Saffron Agronomy & Technology
Homepage: https://saffron.torbath.ac.ir
Vol. 14, No. 1, 2026, p. 63-85

Design and Development of a Deep Learning-Powered Imaging System for Automated Classification of Saffron Based on Stigma Curvature Degree

Iman Zabbah[1,2*], Fateme Kamaliniya[1] and Zahra Heydaran Daroogheh Amnyieh[3]

1- Department of Electrical and Computer Engineering, ToH.C., Islamic Azad University, Torbat Heydarieh,Iran and Torbat Heydarieh, Iran.
2-Saffron Institute, University of Torbat Heydarieh, Torbat Heydarieh, Iran.
3-Department of Electrical Engineering, Dol.C., Islamic Azad University, Isfahan, Iran

ARTICLE INFO

Article type:
Research Article
Article history:
Submitted: 6 July 2026
Revised: 24 September 2026
Accepted: 13 October 2026
Available Online: 17 October 2026
Keywords:
Convolutional Neural Networks
Deep Learning
GoogleNet
Quality Assessment
Saffron Imaging System

EXTENDED ABSTRACT

Introduction

Saffron (*Crocus sativus* L.) is globally recognized as one of the most valuable spices, with Iran producing over 90% of the world's supply. Accurate quality grading and authentication are vital to prevent economic losses and adulteration. Traditional evaluation relies on manual visual inspection by human experts, which is subjective and error-prone. Although machine learning has been applied to agricultural products, automated systems specifically targeting saffron stigma curvature, a key physical indicator of quality, remain scarce. This study introduces an AI-based approach combining computer vision and deep learning to automate saffron classification based on stigma curvature, providing a robust solution for industrial quality control.

Materials and Methods

A custom-designed optical imaging chamber ($50 \times 50 \times 50$ cm) with adjustable camera heights (20, 30, and 40 cm) was built to capture high-resolution images of saffron using a Logitech C930e digital camera under stable lighting. A dataset of 450 saffron threads (150 samples per class) was collected and categorized by experts into three grades: Grade 1 (no curl, low curvature), Grade 2 (curled, moderate curvature), and Grade 3 (fully coiled, high curvature). Pre-processing involved grayscale conversion, filtering, thresholding, and background removal. Two deep learning architectures were evaluated: a custom Convolutional Neural Network (CNN) and a pre-trained GoogleNet model using transfer learning. Three optimizers (ADAM, SGDM, and RMSprop) were tested across 20, 60, and 100 epochs using an 80-20 train-test split (360 training and 90 test samples).

Results and Discussion

Model performance was assessed via accuracy, sensitivity, specificity, F1-score, and confusion matrices. The custom CNN model achieved a max test accuracy of 72.53% using RMSprop at 60 epochs. In contrast, the pre-trained GoogleNet model performed better. GoogleNet with ADAM achieved an outstanding test accuracy of 86.81%, sensitivity of 86.7%, specificity of 93.4%, and an F1-score of 86.8%. Results confirm that GoogleNet's Inception modules effectively extract complex spatial features of saffron threads, outperforming the custom CNN. The ADAM optimizer showed greater stability and faster convergence than RMSprop and SGDM across training epochs.

Conclusion: The proposed AI-driven imaging system provides an efficient, scalable, and non-destructive solution for the automated grading of saffron stigmas, eliminating human subjectivity. Future research directions include expanding the

dataset, exploring other pre-trained architectures like ResNet, and integrating textural feature extraction to further enhance classification robustness.

Acknowledgment

This research was supported by the Saffron Research Institute of the University of Torbat Heydarieh (Contract No. 205313).

Cite this Article:

Zabbah, I., Kamaliniya, F., and Heydaran Daroogheh Amnyieh, Z. (2026). Design and Development of a Deep Learning-Powered Imaging System for Automated Classification of Saffron Based on Stigma Curvature Degree. *Saffron Agronomy & Technology*, *14*(1): 63-85. https://doi.org/10.22048/jsat.2026.586143.1594

Corresponding author email: im.zabbah@iau.ac.ir

Print ISSN: 2383-1529 Online ISSN: 2383-2142
https://doi.org/10.22048/jsat.2026.586143.1594

© 2026, University of Torbat Heydarieh. This is an open-access article distributed under the terms of the Creative Commons Attribution-NonCommercial License (CC BY NC 4.0).

زراعت و فناوری زعفران
جلد۱۴، شماره ۱، بهار ۱۴۰۵ ص. ۸۵-۶۳
Homepage: http://saffron.torbath.ac.ir

طراحی و ساخت سامانه تصویربرداری مجهز به یادگیری عمیق برای طبقه بندی خودکار زعفران بر اساس میزان انحنای کلاله

ایمان ذباح[۱،۲*]، فاطمه کمالی نیا[۱] و زهرا حیدران داروقه امنیه[۳]

۱- گروه مهندسی برق و کامپیوتر، واحد تربت حیدریه، دانشگاه آزاد اسلامی، تربت حیدریه، ایران

۲- پژوهشگر پژوهشکده زعفران تربت حیدریه.

۳- گروه برق، واحد دولت آباد، دانشگاه آزاد اسلامی، اصفهان، ایران.

مقاله پژوهشی

تاریخ دریافت: ۱۵ تیر ۱۴۰۵
تاریخ بازنگری: ۲ مهر ۱۴۰۵
تاریخ پذیرش: ۲۱ مهر ۱۴۰۵

کلمات کلیدی

سامانه تصویربرداری زعفران
یادگیری عمیق
شبکه‌های عصبی کانولوشنی
ارزیابی کیفیت
گوگل نت

چکیده

زعفران یکی از با ارزش‌ترین ادویه های جهان، اغلب بر اساس ویژگی‌های فیزیکی رشته‌های آن درجه‌بندی می‌شود. میزان انحنای رشته های زعفران یکی از شاخص‌های کلیدی کیفیت است. ارزیابی اولیه ظاهری زعفران در آزمایشگاه و شرکت های صادرکننده توسط شخص خبره انجام می‌شود که بروز خطای انسانی را بسیار محتمل می‌کند. این مطالعه ضمن طراحی و ساخت یک سامانه تصویر برداری به منظور عکس برداری صحیح از زعفران ، یک رویکرد مبتنی بر هوش مصنوعی برای طبقه‌بندی رشته‌های زعفران به سه طبقه، درجه ۱: بدون کلاف، (انحنای کم)؛ درجه۲: کلاف، (انحنای متوسط)؛ درجه ۳: کاملا کلاف، (انحنای زیاد) و با استفاده از تکنیک‌های یادگیری عمیق ارائه می‌دهد. یک مجموعه داده از ۴۵۰ نمونه رشته زعفران (۱۵۰ نمونه برای هر درجه) توسط سامانه، نمونه برداری شده است؛ پلتفرم سخت افزاری به گونه ای است که امکان تصویر برداری از زعفران با حداقل نویز را داشته باشد. دو شبکه یادگیری عمیق کانولوشنی و گوگل نت برای طبقه‌بندی استفاده شده اند. همچنین سه الگوریتم بهینه ساز ADAM، SGDM و RMSprop در دو شبکه مورد بررسی قرار گرفته است. در بهترین حالت، شبکه عصبی کانولوشنی با دقت ۷۲/۵۳ درصد و شبکه Google-Net توانست با دقت۸۶/۸۱ درصد، حساسیت معادل ۸۶/۷ درصد، ویژگی معادل ۹۳/۴ درصد و امتیاز F1-score برابر با ۸۶.۸ درصد، میزان انحنای کلاله زعفران را به وسیله بهینه‌ساز ADAM تشخیص دهد. نتایج نشان می‌دهند که شبکه Google-Net برای طبقه‌بندی انحنای کلاله زعفران عملکرد قابل‌قبولی دارد. این مطالعه پتانسیل یادگیری عمیق و پردازش تصویر را به‌عنوان یک روش غیرمخرب در خودکارسازی ارزیابی کیفیت رشته‌های زعفران نشان می‌دهد و راه حلی مقیاس‌پذیر و کارآمد به‌منظور طبقه‌بندی خودکار کلاله زعفران ارائه می‌کند.

نحوه ارجاع دهی به مقاله: ذباح، ا.، کمالی نیا، ف.، و حیدران داروقه امنیه، ز . (۱۴۰۵). طراحی و ساخت سامانه تصویربرداری مجهز به یادگیری عمیق برای طبقه بندی خودکار زعفران بر اساس میزان انحنای کلاله. *زراعت و فناوری زعفران*، ۱۴(۱)، ۶۳-۸۵. https://doi.org/10.22048/jsat.2026.586143.1594

مقدمه

زعفران (*Crocus sativus*) به‌عنوان یکی از گران‌ترین ادویه‌های جهان، اهمیت اقتصادی و فرهنگی قابل‌توجهی دارد. این گیاه به‌طور عمده در مناطق مرتفع آسیایی و مدیترانه‌ای رشد می‌کند و در حوزه‌های آشپزی و دارویی کاربرد گسترده‌ای دارد. این گیاه کوچک و چند ساله به ارتفاع ۱۰ الی ۳۰ سانتی‌متر است

نویسندهٔ مسئول: im.zabbah@iau.ac.ir

شاپا چاپی: ۱۵۲۹-۲۳۸۳ شاپا الکترونیکی: ۲۱۴۲-۲۳۸۳
https://doi.org/10.22048/jsat.2026.586143.1594

حقوق مولفین به نویسندگان و حقوق ناشر به انتشارات دانشگاه ترتب حیدریه داده شده است. این مقاله تحت لیسانس آفرینندگی مردمی (Creative Commons License) در دسترس شما قرار گرفته است. برای جزئیات این لیسانس، از آدرس https://creativecommons.org/licenses/by-nc/4.0/deed.en دیدن فرمائید

که از وسط آن، بنه[1] یا قاعده ساقه و تعدادی برگ باریک و دراز خارج می‌شوند. از وسط برگها گل زعفران خارج شده که به یک تا سه گل منتهی می‌شوند، گل‌ها دارای ۶ گلبرگ بنفشرنگ هستند که ممکن است در بعضی موارد به رنگ ارغوانی باشند. همچنین گلها دارای سه پرچم و یک مادگی منتهی به کلاله سه شاخه به رنگ قرمز متمایل به نارنجی هستند. قسمت مورداستفاده این گیاه انتهای خامه[2] وکلاله[3] سه شاخه می‌باشد که به نام زعفران مشهور است و دارای بوی معطر با طعم کمی تلخ می‌باشد. کلاله، بخش انتهایی خامه است و بخش اصلی و با ارزش محصول نهایی را تشکیل می‌دهد. این بخش حاوی ترکیبات شیمیایی مهمی مانند کروسین[4] (مسئول رنگ)، پیکروکروسین[5] و سافرانال[6] (مسئول طعم و عطر) است که به کیفیت و ویژگی‌های حسی منحصربه‌فرد زعفران کمک می‌کنند. ایران به‌عنوان بزرگ‌ترین تولیدکننده زعفران در جهان شناخته می‌شود، که بیش از ۹۰ درصد تولید جهانی را به خود اختصاص داده است (Bergomi et al., 2022). ارزیابی کیفیت و اطمینان از اصالت زعفران به دلیل ارزش بالای اقتصادی آن امری حیاتی است. از آنجایی که کیفیت زعفران عمدتاً به ویژگی‌های بصری کلاله آن بستگی دارد، فناوری‌های بینایی ماشین[7] و پردازش تصویر به عنوان جایگزینی برای روش‌های سنتی مبتنی بر مشاهده انسانی مطرح شده‌اند. این تکنیک‌ها امکان تحلیل عینی ویژگی‌های کلاله مانند رنگ، بافت و شکل را فراهم کرده و می‌تواند به تشخیص دقیق کیفیت، درجه‌بندی و شناسایی تقلبات احتمالی کمک کنند (Movahed Ghodsinia, 2023). فناوری بینایی ماشین و روش‌های تصویربرداری پیشرفته به‌عنوان رویکردهای غیرمخرب جهت تشخیص تقلبات و ارزیابی اصالت رشته‌های زعفران مورد توجه پژوهشگران قرار گرفته است. ترکیب تصویربرداری فراطیفی مادون قرمز نزدیک (NIR-HSI) با روش‌های کمومتریکس، از جمله تحلیل مؤلفه‌های اصلی و روش‌های طبقه‌بندی و رگرسیون، ظرفیت بالایی برای شناسایی و تعیین میزان تقلب در زعفران دارد. در پژوهش، ملوی و همکاران (Malavi et al., 2024) دقت طبقه‌بندی نمونه‌های اصیل و تقلب‌شده بین ۹۵،۶ تا ۱۰۰ درصد گزارش شد که نشان‌دهنده پتانسیل این رویکرد در احراز اصالت و ارزیابی تقلبات زعفران است.

. درسالهای اخیر، جداسازی مکانیزه کلاله از گل زعفران بسیار موردتوجه تولیدکنندگان و صنعت گران داخلی و خارجی قرارگرفته و ماشینهایی نیز برای این منظور طراحی وساخته شده است. خودکارسازی این فرآیند میتواند قیمت تمام شده محصول را کاهش دهد و منجر به رونق بیشتر صنعت کشت زعفران در کشور گردد (Gandomadeh et al., 2024). کیفیت زعفران مستقیماً به ویژگی‌های فیزیکی و شیمیایی آن بستگی دارد. یکی از مهم‌ترین معیارهای کیفیت زعفران، شکل و انحنای رشته‌های آن است که می‌تواند بر قیمت و ویژگی‌های مصرفی تأثیرگذار باشد (Aissa et al., 2023). تلاشهای متعددی به منظور ارزیابی ویژگی‌های ظاهری زعفران صورت گرفته است. به عنوان نمونه در پژوهشی درجه بندی زعفران با استفاده از شبکه های عصبی مصنوعی در ۴ کلاس پوشال درجه یک، پوشال درجه دو و پوشال درجه سه و چهار انجام شده است (Yasrebi et al., 2019). در پژوهشی دیگر، روشی برای تشخیص زعفران واقعی از تقلبی با ترکیب پردازش تصویر و ماشین بردار پشتیبان (SVM)[8] ارائه شده است. پس از استخراج ۱۰۵ ویژگی مرتبط با بافت و مورفولوژی از تصاویر زعفران سیستم پیشنهادی با دقت

1 -Corm
2- Style
3 -Stigma
4 -Crocin
5 -Picrocrocin
6- Safranal
7- Computer Vision

8 -Support Vector Machine - SVM

۹۷ درصد، توانایی بالایی در تشخیص زعفران واقعی از تقلبی نشان داد (Saeidirad et al., 2021).

پژوهش‌های متعددی در زمینه ارزیابی خودکار کیفیت زعفران با استفاده از روش‌های پردازش تصویر و یادگیری ماشین انجام شده‌اند. برای مثال، مومنی و همکاران (Momeny et al., 2023) سامانه‌ای مبتنی بر شبکه عصبی کانولوشنی Inception-v4و راهبرد افزایش داده برای درجه‌بندی زعفران و تشخیص تقلب توسعه دادند که دقت طبقه‌بندی ۹۹،۵ درصد را گزارش کرد. همچنین، محمدزاده مقدم (Mohamadzadeh Moghadam, 2020) با استفاده از ۴۴۰ تصویر رنگی از سه گروه تجاری زعفران و استخراج ویژگی‌های رنگی و بافتی، عملکرد ۲۲ طبقه‌بند را بررسی کرد؛ نتایج نشان داد که روش‌های مبتنی بر ماشین بردار پشتیبان و سایر طبقه‌بندهای منتخب، قابلیت استفاده در درجه‌بندی غیرمخرب زعفران را دارند. در کاربردی متفاوت، سعدی و ماکاریان (Saedi & Makarian, 2025) با استفاده از تصاویر رنگی و معماری بهبودیافته VGG16، سامانه‌ای برای تفکیک زعفران از دو علف هرز رایج، ازمک و خاکشیر، توسعه دادند که به دقت ۹۱ درصد در مجموعه آزمون دست یافت. این مطالعات نشان‌دهنده ظرفیت روش‌های پردازش تصویر و یادگیری عمیق در تحلیل خودکار تصاویر زعفران، درجه‌بندی کیفیت و تشخیص تقلب یا علف‌های هرز هستند. بااین‌حال، در منابع بررسی‌شده برای پژوهش حاضر، مطالعه‌ای که انحنای کلاله را به‌طور مشخص به‌عنوان شاخص مستقل کیفیت زعفران ارزیابی کرده باشد، شناسایی نشد. ازاین‌رو، بررسی ارتباط میان ویژگی هندسی انحنای کلاله و کیفیت زعفران می‌تواند زمینه‌ای برای پژوهش بیشتر فراهم کند.

همچنین، در مقاله‌ای دیگر، با استفاده از ویژگی‌های رنگی استخراج‌شده از تصاویر زعفران و به‌کارگیری شبکه‌های عصبی مصنوعی، درجه‌بندی کیفی زعفران انجام شد. در این تحقیق، ۴۴۰ تصویر از زعفران در سه کلاس مختلف جمع‌آوری و پس از استخراج ۲۱ ویژگی رنگی، با استفاده از ۲۲ طبقه‌بندی مختلف، طبقه‌بندی انجام شد. نتایج نشان داد که طبقه‌بندهای SVM خطی[1]، بهترین عملکرد را در درجه‌بندی زعفران داشتند (Mohammadzadeh Moghadam et al., 2020). مینایی و همکاران در پژوهش خود نشان دادند که ترکیب سیستم بینایی ماشین و شبکه عصبی پرسپترون چند لایه به عنوان ابزاری برای ارز یابی کیفیت زعفران بر اساس قدرت رنگی بسیار کار آمد است. همچنین آنها نشان دادند که عملکرد پرسپترون چند الیه برای تشخیص قدرت رنگی زعفران بهتر از حداقل مربعات جزئی و MLR بوده و مقدار CSR در این پژوهش ۶/۹۶ در صد بد ست آمده است (Minaei et al., 2017). تحلیل ویژگی‌های بافتی و ویژگی‌های ظاهری یکی از روش‌های کلیدی در اتوماسیون فرآیند ارزیابی کیفیت محصولات کشاورزی به شمار می‌رود. در همین راستا، کاظمی (Kazemi et al., 2026) با بهره‌گیری از الگوریتم‌های استخراج ویژگی بافت و مدل‌های یادگیری ماشین، توانستند انواع تجاری زعفران ایران از جمله سرگل، نگین و پوشال را با دقت بالایی دسته‌بندی کرده و کارایی بینایی ماشین را در تشخیص و تفکیک اصالت این محصول با ارزش را به اثبات برسانند. در پژوهشی دیگر، از فناوری تصویربرداری هایپرسپکترال به همراه الگوریتم‌های یادگیری ماشین به عنوان یک روش سریع برای تشخیص تقلب در زعفران استفاده شده است. نمونه‌های تقلبی با افزودن خامه گیاه به زعفران خالص با غلظت‌های ۲۰ تا ۹۰ درصد تهیه شدند. داده‌های طیفی با روش‌های SNV و MSC پیش‌پردازش و با PCA و PLS کاهش بعد یافتند. این مطالعه هزینه بالای تجهیزات را به عنوان چالش اصلی این فناوری ذکر کرده است (Malavi et al., 2024). پیشرفت‌های اخیر در فناوری بینایی ماشین و الگوریتم‌های یادگیری عمیق، تحول عظیمی در ارزیابی

1- Linear SVM Classifiers

غیرمخرب محصولات کشاورزی و ادویه‌های باارزش ایجاد کرده است. برای نمونه، (Bohlol et al., 2025) با تلفیق سیستم بینایی ماشین، تکنیک‌های پیشرفته‌ی افزایش داده‌های تطبیقی و شبکه‌های عمیق کانولوشنی مانند InceptionV3 پلتفرمی کارآمد برای دسته‌بندی و تشخیص کیفیت زعفران صادراتی در کلاس‌های مختلف ارائه دادند که نشان‌دهنده‌ی پتانسیل بالای این فناوری‌ها در مدیریت هوشمند کیفیت و اتوماسیون صنعتی فرآیندهای پس از برداشت است. در پژوهش قرآنی و همکاران، به تاثیرات دما و رطوبت نسبی و همچنین ریز گردها (مواد زائد) بر ویژگی‌های فیزیکوشیمیایی زعفران اشاره شده است. این پژوهش نشان می‌دهد که افزایش رطوبت، آهنگ خروج ترکیبات مؤثره زعفران را افزایش داده و در نهایت در کیفیت طبقه بندی این محصول تأثیر بسازیی خواهد داشت (Ghorani et al., 2017). در پژوهش مرادی نژاد و همکاران نشان داده شده است که شرایط مختلف خشک کردن و نگهداری سبب کاهش کیفیت و مواد مؤثره کلاله زعفران شده و با تاثیر در طبقه بندی زعفران ، از ارزش و اعتبار آن جهت صادرات کاسته است (Birjandi Toroghi et al., 2023). با گسترش کاربرد هوش مصنوعی در صنایع غذایی، استفاده از الگوریتم‌های یادگیری ماشین و یادگیری عمیق به ابزاری قدرتمند برای ارزیابی اصالت و تشخیص تقلبات زعفران تبدیل شده است. در همین راستا، بررسی‌های جامع انجام‌شده نشان می‌دهد که مدل‌های پیشرفته‌ی یادگیری عمیق توانسته‌اند با تحلیل الگوهای پیچیده‌ی تصویربرداری و داده‌های طیفی، دقت و سرعت شناسایی نمونه‌های تقلبی زعفران را به شکل چشمگیری افزایش دهند (Mahajan et al., 2025). در این پژوهش رویکردی خودکار بر پایه شبکه‌های عصبی عمیق (کانولوشنی) برای ارزیابی انحنای رشته‌های زعفران به عنوان یک روش غیر مخرب ارائه شده است. از آنجایی که یکی از روش‌های تشخیص تقلبی بودن زعفران مشخص کردن میزان خمیدگی رشته زعفران است، لذا روش معرفی شده می‌تواند به طور مؤثری در تشخیص تقلبی بودن زعفران نیز کارامد باشد. در این مطالعه، از مجموعه‌ای از تصاویر زعفران در سه درجه کیفی استفاده شده و با آموزش مدل، دقت و صحت طبقه‌بندی مورد ارزیابی قرار گرفته است.

مواد و روش‌ها

در حال حاضر در بسیاری از شرکت‌های فراوری و بسته بندی زعفران ارزیابی اولیه زعفران قبل از ورود به چرخه آزمایشگاه، به صورت چشمی و توسط شخص خبره انجام می‌شود به طوری که در بدو ورود زعفران به مجموعه، یک کارشناس خبره اقدام پر کردن فرم ارزیابی اولیه می‌کند که معمولا شامل ۷ پارامتر ظاهری: رنگ زعفران، میزان خامه، میزان مواد زائد[1]، وضعیت گرده[2]، میزان خمیدگی زعفران[3]، رطوبت[4] و میزان درشتی کلاله[5] زعفران است. در این مطالعه، به منظور محاسبه انحنا با هدف ارزیابی یکی از ویژگی های ظاهری زعفران در یک پلتفرم سخت افزاری جهت تصویر برداری ساخته شده است.

معیارهای درجشده در جدول ۱ بر اساس روش‌های رایج ارزیابی چشمی و تجربی استخراج شده‌اند که در شرکت‌های فرآوری و بسته‌بندی زعفران در منطقه تربت‌حیدریه برای غربالگری و دسته‌بندی اولیه نمونه‌ها پیش از ارسال به آزمایشگاه مورد استفاده قرار می‌گیرند. لازم به ذکر است که برخی از پارامترهای مندرج در جدول ۱ به عنوان معیار ارزیابی علمی، در پژوهش های مختلف مورد استفاده قرار گرفته است. به عنوان مثال ردیف ۳ جدول ۱ مربوط به انحنای زعفران است

1- Impurities / Foreign matter
2- Pollen
3- Saffron curvature
4- Moisture
5 -Stigma thickness

که عموما توسط شخص خبره اندازه‌گیری شده و در سه کـلاس انحنای زیاد، انحنای متوسط، انحنای کم دسته بندی می‌شود.

جدول ۱- فرم اولیه ثبت اطلاعات زعفران

Table 1- The initial form for registering bulk saffron information

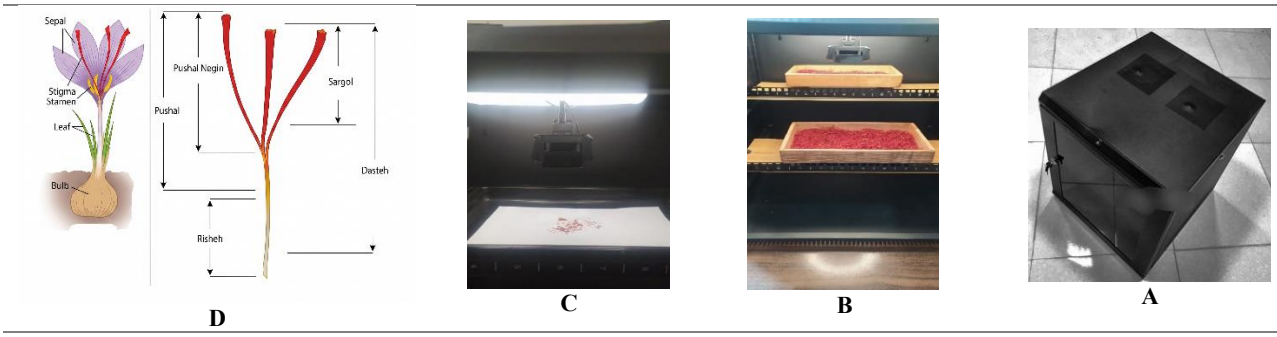
ردیف Number	نوع پارامتر Parameter type	درجات هر پارامتر The degrees of each parameter			
1	درشتی کلاله Large stigma	Good	خوب	Very good	خیلی خوب
		Bad	بد	Median	متوسط
2	رنگ Color	Bright/ Opaque	روشن/ کدر	Bright/ Nitid	روشن/ شفاف
		A little dark	کمی تیره	Normal	معمولی
		Dark & light mixture	مخلوط تیره و روشن	Quite dark	کاملاً تیره
3	انحنا (کلاف) Skein			Full skein	کاملاً کلاف(انحنای زیاد)
				Average skein	کلاف(انحنای متوسط)
				Median skein	بدون کلاف(انحنای کم)
4	خامه Style	Normal	معمولی	High	زیاد
		Very low	خیلی کم	Low	کم
5	رطوبت Moisture	Low moisture	رطوبت کم	Dry	خشک
				High moisture	رطوبت زیاد
6	گرده Pollen	Low	کم	Without pollen	بدون گرده
		High	زیاد	Normal	معمولی
				Very high	خیلی زیاد
7	بقایای مواد خارجی Remnants of foreign matter	Normal	معمولی	Low	کم
		Very high	خیلی زیاد	High	زیاد

طراحی و ساخت سامانه تصویربرداری[1] زعفران

از آنجایی که تصویر برداری از زعفران به منظور ایجاد پایگاه داده تصویری استاندارد نیازمند تکنیک‌های صحیح نور پردازی و تصویربرداری است، اقدام به طراحی و ساخت سامانه تصویر برداری به منظور عکس برداری با مکانیزم صحیح گردید. شکل ۱ سخت افزار طراحی و ساخته شده بدین منظور را نشان می‌دهد.

سامانه طراحی‌شده به منظور تحلیل انحنای زعفران به گونه‌ای است که امکان تصویربرداری دقیق از رشته‌های زعفران را با حداقل نویز و در شرایط نوری پایدار فراهم می‌کند. محفظه طراحی شده دارای مشخصات زیر است : ۱. مشخصات فیزیکی و هندسی سامانه :سامانه تصویربرداری به‌صورت یک محفظه کنترل‌شده نوری با ابعاد ۵۰×۵۰×۵۰ سانتی‌متر طراحی و ساخته شده است. این دستگاه مجهز به طبقات مختلف برای قرارگیری نمونه‌ها بوده و فاصله دوربین از طبقات تصویربرداری در سه سطح متغیر بین ۲۰، ۳۰ و ۴۰ سانتی‌متر قابل تنظیم است. شرایط نوری مناسب و یکنواخت نیز برای به حداقل رساندن نویز و بازتاب‌های نوری در داخل محفظه تعبیه شده است. (شکل ۱. a تا c). ۲. مکانیزم چیدمان نمونه‌ها: چیدمان رشته‌های زعفران در طبقات این سامانه به‌صورت دستی توسط کاربر انجام می‌شود و دستگاه فاقد مکانیزم مکانیکی خودکار برای جداسازی اولیه رشته‌ها است؛ کاربر نمونه‌ها را روی سینی‌های تعبیه‌شده در طبقات قرار داده و تصویربرداری انجام می‌گیرد. ۳. دسترسی به مجموعه داده: مجموعه داده جمع‌آوری‌شده محرمانگی خاصی ندارد و می‌تواند در اختیار سایر محققین قرار گیرد.

1- Imaging Device



شکل ۱- نمای سخت افزاری سامانه تصویر برداری زعفران

Figure 1- Hardware view of the saffron imaging device.

A-:نمای بیرونی - B: نمای درونی -C: نحوه تصویربرداری از کلاله زعفران -D: تصویر شماتیک گل زعفران.

A: External view of the device - B: Internal view - C: How to image saffron stigma - D: Initial image obtained.

نورپردازی صحیح یکی از عوامل کلیدی در تصویربرداری با کیفیت از نمونه‌های کشاورزی مانند زعفران است (Zabbah et al., 2023) به همین دلیل سخت افزار به نحوی طراحی شده است که امکان تنظیم نور و به حداقل رساندن تداخلات نوری وجود داشته باشد. تصاویر با استفاده از یک دوربین دیجیتال[1] logitec مدل e۹۳۰C پیشرفته p۱۰۸۰HD[2] با وضوح بالا تحت شرایط نورپردازی استاندارد ثبت شدند. سپس، تصاویر به محیط MATLAB 2022 منتقل شده و فرآیند پیش‌پردازش بر روی آن‌ها اعمال گردید این نمونه‌ها توسط اشخاص خبره با سابقه طولانی در زمینه‌ی تجارت و کیفیت زعفران مورد ارزیابی قرار گرفته بودند. متخصصان کلاله های زعفران را بر اساس میزان انحنا به سه دسته : درجه یک (کمترین انحنا، بالاترین کیفیت)، درجه دو (با انحنای متوسط، کیفیت معمولی) و درجه سه (با بیشترین انحنا، کیفیت ضعیف) دسته‌بندی کردند. در مجموع ۴۵۰ نمونه رشته زعفران یعنی برای هر درجه (درجه ۱، درجه ۲ و درجه ۳) ۱۵۰ نمونه جمع آوری گردید. هر نمونه یک رشته زعفران بود و انحنا هر رشته به صورت دستی ارزیابی شد تا برچسب‌گذاری[3] دقیق انجام شود.شکل ۲ نمونه های زعفران از نظر میزان انحنا را نشان می‌دهد.

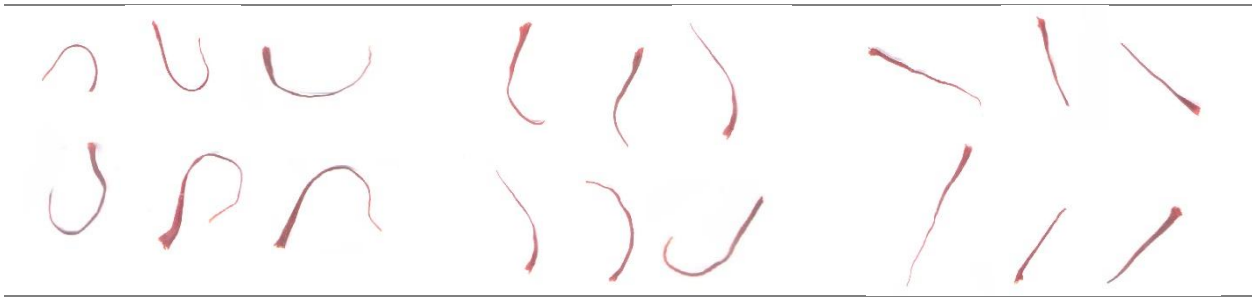
متد کلاس بندی[4] انحنای زعفران و یادگیری انتقالی[5]

به طور کلی باید یک تعادل بین دقت[6] و قابلیت تعمیم[7] در سیستم یادگیر وجود داشته باشد درصورت وجود داده های اعتبار سنجی[8] در این سیستم یادگیر و گزینش صحیح ویژگی ها کلاس بندی انجام شد.

علت بکارگیری یادگر عمیق کانولوشنی به عنوان مدل پایه و برای ارزیابی اولیه، قابلیت استخراج ویژگی‌های مطلوب تصویر کلاله زعفران می‌باشد. از سوی دیگر، به منظور بهبود عملکرد دسته‌بندی و غلبه بر محدودیت‌های مدل‌های پایه در مواجهه با پیچیدگی‌های تصویری، از معماری پیشرفته گوگل نت استفاده گردید. ویژگی بارز این شبکه، بهره‌گیری از ماژول‌هایی است که با اعمال همزمان فیلترهای با اندازه‌های مختلف در یک لایه، امکان استخراج همزمان ویژگی‌های ریز و درشت ساختاری را فراهم می‌کند.

1- Digital camera
2- High definition - HD
3- Labeling

4- Classification method
5- Transfer learning
6- Accuracy
7- Generalizability
8- Validation data



شکل ۲- A: نمونه زعفران درجه یک (بدون کلاف، انحنای کم) - B: نمونه زعفران درجه دو (کلاف، انحنای متوسط) -C: نمونه زعفران درجه سه (کاملا کلاف، انحنا زیاد). (تعداد تصاویر تهیه شده در هر کلاس ۱۵۰ عدد)

Figure 2- A: First-grade saffron sample (no coils, low curvature) - B: Second-grade saffron sample (coils, medium curvature) - C: Third-grade saffron sample (fully coiled, high curvature). (Number of images prepared in each class: 150).

همچنین این ساختار با استفاده از لایه‌های کاهش ابعاد، حجم پارامترهای آموزش‌پذیر و بار محاسباتی را به‌طور چشمگیری کاهش داده و از بیش‌برازش[1] جلوگیری می‌کند؛ امری که آن را به گزینه‌ایمناسب برای طبقه‌بندی دقیق انحنای کلاله زعفران تبدیل می‌سازد. ایده اصلی در یادگیری انتقالی یادگیری عمیق این است که اگر یک شبکه عصبی عمیق با تعداد زیادی لایه و پارامتر در یک مسئله پیچیده آموزش داده شود، می‌توان این شبکه را به عنوان یک مبنای اولیه استفاده کرد و آن را برای حل مسائل مرتبط دیگر به کار برد. در فرایند یادگیری انتقالی، شبکه عصبی عمیق ابتدا با استفاده از داده‌های آموزشی در مسئله اصلی آموزش می‌بیند و وزن‌های آن بهینه می‌شوند. سپس، بخشی از شبکه یا لایه‌های آن به همراه وزن‌هایشان (معمولاً لایه‌های پیش‌آموزش‌دیده) برای حل مسئله یا وظیفه جدید استفاده می‌شوند. این لایه‌ها می‌توانند به صورت جزئی یا کامل به عنوان ورودی برای شبکه جدید استفاده شوند. سپس، شبکه جدید با استفاده از داده‌های جدید در مسئله جدید آموزش داده می‌شود و وزن‌های آن بهبود می‌یابند.

1- Overfitting

تفکیک داده های آموزش و آزمون

مطالعه حاضر بر روی ۴۵۰ نمونه زعفران صورت گرفته است. نمونه ها توسط محققین این پژوهش اخذ شده است. همانطور که ذکر شد، در بسیاری از شرکت های بسته بندی زعفران، یک کارشناس خبره با بررسی وضعیت ظاهری زعفران اقدام به تهیه شناسنامه زعفران وارده به چرخه (جدول ۱) می‌نماید. این اطلاعات شامل ۷ ویژگی است که هریک از آنها مشتمل بر چند حالت است. به منظور تشخیص انحنای زعفران بایستی ویژگی شماره ۳ مد نظر قرار گیرد. بدین منظور در مدل یادگیر ماشین ۸۰ درصد داده‌ها به منظور آموزش (۳۶۰ نمونه) و ۲۰ درصد (۹۰ نمونه) به منظور تست شبکه مورد استفاده قرار گرفته است. جدول ۲ وضعیت نمونه های جمع آوری شده و تعداد نمونه های آموزش و آزمون را نشان می‌دهد.

الگوریتم پیشنهادی

شکل ۳، فلوچارت مراحل کلی الگوریتم پیشنهادی را نشان می‌دهد. همانطور که ذکر شد در این پژوهش، هدف اصلی تشخیص خودکار یکی از شاخص های کیفی زعفران براساس میزان انحنای رشته‌های آن است. برای دستیابی به این هدف، یک فریم‌ورک یادگیری عمیق با استفاده از دو شبکه‌ی عصبی،

شامل یک شبکه‌ی کانولوشنی سفارشی و یک شبکه‌ی گوگل‌نت از پیش‌آموزش‌دیده، طراحی و پیاده‌سازی شده است. انتخاب این دو مدل به دلیل قابلیت بالای آن‌ها در استخراج ویژگی‌های بصری از تصاویر و دقت مناسب در طبقه‌بندی داده‌های تصویری صورت گرفته است. رویکرد پیشنهادی در ۴ گام به شرح زیر طراحی و اجرا شده است:

جدول ۲- تعداد نمونه های موجود در پایگاه داده و تعداد نمونه های آموزش و آزمون
Table 2- Number of samples in the database and number of training and testing samples

پایگاه داده Dataset	درجه ۱ Grade 1	درجه ۲ Grade 2	درجه ۳ Grade 3	مجموع Total
مجموع Total	150	150	150	450
نمونه های آموزش Training sample	120	120	120	360
نمونه های آزمون Testing sample	30	30	30	90

فاز تشکیل دیتاست

از آنجایی که مدل طراحی شده به نمونه های مناسب وابسته است در ابتدا باید دیتاست مناسبی تشکیل داده شود.

فاز اول

پیش پرداز داده ها و تفکیک پایگاه داده مفروض به دو مجموعه آموزش و آزمون.

در این فاز به‌منظور آماده‌سازی تصاویر ثبت‌شده توسط سامانه تصویربرداری و بهبود کیفیت داده‌های ورودی به شبکه‌های یادگیری عمیق، مجموعه‌ای از مراحل پیش‌پردازش روی تصاویر اعمال شد. این مراحل به شرح زیر می‌باشند :۱ . تبدیل به تصویر خاکستری :برای کاهش حجم محاسبات و حذف اطلاعات اضافی رنگی که نقشی در تشخیص انحنا نداشتند، تصاویر رنگی RGB ابتدا به تصاویر تک‌کاناله خاکستری تبدیل شدند .۲ .فیلترینگ و کاهش نویز :جهت حذف نویزهای احتمالی ناشی از بازتاب نور در محفظه، از فیلترهای مناسب هموارسازی استفاده شد .۳ .آستانه‌گذاری : به منظور تفکیک مرزهای کلاله زعفران، عملیات آستانه‌گذاری روی شدت روشنایی پیکسل‌ها اعمال گردید .۴ .جداسازی شیء از پس‌زمینه : در نهایت با استفاده از تکنیک‌های پردازش تصویر، پس‌زمینه تصویر حذف شده و رشته‌های زعفران به‌صورت کامل از پس‌زمینه جدا شدند تا تنها نواحی مورد نظر به عنوان ورودی به مدل‌های CNN و Google-Net اعمال گردند.

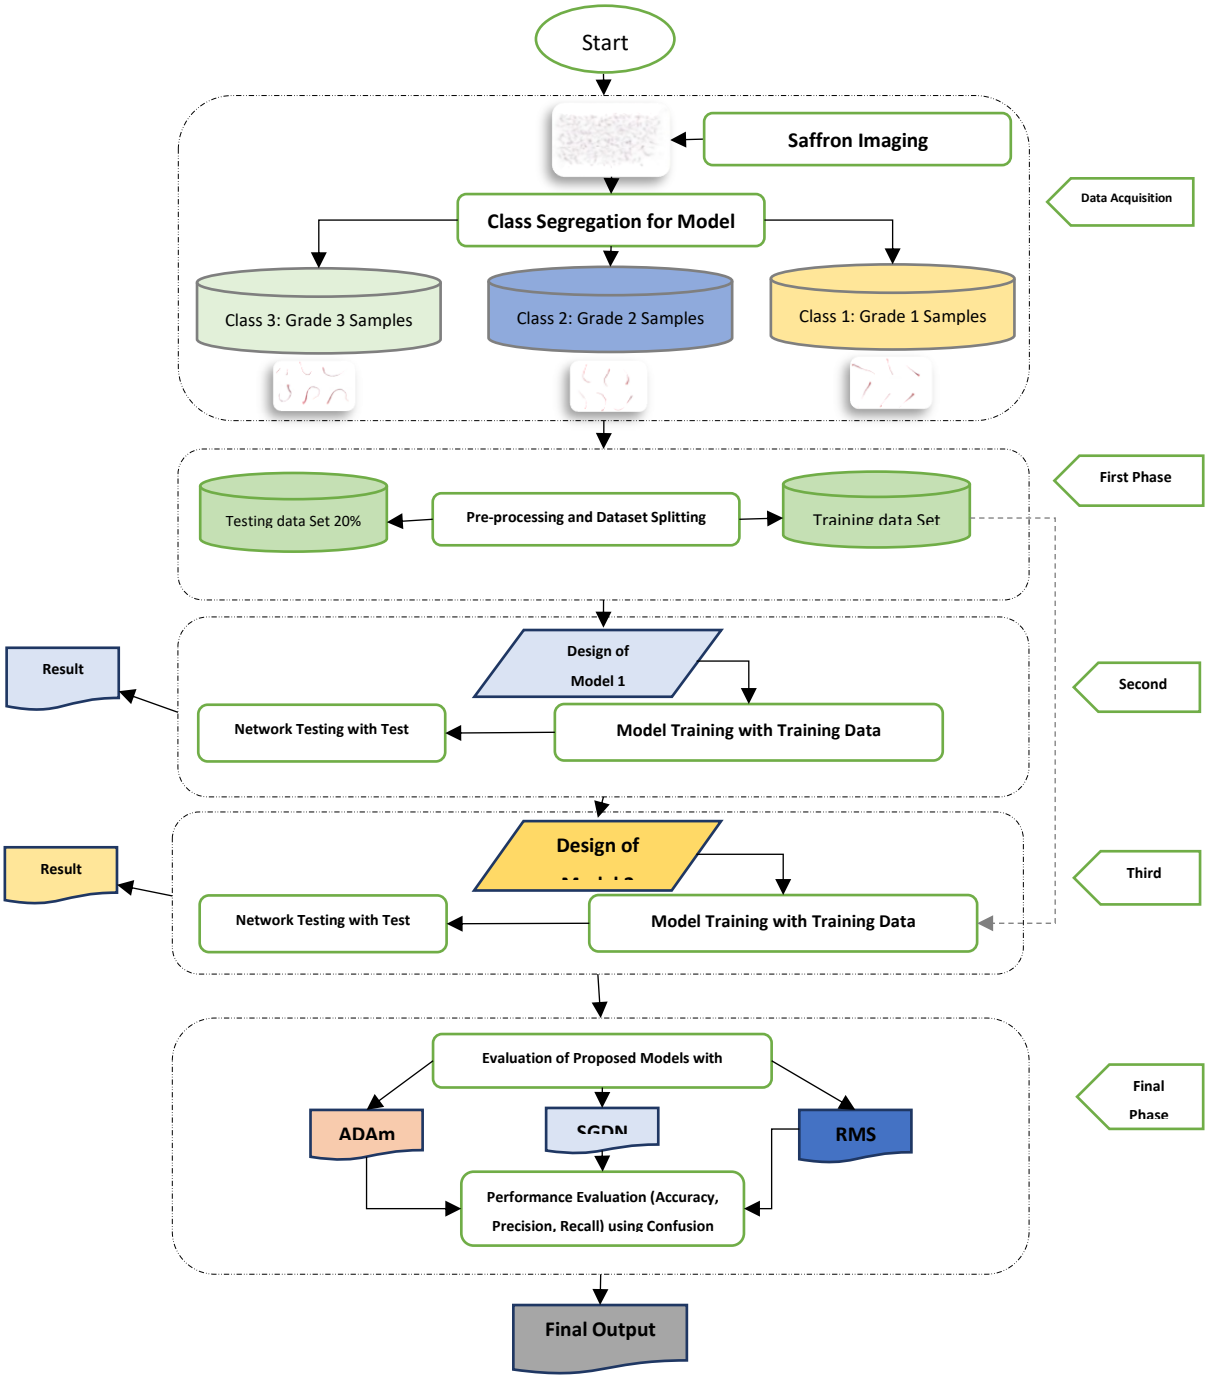
فاز دوم

طراحی یک شبکه‌ی عصبی کانولوشنی سفارشی در محیط متلب شامل لایه‌های کانولوشن، پولینگ[1]، کاملاً متصل [2]و سافت‌مکس[3] برای طبقه‌بندی تصاویر زعفران در سه درجه کیفیت.

فاز سوم

استفاده از مدل از پیش اموزش داده شده گوگل نت و اعمال یادگیری انتقالی جهت تنظیم مجدد شبکه برای طبقه‌بندی درجه‌ی زعفران.

1- Pooling Layer
2- Fully Connected Layer
3- Softmax Layer



شکل ۳- الگوریتم مورد استفاده در این پژوهش

Figure 3 - Algorithm used in this research.

فاز نهایی

آموزش مدل‌ها با استفاده از سه الگوریتم بهینه‌سازی مختلف و تنظیم پارامترهایی نظیر تعداد تکرار و اندازه مینی بچ[1] برای مقایسه عملکرد و دستیابی به بهترین نتایج. ارزیابی دقت طبقه‌بندی هر مدل با استفاده از داده‌های آزمون، بررسی ماتریس آشفتگی،[2] و مقایسه نهایی جهت انتخاب دقیق‌ترین

1- Mini-batch Size

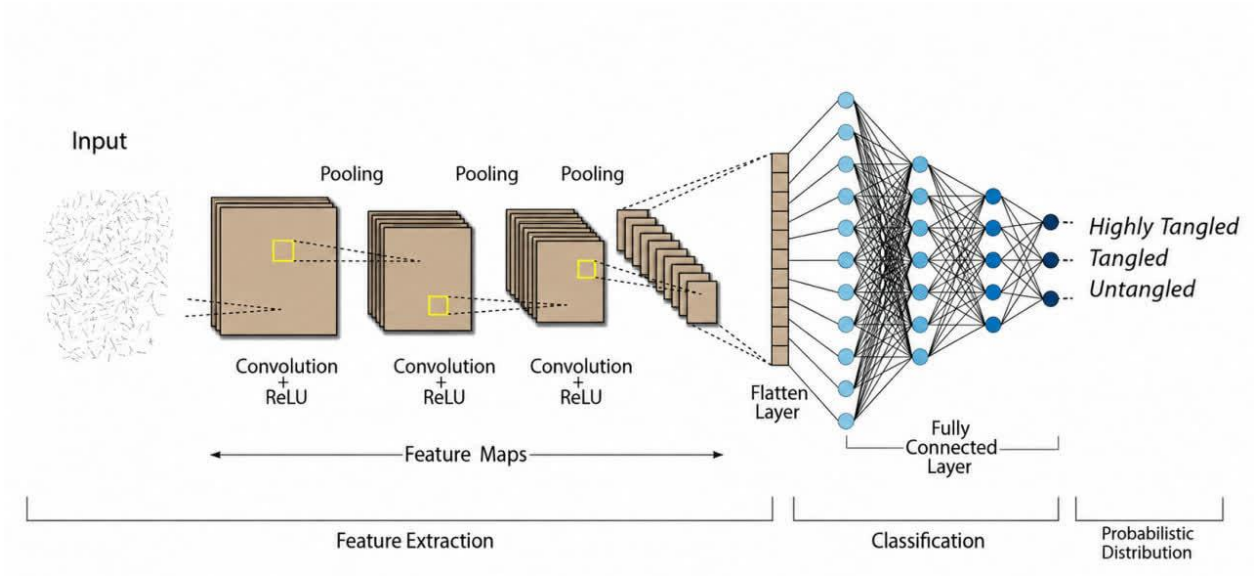
2- Confusion Matrix

مدل برای ارزیابی میزان انحنای تیج زعفران.

طراحی شبکه کانولوشن

شبکه‌های عصبی کانولوشن، از محبوب‌ترین معماری‌های مورد استفاده در حوزه بینایی ماشین هستند. این شبکه‌ها که گاهی در مقالات فارسی به‌عنوان "شبکه‌های پیچشی" شناخته می‌شوند، از ساختار قشر بینایی انسان الهام گرفته شده‌اند و قابلیت تحلیل و استخراج ویژگی‌های پیچیده در داده‌های تصویری را دارند. کانولوشن ها به دلیل عملکرد برتر خود در تشخیص الگوها و ویژگی‌های تصاویر، کاربردهای گسترده‌ای در زمینه‌هایی مانند تشخیص چهره، وسایل نقلیه خودران، و طبقه‌بندی تصاویر پیدا کرده‌اند. بر خلاف شبکه‌های عصبی سنتی مانند پرسپترون چندلایه [1] که مبتنی بر ضرب ماتریسی بین ورودی‌ها و وزن‌ها هستند، شبکه‌های کانولوشن از عملیات کانولوشن برای تحلیل داده‌های ورودی استفاده می‌کنند. شبکه‌های کانولوشن از سه لایه اصلی تشکیل شده‌اند: لایه کانولوشن: این لایه‌ها با استفاده از فیلترهایی که الگوهای خاصی مانند لبه‌ها یا بافت‌ها را جستجو می‌کنند، ویژگی‌های مهم را از تصویر ورودی استخراج می‌کنند. هر فیلتر یا کرنل، یک ماتریس کوچک است که بر تصویر حرکت کرده و حاصل‌ضرب داخلی بین وزن‌های کرنل و مقادیر پیکسل‌های تصویر را محاسبه می‌کند. خروجی این عملیات که به نقشه ویژگی [2] یا نقشه فعالیت معروف است، نشان‌دهنده ویژگی‌های استخراج‌شده از تصویر در آن مرحله است. اندازه کرنل [3]: ابعاد ماتریس فیلتر که معمولاً اعداد فرد مانند ۳×۳ یا ۵×۵ هستند. گام: میزان جابه‌جایی فیلتر بر روی تصویر در هر مرحله. پدینگ [4]: افزودن پیکسل‌های اضافی به حاشیه تصویر برای حفظ ابعاد نقشه ویژگی. تعداد فیلترها: تعداد فیلترها در هر لایه کانولوشن تعیین‌کننده تعداد الگوهای استخراج‌شده است. لایه ادغام: لایه‌های ادغام برای کاهش ابعاد نقشه‌های ویژگی و در نتیجه کاهش تعداد پارامترها و محاسبات مورد استفاده قرار می‌گیرند. لایه‌های تمام‌متصل [5] : این لایه‌ها در انتهای شبکه قرار دارند و با جمع‌آوری ویژگی‌های استخراج‌شده از لایه‌های کانولوشن و ادغام، مسئول پیش‌بینی خروجی نهایی هستند. معماری CNN به دلیل قابلیت کاهش تعداد پارامترها، استفاده مجدد از فیلترها، و امکان تحلیل وابستگی‌های مکانی در تصاویر، به‌ویژه برای داده‌های تصویری پیچیده بسیار مناسب است. لایه‌های ابتدایی این شبکه معمولاً ویژگی‌های سطح پایین (مانند لبه‌ها و بافت‌ها) و لایه‌های میانی و انتهایی ویژگی‌های سطح بالا (مانند اشیاء یا چهره‌ها) را شناسایی می‌کنند. این ساختار چندلایه به کاتولوشن ها اجازه می‌دهد تا ویژگی‌های پیچیده‌تری از تصاویر را شناسایی کرده و دقت بالایی در پیش‌بینی طبقه‌ها داشته باشند. شبکه‌های عصبی کانولوشن با بهره‌گیری از مفاهیم کانولوشن و فیلترها، تحولی اساسی در پردازش تصویر و بینایی ماشین ایجاد کرده‌اند. انعطاف‌پذیری بالا، توانایی استخراج ویژگی‌های پیچیده، و کاهش قابل‌توجه پارامترهای محاسباتی، این شبکه‌ها را به انتخابی ایده‌آل برای کاربردهای مختلفی در حوزه‌های علمی و صنعتی تبدیل کرده است. شکل ۲ ساختار شبکه عمیق مورد استفاده در این پژوهش را نشان می‌دهد.

1- Multi-Layer Perceptron - MLP
2- Feature map
3- Kernel size
4- Padding
5- Fully Connected Layers



شکل ٤- ساختار شبکه عصبی عمیق CNN طراحی شده

Figure 4- CNN (Neural Network structure).

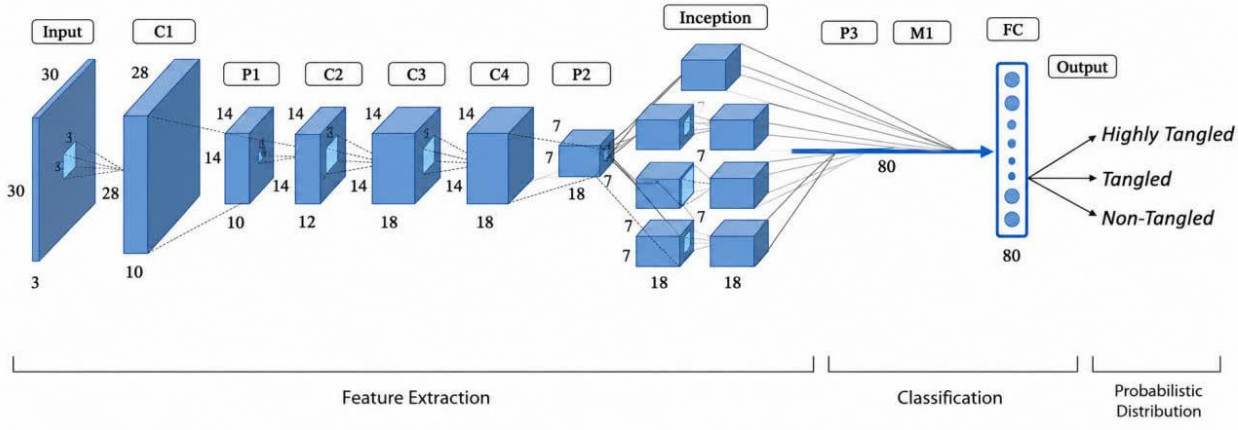
طراحی شبکه عمیق از پیش آموزش دیده Google-Net

یکی از شبکه‌های عصبی عمیق پیشرفته و تحول‌آفرین که توسط تیم تحقیقاتی گوگل در سال ۲۰۱۴ معرفی شد، Google-Net (معروف به Inception v1) است. این شبکه نمایانگر نسل جدیدی از معماری‌های یادگیری عمیق است که تمرکز ویژه‌ای بر کاهش پیچیدگی محاسباتی و افزایش دقت دارد. معماری Inception: قلب گوگل نت هسته اصلی مبتنی بر ماژول‌های اینسپشن[1] است. این ماژول‌ها با هدف استخراج همزمان ویژگی‌های متنوع از تصاویر در چندین مقیاس طراحی شده‌اند. این امر منجر به کاهش چشمگیر تعداد پارامترها و نیاز به حافظه شده است. هر ماژول شامل چندین مسیر موازی با فیلترهایی با اندازه‌های متفاوت (مانند۱×۱، ۳×۳، و ۵×۵) است که برای استخراج ویژگی‌های سطح پایین، متوسط و بالا از تصویر ورودی به‌کار می‌روند. علاوه بر این، یک لایه Pooling نیز به‌صورت موازی قرار می‌گیرد که وظیفه کاهش ابعاد و حفظ اطلاعات مفید را بر عهده دارد. شبکه‌های عصبی کلاسیک به دلیل استفاده از لایه‌های تمام‌متصل و ماتریس‌های وزن بزرگ، تعداد بسیار زیادی پارامتر دارند. شبکه گوگل با بهره‌گیری از فیلترهای۱×۱ در ماژول، نه‌تنها تعداد پارامترها را به‌طور چشمگیری کاهش داده، بلکه توانسته ویژگی‌های بیشتری از تصویر را استخراج کند.گوگل نت شامل ۲۲ لایه است که شامل لایه‌های کانولوشن، ادغام، و ماژول‌های اینسپشن است. ساختار کلی معماری آن به صورت زیر تعریف می‌شود: لایه‌های ورودی: تصویر اولیه زعفران با ابعاد مشخص (مانند ۲۲۴×۲۲۴) وارد شبکه می‌شود. لایه‌های اولیه کانولوشن و ادغام: این لایه‌ها برای استخراج ویژگی‌های پایه و کاهش ابعاد تصویر استفاده می‌شوند. ماژول‌های اینسپشن: ترکیبی از چندین مسیر موازی با فیلترهای متفاوت و عملیات ادغام است که ویژگی‌های متنوع تصویر را استخراج می‌کند. لایه‌های کمکی[2]: این لایه‌ها در میانه شبکه قرار گرفته و با ایجاد یک مسیر کمکی برای انتشار گرادیان، به یادگیری بهتر شبکه کمک می‌کنند. لایه Global Average Pooling: به‌جای لایه‌های تمام‌متصل، از

1- Inception

2- Auxiliary Classifiers

میانگین‌گیری روی تمام مقادیر نقشه ویژگی استفاده می‌شود تا خروجی نهایی شبکه ارائه شود. این شبکه توانست با کاهش تعداد پارامترها، دقت بالا و کارایی محاسباتی مناسب، به یکی از پیشرفته‌ترین معماری‌های یادگیری عمیق تبدیل شود. ساختار ماژول‌های Inception و ویژگی‌های منحصربه‌فرد آن، الهام‌بخش بسیاری از تحقیقات و معماری‌های پیشرفته‌تر، مانند Inception v2 و Inception v3 بوده است. شکل ۵ معماری شبکه گوگل نت مورد استفاده در این پژوهش را نشان می‌دهد.



شکل ۵- ساختار Google-Net طراحی شده

Figure 5- The structure of the Google-Net.

استفاده از بهینه سازها

همانطور که ذکر شد، از سه بهینه‌ساز مختلف به منظور بررسی بهترین مدل طبقه‌بندی زعفران استفاده شده است. بهینه‌ساز ADAM[1] که یکی از پرکاربردترین الگوریتم‌های بهینه‌سازی در یادگیری عمیق است، با ترکیب ویژگی‌های دو الگوریتم مومنتوم، نرخ یادگیری را برای هر پارامتر به‌صورت تطبیقی تنظیم می‌کند و همگرایی سریعی را فراهم می‌سازد. همچنین بهینه‌ساز SGDM[2] که نسخه‌ای بهبودیافته از گرادیان نزولی تصادفی است، با استفاده از مومنتوم، تغییرات ناگهانی گرادیان را کاهش داده و به عبور از مینیمم‌های محلی کمک می‌کند. و در نهایت از بهینه‌ساز RMS Prop استفاده شده است که با در نظر گرفتن میانگین متحرک مربعات گرادیان‌ها، نرخ یادگیری را به صورت پویا برای هر پارامتر تنظیم می‌نماید و برای مدل‌هایی که با داده‌های غیرایستا یا noisy سر و کار دارند، عملکرد مناسبی دارد. در این مطالعه، مدل CNN با استفاده از این سه بهینه‌ساز و در سه بازه‌ی مختلف از تعداد تکرار[3] (۲۰، ۶۰ و ۱۰۰) آموزش داده شده است. همچنین، پارامتر شافل[4] بر روی هر تکرار تنظیم شده تا تنوع داده‌ها در هر دوره‌ی آموزشی حفظ شود. مدل گوگل نت نیز با همین سه بهینه‌ساز آموزش دیده است. تعداد تکرارها هم مانند قبل در نظر گرفته شده و اندازه mini-batch برابر با ۳۲ می‌باشد.

ارزیابی نتایج

نرم افزار مورد استفاده در این مطالعه به منظور ایجاد و بررسی شبکه های عمیق، MATLAB2022 بوده و مشخصات سیستم مورد استفاده عبارت است از ویندو۱۰ نسخه ۶۴ بیتی، gig۱۰ حافظه گرافیکی ، ۸ گیگ حافظه رم و پردازنده اینتل۳۶۸۷ i7@ . به منظور آنالیز پاسخ های هریک از شبکه

1 - Adaptive Moment Estimation
2 - Stochastic Gradient Descent with Momentum

3- epochs
4- shuffle

ها و محاسبه دقت مدل ها از پارامترهای مختلفی استفاده شده است که عبارتند از : دقت که از رابطه ۱ محاسبه می‌شود. علاوه بر محاسبه دقت شبکه، دو شاخص دیگر نیز مورد استفاده قرار گرفته است: ۱- پارامتر حساسیت[1] : شاخص نسبت تعداد تشخیص نادرست به کل نمونه ها و ۲- پارامتر : شاخص نسبت تشخیص درست به کل نمونه ها

$$Accuracy = \frac{\sum True_positive + True_negative}{\sum Total_poputation} \quad (۱)$$

$$Sensivity = \frac{TP}{TP + FN} \quad (۲)$$

$$Specificity = \frac{TN}{TN + FP} \quad (۳)$$

نتایج حاصل از درجه بندی انحنای زعفران با استفاده از شبکه CNN

در ابتدا با استفاده از شبکه عمیق CNN و بهینه سازهای مختلف ذکر شده اقدام به آموزش شبکه شده است. دوره‌های آموزش در الگوریتم‌های فوق به ترتیب (۲۰،۶۰ و ۱۰۰) تکرار (epoch) در نظر گرفته شد. شکل ۶ فرآیند آموزش هر الگوریتم یادگیر را نشان می‌دهد.

نمودار فوق عملکرد سه بهینه‌ساز مختلف (ADAM، SGDM و RMSprop[2]) را در آموزش مدل CNN برای درجه‌بندی زعفران، در سه مقدار مختلف از تعداد تکرارهای (۲۰، ۶۰ و ۱۰۰) مقایسه می‌کند. در حالت آموزش با ۶۰ دوره، بهینه‌ساز RMSprop با دقت ۷۲/۵۳ درصد بالاترین عملکرد را در میان سایر بهینه‌سازها داشته و نشان داده است که در شرایطی خاص می‌تواند بیشترین دقت را در طبقه‌بندی ارائه دهد. در آموزش با ۲۰ دوره، SGDM با دقت ۶۴/۸۴ درصد بهترین نتیجه را نسبت به ADAM (۶۱.۵۴ درصد) و RMSprop ۵۰/۵۵ درصد ارائه کرده است.در تعداد ۱۰۰ دوره نیز، ADAM با دقت ۶۸.۱۳ درصد نسبت به دو بهینه‌ساز دیگر عملکرد بهتری از خود نشان داده است، در حالی که دقت SGDM و RMSprop به ترتیب ۶۰/۴۴ درصد و ۶۳/۷۴ درصد بوده است. این مقایسه نشان می‌دهد که انتخاب نوع بهینه‌ساز و تعداد دوره‌های آموزشی تأثیر مستقیمی بر دقت مدل دارد. همچنین، مشخص است که افزایش تکرارها لزوماً به بهبود عملکرد منجر نمی‌شود، بلکه تعامل بهینه میان ساختار مدل، بهینه‌ساز و پارامترهای آموزش عامل کلیدی در رسیدن به دقت بالا در طبقه‌بندی زعفران است.

نتایج حاصل از درجه بندی انحنای زعفران با استفاده از شبکه گوگل

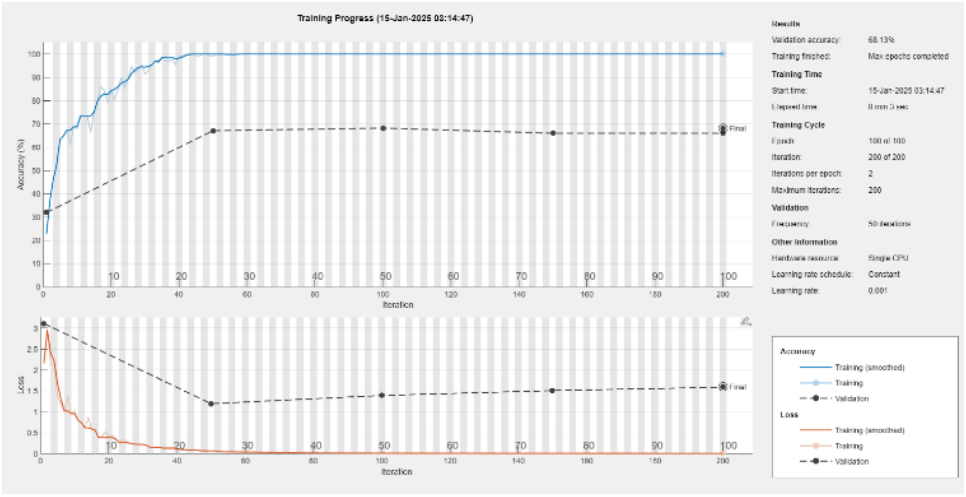
همانطور که اشاره شد در این پژوهش دو نوع یادگیری عمیق مورد بررسی قرار گرفته است. یادگیری CNN سفارشی که فرآیند آموزش آن در

مرحله قبل تشریح شد و دوم شبکه گوگل نت از پیش آموزش داده شده. فرایند آموزش با استفاده از ۳ الگوریتم یادگیر به شکل ۶ است.

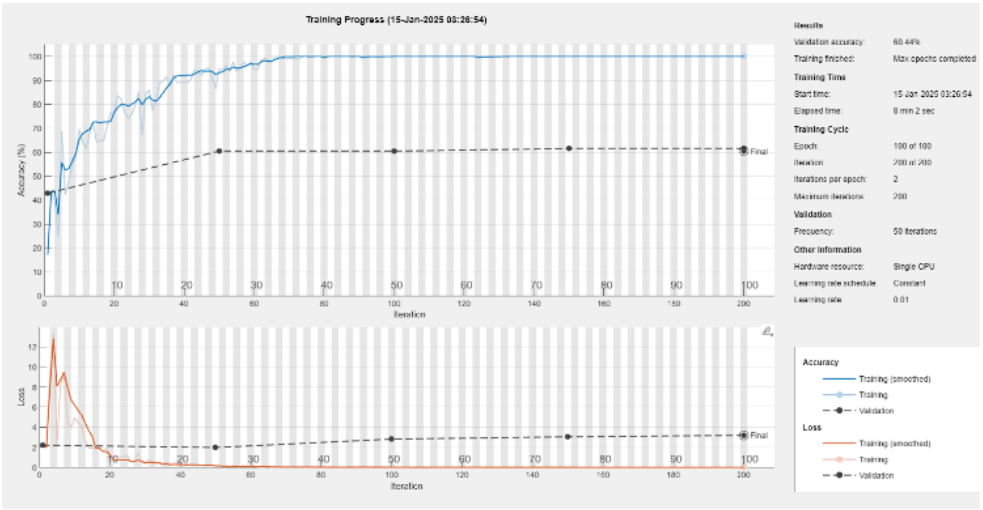
نتایج حاکی از ان است که در صورت اعطای زمان به مدل یادگیر گوگل بکارگیری الگوریتم‌های آموزش مختلف در تکرارهای بالا نزدیک به یکدیگر خواند بود. شکل ۶ مقایسه دقیق‌تری را در این خصوص نشان می‌دهد.

نمودار فوق، عملکرد سه بهینه‌ساز مختلف مذکور را در مدل گوگل‌نت برای درجه‌بندی زعفران، در سه مقدار مختلف از تعداد دوره‌های آموزش (۲۰، ۶۰ و ۱۰۰) مقایسه می‌کند. در آموزش با ۲۰ دوره، بهینه‌ساز ADAM با دقت ۸۱/۸۶ درصد، عملکرد بهتری نسبت به SGDM با دقت ۱۲/۷۹ درصد و RMSprop با دقت ۳۲/۸۱ درصد داشته است.

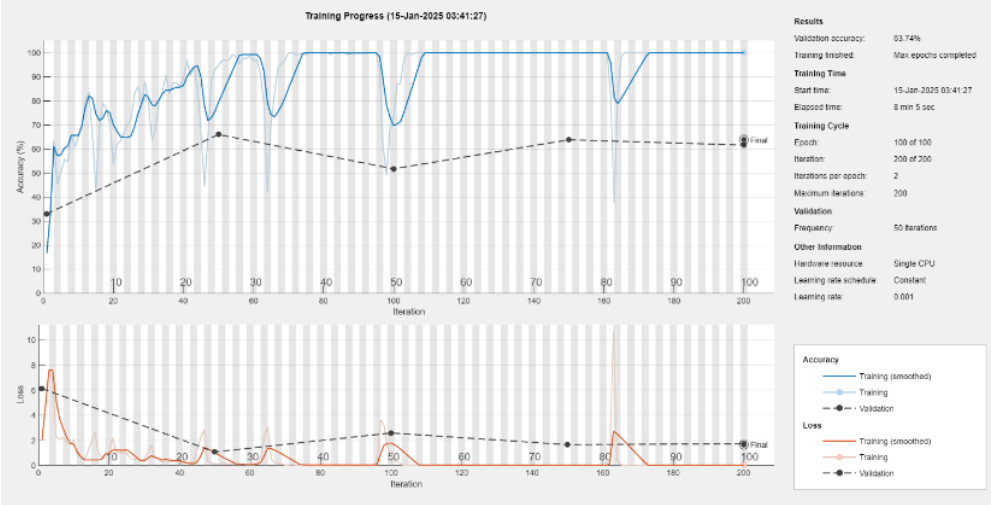
1- Sensitivity
2 - Root Mean Square Propagation



A



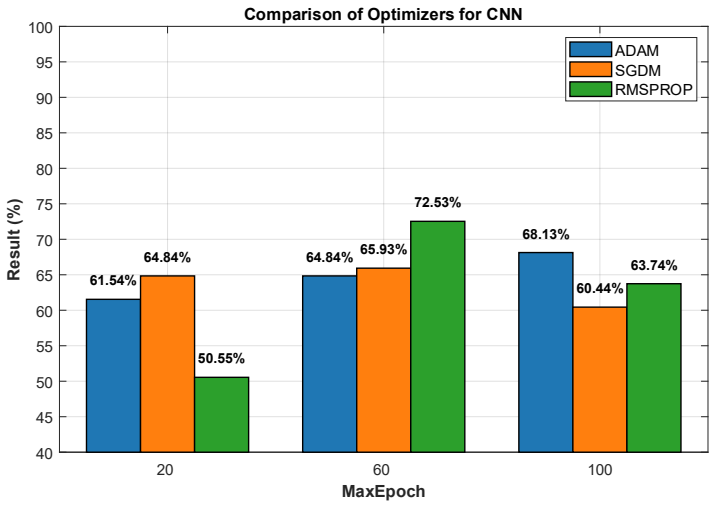
B



C

شکل ٦- الف- فرایند آموزش شبکه CNN با استفاده از الگوریتم : A- ADAM – B- SGDM – C- RMSprop

Figure 7- A. CNN network training process using the following algorithm: A. ADAM – B. SGDM – C. RMSprop.



شکل ۷- مقایسه الگوریتمهای مختلف در تشخیص انحنای زعفران با استفاده از شبکه CNN

Figure 8- Comparison of different algorithms in saffron curvature detection using CNN network.

در ۶۰ دوره، مجدداً ADAM با دقت ۵۲/۸۳ درصد عملکرد برتری داشته است، درحالی‌که عملکرد RMSprop به ۰۳/۶۷ درصد کاهش یافته و ضعیف‌ترین نتیجه را در این مرحله ارائه کرده است. در نهایت، با افزایش تعداد دوره‌های آموزش به ۱۰۰، هر سه بهینه‌ساز عملکرد بسیار نزدیکی داشته‌اند؛ بهینه‌سازهای ADAMو SGDM هر دو با دقت ۷۱/۸۵ درصد در جایگاه نخست قرار گرفته‌اند و RMSprop نیز با دقت ۶۲/۸۴ درصد در پی آن‌ها قرار دارد. این نتایج نشان می‌دهد که در مدل Google-Net، بهینه‌ساز ADAM در اغلب موارد بهترین عملکرد را داشته و نسبت به نوسانات تعداد دوره‌های آموزش، پایداری بیشتری از خود نشان داده است. همچنین، برخلاف مدلCNN ، در اینجا افزایش تعداد دوره‌های آموزش باعث همگرایی نتایج بهینه‌سازها و کاهش تفاوت عملکرد میان آن‌ها شده است.

مقایسه نتایج دو شبکه در تشخیص انحنای زعفران (ماتریس آشفتگی)

به‌منظور ارزیابی عملکرد دو مدل یادگیری عمیق، ماتریس‌های آشفتگی مربوط به مجموعه‌های آموزش و آزمون بررسی شدند که نتایج آن‌ها به‌ترتیب در جداول ۳ و ۴ ارائه شده است.

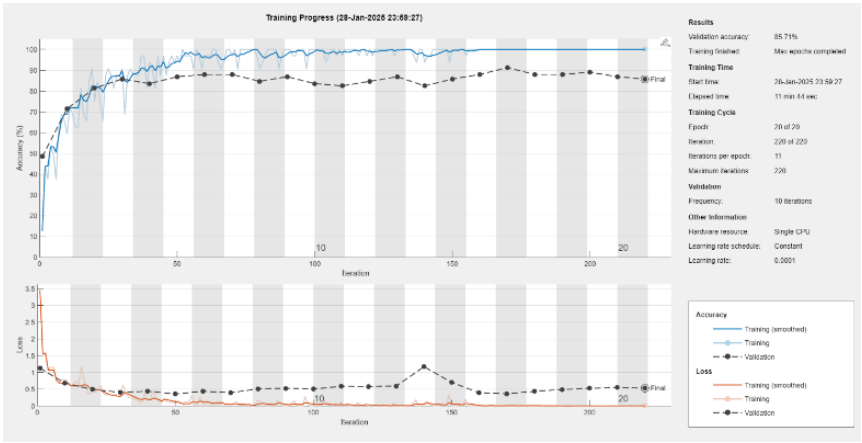
همانطور که جداول فوق نشان می‌دهد عملکرد هر دو شبکه در داده های آموزش درست می‌باشد و در داده های آزمون تفاوت محسوسی وجود دارد. به منظور مقایسه الگوریتم‌های مختلف جدول ۵ در داده های آزمون ترسیم شده است.

نتیجه‌گیری

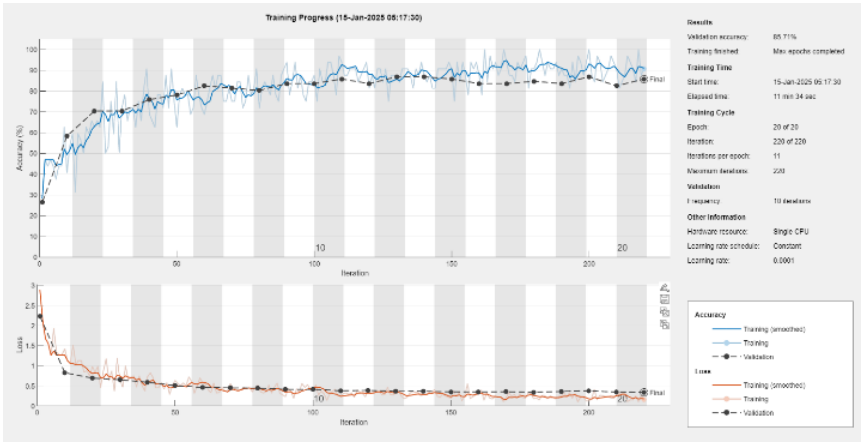
در پژوهش حاضر، به بررسی انحنای زعفران به‌صورت هوشمند و با استفاده از متدهای مبتنی بر یادگیری عمیق پرداختیم. نتایج حاکی از آن است که استفاده از شبکه‌های یادگیری عمیق برای طبقه‌بندی رشته‌های زعفران بر اساس انحنا، عملکرد مطلوبی روی داده‌های آزمون دارد. اگرچه در برخی کاربردهای زمان‌واقعی[1] زمان آموزش و بار محاسباتی اهمیت بالایی دارند، اما در فرایندهای کنترل کیفیت و درجه‌بندی آفلاین زعفران، دستیابی به حداکثر دقت، حساسیت و قابلیت اطمینان مدل در تفکیک درجات انحنا، اولویت اصلی

1- Real Time

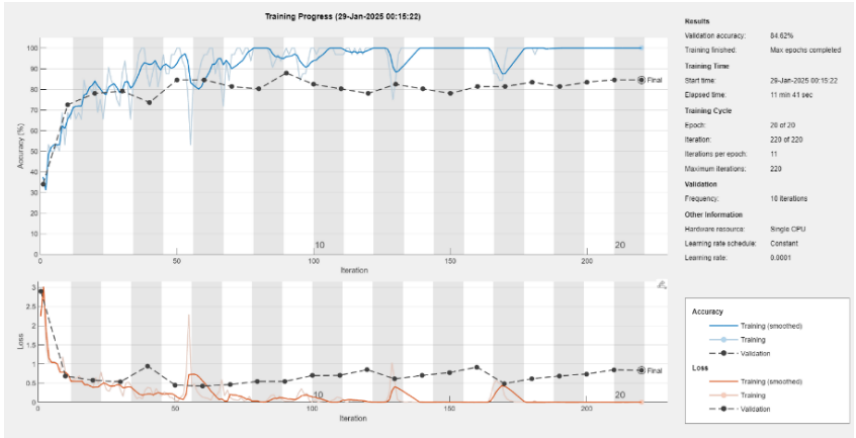
محسوب می‌شود. لذا در این پژوهش، تمرکز اصلی بر ارتقای شاخص‌های ارزیابی کیفی و بهره‌گیری از توانمندی‌های معماری گوگل‌نت قرار گرفت و افزایش احتمالی زمان آموزش به‌عنوان چالشی محدودکننده در این سطح از کاربرد صنعتی ارزیابی نگردید.



A



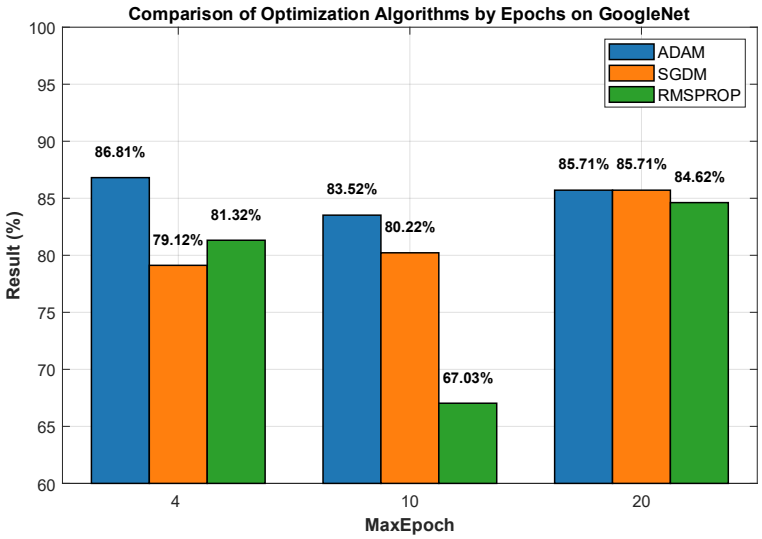
B



C

شکل ۸- الف- فرایند آموزش شبکه گوگل نت با استفاده از الگوریتم : A- ADAM – B- SGDM –C- RMSprop

Figure 9- A. Google-Net network training process using the algorithm: A. ADAM – B. SGDM C. RMSprop.



شکل ۹- مقایسه الگوریتمهای مختلف در تشخیص انحنای زعفران با استفاده از شبکه گوگل نت

Figure 10- Comparison of different algorithms in detecting saffron curvature using Google-Net.

جدول ۳- وضعیت کلاس بندی زعفران در شبکه عمیق CNN در تعداد ۱۰۰ تکرار (درجه یک بدون کلاف- درجه ۲ کلاف- درجه ۳ کاملا کلاف)

Table 3- Saffron classification status in deep CNN network in 100 iterations (level 1 no tangle - level 2 tangle - level 3 fully tangle)

وضعیت تشخیص انحنای زعفران Detection status	نوع Type	آموزش(از ۱۲۰ نمونه) Train (out of 120 samples)	تشخیص Status	آزمون(از ۳۰ نمونه) Train (out of 30 samples)	تشخیص Status
تعداد نمونه های درجه ۱ که درجه ۱شناسایی شده Number of grade 1 samples identified as grade 1	دقت Accuracy	120	100.0%	23	76.7%
تعداد نمونه های درجه ۱ که درجه ۲شناسایی شده Number of grade 1 samples identified as grade 2	خطا Error	0	0.0%	5	16.7%
تعداد نمونه های درجه ۱ که درجه ۳شناسایی شده Number of grade 1 samples identified as grade 3	خطا Error	0	0.0%	2	6.7%
تعداد نمونه های درجه ۲ که درجه ۱شناسایی شده Number of grade 2 samples identified as grade 1	خطا Error	0	0.0%	5	16.7%
تعداد نمونه های درجه ۲ که درجه ۲شناسایی شده Number of grade 2 samples identified as grade 2	دقت Accuracy	120	100.0%	16	53.3%
تعداد نمونه های درجه ۲ که درجه ۳شناسایی شده Number of grade 2 samples identified as grade 3	خطا Error	0	0.0%	9	30.0%
تعداد نمونه های درجه ۳ که درجه ۱شناسایی شده Number of grade 3 samples identified as grade 1	خطا Error	0	0.0%	0	0.0%
تعداد نمونه های درجه ۳ که درجه ۲شناسایی شده Number of grade 3 samples identified as grade 2	خطا Error	0	0.0%	8	26.7%
تعداد نمونه های درجه ۳ که درجه ۳شناسایی شده Number of grade 3 samples identified as grade 3	دقت Accuracy	120	100.0%	22	73.3%

جدول ٤- وضعیت کلاس بندی زعفران در شبکه عمیق گوگل نت در تعداد ۱۰۰ تکرار (درجه یک بدون کلاف- درجه ۲ کلاف- درجه ۳ کاملا کلاف)

Table 4- Saffron classification status in Google-Net deep network in 100 iterations (level 1 no tangle - level 2 tangle - level 3 completely tangle)

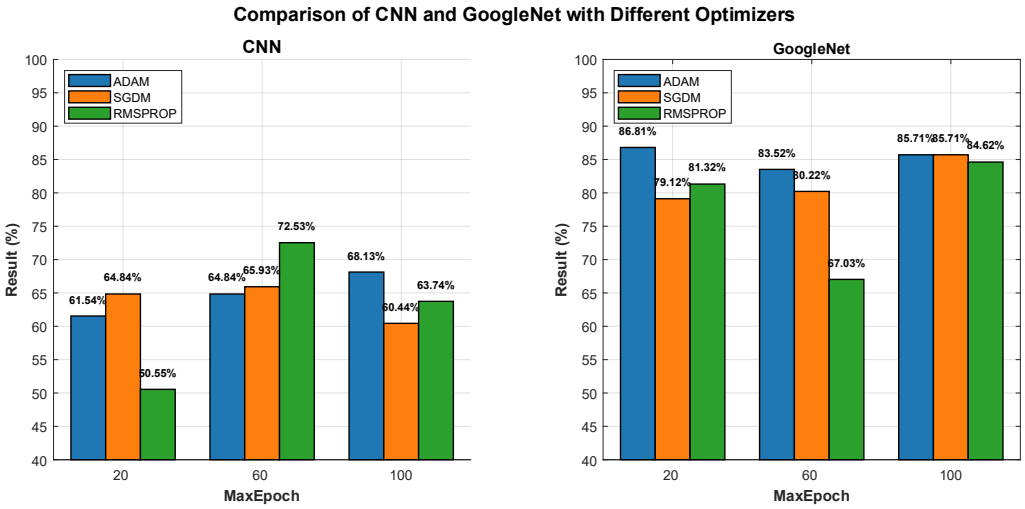
وضعیت تشخیص انحنای زعفران Detection status	نوع Type	آموزش(از ۱۲۰ نمونه) Train (out of 120 samples)	تشخیص Status	آزمون(از ۳۰ نمونه) Train (out of 30 samples)	تشخیص Status
تعداد نمونه های درجه ۱ که درجه ۱شناسایی شده Number of grade 1 samples identified as grade 1	دقت Accuracy	120	100.0%	30	100.0%
تعداد نمونه های درجه ۱ که درجه ۲شناسایی شده Number of grade 1 samples identified as grade 2	خطا Error	0	0.0%	0	0.0%
تعداد نمونه های درجه ۱ که درجه ۳شناسایی شده Number of grade 1 samples identified as grade 3	خطا Error	0	0.0%	0	0.0%
تعداد نمونه های درجه ۲ که درجه ۱شناسایی شده Number of grade 2 samples identified as grade 1	خطا Error	0	0.0%	2	6.7%
تعداد نمونه های درجه ۲ که درجه ۲شناسایی شده Number of grade 2 samples identified as grade 2	دقت Accuracy	120	100.0%	23	76.7%
تعداد نمونه های درجه ۲ که درجه ۳شناسایی شده Number of grade 2 samples identified as grade 3	خطا Error	0	0.0%	5	16.7%
تعداد نمونه های درجه ۳ که درجه ۱شناسایی شده Number of grade 3 samples identified as grade 1	خطا Error	0	0.0%	0	0.0%
تعداد نمونه های درجه ۳ که درجه ۲شناسایی شده Number of grade 3 samples identified as grade 2	خطا Error	0	0.0%	6	20.0%
تعداد نمونه های درجه ۳ که درجه ۳شناسایی شده Number of grade 3 samples identified as grade 3	دقت Accuracy	120	100.0%	24	80.0%

جدول ٥- عملکرد الگوریتم های مختلف در تشخیص انحنای زعفران در تکرار ۱۰۰ در داده های آزمون

Table 5- Performance of different algorithms in detecting saffron curvature in 100 iterations on test data

نام شبکه Network name	نام الگوریتم Algorithm name	تعداد صحیح بدون کلاف Correct non-tangled count	دقت تشخیص Accuracy	تعداد صحیح کلاف Correct tangled count	دقت تشخیص Accuracy	تعداد صحیح کاملا کلاف Correct highly tangled count	دقت تشخیص Accuracy
CNN	ADAM	23	76.7%	16	53.3%	22	**73.3%**
CNN	SGDM	25	83.3%	12	40.0%	17	**56.7%**
CNN	RMSPROP	21	70.0%	20	66.7%	16	**53.3%**
Google-Net	ADAM	30	100.0%	23	76.7%	24	**80.0%**
Google-Net	SGDM	26	86.7%	25	83.3%	26	**86.7%**
Google-Net	RMSPROP	26	86.7%	25	83.3%	25	**83.3%**

گوگل نت، با معماری از پیش‌آموزش‌دیده‌اش، نتایج بهتری نسبت به CNN سفارشی داشته است. یافته‌ها نشان می‌دهند که یادگیری انتقالی با شبکه‌های پیش‌آموزش‌دیده می‌تواند برای وظایف خاص طبقه‌بندی در ارزیابی کیفیت کشاورزی و غذایی بسیار مؤثر باشد. جدول زیر عملکرد هر یک از یادگیرها را در تشخیص میزان کلاف بودن نشان می‌دهد.



شکل ۱۰- مقایسه عملکرد دوئ شبکه CNN و گوگل نت در الگوریتم‌ها و تکرار های مختلف در تشخیص انحنای زعفران

Figure 11- Comparison of the performance of CNN and Google-Net in different algorithms and iterations in saffron curvature detection.

با توجه به نمودار ترکیبی ارائه‌شده در بالا که به‌صورت تلفیقی عملکرد سه بهینه‌ساز ADAM، SGDM و RMSprop را در دو معماری شبکه عمیق کانولوشنی و گوگل نت و در سه مقدار مختلف از تعداد دوره‌های آموزشی (۲۰، ۶۰ و ۱۰۰ تکرار) نمایش می‌دهد، می‌توان به تحلیل جامعی از تأثیر نوع بهینه‌ساز و معماری شبکه بر دقت طبقه‌بندی زعفران دست یافت. در مدل CNN، که از معماری کم‌عمق‌تری برخوردار است، تفاوت عملکرد میان بهینه‌سازها بیشتر مشهود است. به‌طور مشخص، RMSprop در تکرار ۶۰ بهترین نتیجه را با دقت ۷۲/۵۳ درصد به ثبت رسانده، اما در تکرارهای ۲۰ و ۱۰۰ عملکرد کمتری داشته است. ADAM در تکرار ۱۰۰ بالاترین دقت را ۶۸/۱۳ درصد در بین بهینه‌سازها نشان داده و نسبت به نوسانات epoch عملکردی پایدارتر از SGDM و RMSprop ارائه داده است. در مقابل، مدل Google-Net که از ساختاری پیچیده‌تر و عمیق‌تر برخوردار است، تفاوت عملکرد میان بهینه‌سازها به‌مراتب کمتر شده و در سطوح بالاتر epoch (به‌ویژه ۱۰۰) نتایج آن‌ها به هم نزدیک شده‌اند. در این معماری، ADAM در تکرارهای ۲۰ و ۶۰ دقیق‌ترین نتایج را ۸۶/۸۱ درصد و ۸۳/۵۲ درصد ارائه داده و در تکرار ۱۰۰ نیز با SGDM برابر بوده است (۸۵/۷۱ درصد). این در حالی‌ست که RMSprop در تکرار ۶۰ عملکرد ضعیفی (۶۷/۳ درصد) داشته اما در تکرار ۱۰۰ بهبود یافته و به ۸۴/۶۲ درصد رسیده است. این رفتار نشان می‌دهد که در معماری‌های عمیق‌تر، با افزایش تعداد دوره‌های آموزشی، الگوریتم‌های بهینه‌سازی به سمت همگرایی در عملکرد حرکت می‌کنند. به‌صورت کلی، ADAM در هر دو مدل عملکردی پایدار و برتر از سایر بهینه‌سازها داشته و نسبت به تغییرات در ساختار شبکه و تعداد epoch کمتر دچار نوسان شده است. RMSprop عملکردی ناپایدارتر و وابسته به شرایط خاص آموزش داشته و SGDM معمولاً در بازه‌ای بین این دو عمل کرده است. این نتایج تأکید می‌کنند که انتخاب بهینه‌ساز نه‌تنها به ساختار شبکه، بلکه به تنظیمات دقیق آموزش مانند تعداد تکرار نیز وابسته است و در پروژه‌های عملی باید متناسب با نوع معماری و داده، مورد بررسی و تنظیم قرار گیرد. در تحقیقات آینده می‌تواند به بررسی استفاده از شبکه‌های پیش‌آموزش‌دیده دیگر، مانند ResNet یا

EfficientNet، برای بهبود بیشتر دقت طبقه‌بندی بپردازد. علاوه بر این، گسترش مجموعه داده و گنجاندن نمونه‌های متنوع‌تر می‌تواند قابلیت تعمیم‌پذیری مدل‌ها را افزایش دهد. همچنین پیشنهاد می‌شود برای پژوهش‌های آتی، استفاده از تکنیک‌های افزایش داده[1]، یا ترکیب ویژگی‌های بافتی با یادگیری عمیق مطرح شود. در نهایت، بررسی تأثیر تکنیک‌های مختلف پیش‌پردازش تصویر بر عملکرد طبقه‌بندی می‌تواند یک حوزه تحقیقاتی ارزشمند باشد.

سپاسگزاری

این مقاله مستخرج از نتایج طرح تحقیقاتی اجرا شده به شماره قرارداد 205313 از محل اعتبارات پژوهشکده زعفران دانشگاه تربت‌حیدریه می‌باشد که بدین وسیله تشکر و قدردانی می‌گردد.

منابع

Aissa, R., Ibourki, M., Ait Bouzid, H., Bijla, L., Oubannin, S., Sakar, E. H., Jadouali, S., Hermansyah, A., Goh, K. W., Ming, L. C., Bouyahya, A., & Gharby, S. (2023). Phytochemistry, quality control and medicinal uses of Saffron (*Crocus sativus* L.): An updated review. *Journal of Medicine & Life, 16*(6), 822–836. https://doi.org/10.25122/jml-2022-0353

Bergomi, A., Comite, V., Santagostini, L., Guglielmi, V., & Fermo, P. (2022). Determination of saffron quality through a multi-analytical approach. *Foods, 11*(20), 3227. https://doi.org/10.3390/foods11203227

Birjandi Toroghi, Z., Moradinezhad, F., Niazmand, R., & Bayat, H. (2023). Effect of vacuum and active packaging on the qualitative characteristics and microbial load of dry saffron stigma (*Crocus sativus* L.). *Saffron Agronomy and Technology, 11*(4), 413–430.

Bohlol, P., Bakherad, A., Omid, M., Firouz, M. S., & Hosseinpour-Zarnaq, M. (2025). Deep learning approach and adaptive data augmentation technique for non-destructive quality recognition of exported saffron. *Journal of Food Composition & Analysis, 144*, 107758. https://doi.org/10.1016/j.jfca.2025.107758

Gandomadeh, D, Saeidirad, M. H., & Sabeghi, Y. (2024). Separating stigma from saffron flower: Mechanized methods (Review). *Saffron Agronomy & Technology, 12*(3), 327-349. (In Persian with English abstract). https://doi.org/10.22048/jsat.2024.445321.1525

Ghorani, B., Kadkhodai, R., & Alhosseini, A. (2017). The effect of biopolymer type, temperature and relative humidity on the physicochemical characteristics and stability of microencapsulated bioactive compounds of saffron. *Journal of Food Science and Technology, 14*(3), 127–142. https://doi.org/10.22048/jsat.2023.397103.1487.

Kazemi, A., & Khojastehnazhand, M. (2026). Classification of Iranian king of spices (saffron) types by texture features. *Journal of Food Composition & Analysis,* 108883. https://doi.org/10.1016/j.jfca.2026.108883

Mahajan, A., & Gupta, M. K. (2025). Advancements in saffron authentication: A review of ML and DL techniques for adulteration prediction. 2025 International Conference on Networks and Cryptology (NETCRYPT), 484–489. https://doi.org/10.1109/NETCRYPT65877.2025.11102684.

Malavi, D., Nikkhah, A., Alighaleh, P., Einafshar, S., Raes, K., & Van Haute, S. (2024). Detection of saffron adulteration with *Crocus sativus* style

1 -Data Augmentation

using NIR-hyperspectral imaging and chemometrics. *Food Control, 157*, 110189. https://doi.org/10.1016/j.foodcont.2023.110189

Minaei, S., Kiani, S., Ayyari, M., & Ghasemi Varnamkhasti, M. (2017). A portable computer-vision-based expert system for saffron color quality characterization. *Journal of Applied Research on Medicinal & Aromatic Plants, 7*, 124–130. https://doi.org/10.1016/j.jarmap.2017.07.004

Mohamadzadeh Moghadam, M. (2020). Nondestructive classification of saffron using color and textural analysis. *Food Science & Nutrition, 8*(4), 1923–1932. https://doi.org/10.1002/fsn3.1478

Mohammadzadeh Moghadam, M., Taghizadeh, M., Sadrnia, H., & Pourreza, H. (2020). Saffron classification using color features extracted from images. *Journal of Saffron Agriculture & Technology, 8*(3), 399–419. (In Persian with English abstract). https://doi.org/10.22048/jsat.2020.206278.1362

Momeny, M., Neshat, A. A., Jahanbakhshi, A., Mahmoudi, M., Ampatzidis, Y., & Radeva, P. (2023). Grading and fraud detection of saffron via learning-to-augment incorporated Inception-v4 CNN. *Food Control, 147*, 109554. https://doi.org/10.1016/j.foodcont.2022.109554

Movahed Ghodsinia, S. R. (2023). Applications of machine vision in the field of saffron plant. *Saffron Research, 11*(1), 177–200. (In Persian with English abstract). https://doi.org/10.22077/jsr.2023.6225.1211

Saedi, S. I., Makarian, H. (2025). Development of a deep learning model based on VGG16 network for classifying saffron plants and weeds by color images. *Journal of Researches in Mechanics of Agricultural Machinery, 35*, 69-82. https://doi.org/10.22034/jrmam.2025.15034.738

Saeidirad, M. H., & Zarifneshat, S. (2021). Development and performance evaluation of an automatic saffron corm planter. *Iranian Journal of Biosystems Engineering, 51*(4), 683–693. (In Persian with English abstract). https://doi.org/10.22059/ijbse.2020.264261.665087

Yasrebi, S. E., Zabbah, I., Behzadiyan, B., Maroosi, A., & Rezaie, R. (2019). Classification of saffron based on its apparent characteristics using artificial neural networks. *Saffron Agronomy & Technology, 7*(4), 521-535. (In Persian with English abstract). https://doi.org/10.22048/jsat.2019.149440.1316

Zabbah, I., Heydaran Darogheh, O., Zahra, Z., Behzadian, B., & Rezaei, R. (2024). Fuzzy evaluation of saffron appearance characteristics using artificial intelligence-based methods. *Agricultural Systems & Mechanization Research, 24*(85), 75–90. (In Persian with English abstract). https://doi.org/10.22092/amsr.2024.364271.1471.