*, Vol. 5, pp. V-677, 2004.
- [17] Shorten, Connor, Khoshgoftaar, Taghi M., "A survey on image data augmentation for deep learning," *Journal of Big Data*, Vol. 6, No. 1, pp. 1-48, 2019.
- [18] Qian, Siying, Ning, Chenran, Hu, Yuepeng, "MobileNetV3 for image classification," *Proceedings of the 2021 IEEE 2nd International Conference on Big Data, Artificial Intelligence and Internet of Things Engineering (ICBAIE)*, IEEE, pp. 490-497, 2021.
- [19] Howard, Andrew, et al., "Searching for mobilenetv3," *Proceedings of the IEEE/CVF International Conference on Computer Vision*, pp. 1314-1324, 2019.
- [20] Hastie, Trevor, et al., *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*, New York: Springer, 2009.
- [21] Cleophas, Ton J., et al., *Machine Learning in Medicine-A Complete Overview*, Cham; Heidelberg: Springer International Publishing, 2015.
- [22] Müller, Andreas C., Guido, Sarah, *Introduction to Machine Learning with Python: A Guide for Data Scientists*, O'Reilly Media, Inc., 2016.

## زیر نویس ها

<sup>1</sup> Kirmizi

<sup>2</sup> Siirt

<sup>3</sup> Augmentation

<sup>4</sup> Overfitting

<sup>5</sup> K-Nearest Neighbors

<sup>6</sup> Neural Architecture Search

<sup>7</sup> Support Vector Machine

<sup>8</sup> Pareto-Quantum Neural Network

<sup>9</sup> Validation

<sup>10</sup> Train

<sup>11</sup> Precision

<sup>12</sup> Accuracy

<sup>13</sup> Recall