

Design and Development of an Intelligent Golden Raisin Grading System Based on a Deep Convolutional Neural Network

H. Mirkhorasani¹, M. Abbasgholipour^{1*}, B. Mohammadi Alasti¹

1- Department of Bio-System Mechanical Engineering, Bon.C., Islamic Azad University, Bonab, Iran

(*- Corresponding Author Email: mahdiabbasgholipour@iau.ac.ir)

<https://doi.org/10.22067/jam.2026.97133.1458>

Introduction

The qualitative grading of raisins, as an important agricultural commodity, plays a critical role in determining market value, pricing strategies, and competitiveness in both domestic and international markets. Conventional intelligent grading approaches have largely relied on manual feature extraction and complex image preprocessing techniques, which substantially increase computational cost and system complexity. Consequently, there is an increasing demand for automated, accurate, and non-destructive grading methods based on deep learning technologies, particularly for golden Sultana raisins.

The primary objective of this study is to develop a deep convolutional neural network (DCNN) capable of grading and evaluating golden Sultana raisins without requiring explicit image preprocessing, while simultaneously reducing processing time and computational overhead. Unlike previous studies that mainly focused on computational limitations or restricted classification schemes, the proposed model automatically extracts discriminative visual features; including texture, shape, and colour to accurately assess raisin quality and size under varying imaging conditions. This capability enhances robustness against variations in illumination, imaging angle, and background, thereby eliminating the need for complex preprocessing pipelines or manual parameter tuning.

Materials and Methods

In this study, a dedicated deep convolutional neural network, referred to as Raisin_DCNN, was specifically designed for grading golden Sultana raisin grains. The dataset consisted of 3,320 images representing four distinct quality grades. All images were acquired using a flatbed scanner under controlled lighting conditions to ensure consistency and uniform image quality.

To increase dataset diversity and reduce the risk of overfitting, data augmentation techniques were applied. These techniques included random horizontal and vertical flipping, cropping, shifting, zooming, and rotation. Notably, the proposed model was trained directly on the augmented images without applying complex preprocessing operations or manual feature extraction methods.

The Raisin_DCNN architecture was purpose-built to effectively extract visual features from each raisin. It comprises multiple convolutional layers with small kernel sizes, followed by MaxPooling layers for spatial dimensionality reduction, and fully connected layers at the final stage. ReLU activation functions were employed to facilitate the learning of nonlinear feature representations, while a Softmax function was used in the output layer to perform four-class classification. The architecture was carefully optimised to achieve an appropriate balance between classification accuracy and computational efficiency.

The dataset was divided into training, validation, and test subsets. Network training was performed using the Adam optimisation algorithm in conjunction with the categorical cross-entropy loss function. Learning rate scheduling and early stopping strategies were implemented to improve convergence and prevent overfitting. Hyperparameter tuning was conducted through iterative experimentation based on validation performance.

For comprehensive performance evaluation, the proposed Raisin_DCNN model was compared with transfer learning approaches based on pre-trained InceptionV3 and InceptionResNetV2 architectures, as well as classical machine learning methods employing histogram-oriented gradients (HOG) and scale invariant feature transform (SIFT) feature extraction combined with support vector machine (SVM), k-nearest neighbours (KNN), and logistic regression (LR) classifiers.

Results and Discussion

Model performance was assessed using accuracy, precision, recall, and F1-score metrics. Experimental results demonstrated that the Raisin_DCNN model achieved an overall classification accuracy of 96%, outperforming both the transfer learning models and classical feature-based approaches. This superior performance highlights the effectiveness of the proposed network in automatically learning discriminative

features directly from images of raisins. Furthermore, the elimination of complex preprocessing stages significantly reduced computational cost, thereby improving system efficiency and practical applicability.

Conclusion

The results of this study confirm that a dedicated deep convolutional neural network can provide an accurate, robust, and reliable solution for the automatic grading of golden Sultana raisins. The proposed Raisin_DCNN model demonstrates strong potential for real-world deployment in industrial grading systems and offers an effective approach for enhancing quality control processes in agricultural product inspection.

Acknowledgements

The authors sincerely thank all individuals and research groups who contributed to this work and provided technical assistance throughout the study. The authors would like to thank Department of Bio-System Mechanical Engineering, Islamic Azad University of Bonab Branch for their support and participation in this study. The authors also gratefully acknowledge the anonymous reviewers for their insightful comments and constructive suggestions, which significantly improved the quality of this manuscript.

Keywords: Convolutional layer, Feature extraction, Machine learning, Non-destructive evaluation, Transfer learning

طراحی و توسعه سیستم هوشمند درجه‌بندی کشمش طلایی مبتنی بر شبکه عصبی کانولوشن عمیق

حامد میرخراسانی^۱، مهدی عباسقلی پور^{۱*}، بهزاد محمدی الستی^۱

تاریخ دریافت: ۱۴۰۴/۱۰/۰۵

تاریخ پذیرش: ۱۴۰۴/۱۲/۰۵

چکیده

در تحقیق حاضر هدف اصلی، توسعه یک روش هوشمند، غیرمخرب و دقیق برای ارزیابی کیفی کشمش تیزآبی طلایی، مبتنی بر شبکه عصبی کانولوشن عمیق با عنوان Raisin_DCNN و بدون نیاز به پیش‌پردازش پیچیده تصویر و استخراج دستی ویژگی‌ها است. به‌منظور آموزش و ارزیابی مدل پیشنهادی، مجموعه داده‌ای شامل ۳۳۲۰ تصویر از دانه‌های کشمش در چهار سطح کیفی مختلف جمع‌آوری شد. مدل پیشنهادی Raisin_DCNN یک شبکه عصبی کانولوشن عمیق اختصاصی است که به‌طور خاص برای استخراج ویژگی‌های بصری دانه‌های کشمش طراحی شده است. در این شبکه از چندین لایه کانولوشن و توابع فعال‌ساز برای طبقه‌بندی چهار کلاسه استفاده شد. این شبکه، درجه‌بندی کشمش تیزآبی طلایی را بدون نیاز به پیش‌پردازش و با زمان پردازش کمتر با تکیه بر استخراج خودکار ویژگی‌های تصویری در شرایط تصویربرداری متغیر را انجام می‌دهد. عملکرد مدل پیشنهادی با دو مدل از پیش‌آموزش‌دیده مبتنی بر یادگیری انتقالی شامل InceptionV3 و InceptionResNetV2 و همچنین چندین الگوریتم کلاسیک یادگیری ماشین مبتنی بر ویژگی‌های HOG و SIFT و طبقه‌بندی‌کننده‌های ماشین بردار پشتیبان (SVM)، نزدیک‌ترین همسایگی K (KNN) و رگرسیون لجستیک (LR) مقایسه شد. ارزیابی مدل‌ها با استفاده از معیارهای دقت، صحت، حساسیت و F1-score انجام گرفت. نتایج نشان داد که مدل Raisin_DCNN با دستیابی به دقت کلی ۹۶ درصد، عملکردی برتر نسبت به مدل‌های یادگیری انتقالی و روش‌های کلاسیک ارائه می‌دهد. بر اساس نتایج به‌دست‌آمده، طراحی یک شبکه عصبی عمیق اختصاصی متناسب با ویژگی‌های بصری دانه‌های کشمش، نقش مؤثری در افزایش دقت درجه‌بندی دارد.

واژه‌های کلیدی: ارزیابی غیرمخرب، استخراج ویژگی، لایه کانولوشن، یادگیری انتقالی، یادگیری ماشین

مقدمه

این محصول برخوردار است. تنوع گسترده گونه‌های کشمش که در سطح جهانی مبادله می‌شوند، این محصول را به یک کالای راهبردی و اقتصادی پراهمیت تبدیل کرده است. درجه‌بندی کشمش تیزآبی طلایی (فراوری شده از رقم انگور بی‌دانه سلطانی)، فرآیندی ضروری برای تعیین کیفیت و ارزش این محصول صادراتی است. این کار بر اساس معیارهایی مانند اندازه، رنگ و یکنواختی انجام می‌شود. درجه‌بندی استاندارد، کیفیت را تضمین کرده، رضایت مشتری را جلب می‌کند و اعتماد خریداران بین‌المللی را افزایش می‌دهد. در نهایت، این امر به موفقیت در بازارهای جهانی و حفظ جایگاه رقابتی محصول کمک شایانی می‌کند (Malek Madani & Soleimani, 2025).

از این‌رو، ایجاد یک سیستم ارزیابی دقیق برای تشخیص کیفیت کشمش و شناسایی دانه‌های نامطلوب از اهمیت بالایی برخوردار است و ضرورت انجام این تحقیق را نشان می‌دهد. روش‌های سنتی در طبقه‌بندی دانه‌های خشکبار معمولاً از دقت کافی برخوردار نبوده و غالباً زمان‌بر هستند و دارای پیچیدگی‌های فنی می‌باشند

کشمش میوه خشک‌شده انگور با نام علمی ویتیس وینیفر^۲ است که طی فرآیند خشک‌شدن حدود ۷۵ تا ۸۰ درصد از رطوبت خود را از دست داده و به منبعی غلیظ از مواد مغذی تبدیل می‌شود. این محصول منبعی عالی از کربوهیدرات‌ها، فروکتوز و گلوکز، ویتامین‌های گروه B و K و نیز مواد معدنی همچون پتاسیم، کلسیم و منیزیم محسوب می‌شود (Kanellos et al., 2013; Malek Madani & Soleimani, 2025; Schuster, Wang, Hawkins, & Painter, 2017). بر اساس گزارش سازمان خواربار و کشاورزی ملل متحد^۳، ایران با قرار گرفتن در جایگاه سوم صادرات کشمش در جهان پس از ترکیه و آمریکا (FAO, 2023)، از جایگاهی مهمی در بازار جهانی

۱- گروه مهندسی مکانیک بیوسستم، واحد بناب، دانشگاه آزاد اسلامی، بناب، ایران
 (*- نویسنده مسئول: Email: mahdiabbasgholipour@iaui.ac.ir)

2- Vitis vinifera

3- FAO

هستند و می‌توانند چندین ویژگی را به‌طور هم‌زمان از یک تصویر استخراج کنند. لایه‌های کانولوشنی، بخش تشخیص ویژگی را ایجاد می‌کنند که در فرآیند یادگیری آموزش‌پذیر است. هرچه شبکه عمیق‌تر و پیچیده‌تر شود، توانایی یادگیری آن افزایش می‌یابد، اما این افزایش عملکرد به هزینه محاسباتی و زمان بیشتر نیاز دارد. در نتیجه، مدل‌های یادگیری ماشینی مبتنی بر یادگیری انتقالی^۳ (TL) به‌عنوان رویکردی کارآمد برای کاهش هزینه‌های محاسباتی و زمان آموزش مورد توجه قرار گرفته‌اند. با گسترش کاربردهای یادگیری ماشین در سال‌های اخیر، نیاز به مجموعه‌داده‌های بزرگ نیز افزایش یافته و این موضوع موجب پیشرفت چشمگیر روش‌های یادگیری شده است. از منظر یادگیری ماشین، مدل‌هایی که بر روی مجموعه‌داده‌های گسترده و متنوع آموزش دیده‌اند، توانایی تعمیم‌یابی بالایی پیدا می‌کنند و قادرند تصاویر را در دامنه‌های جدید با دقت قابل‌توجهی تشخیص دهند. در تحقیقی نادری بنی و همکاران (Naderi Beni, Bagherpour, & Amiri Parian, 2024) در رویکرد اول با استفاده از یادگیری انتقالی، دو الگوریتم مهم Inception-ResNet-v2 و ResNet-101 و در رویکرد دوم یک الگوریتم بهینه‌شده پیشنهادی برای طبقه‌بندی بیماری‌ها استفاده کردند. نتایج مدل‌ها نشان داد که حذف تصادفی باعث اصلاح دقت بعضی مدل‌ها گردید و بیشترین عملکرد با ۶۴ نوروں در لایه مخفی حاصل گردید.

یو و همکاران (Yu, Liu, Wu, & He, 2012) با استفاده از روش ماشین بردار پشتیبان^۴ (SVM)، کَشَمَش‌ها را بر اساس رنگ، شکل و میزان چین‌وچروک به چهار دسته تقسیم کردند. آن‌ها با به‌کارگیری ویژگی‌های رنگ و بافت در تصاویر کَشَمَش، به حدود ۹۵ درصد دقت طبقه‌بندی دست یافتند. در تحقیقی، باکس و خجسته‌نژاد (Backes & Khojastehnazhand, 2024) با استفاده از روش بینایی ماشین، ۱۵ کلاس مختلف کَشَمَش فله‌ای بر اساس ترکیب دانه‌های خوب و بد و چوب خشک را بررسی کردند. از ویژگی‌های بافت تصاویر برای طبقه‌بندی استفاده شد و بهترین ترکیب الگوریتم‌های استخراج بافت تصویر با استفاده از روش بهینه‌سازی ازدحام ذرات^۵ (PSO) ارزیابی شد. سه طبقه‌بندی‌کننده مختلف به نام‌های ماشین بردار پشتیبان، تحلیل تشخیص خطی^۶ (LDA) و نزدیکترین همسایگی^۷ (KNN) برای مدل‌سازی استفاده شدند. نتایج نشان داد که ترکیب چندین روش استخراج ویژگی بافت با استفاده از بهینه‌سازی ازدحام ذرات، دقت طبقه‌بندی را برای همه طبقه‌بندی‌کننده‌ها بهبود می‌بخشد. بهترین نتایج با استفاده از

(Abbasgholipour, Omid, Keyhani, & Mohtasebi, 2011; Mollazade, Omid, & Arefi, 2012). در سال‌های اخیر فناوری بینایی کامپیوتر به‌طور فزاینده‌ای در ارزیابی کنترل کیفیت و درجه‌بندی کَشَمَش مورد توجه قرار گرفته است (Çinar, Koklu, & Taşdemir, 2020). روش‌های متعدد پردازش تصویر برای سنجش کمی کیفیت کَشَمَش و تعیین معیارهای هندسی مانند اندازه و شکل ارائه شده‌اند (Omid, Abbasgolipour, Keyhani, & Mohtasebi, 2010). این روش‌ها شامل تحلیل رنگ، تخمین طول و ابعاد کَشَمَش (Omid, Sharouzi, & Keyhani, 2010) و تعیین نسبت کَشَمَش‌های سالم به ناسالم (Abbasgholipour et al., 2011) می‌باشند. اگرچه تمامی این تکنیک‌های پردازش تصویر به نتایج بهتری منجر می‌شوند، اما همگی در یک ویژگی مشترک هستند: این الگوریتم‌ها کارایی تشخیص بلادرنگ را کاهش می‌دهند، چرا که به پیش‌پردازش گسترده تصویر و تکنیک‌های استخراج ویژگی نیاز دارند (Angadi & Hiregoudar, 2016).

یادگیری عمیق به‌عنوان یک فناوری نوین در حوزه یادگیری ماشین، انقلابی در عرصه هوش مصنوعی ایجاد کرده و قابلیت‌هایی را فراهم ساخته که پیش از این غیرقابل دسترس بودند. شبکه عصبی کانولوشنی^۱ (CNN) به‌عنوان پیشرفته‌ترین فناوری این حوزه، مدلی مؤثر برای نمایش دادن و طبقه‌بندی داده‌ها ثابت شده است (Zhu, Li, Li, Wu, & Yue, 2018). شبکه‌های عصبی کانولوشنی عملکرد برجسته‌ای از خود نشان داده و مزایای آشکاری در مقایسه با سایر الگوریتم‌های کلاسیک یادگیری ماشین در تشخیص و طبقه‌بندی دارند (Wang, Shi, Zhang, & Ying, 2017). مزیت کلیدی استفاده از شبکه‌های عصبی کانولوشنی در این است که از پیکسل‌های تصویر به‌عنوان ورودی مستقیم شبکه استفاده می‌کند و هیچ‌گونه پردازش پیچیده تصویر یا تکنیک استخراج دستی ویژگی مورد نیاز نیست. علاوه بر این، به دلیل عملیات نمونه‌برداری و تجمیع که در لایه‌های مختلف شبکه انجام می‌شود، عملکرد شبکه‌های عصبی کانولوشنی نسبت به تبدیل‌های اولیه مانند چرخش و جابه‌جایی حساسیت کمتری نشان می‌دهد (Hinton et al., 2012). در پژوهش‌های متعددی CNN به‌طور گسترده برای تقسیم‌بندی و طبقه‌بندی تصاویر به‌کار رفته است (Din et al., 2024; Falahat, Nejad Mahani & Karami, 2023; Fatehi, Bagherpour, & Amiri Parian, 2025; Raihen & Akter, 2024; Singla, Sarangi, Sahoo, & Singh, 2022). به‌عنوان مثال، لی و همکاران (Liu, Yang, Chen, Yu, & Li, 2022) شبکه عصبی کانولوشن را برای قطعه‌بندی تصاویر پزشکی مورد ارزیابی قرار دادند. این شبکه‌های عصبی از شبکه‌های عصبی کانولوشن عمیق^۲ (DCNN)

3- Transfer learning (TL)

4- Support vector machines (SVM)

5- Particle swarm optimisation (PSO)

6- Linear discriminant analysis (LDA)

7- K-Nearest Neighbours (KNN)

1- Convolutional neural networks (CNN)

2- Deep convolutional neural networks (DCNN)

مواد و روش‌ها

در این مطالعه، پس از جمع‌آوری تصاویر دانه‌های کشمش تیزآبی طلایی، مربوط به چهار درجه مختلف از این نوع کشمش، این تصاویر به‌عنوان ورودی، وارد مدل‌های شبکه عصبی خواهند شد. یک مدل شبکه عصبی کانولوشن عمیق ساده به نام Raisin_DCNN و دو مدل پیش‌آموزش‌دیده، یعنی InceptionV3 و InceptionResNetV2، برای آزمایش استفاده خواهد شد. نتایج به‌دست‌آمده همچنین با روش‌های سنتی یادگیری ماشین مقایسه خواهد گردید.

برای انجام این پژوهش، ابتدا مجموعه جامعی از تصاویر دانه‌های کشمش تیزآبی طلایی مطابق با جدول ۱ تهیه شد. تصاویر نمونه‌هایی از دانه‌های کشمش تیزآبی طلایی با چهار درجه مختلف در شکل ۱ نشان داده شده است. طبق استعلام از اداره تحقیقات کشاورزی شهرستان بناب درجه‌بندی کشمش تیزآبی طلایی حداقل به دو درجه و حداکثر به چهار درجه طبق استانداردهای صادراتی، توجیه اقتصادی دارد لذا بر اساس تعاریف آورده‌شده در جدول ویژگی‌های درجه‌های مختلف کشمش تیزآبی طلایی، در این تحقیق از حداکثر تعداد درجه‌بندی کشمش تیزآبی طلایی (چهار درجه مختلف) استفاده شد.

جمع‌آوری و پردازش اولیه داده‌ها

از نمونه‌های استاندارد درجه‌بندی‌شده‌ی کشمش تیزآبی طلایی (فراآوری‌شده از رقم انگور بی‌دانه سلطانی) در اداره تحقیقات کشاورزی شهرستان بناب، از هر درجه (کلاس) ۸۳۰ دانه به‌صورت تصادفی انتخاب شد؛ در نتیجه، در مجموع ۳۳۲۰ تصویر برای ایجاد مجموعه‌داده تهیه گردید. این تصاویر با اسکن تک‌تک دانه‌های کشمش به‌وسیله‌ی یک اسکنر با وضوح بالا تهیه شدند. تصویربرداری از دانه‌های کشمش با استفاده از اسکنر تخت Scanjet Pro 2500 hp با وضوح اسکن نوری 200 dpi و عمق رنگی ۲۴ بیت انجام پذیرفت. در هر مرحله، ۲۴ دانه از یک درجه کشمش به‌صورت تصادفی روی صفحه شیشه‌ای اسکنر چیده شده و با یک لایه کاغذ سفید پوشانده شدند تا تصاویری با فرمت PNG تولید شود که سپس در حافظه رایانه ذخیره گردید. این جای‌گذاری تصادفی با هدف شبیه‌سازی سناریوهای دنیای واقعی و توزیع طبیعی و تنوع دانه‌های کشمش انجام شد. چیدمان تصادفی، مسئله‌ی شناسایی و تمایز دقیق دانه‌های منفرد را چالش‌برانگیزتر کرد. هر یک از ۳۳۲۰ تصویر، نمایانگر یک دانه کشمش منفرد است که در نهایت به ایجاد مجموعه‌داده‌ای جامع برای تجزیه و تحلیل منجر شد. سپس مجموعه‌داده به دو زیرمجموعه، مجموعه آموزش و مجموعه اعتبارسنجی تقسیم شد. مجموعه آموزش شامل ۲۲۴۰ تصویر و

مدل‌سازی ماشین بردار پشتیبان و تحلیل تشخیص خطی به‌ترتیب با ۹۹/۳۳ و ۹۹/۷۳ درصد به‌دست آمد. البته قابل‌ذکر است که نتایج این تحقیق برای طبقه‌بندی کشمش فله‌ای گزارش شده است و طبقه‌بندی دانه‌های کشمش به‌صورت مجزا تحقیق متفاوتی است. در پژوهشی که اینچکارا (Incekara, 2024) انجام داد، دانه‌های کشمش با استفاده از مجموعه‌داده‌ی کشمش از مخزن یادگیری ماشین UCI و با به‌کارگیری سه روش مختلف شبکه عصبی مصنوعی طبقه‌بندی شدند. در این مطالعه، عملکرد سه مدل شبکه عصبی لایه رقابتی^۱ (CLNN)، شبکه عصبی تشخیص الگو^۲ (PRNN) و نقشه خودسازمان‌دهنده^۳ (SOM) مورد ارزیابی قرار گرفت. نتایج نشان داد که مدل شبکه عصبی تشخیص الگو بهترین عملکرد را دارد، در حالی که نقشه خودسازمان‌دهنده نسبت به دو روش دیگر ضعیف‌تر عمل می‌کند. از سوی دیگر، شبکه عصبی لایه رقابتی عملکردی نزدیک به شبکه عصبی تشخیص الگو ارائه داده و می‌تواند به‌عنوان جایگزینی مناسب برای آن در طبقه‌بندی دانه‌های کشمش تیزآبی مورد استفاده قرار گیرد.

با توجه به این‌که شبکه عصبی کانولوشن عمیق یک روش جامع و کلی برای توسعه یک سیستم هوشمند تشخیص و شناسایی می‌باشد لذا طراحی یک شبکه اختصاصی با پارامترها و متغیرهای ویژه، برای ارزیابی کیفی کشمش، نوآوری اصلی این پژوهش می‌باشد؛ به‌طوری‌که طراحی یک شبکه عصبی کانولوشن عمیق (DCNN) می‌تواند فرآیند درجه‌بندی و ارزیابی کشمش تیزآبی طلایی را بدون نیاز به پیش‌پردازش و با زمان پردازش و هزینه محاسباتی کمتر انجام دهد. برخلاف مطالعات قبلی که بیشتر بر مسائل محاسباتی یا طبقه‌بندی‌های محدود تمرکز داشتند، مدل پیشنهادی این تحقیق با تکیه بر استخراج خودکار ویژگی‌های تصویری مانند بافت، شکل و رنگ، قادر است کیفیت و اندازه دانه‌ها را حتی در شرایط تصویربرداری متغیر به‌طور دقیق تشخیص دهد. این ویژگی باعث می‌شود مدل نسبت به تغییرات نور، زاویه و پس‌زمینه حساسیت کمتری داشته باشد و دیگر نیازی به مراحل پیچیده‌ی پیش‌پردازش یا تنظیمات دستی نباشد.

هدف این تحقیق، بررسی امکان استفاده از شبکه‌های عصبی کانولوشن عمیق برای شناسایی و طبقه‌بندی انواع کشمش با استفاده از تصاویر آن می‌باشد. همچنین، این مطالعه به دنبال توسعه یک سیستم طبقه‌بندی هوشمند، غیرمخرب، مستقل و کارآمد است که بتواند در درجه‌بندی کشمش نقش موثری را ایفا نماید.

- 1- Competitive layer neural network (CLNN)
- 2- Pattern recognition artificial neural network (PRNN)
- 3- Self-organising map (SOM)

تصاویر ورودی با ابعاد ثابت نیاز دارد، لذا کلیه تصاویر با استفاده از کدی در نرم‌افزار پایتون به ابعاد 512×512 پیکسل برش داده و تغییر اندازه داده شدند. هرچه‌قدر اندازه تصویر دانه‌های کشمش بزرگ‌تر انتخاب شود کیفیت تصویر بیشتر شده و دقت شناسایی و درجه‌بندی آن بهتر انجام خواهد گرفت اما زمان پردازش افزایش خواهد یافت لذا حالت بهینه اندازه تصویر، با توجه به تحقیقات مشابه گذشته، به ابعاد 512×512 پیکسل انتخاب گردید.

مجموعه اعتبارسنجی شامل ۱۰۸۰ تصویر بود. مجموعه داده‌های آزمایش نیز متشکل از ۱۲۰ تصویر دانه کشمش بود که متخصصین اداره تحقیقات کشاورزی شهرستان بناب - به‌منظور حفظ یکپارچگی و اطمینان از ارزیابی بی‌طرفانه مدل - درجه‌بندی آن‌ها را افشا نکردند. این مجموعه آزمایشی برای ارزیابی مدل‌های یادگیری عمیق طراحی شده در این تحقیق و مدل‌های دیگر یادگیری ماشین مورد استفاده قرار گرفت. شرح جامع مجموعه‌داده‌های کشمش در جدول ۲ ارائه شده است. با توجه به این‌که الگوریتم شبکه عصبی مصنوعی به

جدول ۱- ویژگی‌های درجه‌های مختلف کشمش تیزابی طلایی

Table 1- Golden raisin grading

درجه Grade	رنگ Colour	اندازه Size	شکل و بافت Shape & Texture
درجه ۱ (عالی) (Excellent)	طلایی روشن و یکنواخت Bright and uniform golden	بزرگ و یکسان Large and uniform	شکل منظم و بافت یکنواخت Regular shape and uniform texture
درجه ۲ (متوسط) (Premium)	طلایی با لکه جزئی Golden with slight spotting	متوسط تا نسبتاً بزرگ Medium to relatively large	نسبتاً منظم با بافت متعادل Relatively regular with balanced texture
درجه ۳ (استاندارد) (Standard)	طلایی تیره‌تر یا لکه‌دار Darker golden or spotted	اندازه متوسط Medium size	شکل نامنظم‌تر و بافت خشک‌تر Irregular shape and drier texture
درجه ۴ (ضعیف) (Low Grade)	رنگ ناهمگون و تیره Inconsistent and dark color	ریز و کوچک Small and tiny	شکل نامنظم و بافت نامطلوب Irregular shape and undesirable texture


جدول ۲- توزیع داده‌های آموزش، اعتبارسنجی و آزمایش برای چهار درجه از کشمش تیزابی طلایی

Table 2- The distribution of the training, validation, and test datasets for the four grades of golden raisins

درجه کشمش Raisin grade	تعداد آموزش Training samples	تعداد اعتبارسنجی Validation samples	تعداد آزمون Test samples
درجه ۱ (Grade 1)	560	270	30
درجه ۲ (Grade 2)	560	270	30
درجه ۳ (Grade 3)	560	270	30
درجه ۴ (Grade 4)	560	270	30
مجموع (Sum)	2240	1080	120

تصاویر تولیدشده در قالب دسته‌های منظم سازمان‌دهی شدند. دسته‌ای‌سازی، امکان پردازش هم‌زمان چندین تصویر را فراهم می‌کند که باعث افزایش کارایی آموزش و مدیریت بهتر حافظه می‌شود، زیرا نیازی به بارگذاری تمام مجموعه‌داده در حافظه‌ی سیستم به‌صورت یک‌باره نیست. در ادامه، اندازه‌ی تمام تصاویر در هر دسته به 512×512 پیکسل تغییر داده شد. همچنین در مرحله‌ی نرمال‌سازی، مقادیر پیکسل‌ها که در ابتدا در بازه‌ی [۰-۲۵۵] قرار داشتند، به محدوده‌ی [۰-۱] مقیاس‌بندی شدند تا شرایط برای آموزش پایدار و کارآمد مدل فراهم شود.

در مرحله‌ی پردازش اولیه داده‌ها، ابتدا تعداد تصاویر با استفاده از روش‌های افزایش مصنوعی داده‌ها، گسترش یافت. در این فرایند، مجموعه‌ی تصاویر به‌صورت دسته‌ای آماده و سپس تغییر اندازه داده شدند. هدف از افزایش داده، ایجاد تنوع بیشتر در نمونه‌ها و جلوگیری از بیش‌برازش بود. برای این منظور، مجموعه‌ای از تبدیلات تصادفی مانند وارونه‌سازی، برش، جابه‌جایی، بزرگ‌نمایی و چرخش بر هر تصویر اعمال شد. این تبدیلات مدل را در معرض طیف گسترده‌تری از تغییرات ظاهری قرار می‌دهد و احتمال حفظ نمونه‌های خاص توسط مدل را کاهش می‌دهد. پس از انجام عملیات افزایش داده،



شکل ۱- نمونه‌هایی از دانه‌های کشمش تیزآبی طلایی با چهار درجه مختلف

Fig. 1. Samples of golden raisins in four different grades

مدل پیشنهادی Raisin_DCNN

برای طبقه‌بندی دانه‌های کشمش تیزآبی طلایی، یک مدل جدید مبتنی بر شبکه عصبی کانولوشن عمیق با نام Raisin_DCNN پیاده‌سازی شد که در شکل ۲ نشان داده شده است. در این پژوهش، تصاویر دانه‌های کشمش با ابعاد ثابت 512×512 پیکسل به‌عنوان ورودی به مدل Raisin_DCNN داده شدند. مدل طبقه‌بندی پیشنهادی، با استفاده از زبان برنامه‌نویسی پایتون و بهره‌گیری از کتابخانه یادگیری عمیق Keras بر بستر TensorFlow در محیط Google Colab توسعه داده شد. ساختار معماری مدل Raisin_DCNN در جدول ۳ نشان داده شده است. این معماری شامل ده بلوک کانولوشن Conv. Blocks و دو بلوک کاملاً متصل^۱ F.C. Blocks می‌باشد. هر بلوک کانولوشن (به‌جز اولین بلوک) از یک لایه کانولوشن، یک لایه نرمال‌سازی دسته‌ای^۲، یک لایه فعال‌سازی ReLU و یک لایه تجمیع حداکثری Maxpooling تشکیل شده است. اولین بلوک، فقط شامل یک لایه کانولوشن، یک لایه نرمال‌سازی دسته‌ای و یک لایه فعال‌سازی ReLU است. پیکربندی فیلترها (کرنل‌ها) در بلوک‌های کانولوشن به این صورت است که در دو بلوک اول ۱۶ عدد فیلتر با ابعاد 5×5 در بلوک‌های سوم و چهارم ۳۲ عدد فیلتر با ابعاد 3×3 در بلوک‌های پنجم و ششم ۶۴ عدد فیلتر با ابعاد 3×3 در بلوک‌های هفتم و هشتم ۱۲۸ عدد فیلتر با ابعاد 3×3 و در بلوک‌های نهم و دهم ۱۹۲ عدد فیلتر با ابعاد 3×3 استفاده شده است. ویژگی‌های که مدل مذکور توسط اولین بلوک کانولوشن یادگرفته، در شکل ۳ قابل مشاهده است. ابعاد ماتریس ویژگی‌ها با استفاده از لایه تجمیع حداکثری به یک ماتریس 2×2 کاهش بعد داده شد. برای یادگیری ترکیب ویژگی‌های تولیدشده توسط لایه‌های کانولوشنی، از بلوک‌های کاملاً متصل F.C. Block استفاده شد. اولین F.C. Block شامل یک لایه کاملاً متصل با ۱۹۲ نورون، یک لایه نرمال‌سازی دسته‌ای (BN)، یک لایه فعال‌سازی ReLU و یک لایه حذف Dropout است. آخرین F.C. Block نیز شامل یک لایه کاملاً متصل با ۴ نورون (متناظر با تعداد کلاس‌های

خروجی یعنی چهار درجه کشمش تیزآبی طلایی) و یک تابع فعال‌سازی Softmax برای تبدیل ورودی به توزیع احتمال می‌باشد. در کل ساختار معماری Raisin_DCNN از تابع فعال‌سازی ReLU استفاده شده است. این تابع با حفظ مقادیر مثبت ورودی، مسئله ناپدید شدن گرادیان را حل می‌کند و به آموزش مؤثر مدل کمک می‌نماید. لایه نرمال‌سازی دسته‌ای در بلوک‌های کانولوشن گنجانده شد و مدل با ۵۰ دوره^۳ آموزش داده شد. تکنیک نرمال‌سازی دسته‌ای می‌تواند تغییرپذیری متغیرهای کمکی داخلی را کاهش داده و فرآیند آموزش شبکه‌های عصبی عمیق را تسریع ببخشد (Alom, Hasan, & Yakopcic, Taha, & Asari, 2020). در این آزمایش، یک لایه نرمال‌سازی دسته‌ای بین لایه کانولوشن و لایه فعال‌سازی ReLU قرار داده شد. با به‌کارگیری لایه حذف Dropout که ترکیبی تقریبی از پیکربندی‌های متعدد شبکه عصبی را ارائه می‌دهد، می‌توان از بروز پدیده بیش‌برازش جلوگیری کرد (Vidhyarthi, Singh, Xiao, & Tiwari, 2021). در این پژوهش، نرخ حذف^۴ بر روی ۰/۵ ثابت نگه داشته شد. از الگوریتم بهینه‌ساز Adam با نرخ یادگیری^۵ (lr) 0.0003 استفاده شد. این پارامترها به‌منظور دستیابی به بهترین عملکرد مدل و جلوگیری از همگرایی زود هنگام تنظیم شدند. نحوه انتخاب تعداد لایه‌ها و نوع توابع فعال‌سازی و پارامترهای شبکه، براساس تعداد لایه‌ها و نوع توابع به‌کار رفته در تحقیقات مشابه و مقدار پارامترها به روش سعی و خطا انتخاب گردید. الگوریتم‌های ماشین بردار پشتیبان، نزدیکترین همسایگی K و رگرسیون لجستیک^۶ از رایج‌ترین الگوریتم‌های یادگیری ماشین در طبقه‌بندی داده‌ها محسوب می‌شوند. بر این اساس، در ادامه این تحقیق، عملکرد مدل پیشنهادی Raisin_DCNN با الگوریتم‌های یادگیری ماشین مذکور مقایسه خواهد شد. کلیه آزمایش‌ها بر روی مجموعه داده‌ای متشکل از ۲۲۴۰ تصویر آموزشی و ۱۰۸۰ تصویر اعتبارسنجی انجام خواهد پذیرفت.

3- Epoch

4- Dropout rate

5- Learn rate

6- Logistic Regression

1- Fully Connected

2- Batch Normalisation

جدول ۳- ساختار مدل Raisin_DCNN

Table 3- Raisin_DCNN model architecture

پارامترها	فعال‌سازی	اندازه فیلتر تعداد فیلترها	لایه‌های عملکردی	بلوک
Parameters	Activation	Filter size Filters	Operational layers	Block
	$512 \times 512 \times 3$		لایه ورودی	
			Input layer	
1,216	$512 \times 512 \times 16$	5×5	Conv* layer	Block 1
			BN layer + Relu	
6,416	$512 \times 512 \times 16$	5×5	Conv layer	Block 2
			BN layer + Relu + Maxpooling	
4,640	$256 \times 256 \times 16$	3×3	Conv layer	Block 3
			BN layer + Relu + Maxpooling	
9,248	$128 \times 128 \times 32$	3×3	Conv layer	Block 4
			BN layer + Relu + Maxpooling	
18,496	$64 \times 64 \times 64$	3×3	Conv layer	Block 5
			BN layer + Relu + Maxpooling	
36,928	$32 \times 32 \times 64$	3×3	Conv layer	Block 6
			BN layer + Relu + Maxpooling	
73,856	$16 \times 16 \times 128$	3×3	Conv layer	Block 7
			BN layer + Relu + Maxpooling	
147,584	$8 \times 8 \times 128$	3×3	Conv layer	Block 8
			BN layer + Relu + Maxpooling	
147,584	$4 \times 4 \times 192$	3×3	Conv layer	Block 9
			BN layer + Relu + Maxpooling	
221,376	$2 \times 2 \times 192$	3×3	Conv layer	Block 10
			BN layer + Relu + Maxpooling	
37,056	$1 \times 1 \times 192$		F.C. Dense layer	Block 1
			BN layer + Relu + Dropout layer	
772	$1 \times 1 \times 4$		F.C. Dense layer + Softmax layer	Block 2

Conv*: کانولوشن (Convolution)، BN: نرمال‌سازی دسته‌ای (Batch Normalisation)، F.C.: کاملاً متصل (Fully Connected)

(et al., 2020).

مدل‌های یادگیری انتقالی

یادگیری انتقالی یک روش مؤثر در یادگیری عمیق است که از مدل‌هایی استفاده می‌کند که قبلاً با داده‌های بزرگ آموزش دیده‌اند و ویژگی‌های مهم را آموخته‌اند. در این شیوه، به جای شروع آموزش از ابتدا، از دانشی که این مدل‌ها از قبل دارند برای حل مسئله جدید بهره گرفته می‌شود. با انجام تنظیمات دقیق^۱ و سازگار کردن مدل با داده‌های حوزه هدف (که معمولاً کوچک‌تر هستند) می‌توان سرعت یادگیری را افزایش داد، دقت را بهبود بخشید و عملکرد مدل را پایدارتر کرد. این موضوع زمانی اهمیت بیشتری پیدا می‌کند که داده‌های کمی در اختیار داشته باشیم؛ زیرا مدل می‌تواند از تجربه قبلی خود برای یادگیری بهتر در شرایط جدید استفاده کند. بنابراین، هنگام کار با مجموعه داده‌های محدود، استفاده از یادگیری انتقالی یک راهکار ضروری است تا از بیش‌برازش جلوگیری شده و نتایج قابل اعتمادتری به دست آید.


در این مطالعه از دو معماری پیشرفته کانولوشنی، یعنی InceptionV3 و InceptionResNetV2، بهره گرفته شد (Alom

این دو مدل پیش‌تر بر روی پایگاه داده بزرگ-Fei ImageNet (Fei, Deng, & Li, 2009) آموزش دیده‌اند و بنابراین قادرند ویژگی‌های اساسی تصاویر را به خوبی استخراج کنند. در روند پیاده‌سازی، بخش‌های انتهایی این شبکه‌ها که معمولاً شامل لایه‌های کاملاً متصل و خروجی Softmax هستند و صرفاً برای وظیفه طبقه‌بندی اولیه طراحی شده‌اند از ساختار مدل حذف می‌شوند. حذف این بخش‌ها شرایطی فراهم می‌کند تا مدل بتواند ضمن حفظ الگوهای آموخته‌شده در لایه‌های ابتدایی و میانی، برای مسئله جدید، سازگار شده و عملکرد بهتری در وظیفه جدید ارائه دهد. در معماری شبکه‌های عصبی عمیق، لایه‌های نهایی طبقه‌بندی متناسب با وظیفه اولیه و مجموعه داده مرجع، طراحی می‌شوند و نقش آن‌ها نگاشت بردارهای ویژگی به برچسب‌های خروجی است. حذف این بخش‌ها امکان پیکربندی مجدد مدل را فراهم می‌سازد تا شبکه بتواند وظایف تخصصی‌تری را برای مسئله جدید، مانند استخراج ویژگی‌های مرتبط با درجه‌بندی‌های دانه‌های کشمش، فراگیرد. در این تحقیق، از پیاده‌سازی دو مدل پیش‌آموزش‌دیده InceptionV3 و InceptionResNetV2 در کتابخانه Keras بهره گرفته شد.

1- Fine-tuning


عمومی حاصل از داده‌های گسترده، با ویژگی‌های خاص مجموعه داده هدف نیز سازگار شود.

به‌کارگیری یادگیری انتقالی و انتقال بخشی از وزن‌های آموزش‌دیده ImageNet باعث شد مدل، ضمن حفظ دانش



شکل ۲- ساختار معماری مدل Raisin_DCNN

Fig. 2. Raisin_DCNN model architecture




شکل ۳- ویژگی‌های آموخته‌شده توسط اولین بلوک کانولوشن با ۱۶ هسته کانولوشن (کرنل) با ابعاد 5×5
Fig. 3. Features learned by the first convolutional block with 16 convolutional kernels of size $5 \times 5 \times 16$

مدل ترکیبی InceptionResNetV2 با تنظیم دقیق

معماری مدل InceptionResNetV2 ترکیبی از ساختارهای چندلایه‌ای مدل‌های آغازین و اتصالات باقی‌مانده است. این شبکه با استفاده هم‌زمان از بلوک‌های Inception و مسیریهای میان‌بر، هم سرعت و هم زمان یادگیری عمیق را بهبود می‌بخشد. در این پژوهش، این مدل برای طبقه‌بندی چهار درجه از دانه‌های کشمش تیزابی طلایی با اعمال تنظیم دقیق به کار گرفته شد. همان‌طوری که در شکل ۵ نشان داده شده است فرایند آموزش در دو گام صورت گرفت در مرحله اول تمام لایه‌های مدل اصلی قفل شدند و یک Head جدید جایگزین سه لایه کاملاً متصل پایانی شد. این Head شامل یک لایه Pooling و سه بلوک کاملاً متصل می‌باشد. دو بلوک اول و دوم هر کدام به ترتیب شامل یک لایه Dense با ۵۱۲ و ۱۲۸ نورون، یک لایه حذف با نرخ 0.2 و یک لایه تابع فعال‌سازی ReLU می‌باشند. بلوک آخر شامل یک لایه Dense با ۴ نورون و یک لایه تابع Softmax برای خروجی نهایی (چهار درجه کشمش تیزابی طلایی) می‌باشد. تمام وزن‌های Head به‌طور تصادفی مقداردهی اولیه شدند. در مرحله دوم پس از آموزش Head، بخشی از لایه‌های InceptionResNetV2 فعال و شبکه به‌صورت مشترک آموزش داده شد تا وزن‌های مدل پایه نیز تنظیم دقیق شوند. آموزش با بهینه‌ساز Adam و نرخ یادگیری 0.0003 انجام شد. آزمایش‌ها در ۵۰ دوره و با اندازه دسته ۳۲ اجرا گردید.


مدل InceptionV3 با تنظیمات دقیق

در این پژوهش، مدل InceptionV3 که پیش‌تر روی مجموعه داده ImageNet (مجموعه داده‌ای با ۱۴ میلیون تصویر و ۱۰۰۰ دسته) آموزش دیده بود، در ابتدا بدون تنظیم دقیق و تنها به‌عنوان استخراج‌کننده ویژگی مورد استفاده قرار گرفت. در شکل ۵ مراحل اعمال تنظیمات دقیق روی مدل InceptionV3 نشان داده شده است. در این مدل قبل از عملیات Flatten خروجی آخرین لایه یعنی لایه mixed7 به‌عنوان لایه استخراج‌کننده ویژگی، انتخاب گردید. به دلیل اختصاصی بودن لایه‌های کاملاً متصل اولیه برای ImageNet، این لایه‌ها حذف شدند و دو بلوک کاملاً متصل بر روی مدل طراحی شدند. لایه اول شامل یک لایه Dense با ۱۰۲۴ نورون، یک لایه نرمال‌سازی دسته‌ای، یک تابع فعال‌سازی ReLU و یک لایه حذف با نرخ حذف 0.2 می‌باشد و بلوک دوم شامل یک لایه Dense چهار نورونی و یک تابع Softmax می‌باشد. همان‌طوری که در شکل ۵ نشان داده شده است آموزش مدل در دو مرحله انجام شد. ابتدا فقط بلوک‌های کاملاً متصل آموزش داده شدند و بخش پیش‌آموزش دیده ثابت ماند. سپس لایه‌های ماژول mixed7 از حالت انجماد خارج شده و تنظیم دقیق برای سازگاری با مجموعه داده جدید اجرا شد آزمایش‌ها برای ۵۰ دوره با نرخ یادگیری 0.0003 و اندازه دسته ۳۲ انجام گرفت. این پارامترها به‌منظور دستیابی به تعادل بهینه بین سرعت همگرایی و دقت مدل انتخاب شدند.



شکل ۴- تنظیم دقیق InceptionV3

Fig. 4- Fine-tuning InceptionV3



شکل ۵- مدل از پیش آموزش دیده InceptionResnetV2 با تنظیم دقیق برای درجه بندی دانه های کشمش تیزابی طلایی

Fig. 5. The pre-trained InceptionResnetV2 model with fine-tuning for grading of golden raisin grains

معیارهای ارزیابی عملکرد مدل‌ها

برای مقایسه و ارزیابی عملکرد مدل‌های مختلف از معیارهای ویژه‌ای همچون دقت (رابطه ۱)، صحت (رابطه ۲)، حساسیت (رابطه ۳) و معیار F1-score (رابطه ۴) استفاده می‌شود. این معیارها را می‌توان از ماتریس اغتشاش استخراج کرد (Grandini, Bagli, & Visani, 2020). مقادیر مثبت واقعی (TP)، منفی واقعی (TN)، مثبت کاذب (FP) و منفی کاذب (FN) برای محاسبه این معیارهای عملکردی مورد استفاده قرار گرفتند.

$$\text{دقت} = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

$$\text{صحت} = \frac{TP}{TP+FP} \quad (2)$$

$$\text{حساسیت} = \frac{TP}{TP+TN} \quad (3)$$

$$F1 - score = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (4)$$

نتایج و بحث

نتایج آزمایش‌های Raisin_DCNN

آموزش مدل Raisin_DCNN روی پردازنده گرافیکی T4GPU در محیط Google Colab انجام شد. برای بهینه‌سازی پارامترهای مدل و کاهش خطای انتشار معکوس در طول فرآیند آموزش، از بهینه‌ساز Adam با نرخ یادگیری 0.0003 استفاده گردید. پارامتر دوره آموزش روی 50 تنظیم گردید. با توجه به مناسب بودن تابع آنتروپی متقاطع^۱ برای مسائل طبقه‌بندی چندکلاسه، از این تابع به‌عنوان تابع هزینه استفاده شد. ماتریس اغتشاش و نمودار مشخصه عملکرد^۲ (ROC) مربوط به مجموعه داده‌های آزمون روی مدل Raisin_DCNN در شکل ۶ نمایش داده شده است. برای ارزیابی عملکرد طبقه‌بندی این مدل، از دقت، صحت، حساسیت و معیار F1-score استفاده شد. مقادیر این معیارها روی مجموعه آزمون در جدول ۴ ارائه شده است. نسبت تصاویر صحیح‌شناسایی‌شده دانه‌های کشمش به کل تصاویر، دقت کلی مدل را در تمامی کلاس‌ها نشان می‌دهد که در این پژوهش به 96 درصد رسیده است. روند دقت و تابع هزینه داده‌های آموزش و اعتبارسنجی مدل Raisin_DCNN در طول 50 دوره در شکل ۷ ترسیم شده است.

با توجه به شکل ۶ الف دانه‌های دسته اول (درجه ۱) با دقت

100% به‌طور کامل شناسایی شدند. اما دانه‌های کشمش از دسته دوم (درجه ۲) با دقت $93/70$ درصد طبقه‌بندی شدند. همان‌طور که از ماتریس اغتشاش در شکل ۶ الف مشهود است، دو نمونه از دانه‌های کشمش درجه ۲ به اشتباه به‌عنوان دانه‌های درجه ۳ طبقه‌بندی شدند و سه نمونه از دانه‌های کشمش دسته سوم (درجه ۳) به اشتباه به‌عنوان دانه‌های درجه ۲ و دانه‌های درجه ۴ طبقه‌بندی شدند و همچنین دانه‌های دسته چهارم (درجه ۴) با دقت 100% به‌طور کامل شناسایی شدند.

نتایج آزمایش‌های InceptionV3 و InceptionResNetV2


آزمایش‌های یادگیری انتقالی روی پردازنده گرافیکی T4GPU در محیط Google Colab انجام شد. برای ارزیابی عملکرد هر مدل شبکه عصبی کانولوشن عمیق از پیش آموزش‌دیده، مجموعه داده به صورت تصادفی به سه بخش آموزش، اعتبارسنجی و آزمایش تقسیم شد. تعداد نمونه‌ها در این بخش‌ها به ترتیب در مقادیر ثابت 2240 ، 1080 و 120 در نظر گرفته شد. در جدول ۲ توصیف کامل مجموعه داده آورده شده است. برای تعیین کارآمدترین پارامترها برای هر دو مدل شبکه عصبی کانولوشن عمیق از پیش آموزش‌دیده، آموزش با بهینه‌ساز Adam و نرخ یادگیری 0.0003 و در 50 دوره و با اندازه دسته 32 انجام گرفت.

در مرحله آموزش، هر دو مدل شبکه عصبی کانولوشن عمیق از پیش آموزش‌دیده، به دقت طبقه‌بندی بالای 90 درصد دست یافتند (جدول ۸). همچنین این مدل‌ها تقریباً در دوره 30 ام به همگرایی رسیدند. ماتریس‌های اغتشاش مربوط به مجموعه داده‌های آزمایش مدل‌های شبکه عصبی کانولوشن عمیق از پیش آموزش‌دیده، پس از اتمام مرحله آموزش استخراج شدند (شکل ۸). علاوه بر این، جداول ۵

و ۶ به ترتیب معیارهای عملکرد InceptionV3 و InceptionResNetV2 را که از ماتریس‌های اغتشاش حاصل شده‌اند، ارائه می‌دهند. برای مقایسه جامع‌تر، عملکرد تمامی مدل‌های شبکه عصبی کانولوشن عمیق روی داده‌های آزمایش مورد ارزیابی قرار گرفت. نتایج مربوط به دقت، حساسیت و معیار F1-Score برای هر مدل شبکه عصبی کانولوشن عمیق در شکل ۹ نمایش داده شده است.

1- Cross-entropy function

2- Receiver operating characteristic (ROC)




شکل ۶- الف) ماتریس اغتشاش و ب) نمودار مشخصه عملکرد مدل Raisin_DCNN روی مجموعه داده‌های آزمون کشمش تیزآبی طلایی

Fig. 6. (a) Raisin_DCNN confusion matrix, and (b) receiver operating characteristic of the test raisins data

جدول ۴- عملکرد مدل Raisin_DCNN روی داده‌های آزمایش دانه‌های کشمش تیزآبی طلایی


Table 4- Performance of Raisin_DCNN model using the test raisins dataset

Grade	Accuracy	Precision	Recall	F1-Score
Grade 1	100.00	94.10	100.00	97.00
Grade 2	93.70	96.12	93.20	95.00
Grade 3	90.40	99.63	93.33	96.25
Grade 4	100.00	90.12	93.34	92.43
Accuracy	96.00			
macro avg		94.99	94.97	95.17
weighted avg		94.99	94.97	95.17



شکل ۷- الف) روند دقت آموزش و اعتبارسنجی و ب) روند تابع هزینه آموزش و اعتبارسنجی مدل Raisin_DCNN در طول ۵۰ دوره

Fig. 7. (a) Training and validation accuracy, (b) Training and validation loss of Raisin_DCNN for 50 epochs



شکل ۸- الف) ماتریس اغتشاش مدل InceptionV3 و ب) ماتریس اغتشاش مدل InceptionResNetV2 روی مجموعه داده‌های آزمون کشمش تیزآبی طلایی

Fig. 8. (a) Raisin_DCNN confusion matrix, and (b) receiver operating characteristic of the test raisins data

جدول ۵- عملکرد مدل InceptionV3 روی داده‌های آزمایش دانه‌های کشمش


Table 5- Performance of the InceptionV3 model using the test raisins dataset

Grade	Accuracy	Precision	Recall	F1-Score
Grade 1	91.10	88.20	97.30	92.00
Grade 2	89.20	96.30	87.40	91.50
Grade 3	89.30	100.00	87.10	93.20
Grade 4	90.40	79.50	90.00	84.30
Accuracy	90.00			
macro avg		91.00	90.45	90.25
weighted avg		91.00	90.45	90.25

جدول ۶- عملکرد مدل InceptionResNetV2 روی داده‌های آزمایش دانه‌های کشمش

Table 6- Performance of the InceptionResNetV2 model using the test raisins dataset

Grade	Accuracy	Precision	Recall	F1-Score
Grade 1	90.12	91.30	97.30	94.30
Grade 2	89.32	90.40	90.40	90.25
Grade 3	89.34	90.20	90.10	90.33
Grade 4	90.40	86.30	80.25	83.40
Accuracy	89.80			
macro avg		89.55	89.51	89.57
weighted avg		89.55	89.51	89.57



شکل ۹- مقایسه معیارهای ارزیابی مدل‌های Raisin_DCNN, InceptionV3, و InceptionResNetV2
Fig. 9. Comparison of performance measures of Raisin_DCNN, InceptionV3, and InceptionResNetV2 models

طراحی و آموزش داده شده است و همین امر توانایی آن در یادگیری و تشخیص الگوهای مرتبط را به‌طور چشمگیری افزایش داده است. دوم، مدل‌های از پیش آموزش‌دیده InceptionV3 و InceptionResNetV2 به دلیل دارا بودن معماری‌های عمیق و پیچیده، از ساختارهای پردازشی پیچیده‌تری برخوردارند. این مدل‌ها عموماً بر روی مجموعه‌داده‌های بزرگ با کلاس‌های متنوع آموزش می‌بینند که ممکن است کاملاً با ویژگی‌های منحصر به فرد داده‌های کشمش همخوانی نداشته باشند. در حالی که مدل Raisin_DCNN که به‌طور خاص بر روی مجموعه‌داده‌هایی با مقیاس کوچک آموزش دیده است، توانست خود را با الگوهای خاص این داده‌ها به‌طور مؤثرتری تطبیق دهد.

جدول ۷ مقایسه‌ای با مطالعات پیشین در حوزه طبقه‌بندی دانه‌های کشمش ارائه می‌دهد. با بررسی این مطالعات مشخص می‌شود که مدل Raisin_DCNN مورد استفاده در این پژوهش به بالاترین نرخ موفقیت در طبقه‌بندی دست یافته است. با این حال، لازم به تأکید است که هر مجموعه‌داده ذکرشده در جدول ۷ منحصر به فرد بوده و از نظر انواع دانه‌های کشمش، اندازه مجموعه‌داده و تعداد ویژگی‌های مورد بررسی، متفاوت است.

نتایج به‌وضوح نشان می‌دهد که مدل پیشنهادی Raisin_DCNN با دستیابی به دقت بالاتر، عملکرد بهتری نسبت به سایر مدل‌های از پیش آموزش‌دیده دارد. با دستیابی به دقت ۹۶ درصد، مدل Raisin_DCNN صرف‌نظر از زمان آموزش، بالاترین عملکرد طبقه‌بندی را در مقایسه با مدل‌های تنظیم‌شده InceptionResNetV2 و InceptionV3 به‌دست آورد (شکل ۹). زمان آموزش مدل‌های DCNN به‌طور مستقیم تحت تأثیر منابع سخت‌افزاری قرار دارد و استفاده از پردازنده‌های گرافیکی قدرتمندتر می‌تواند همزمان هم دقت و هم سرعت آموزش و آزمون این مدل‌ها را بهبود ببخشد. یافته‌های این پژوهش به‌وضوح برتری مدل Raisin_DCNN را از نظر دقت، صحت و فراخوانی در مقایسه با مدل‌های از پیش آموزش‌دیده نشان می‌دهد. این برتری را می‌توان به چندین عامل کلیدی نسبت داد: نخست، مدل‌های از پیش آموزش‌دیده ابتدا بر روی مجموعه‌داده‌هایی آموزش دیده بودند که شباهت کافی با وظیفه طبقه‌بندی دانه‌های کشمش تیزآبی نداشتند و این امر توانایی آن‌ها در یادگیری ویژگی‌های خاص و ضروری برای طبقه‌بندی دقیق را محدود می‌کرد. در حالی که مدل Raisin_DCNN که یک شبکه عصبی کانولوشن عمیق ساده است، به‌طور خاص برای مجموعه‌داده طبقه‌بندی دانه‌های کشمش تیزآبی

جدول ۷- مقایسه تحقیق حاضر با مطالعات مشابه

Table 7- Comparison of proposed work with similar studies

مرجع	کلاس‌ها اندازه داده‌ها	مدل	دقت
Reference	dataset size Classes	Model	Accuracy
(Yu et al., 2012)	480 4	ماشین بردار پشتیبان (SVM)	95
(İncekara, 2024)	6300 2	شبکه عصبی تشخیص الگو (PRNN)	89.5
مطالعه حاضر (Present study)	3320 4	شبکه عصبی کانولوشن عمیق (Raisin_DCNN)	96

طبقه‌بندی طیف وسیع‌تری از ارقام کشمش به‌همراه درجه‌بندی آن‌ها را گسترش خواهد داد.

تحلیل مقایسه‌ای مدل‌های یادگیری ماشین و یادگیری عمیق

در این پژوهش، مقایسه‌ای نظام‌مند میان مدل پیشنهادی Raisin_DCNN، مدل‌های از پیش آموزش‌دیده InceptionV3 و InceptionResNetV2 با الگوریتم‌های مبتنی بر ویژگی‌های کلاسیک شامل HOG-KNN، HOG-LR، HOG-SVM، SIFT-LR، SIFT-KNN و SVM به‌منظور طبقه‌بندی دانه‌های کشمش تیزآبی طلایی انجام شد. در این راستا، ۱۷۶۴ ویژگی توسط الگوریتم HOG و ۲۰۰ ویژگی توسط استخراج‌کننده ویژگی SIFT استخراج گردید.


در پیاده‌سازی مدل طبقه‌بندی‌کننده SVM، از تابع پایه شعاعی^۳ (rbf) و کرنل خطی استفاده شد ($\text{kernel} = [\text{'linear'}, \text{'rbf'}]$). به‌منظور تنظیم دقیق ابرپارامترهای SVM، الگوریتم GridSearchCV به‌کار برده شد و محدوده جستجوی هر پارامتر $C = [0.1, 1, 10, 100]$ ، $\gamma = [\text{'scale'}, \text{'auto'}]$ بود. از میان ۱۶ ترکیب پارامتری آزمایش‌شده بر روی داده‌های آموزش، بالاترین دقت پیش‌بینی با مقادیر $C=1$ ، $\gamma=\text{'scale'}$ و $\text{kernel}=\text{'linear'}$ برای هر دو الگوریتم HOG-SVM و HOG-LR به‌دست آمد.

همان‌گونه که در جدول ۸ نشان داده شده است، دقت‌های حاصل از مدل‌های DCNN به‌طور معناداری برتر از روش‌های ترکیبی مبتنی بر ویژگی‌های دست‌ساز بوده‌اند. نتایج دقت بر روی مجموعه آزمون برای مدل‌های HOG-SVM، HOG-LR، HOG-KNN، SIFT-، SIFT-LR، SVM و SIFT-KNN به‌ترتیب برابر با ۷۵، ۶۷/۴۶، ۴۰، ۵۰/۲۷، ۵۰/۲۲ و ۶۷/۲۶ درصد به‌دست آمد. در حالی که بالاترین دقت پیش‌بینی (۹۶ درصد) متعلق به مدل پیشنهادی Raisin_DCNN بود که برتری روش‌های یادگیری عمیق را در طبقه‌بندی دانه‌های کشمش به‌وضوح نشان می‌دهد.

با توجه به نقش مهم بخش کشاورزی در تأمین نیازهای جمعیت قابل‌توجهی از جهان، تولید و شناسایی انواع باکیفیت کشمش از اهمیت بالایی برخوردار است. روش‌های سنتی شناسایی و طبقه‌بندی کشمش معمولاً پرهزینه، زمان‌بر و مستعد خطا هستند. برای رفع این چالش‌ها، این پژوهش از قابلیت‌های بینایی کامپیوتر به‌عنوان یک فناوری پیشرفته در پردازش تصویر و تحلیل داده‌ها بهره‌برده است. در این مطالعه، چهار درجه از دانه‌های کشمش تیزآبی طلایی مورد تجزیه و تحلیل قرار گرفتند. سیستم Raisin_DCNN که مبتنی بر معماری شبکه عصبی کانولوشن عمیق است، به‌منظور بهبود دقت شناسایی انواع دانه کشمش تیزآبی طلایی طراحی شد. برای ارتقای عملکرد مدل، از تکنیک‌های مختلف افزایش داده به‌منظور تقویت مجموعه داده آموزشی و افزایش مؤثر تنوع و تغییرپذیری نمونه‌های آموزشی استفاده گردید. علاوه بر این، یادگیری انتقالی با بهره‌گیری از مدل‌های از پیش آموزش‌دیده شبکه عصبی کانولوشنی شامل InceptionV3 و InceptionResNetV2 که با بهینه‌ساز Adam تنظیم دقیق شده بودند، به‌کار گرفته شد. عملکرد Raisin_DCNN با روش‌های کلاسیک یادگیری ماشین شامل SVM¹-HOG، SVM²-SIFT، HOG-LR، SIFT-LR، HOG-KNN و SIFT- KNN مقایسه گردید. به‌طوری‌که در شکل ۱۰ نشان داده شده است مدل Raisin_DCNN از نظر دقت پیش‌بینی، برتری قابل‌توجهی نسبت به سایر روش‌ها دارد. در حالی که سایر مدل‌های یادگیری ماشین به دقتی بین ۲۶ تا ۷۵ درصد دست یافتند، مدل‌های InceptionResNetV2 و InceptionV3، Raisin_DCNN به‌ترتیب به دقت ۹۶، ۹۰ و ۸۹/۸۰ درصد دست یافتند.

مدل پیشنهادی Raisin_DCNN با هدف رفع چالش‌های موجود در روش‌های مرسوم شناسایی دانه‌ها، توسعه یافته است. تغییرات شرایط نوری به‌عنوان یکی از موانع رایج، تأثیر مستقیمی بر ظاهر و کیفیت تصاویر دانه‌ها دارد. برای مقابله با این چالش، Raisin_DCNN با بهره‌گیری از عملیات افزایش داده همچون تغییر مقیاس، چرخش و تبدیل‌های تصادفی، توانایی شناسایی دانه‌ها در شرایط نوری متنوع را کسب می‌کند و براین اساس قابلیت تطبیق‌پذیری خود در محیط‌های عملیاتی واقعی را ارتقا می‌بخشد. علاوه بر این، ادغام این مدل با فناوری‌های نوظهور نظیر اینترنت اشیا (IoT) و بلاک‌چین در آینده، چشم‌اندازهای امیدوارکننده‌ای برای بهبود قابلیت ردیابی و کنترل کیفیت در سامانه‌های تشخیص دانه فراهم خواهد آورد. همچنین، گنجاندن انواع متنوع‌تری از دانه‌ها در مجموعه داده‌های آموزشی، ظرفیت مدل را برای تشخیص و

- 1- Histogram oriented gradients (HOG)
- 2- Scale invariant feature transform (SIFT)



شکل ۱۰- ماتریس‌های اغتشاش همراه با دقت تشخیص داده‌های آزمون برای روش‌های طبقه‌بندی مختلف

Fig. 10. Confusion matrices for different classification methods

جدول ۸- تحلیل مقایسه‌ای نتایج آزمایش روش‌های مختلف برای درجه‌بندی چهار درجه کشمش طلایی

Table 8- Comparative analysis of the experimentation results of different methods for four grades of golden raisin

مدل	دقت آموزش	دقت آزمون
Model	Training Accuracy	Test Accuracy
HOG-SVM	90.40	75
HOG-LR	95.30	46.67
HOG-KNN	82.25	40
SIFT-SVM	85.47	27.5
SIFT-LR	75.67	22.5
SIFT-KNN	79.59	26.67
Raisin_DCNN	92.34	96
InceptionV3	94.67	90
InceptionResNetV2	90.45	89.80

نتیجه‌گیری

در این مقاله، یک معماری جدید مبتنی بر شبکه عصبی کانولوشنی عمیق با نام Raisin_DCNN برای درجه‌بندی دانه‌های کشمش تیزابی طلایی که از نمونه‌های محلی جمع‌آوری شده بودند، طراحی شده است. در این معماری، از لایه‌های کانولوشنی و لایه‌های تجمیع برای استخراج ویژگی‌های پیچیده و عمیق دانه‌های کشمش استفاده گردید. همچنین دو مدل از پیش آموزش‌دیده DCNN یعنی InceptionV3 و InceptionResNetV2 برای درجه‌بندی دانه‌های کشمش تیزابی طلایی به کار گرفته شدند. به کارگیری تکنیک‌های متنوع افزایش داده بر روی مجموعه آموزشی، موجب افزایش تنوع

مجموعه داده و بهبود قابلیت تعمیم مدل‌های DCNN شده و همزمان از بروز پدیده بیش‌برازش جلوگیری به عمل می‌آورد. بر اساس نتایج آزمایش‌ها، مدل Raisin_DCNN بدون آن‌که نشانه‌ای از تخریب عملکرد یا بیش‌برازش در آموزش مدل مشاهده شود، با دستیابی به دقت ۹۶ درصد در مجموعه داده‌های آزمایش پس از ۵۰ دوره آموزش، عملکرد برتری در مقایسه با سایر معماری‌ها از خود نشان داد. برای ارزیابی عینی کارایی مدل‌های پیشنهادی DCNN، نتایج حاصل از چندین مدل شناخته‌شده یادگیری ماشین با ویژگی‌های استخراج‌شده توسط روش‌های HOG-SVM، SIFT-SVM، HOG-LR، SIFT-LR، HOG-KNN، SIFT-KNN و SIFT-KNN با نتایج مدل Raisin_DCNN و مدل‌های یادگیری انتقالی روی

مجموعه داده دانه‌های کشمش مقایسه گردید. تحلیل‌های مقایسه‌ای به‌وضوح نشان می‌دهند که مدل‌های DCNN به‌طور پیوسته و در تمامی وظایف مشابه بینایی ماشین، عملکردی برتر از سایر رویکردها ارائه می‌دهند.

مشارکت نویسندگان

حامد میرخراسانی: جمع‌آوری داده‌ها، پردازش داده‌ها، شبیه‌سازی

عددی یا کامپیوتری، استخراج و تهیه متن اولیه

مهدی عباسقلی‌پور: نظارت و مدیریت، مفهوم‌سازی، روش‌شناسی، تحلیل آماری، اعتبارسنجی، شبیه‌سازی عددی یا کامپیوتری، ویرایش متن

بهزاد محمدی‌الستی: روش‌شناسی، مشاوره فنی، خدمات نرم‌افزاری، ویرایش متن

References

1. Abbasgholipour, M., Omid, M., Keyhani, A., & Mohtasebi, S. S. (2011). Color image segmentation with genetic algorithm in a raisin sorting system based on machine vision in variable conditions. *Expert Systems with Applications*, 38(4), 3671-3678. <https://doi.org/10.1016/j.eswa.2010.09.023>
2. Alom, M. Z., Hasan, M., Yakopcic, C., Taha, T., & Asari, V. (2020). Improved inception-residual convolutional neural network for object recognition. *Neural Computing and Applications*, 32(1), 279-293. <https://doi.org/10.1007/s00521-018-3627-6>
3. Angadi, Sh. A., & Hiregoudar, N. (2016). A cost effective algorithm for grading raisins using image processing. *International Journal of Recent Trends in Engineering & Research (IJRTER)*, 2, 2455-2457.
4. Backes, A. R., & Khojastehnazhand, M. (2024). Optimizing a combination of texture features with partial swarm optimizer method for bulk raisin classification. *Signal, Image and Video Processing*, 18(3), 2621-2628. <https://doi.org/10.1007/s11760-023-02935-y>
5. Çınar, İ., Koklu, M., & Taşdemir, Ş. (2020). Classification of raisin grains using machine vision and artificial intelligence methods. *Gazi Journal of Engineering Sciences*, 6(3), 200-209.
6. Din, N. M. U., Assad, A., Dar, R. A., Rasool, M., Sabha, S. U., Majeed, T., Islam, Z. U., Gulzar, W., & Yaseen, A. (2024). RiceNet: A deep convolutional neural network approach for classification of rice varieties. *Expert Systems with Applications*, 235, 121214. <https://doi.org/10.1016/j.eswa.2023.121214>
7. Falahat Nejad Mahani, Sh., & Karami, A. (2023). Maize Tassel Detection and Counting Using Deep Learning Techniques. *Journal of Agricultural Machinery*, 13(2), 175-194. <https://doi.org/10.22067/jam.2022.72477.1062>
8. FAO. (2023). Food and Agricultural Organization of the United Nations. *FAOSTAT Database*. <http://apps.fao.org/>
9. Fatehi, F., Bagherpour, H., & Amiri Parian, J. (2025). Investigating the Potential of the Innovative YOLOv8s Model for Detecting Bloomed Damask Roses in Open Fields. *Journal of Agricultural Machinery*, 15(3), 275-289. <https://doi.org/10.22067/jam.2024.88066.1249>
10. Fei-Fei, L., Deng, J., & Li, K. (2009). ImageNet: Constructing a large-scale image database. *Journal of Vision*, 9(8), 1037-1037. <https://doi.org/10.1167/9.8.1037>
11. Grandini, M., Bagli, E., & Visani, G. (2020). Metrics for multi-class classification: an overview. *arXiv preprint arXiv:2008.05756*. <https://doi.org/10.48550/arXiv.2008.05756>
12. Hinton, G., Deng, L., Yu, D., Dahl, G. E., Mohamed, A., Jaitly, N., ..., & Sainath, T. N. (2012). Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups. *IEEE Signal Processing Magazine*, 29(6), 82-97. <https://doi.org/10.1109/MSP.2012.2205597>
13. İncekara, H. (2024). Classification of raisin grains using different artificial neural network methods. *Intelligent Methods in Engineering Sciences*, 3(3), 99-107. <https://doi.org/10.58190/imiens.2024.104>
14. Kanellos, P. T., Kaliora, A. C., Gioxari, A., Christopoulou, G. O., Kalogeropoulos, N., & Karathanos, V. T. (2013). Absorption and bioavailability of antioxidant phytochemicals and increase of serum oxidation resistance in healthy subjects following supplementation with raisins. *Plant Foods for Human Nutrition*, 68(4), 411-415. <https://doi.org/10.1007/s11130-013-0389-2>
15. Liu, X., Yang, L., Chen, J., Yu, S., & Li, K. (2022). Region-to-boundary deep learning model with multi-scale feature fusion for medical image segmentation. *Biomedical Signal Processing and Control*, 71, 103165. <https://doi.org/10.1016/j.bspc.2021.103165>
16. Malek Madani, P., & Soleimani, N. (2025). Risk Analysis and Economic Strategies of Iranian Raisin Supply Chain with Failure Mode Analysis (FMEA): A Case Study of Malayer Raisin Industry. *Journal of Applied Economics Studies in Iran (AESI)*, 14(53), 135-167. <https://doi.org/10.22084/aes.2025.30475.3762>
17. Mollazade, K., Omid, M., & Arefi, A. (2012). Comparing data mining classifiers for grading raisins based on visual features. *Computers and Electronics in Agriculture*, 84, 124-131. <https://doi.org/10.1016/j.compag.2012.03.004>
18. Naderi Beni, A., Bagherpour, H., & Amiri Parian, J. (2024). Development and Optimization of a Novel Deep Learning Model for Diagnosis of Quince Leaf Diseases. *Journal of Agricultural Machinery*, 14(4), 445-458. <https://doi.org/10.22067/jam.2024.88013.1248>

19. Omid, M., Abbasgolipour, M., Keyhani, A., & Mohtasebi, S.S. (2010). Implementation of an efficient image processing algorithm for grading raisins. *International Journal of Signal and Image Processing*, 1(1), 31-34.
20. Omid, M., Sharouzi, M., & Keyhani, A. (2010). Development of an Automated Machine for Grading Raisins based on Color and Size. *Journal of Modelling and Simulation of System*, 1(3), 157-162.
21. Raihen, M. N., & Akter, S. (2024). Prediction modeling using deep learning for the classification of grape-type dried fruits. *International Journal of Mathematics and Computer in Engineering*, 2(1), 1-12.
22. Schuster, M. J., Wang, X., Hawkins, T., & Painter, J. E. (2017). A Comprehensive review of raisins and raisin components and their relationship to human health. *Journal of Nutrition and Health*, 50(3), 203-216. <https://doi.org/10.4163/jnh.2017.50.3.203>
23. Singla, Ch., Sarangi, P. K., Sahoo, A. K., & Singh, P. K. (2022). Deep learning enhancement on mammogram images for breast cancer detection. *Materials Today: Proceedings*, 49, 3098-3104.
24. Vidyarthi, S. K., Singh, S. K., Xiao, H. W., & Tiwari, R. (2021). Deep learnt grading of almond kernels. *Journal of Food Process Engineering*, 44(4), e13662. <https://doi.org/10.1111/jfpe.13662>
25. Wang, Ch., Shi, J., Zhang, Q., & Ying, Sh. (2017). *Histopathological image classification with bilinear convolutional neural networks*. Paper presented at the 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), Jeju, Korea (South).
26. Yu, X., Liu, K., Wu, D., & He, Y. (2012). Raisin quality classification using least squares support vector machine (LSSVM) based on combined color and texture features. *Food and Bioprocess Technology*, 5(5), 1552-1563. <https://doi.org/10.1007/s11947-011-0531-9>
27. Zhu, L., Li, Zh., Li, Ch., Wu, J., & Yue, J. (2018). High performance vegetable classification from images based on AlexNet deep learning model. *International Journal of Agricultural and Biological Engineering*, 11(4), 217-223. <https://doi.org/10.25165/j.ijabe.20181104.2690>