



مقاله پژوهشی

استفاده از بینایی کامپیوتر در تشخیص غیرمخرب زعفران واقعی و تقلبی

بهروز اکبری آدرگانی^۱، مرتضی محمدزاده مقدم^{۲*}، مهدی کریمی نوقابی^۳، مجتبی محمدپور^۳ و محمد خلیلیان موحد^۴

تاریخ دریافت: ۲۰ مرداد ۱۴۰۰ تاریخ پذیرش: ۱۵ آبان ۱۴۰۰

اکبری آدرگانی، ب.، محمدزاده مقدم، م.، کریمی نوقابی، م.، محمدپور، م.، خلیلیان موحد، م. ۱۴۰۰. استفاده از بینایی کامپیوتر در تشخیص غیرمخرب زعفران واقعی و تقلبی. زراعت و فناوری زعفران، ۹(۴): ۴۰۹-۴۲۹.

چکیده

زعفران یکی از گرانترین ادویه‌های جهان محسوب می‌شود. زعفران ادویه‌ای که بسیار مورد تقلب قرار می‌گیرد. توسعه تکنیک‌های مبتنی بر ابزار ساده، ارزان قیمت، مناسب و سریع در صنایع غذایی جهت تشخیص تقلباتی همچون تقلبات زعفران ضروری است. در پژوهش حاضر، ترکیب پردازش تصویر و روش ماشین بردار پشتیبان (SVM) برای ارزیابی سریع و غیر مخرب تشخیص زعفران واقعی از زعفران تقلبی به کار رفته است. پس از تهیه تصاویر از توده زعفران خالص و تقلبی و کالاهای مجزا، تصاویر وارد مراحل پیش پردازش شدند و در نهایت، ویژگی‌های آماری مرتبط با بافت تصاویر و ویژگی‌های مورفولوژی شامل ۱۰۵ ویژگی استخراج شدند. به منظور افزایش سرعت و دقت طبقه‌بندی، از روش آنالیز مؤلفه‌های اصلی PCA برای کاهش ابعاد ماتریس ویژگی استفاده شد. همچنین طبقه‌بندی تصاویر به کمک توابع کرنل مختلف SVM، به صورت دو کلاس انجام شد. سپس شاخص‌های آماری نظیر دقت، صحت، حساسیت، اختصاصی بودن و سطح زیر منحنی به منظور ارزیابی طبقه‌بند محاسبه شدند که مقادیر این شاخص‌ها برای طبقه‌بندی با کرنل کوپیک SVM برای تشخیص زعفران تقلبی از زعفران واقعی به ترتیب ۹۷، ۹۳، ۸۳، ۹۷/۵ و ۹۷ درصد بدست آمد. نتایج حاصل از این طبقه‌بندی نشان داد که این سیستم به عنوان یک روش هوشمند، سریع، غیرمخرب و دقیق، قابلیت تشخیص زعفران واقعی را از تقلبی دارد.

کلمات کلیدی: تقلب، پردازش تصویر، ماشین بردار پشتیبان

۱- استاد، مرکز تحقیقات آزمایشگاهی غذا و دارو، سازمان غذا و دارو، وزارت بهداشت، درمان و آموزش پزشکی، تهران، ایران
۲- استادیار، اداره آزمایشگاه کنترل غذا و دارو، معاونت غذا و دارو، دانشگاه علوم پزشکی گناباد، گناباد، ایران
۳- استادیار، گروه مهندسی برق و کامپیوتر، مجتمع آموزش عالی گناباد
۴- دانشجوی دکتری علوم و صنایع غذایی، دانشگاه فردوسی مشهد، مشهد، ایران
(*)-نویسنده مسئول: (mohammadzade.m@gmu.ac.ir)

مقدمه

تجارت ادویه در دنیا سابقه طولانی دارد. زعفران ادویه‌ای است که به خاطر داشتن عطر و رنگ مناسبی که در انواع غذاها ایجاد می‌کند مصرف جهانی دارد و یکی از گرانتین ادویه‌های جهان محسوب می‌شود (Koocheki & Milani, 2020). ایران یکی از کشورهای اصلی تولیدکننده در جهان می‌باشد. در حال حاضر بالغ بر ۳۰۰ تن زعفران خشک بصورت سالیانه در ایران تولید می‌شود. زعفران به دلیل موقعیت خاص از لحاظ اشتغال-زایی کشاورزی و ایجاد درآمد ارزی قابل توجه برای کشور، به عنوان گیاه مهم و استراتژیک در اقتصاد ملی محسوب می‌شود (Rastegaripour & Mohammadi, 2018). هر گل زعفران داری سه کلاله است که وزن تقریبی آن ۵ میلی گرم می‌باشد. برای تولید یک کیلوگرم زعفران خشک باید حدود ۲۰۰۰۰ گل زعفران به دقت چیده شده و کلاله آن جدا شود (Javanmardi et al., 2011). زعفران به دلیل محدودیت تولید و هزینه بالا، ادویه‌ای که بسیار مورد تقلب قرار می‌گیرد. مواد گیاهی غیر زعفران با رنگ‌های مصنوعی رنگ آمیزی می‌شوند تا زعفران تقلبی تولید شود. نظارت مستمر بر رنگ‌های مصنوعی مورد استفاده در زعفران تقلبی ضروری است زیرا برخی از رنگ‌ها برای مصرف انسان ایمن نیستند (Bhooma et al., 2020). با توجه به ارزش بالای این محصول، همواره توسط افراد سودجو اقدام به تولید محصول تقلبی مشابه آن می‌شود. تقلب در صنایع غذایی سابقه طولانی دارد و به هزاران سال قبل باز می‌گردد. زعفران یکی از رایج ترین اهداف جهت تقلب و کلاهبرداری است (Hagh-Nazari & Keifi, 2006). با توجه به گرانبه بودن محصول زعفران، افراد سود جو شیوه‌های گوناگونی جهت تقلب زعفران استفاده می‌کنند (Kiani et al., 2017). این تقلبات می‌تواند شامل رنگ کردن خامه و پرچم خود زعفران، استفاده از اجزای سایر گیاهان مثل گلرنگ، رنگ کردن خمیر

نشاسته و برش آن بصورت رشته‌هایی شبیه کلاله زعفران و موارد مشابه دیگر باشد (Feizi & Hemmati Kakhki, 2006). در بازار ایران عمده زعفران بصورت درسته و غیر پودر شده عرضه می‌شود. روش‌های مختلفی برای شناسایی تقلبات زعفران از قبیل تکنیک‌های کروماتوگرافی، اسپکتروسکوپی، طیف‌سنجی فروسرخ، تکنیک‌های مولکولی، فناوری زبان الکترونیک ارائه شده‌اند (Heidarbeigi et al., 2015). روش‌های آزمایشگاهی وقت گیر و هزینه‌بر هستند و نیاز به افراد متخصص و ماهر جهت انجام آزمون‌های تشخیص تقلبات وجود دارد. یکی از روش‌های ساده و ارزان جهت تشخیص تقلبات در مواد غذایی، استفاده از پردازش تصویر می‌باشد. سیستم بینایی ماشین از یک دوربین دیجیتال جهت عکس‌برداری استفاده می‌شود که شبیه چشم انسان کار می‌کند و از الگوریتم‌های یادگیری استفاده می‌شود که می‌تواند مشابه مغز انسان عمل کند (Taheri-Garavand & Yousefian, 2020). در یک پژوهش از تکنیک بینی الکترونیکی و بینایی ماشین بصورت ترکیبی با هم جهت شناسایی زعفران تقلبی استفاده شده‌است. در این تکنیک یازده ویژگی رنگی از تصاویر استخراج شد (Kiani et al., 2017). طبق بررسی انجام شده تا کنون پژوهشی که به تنهایی از روش بینایی ماشین برای تشخیص زعفران تقلبی استفاده کند انجام نشده است. روش ماشین بردار پشتیبان از جمله روش‌های نسبتاً جدیدی است که در سال‌های اخیر نسبت به روش‌های قدیمی‌تر طبقه‌بندی از جمله شبکه‌های عصبی پرسپترون، کارایی خوبی نشان داده است. با این روش می‌توان ویژگی‌های مورد نیاز را تعریف و آموزش داده، سپس برای ورودی‌های جدید، استخراج ویژگی انجام داد (de Oliveira et al., 2016). هدف از این تحقیق استخراج ویژگی‌های بافت تصاویر نمونه‌های زعفران خالص و نمونه‌های تقلبی و استفاده از الگوریتم SVM جهت تشخیص زعفران

تقلبی می‌باشد.

مواد و روش‌ها

تهیه نمونه‌ها

تعداد ۵۶۲ نمونه زعفران خالص از مناطق مختلف خراسان تهیه شد. نمونه‌های خالص زعفران (شکل ۱) شامل ۲۴۳ نمونه زعفران نگین، ۱۶۴ نمونه پوشال و ۱۵۵ نمونه سرگل بودند. جهت تهیه نمونه‌های تقلبی زعفران (شکل ۲)، گلرنگ از عطاری‌های شهر گناباد تهیه شد. خامه خالص زعفران از عطاری‌های سطح شهر گناباد تهیه شد و توسط رنگ‌های مصنوعی آلوارد، تارتارازین، پونسو ۴ و کینولین یلو در آزمایشگاه معاونت غذا و دارو دانشگاه علوم پزشکی گناباد رنگ شدند. همچنین نمونه پرچم رنگ شده زعفران و نمونه زعفران تقلبی که از ترکیبات نشاسته‌ای تهیه شده بود، جزء نمونه‌هایی بودند که در طی بازدیدهای نظارتی تحویل آزمایشگاه معاونت غذا و دارو شده بودند. نمونه‌های تقلبی تهیه شده شامل ۲۱ نمونه خامه رنگ شده با تارتارازین^۱، پونسو ۴^۲، آلوارد^۳، کینولین یلو^۴ و سانست یلو^۵، ۵ نمونه گلرنگ خالص، ۶ نمونه گلرنگ که با تارتارازین و پونسو ۴ رنگ شده‌اند و ۷ نمونه خامه رنگ شده با آب زعفران که در آزمایشگاه معاونت غذا و دارو دانشگاه علوم پزشکی گناباد تهیه شدند. نمونه‌های تقلبی مکشوفه شامل ۱۳ نمونه پرچم رنگ شده با رنگ‌های شیمیایی مخلوط با زعفران خالص، ۳ نمونه زعفران نشاسته‌ای معروف به زعفران هندی، ۲۵ نمونه مختلف تقلبی مکشوفه در آزمایشگاه معاونت غذا و دارو دانشگاه علوم پزشکی مشهد بودند. در مجموع تعداد ۸۱ نمونه زعفران تقلبی تهیه شد. رنگ‌های شیمیایی تارتارازین، پونسو ۴،

آلوارد و کینولین یلو به عنوان رنگ‌های استفاده شده در رنگ آمیزی خامه زعفران و نیز گلرنگ به کار رفت. این مواد رنگی از شرکت سیگما خریداری شد. نمونه‌ها تا زمان انجام آزمایش، دور از نور و در جای خشک و خنک نگهداری شد. یک میلی‌لیتر از محلول رنگی، با یک افشانک، به یک گرم خامه که روی شیشه ساعت پهن شده بود، ۵ تا ۶ بار اسپری و سپس اجازه داده شد تا خشک شود. نمونه‌های گلرنگ نیز با همین روش رنگ آمیزی شدند.

تهیه تصاویر


برای تهیه تصاویر از یک دوربین دیجیتال کانن (مدل EOS 1300D) استفاده شد که بر روی یک محفظه تصویر برداری به فاصله ۱۹ سانتی‌متر از نمونه قرار داده شد. برای سیستم روشنایی محفظه تصویر برداری از ۱۲ لامپ ال‌ئی دی استفاده شد. در این پژوهش ۹ لامپ دو ردیف بالای محفظه روشن بود و ۴ لامپ ردیف پایین محفظه خاموش بود. هر لامپ ال‌ئی دی دارای شار نوری ۱۴۴۰ Lm و اثر بخشی نوری ۹۰ L/W بود. برای این‌که رنگ پس زمینه تصاویر مشکلی باشد در کف آن از یک پارچه مخمل مشکی مات استفاده شد (شکل ۳).

سرعت شاتر دوربین ۱/۸ ثانیه، بدون استفاده از فلش، فاصله کانونی لنز ۵۵ میلی‌متر، مقدار دیافراگم F/8 و ایزو ۱۰۰ تنظیم شد. تصاویر با حداکثر رزولوشن (۳۴۵۶×۵۱۸۴ pixels) گرفته و با فرمت "JPG" ذخیره شدند. از هر نمونه دو نوع تصویر، عکس برداری شد. تصاویر به لپ‌تاب منتقل شده و پس از کدگذاری، ذخیره شدند. تصویر برداری در حالتی که رشته‌های نمونه بصورت مجزا در کنار هم قرار گرفتند که در هر تصویر پنج رشته مجزا از هر نمونه قرار داده شد و تصویر برداری در حالتی که رشته‌های زعفران بصورت فله‌ای و درهم بودند.


- 1- Tartrazine (C.I. 19140)
- 2- Ponceau 4R (C.I. 16255)
- 3- Allura Red (C.I. 16035)
- 4- Quinoline yellow (C.I. 47005)
- 5- Sunset yellow S (C.I. 15985)



شکل ۱- نمونه زعفران خالص
Figure 1- Pure saffron sample.



شکل ۲- نمونه زعفران تقلبی
Figure 2- Adultrated saffron sample.



شکل ۳- محفظه تصویربرداری
Figure 3- The imaging chamber.

پیش پردازش تصویر

یک نمونه اصلی از گلرنگ بصورت توده در شکل ۴A ارائه شده است. در مرحله اول، یک فیلتر پایین گذر برای حذف نویز و صاف کردن تصویر برای پردازش بیشتر استفاده شد. فیلتر پایین گذر از نوع متوسط گیر 3×3 انتخاب شد (شکل B ۴). در شکل ۴C، تصویر پس زمینه کالاهای جداگانه زعفران به تصویر کشیده شده است. نویز پس زمینه در تصویر هر کالاه زعفران برداشته شد (شکل ۴D).

یک نمونه اصلی از گلرنگ بصورت رشته مجزا در شکل ۵A ارائه شده است. در مرحله اول، یک فیلتر کم عبور برای حذف نویز و صاف کردن تصویر برای پردازش بیشتر استفاده شد (شکل B ۵). در شکل ۵C، تصویر پس زمینه کالاهای جداگانه زعفران به تصویر کشیده شده است. نویز پس زمینه در تصویر

هر کالاه زعفران برداشته شد (شکل ۵D).

استخراج ویژگی‌ها

استخراج ویژگی‌های مورفولوژی از تصاویر رشته های مجزا


میانگین قطر، میانگین طول، میانگین سطح و میانگین پیچ خوردگی از تصاویر باینری بدست آمد (شکل ۵).

Original image #1




4A


Filtered image #1



4B




4C



4D

شکل ۴- پیش پردازش تصویر: تصویر اصلی (A)، تصویر فیلتر شده (B)، پیش زمینه تصویر (C)، تصویر باینری (D)
Figure 4- Image pre-processing: (A) Original sample image, (B) Filtered image, (C) Foreground of the image, (D) Binary image.

Original image #1



5A


Filtered image #1



5B



5C




5D

شکل ۵- پیش پردازش تصویر: تصویر اصلی (A)، تصویر فیلتر شده (B)، پیش زمینه تصویر (C) و تصویر باینری (D)
Figure 5- Image pre-processing: (A) Original sample image, (B) Filtered image, (C) Foreground of the image and (D) Binary image.

اندازه گیری پیچ خوردگی زعفران

برای اندازه گیری پیچ خوردگی، کلاله های زعفران همانند یک منحنی در نظر گرفته شد. روش اندازه گیری پیچ خوردگی بر اساس اندازه گیری انحنا در منحنی بود. برای محاسبه انحنا،

یک روش جدید به نام روش دیسک قالب استفاده شد (شکل ۶). برای بررسی دقیق تر الگوریتم اندازه گیری پیچ خوردگی به مقاله (Aghamohamadian-Sharbat et al., 2016) رجوع شود.



شکل ۶- محاسبه پیچ خوردگی با روش دیسک قالب
Figure 6- Curvature calculation with the template disk method.

$$\kappa_{cp} \triangleq \frac{1}{A^2} \quad (4)$$

$$\kappa_{tr} \triangleq \frac{2 \sin \theta_c}{1 - \sin^2 \theta_c} \quad (5)$$

برای هر یک از انحنای ذکر شده مطابق فرمول ذیل پیچ خوردگی محاسبه می شود:

$$\tau = \frac{1}{m} \sum_{i=1}^m \kappa_i \quad (6)$$

در این مطالعه تابعی در متلب تعریف شد که پس از پردازش تصویر، انحنا را محاسبه می کرد (Aghamohamadian-Sharbat et al., 2016).

استخراج خصوصیات بافت از تصاویر توده

بافت تکرار یک عنصر با الگوی خاص است که خود از تغییرات محلی سطح نور تشکیل شده است. بافت اطلاعات بیشتری در مورد رنگ و حتی شکل اشیا فراهم می کند (به خصوص وقتی اطلاعات رنگی مانند دید در شب را نمی توان

بطور خلاصه در این تحقیق ۲ نوع پیچ خوردگی محاسبه شد. ابتدا انحنا بدست آمد و سپس پیچ خوردگی کلی محاسبه شد. برای یک شکل منحنی $y = f(x)$ ، انحنا به صورت ذیل محاسبه می شود:

$$\kappa = \frac{y'''}{(1+y'^2)^{\frac{3}{2}}} \quad (1)$$

برای نمودار منحنی در مختصات دکارتی اگر $x = x(t)$ و $y = y(t)$ ، انحنا از رابطه ذیل بدست می آید:

$$\kappa = \frac{|x' y'' - y' x''|}{(x'^2 + y'^2)^{\frac{3}{2}}} \quad (2)$$

با توجه به اینکه روش های عددی زمان بر هستند، روش دیسک قالب برای تصاویر دوبعدی استفاده شد. ایده اصلی این روش، ارتباط سطح بین منحنی با دیسک الگو در یک شعاع مناسب با انحنا می باشد. بعد از ساده سازی توابع و فرمول ها، تخمین غیر خطی انحنا به شرح ذیل تعریف می شود:

$$\kappa_{nl} \triangleq A_c \quad (3)$$

$$\text{Energy} = \sum_{i,j} p(i,j)^2 \quad (9)$$

$$\text{Homogeneity} = \sum_{i,j} \frac{p(i,j)}{1 + |i-j|} \quad (10)$$

مشخصات استخراج شده از آنتروپی، انحراف معیار و الگوی دودویی محلی شامل میانگین، انحراف معیار، صافی، لحظه سوم، یکنواختی، آنتروپی و خشم سطح خاکستری است که به صورت زیر تعریف می‌شود (Pourreza et al., 2012):

$$\text{Mean, } \mu = \sum_i p(i) \quad (11)$$

$$\text{Standard deviation, } \sigma = \sqrt{\sum_i (i - \mu)^2 p(i)} \quad (12)$$

$$\text{Smoothness} = 1 - \frac{1}{(1 + \sigma^2)} \quad (13)$$

$$\text{Third moment} = \sum_i (i - \mu)^3 p(i) \quad (14)$$

$$\text{Uniformity} = \sum_i p(i)^2 \quad (15)$$

$$\text{Entropy} = - \sum_i p(i) \log\{p(i)\} \quad (16)$$

$$\text{Gray level range} = \max\{t | p(t) \neq 0\} - \min\{t | p(t) \neq 0\} \quad (17)$$

علاوه بر این، هیستوگرام یک نمایش گرافیکی از تعداد پیکسل‌ها در هر سطح روشنایی در تصویر ورودی است. در این مطالعه ۲۵ بین تعریف شده است و در هر دوره، فراوانی‌ها با هم جمع شده و در آنجا قرار داده شده است (Cen et al., 2016).

یکی از روش‌هایی که برای استخراج مشخصات و طبقه بندی بافت تصویر استفاده می‌شود، روش الگوهای باینری محلی است. در این روش ابتدا محله‌ای از تصویر در نظر گرفته می‌شود و شدت نور نقاط در این محله با شدت نور نقطه در مرکز محله مقایسه می‌شود. برای اینکه اپراتور نسبت به چرخش تصویر حساس نباشد، نقاط همسایه مدور در نظر گرفته می‌شوند و نقاطی که مختصات آنها دقیقاً در مرکز پیکسل نیست با یافتن ورودی پیدا می‌شوند (Pourreza et al., 2012).

در یک LBP پایه، هر محله 3×3 با مقدار پیکسل مرکزی ایجاد می‌شود. مقادیر محله بر اساس پیکسل مربوطه در وزن

بدست آورد. برخلاف رنگ، بافت معمولاً به تغییرات نور حساس نیست، بنابراین برای استفاده در فضای باز مناسب است. تجزیه و تحلیل بافت به ویژگی‌های مناطق بر اساس محتوای بافت آنها در تصویر اشاره دارد. بافت یک تصویر توصیف خصوصیات یک منطقه از تصویر است، که به بیننده درک صافی، ناهمواری، منظم بودن یا بی‌نظمی تغییرات آن منطقه، کوچک بودن اجزای تصویر و غیره می‌دهد. روشهای مختلفی برای استخراج خواص بافت وجود دارد، از جمله روش‌های آماری، ساختاری و طیفی. جعبه ابزار پردازش تصویر MATLAB شامل چندین عملکرد تجزیه و تحلیل بافت است که با استفاده از روش‌های استاندارد آماری، تصویری را فیلتر می‌کند. این روش‌های آماری می‌توانند بافت یک تصویر را تعیین کنند زیرا اطلاعاتی را درباره تغییرات محلی شدت پیکسل در تصویر فراهم می‌کند. به عنوان مثال، در مناطقی با بافت صاف، دامنه پیکسل‌های محلی در اطراف یک پیکسل کم است. در مناطق با بافت خشن، دامنه بیشتر خواهد بود. به همین ترتیب، محاسبه انحراف استاندارد پیکسل در یک مکان می‌تواند درجه تنوع مقادیر پیکسل را در آن منطقه نشان دهد. ویژگی‌های استخراج شده از تصویر شامل آنتروپی محلی تصویر در مقیاس خاکستری (آنتروپی)، انحراف معیار محلی تصویر (STD)، الگوهای باینری محلی (LBP^۲) و ماتریس همزمانی سطح خاکستری (GLCM^۳) است. ویژگی‌های استخراج شده از GLCM شامل کنتراست، همگنی، همبستگی و انرژی است که همه از تصاویر استخراج می‌شوند. کنتراست شدت تنوع خاکستری تصویر را نشان می‌دهد (Wang et al., 2019).

$$\text{Contrast} = \sum_{i,j} |i - j|^2 p(i,j) \quad (7)$$

$$\text{Correlation} = \sum_{i,j} \frac{(i - \mu_i)(j - \mu_j) p(i,j)}{\sigma_i \sigma_j} \quad (8)$$

1- Local standard deviation of image

2- Local binary patterns

3- Gray level cooccurrence matrix

ضرب می‌شوند. سرانجام، مقادیر حاصل برای بدست آوردن تعداد واحد بافت جمع می‌شوند (Pantazi et al., 2019).

طبقه بندی

یک الگوریتم طبقه‌بندی بدون نظارت و یک الگوریتم طبقه بندی نظارت شده شامل تجزیه و تحلیل مؤلفه‌های اصلی (PCA) و ماشین بردار پشتیبان (SVM) برای تشخیص تقلبات زعفران استفاده شد.

تحلیل مؤلفه‌های اصلی در تعریف ریاضی یک تبدیل خطی متعامد است که داده را به دستگاه مختصات جدید می‌برد به طوری که بزرگترین واریانس داده بر روی اولین محور مختصات، دومین بزرگترین واریانس بر روی دومین محور مختصات قرار می‌گیرد و همین طور برای بقیه این عمل انجام می‌گیرد. تحلیل مؤلفه‌های اصلی می‌تواند برای کاهش ابعاد داده مورد استفاده قرار بگیرد، به این ترتیب مؤلفه‌هایی از مجموعه داده را که بیشترین تأثیر در واریانس را دارند حفظ می‌کند (Jolliffe, 2011).

ماشین بردار پشتیبان به عنوان یکی از بهترین تکنیک های دسته‌بندی و پیش بینی و تشخیص داده‌های خارج از محدوده شناخته می‌شود و برخلاف الگوریتم‌های خوشه‌بندی در دسته یادگیری با نظارت محسوب می‌شود و دو فاز آموزش و تست دارد. مبنای کاری دسته‌بندی کننده ماشین بردار پشتیبان، دسته‌بندی خطی داده‌ها است و در تقسیم خطی داده‌ها سعی می‌کنیم خطی را انتخاب کنیم که حاشیه اطمینان بیشتری داشته باشد (Huang et al., 2016). در مرحله آموزش SVM براساس توابع کرنل مختلف مثل، خطی، کوادراتیک^۱، کوپیک^۲، انواع گوسین انجام می‌شود که دقت هر طبقه‌بندی مشخص می‌شود.

شاخص های اعتبار سنجی و ارزیابی عملکرد

روش اعتبار سنجی متقابل^۳ یک روش ارزیابی مدل است که تعیین می‌نماید نتایج یک تحلیل آماری بر روی یک مجموعه داده تا چه اندازه قابل تعمیم و مستقل از داده‌های آموزشی است. این روش به طور ویژه در کاربردهای پیش‌بینی مورد استفاده قرار می‌گیرد تا مشخص شود مدل مورد نظر تا چه اندازه در عمل مفید خواهد بود. در اعتبارسنجی متقابل K لایه، داده‌ها به K زیرمجموعه افراز می‌شوند. از این K زیرمجموعه، هر بار یکی برای اعتبارسنجی و K-1 تای دیگر برای آموزش بکار می‌روند. این روال K بار تکرار می‌شود و همه داده‌ها دقیقاً یک بار برای آموزش و یک بار برای اعتبارسنجی بکار می‌روند. در نهایت میانگین نتیجه این K بار اعتبارسنجی به عنوان یک تخمین نهایی برگزیده می‌شود. به طور معمول از روش اعتبارسنجی پنج لایه یا ده لایه در پژوهش‌های مدل سازی و پیش‌بینی استفاده می‌شود (Siedliska et al., 2014).

برای اعتبار سنجی از یک روش اعتبار سنجی طبقه‌ای ۵ لایه استفاده شد. همچنین درصد دقت، ماتریس درهم ریختگی، نرخ مثبت صحیح نرخ منفی کاذب، ارزش بیش بینی مثبت، نرخ کشف کاذب و نرخ طبقه‌بندی صحیح در روش‌های فوق محاسبه و گزارش شد (Xie et al., 2017). تمام موارد فوق توسط جعبه ابزار متلب محاسبه شد.

(۱۸)

$$\text{Sensitivity or true positive rate (TPR)} = \frac{TP}{TP+FN}$$

(۱۹)

$$\text{Selectivity or true negative rate (TNR)} = \frac{TN}{TN+FP}$$

Precision or

$$\text{positive predictive rate (PPR)} = \frac{TP}{TP+FP} \quad (20)$$

اعتبار سنجی به کار گرفته شد (Kuo et al., 2016). تصاویر در دو کلاس زعفران خالص و زعفران تقلبی طبقه‌بندی شدند. نتایج SVM خطی، کوادراتیک، کوئیک، گوسین نرم، گوسین زبر ۲ و گوسین متوسط ۳ در جدول یک ارائه شده است. با توجه به نتایج ارائه شده در جدول یک بیشترین دقت طبقه‌بندی مربوط به طبقه بند کوئیک می‌باشد.

در شکل ۷ ماتریس اغتشاش بر اساس کرنل کوئیک ارائه شده‌است. در محور افقی کلاس پیش‌بینی و در محور عمودی کلاس واقعی نمایش داده شده‌است. الگوریتم Cubic SVM از ۵۶۲ نمونه زعفران واقعی، تعداد ۵۵۷ نمونه را به درستی تشخیص داده که مثبت صحیح است و ۵ نمونه دیگر را به اشتباه زعفران تقلبی تشخیص داده‌است که مثبت کاذب است. همچنین از ۸۱ نمونه تقلبی، تعداد ۶۷ نمونه را به درستی تشخیص داده که مثبت صحیح است و ۱۴ نمونه را به اشتباه زعفران واقعی تشخیص داده‌است که مثبت کاذب می‌باشد.

همچنین جزئیات آنالیز دقت طبقه‌بندی توابع کرنل مختلف SVM در جدول ۲ گزارش شده‌است. ارزش بالای نرخ TPR و PPR، و ارزش پایین نرخ FNR و FDR، به معنی مدل طبقه‌بندی خوب است. این مقادیر برای زعفران واقعی بهتر از زعفران تقلبی بود. نرخ TPR برای زعفران واقعی بین ۹۹ تا ۱۰۰ درصد برای تمامی توابع کرنل مختلف SVM بود. بالا بودن نرخ TPR نشان‌دهنده حساسیت طبقه‌بند برای تشخیص زعفران واقعی است. یعنی اینکه طبقه‌بندها قادرند بین ۹۹ تا ۱۰۰ درصد از ۵۶۲ نمونه واقعی را به درستی زعفران تشخیص دهند. برای مثال طبقه بند کوئیک، نرخ TPR برای زعفران واقعی مقدار ۹۹ درصد گزارش داد.

$$\text{False discovery rate (FDR)} = \frac{FP}{FP+TP} \quad (21)$$

$$\text{False positive rate (FPR)} = \frac{FP}{TN+FP} \quad (22)$$

$$\text{Accuracy (ACC)} = \frac{TP+TN}{TP+TN+FP+FN} \quad (23)$$

$$\text{AUC} = \frac{1}{2} \left(\frac{TP}{TP+FN} + \frac{TN}{TN+FP} \right) \quad (24)$$

منحنی مشخصه عملکرد سیستم (ROC^۱) یک روش اضافه برای ارزیابی مدل طبقه‌بندی است. منحنی ROC ارتباط بین مثبت واقعی و کاذب را مشخص می‌کند. محور X ها نرخ مثبت کاذب و محور Y ها نرخ مثبت واقعی را نشان می‌دهد. سطح زیر منحنی منحنی مشخصه عملکرد سیستم (AUC) یکی از مهمترین پارامترهای آماری برای ارزیابی عملکرد طبقه‌بندی است (Nasirahmadi et al., 2019).


نتایج و بحث

در این تحقیق از ۵۶۲ عکس رنگی از نمونه‌های مختلف زعفران، شامل پوشال، نگین و سرگل و ۸۱ نمونه زعفران تقلبی استفاده شد. از ۴ نوع طبقه‌بندی کننده مختلف SVM شامل خطی، کوادراتیک، کوئیک و گوسین استفاده شد. واژه نامه تعریف شده برای طبقه‌بندی کننده‌ها از ۶۴۳ نمونه شامل ۹۹ ویژگی بافت زعفران توده و شش ویژگی مورفولوژیک از رشته های مجزا بود. یعنی ویژگیها از ۱۲۸۶ تصویر مجزا استخراج شدند. سپس ۶ طبقه بندی کننده مختلف SVM با استفاده از اعتبار سنجی متقابل ۵ برابر با استفاده از PCA با ۳۳ جز عددی مورد ارزیابی قرار گرفتند به طوری که نمونه‌های اصلی به طور تصادفی در پنج گروه تقسیم شدند. از چهار گروه به عنوان داده های آموزشی برای توسعه مدل استفاده شد و گروه باقیمانده به عنوان داده‌های اعتبارسنجی برای آزمایش طبقه‌بندی حفظ شد. این فرآیند پنج بار تکرار شد و هر گروه یک بار به عنوان داده

جدول ۱- دقت طبقه‌بندی توابع کرنل مختلف SVM

Table 1- Accuracy of classifying different SVM kernel functions

نوع کرنل ماشین بردار پشتیبان	دقت طبقه بندی
SVM kernel functions	Accuracy of classification (%)
ماشین بردار پشتیبان خطی	94.4
Linear SVM	
ماشین بردار پشتیبان کوادراتیک	96.6
Quadratic SVM	
ماشین بردار پشتیبان کوبیک	97
Cubic SVM	
ماشین بردار پشتیبان گوسین نرم	87.4
Fine Gaussian SVM	
ماشین بردار پشتیبان گوسین متوسط	94.2
Medium Gaussian SVM	
ماشین بردار پشتیبان گوسین درشت	91.8
Coarse Gaussian SVM	



شکل ۷- ماتریس اغتشاش براساس کرنل کوبیک

Figure 7- Confusion matrix based on Cubic kernel.

نمونه تقلبی ۶۷ مورد را تشخیص داده که زعفران واقعی نیست. همچنین نرخ PPR بین ۹۱ تا ۹۸ درصد برای زعفران واقعی گزارش شد. نرخ FNR و نرخ FDR نشان داد که خطای طبقه

یعنی حساسیت این طبقه‌بند برای تشخیص زعفران واقعی ۹۹ درصد است. از طرفی نرخ TNR یا تشخیص اینکه نمونه زعفران واقعی نیست ۹۳ درصد است. یعنی طبقه‌بند از بین ۸۱

مورد بررسی قرار دادند. ابتدا، احراز هویت صد نمونه زعفران با تجزیه و تحلیل مؤلفه اصلی (PCA) مورد بررسی قرار گرفت. نتایج نشان داد که طیف سنجی NIR می تواند منشا نمونه ها را بهتر از MIR پیش بینی کند. در مرحله بعد، تجزیه و تحلیل جزئی حداقل مربعات (PLS-DA) برای تشخیص چهار تقلب کننده مشتق از گیاه (خامه زعفران، گل همیشه بهار، گلرنگ و روناس) ایجاد شد. در همه موارد، ارقام طبقه بندی PLS-DA از نظر حساسیت، ویژگی، میزان خطا و دقت برای مجموعه داده های NIR و MIR رضایت بخش بود. سپس مدل های ساخته شده با استفاده از مجموعه آزمایش و همچنین نمونه های تجاری با موفقیت تأیید شدند. در نهایت، از رگرسیون جزئی حداقل مربعات (PLSR) برای برآورد میزان تقلب استفاده شد. در این مورد، تنها NIR عملکرد خوبی با ضرایب رگرسیون (R^2) در محدوده ۰/۹۵ تا ۰/۹۹ نشان داد (Amirvaresi et al., 2021).

منحنی مشخصه عملکرد سیستم (ROC) یک روش اضافه برای ارزیابی مدل طبقه بندی است. منحنی ROC ارتباط بین مثبت واقعی و کاذب را مشخص می کند. محور X ها نرخ مثبت کاذب و محور Y ها نرخ مثبت واقعی را نشان می دهد (Siedliska et al., 2014).

سطح زیر منحنی منحنی مشخصه عملکرد سیستم (AUC) یکی از مهمترین پارامترهای آماری برای ارزیابی عملکرد طبقه بندی است. هرچه مقدار AUC به یک نزدیکتر باشد کارایی تشخیص کلی طبقه بند بهتر است (Faucitano et al., 2005). شکل ۸ منحنی ROC همراه با AUC را برای طبقه بندی زعفران واقعی و زعفران تقلبی مربوط به طبقه بند Cubic SVM نشان می دهد.


بندی زعفران تقلبی بیشتر از زعفران واقعی است. نرخ FNR برای زعفران واقعی با کرنل کوپیک SVM مقدار ۱ درصد بدست آمد. همچنین نرخ FDR برای زعفران واقعی با کرنل کوپیک SVM مقدار ۳ درصد بدست آمد. امیروارسی و همکاران (Amirvaresi et al., 2020) روشی را با استفاده از کروماتوگرافی لایه نازک (HPTLC) همراه با تجزیه و تحلیل تصویر چند متغیره (MIA) به عنوان ابزاری سریع و قابل اعتماد جهت تشخیص زعفران تقلب و زعفران واقعی بر اساس اثر انگشت HPTLC پیشنهاد دادند. در این پژوهش گیاهانی که بصورت عمومی در تقلب زعفران استفاده می شوند شامل گلرنگ، خامه زعفران، گل همیشه بهار و روناس بررسی شدند. نتایج تجزیه و تحلیل حداقل مربعات جزئی (PLS-DA) برای طبقه بندی زعفران تقلبی و زعفران خالص به این شرح بود که حساسیت ۹۹/۱۴ درصد، تشخیص ۹۶/۹۴ درصد، نرخ خطا ۱/۹۶ درصد و دقت ۹۸/۰۴ درصد گزارش شد (Amirvaresi et al., 2020). در مطالعه ای فرج و همکاران (Farg et al., 2020) از کروماتوگرافی گازی-طیف سنجی جرمی (GC-MS) برای تعیین اصالت، تشخیص تقلبات و ارزیابی تأثیر برشته شدن بر عطر آن استفاده شد. در مجموع ۹۳ ماده فرار متعلق به طبقات مختلف شناسایی شد. به منظور تمایز بین زعفران و گلهای شبیه به آن (گلرنگ و گل همیشه بهار)، دو مدل OPLS-DA برای بهبود تمایز بین زعفران و گلهای شبیه به آن ایجاد شد. نمونه های زعفران در یک کلاس در برابر نمونه های گلرنگ مدل شدند که دارای مقادیر R^2 و Q^2 به ترتیب ۰/۹۶ و ۰/۹۱ بودند. تمایز واضحی بین گلرنگ و زعفران مشاهده شد. سافرانال به عنوان یک ترکیب فرار منحصر به فرد است که آنرا از گلرنگ متمایز می کند (Farag et al., 2020). امیروارسی و همکاران (Amirvaresi et al., 2021) پتانسیل طیف سنجی مادون قرمز (NIR) و مادون قرمز میانی (MIR) به همراه کمومتریکس برای احراز هویت و تشخیص تقلب نمونه های زعفران ایرانی

جدول ۲- جزئیات آالیز دقت طبقه بندی


Table 2- Detailed accuracy analysis

مدل طبقه بندی Classification model	نرخ مثبت صحیح TP rate authentic saffron (%)	نرخ مثبت تقلبی FP rate (The adulterated saffron) (%)	نرخ منفی کاذب FN rate (The adulterated saffron) (%)	ارزش پیش مثبت PP rate (The authentic saffron) (%)	ارزش پیش منفی NP rate (The authentic saffron) (%)	نرخ کشف کاذب FD rate (The adulterated saffron) (%)	نرخ منفی واقعی TN rate (The authentic saffron) (%)	نرخ منفی واقعی TN rate (The authentic saffron) (%)	نرخ مثبت واقعی PP rate (The authentic saffron) (%)	نرخ مثبت تقلبی FP rate (The adulterated saffron) (%)
ماشین بردار پشتیبان خطی Linear SVM	99	62	1	38	95	91	5	9	95	5
ماشین بردار پشتیبان کوارداتیک Quadratic SVM	99	77	1	23	97	95	3	5	97	3
ماشین بردار پشتیبان مکعبی Cubic SVM	99	83	1	17	98	93	2	7	93	2.5
ماشین بردار پشتیبان گوسی نرم Fine Gaussian SVM	100	0	0	100	91	-	9	-	0	13
ماشین بردار پشتیبان گوسی متوسط Medium Gaussian SVM	100	0	54	46	94	100	6	0	100	6
ماشین بردار پشتیبان گوسی زبر Coarse Gaussian SVM	99	37	1	63	92	94	8	6	94	8

* TP= True positive rate, FN= False negative rate, PP= Positive predictive rate and FD= False discovery rate, TN= True negative rate, FP= False positive rate.



شکل (۸A)



شکل (۸B)

شکل ۸- منحنی ROC همراه با مقادیر AUC طبقه بند Cubic SVM زعفران اصل (A) و زعفران تقلبی (B)

Figure 8- The ROC along with AUC values of the Cubic SVM classifier: (A) The authentic saffron (B) The adulterated saffron.

درصد است و طبقه بند قادر است که ۹۹ درصد از نمونه‌های زعفران واقعی را زعفران تقلبی تشخیص ندهد و ۱۷ درصد از نمونه‌های تقلبی را به اشتباه زعفران واقعی تشخیص داد.

شکل (۸A) منحنی مشخصه عملکرد سیستم را برای تشخیص زعفران واقعی نشان می‌دهد با توجه به داده‌های شکل مورد نظر، حساسیت طبقه‌بند برای تشخیص زعفران واقعی ۹۷

همچنین شکل (AB) نشان می‌دهد که حساسیت طبقه‌بند برای تشخیص زعفران تقلبی ۹۷ درصد است و طبقه‌بند قادر بود که ۸۳ درصد از نمونه‌های زعفران تقلبی را واقعی تشخیص ندهد و ۱ درصد از نمونه‌های واقعی را به اشتباه تقلبی تشخیص داد.

جدول ۳- مقادیر AUC توابع کرنل مختلف SVM برای زعفران خالص و زعفران تقلبی
Table 3- The AUC (area under the ROC curve) of the different SVM kernel functions

مدل طبقه‌بندی	زعفران واقعی	زعفران تقلبی	مجموع
Classification model	Authentic saffron	Adultrated saffron	Overall
ماشین بردار پشتیبان خطی Linear SVM	0.96	0.96	0.96
ماشین بردار پشتیبان کوادراتیک Quadratic SVM	0.98	0.98	0.98
ماشین بردار پشتیبان کویک Cubic SVM	0.97	0.97	0.97
ماشین بردار پشتیبان گوسین نرم Fine Gaussian SVM	0.85	0.85	0.85
ماشین بردار پشتیبان گوسین متوسط Medium Gaussian SVM	0.99	0.99	0.99
ماشین بردار پشتیبان گوسین زبر Coarse Gaussian SVM	0.98	0.98	0.98

شاخص‌های خوبی برای جداسازی زعفران واقعی از زعفران تقلبی هستند. در این تحقیق نمونه‌های زعفران واقعی از شهرهای مختلف استان خراسان جمع‌آوری شد. جهت تهیه نمونه‌های تقلبی زعفران گلرنگ و خامه زعفران از عطاری‌های شهر گناباد تهیه شد و توسط رنگ‌های مصنوعی آلوده، تارتارازین، پونسینو ۴ و کینولین یلو در آزمایشگاه معاونت غذا و دارو دانشگاه علوم پزشکی گناباد رنگ شدند. همچنین تعداد ۴۱ نمونه تقلبی که در آزمایشگاه معاونت غذا و دارو دانشگاه علوم پزشکی گناباد و مشهد شناسایی و طبقه‌بندی شده بودند. برای گرفتن تصاویر زعفران از دوربین دیجیتال حرفه‌ای در شرایط نورپردازی ثابت استفاده شد. از هر نمونه دو نوع تصویر گرفته شد. تعداد ۹۹ ویژگی بافت از تصاویر توده و ۶ ویژگی مورفولوژی از تصاویر رشته‌های مجزا استخراج شد. در مجموع ۱۰۵ ویژگی به عنوان ورودی برای شش تابع کرنل مختلف SVM در جهت تشخیص و طبقه‌بندی زعفران واقعی از زعفران تقلبی در نظر گرفته شد. دقت طبقه‌بندی برای طبقه‌بند Cubic

طبق جدول ۳ طبقه‌بند Medium Gaussian SVM بیشترین مقدار AUC را برای تشخیص زعفران واقعی و زعفران تقلبی داشت. علاوه بر این مقادیر کلی AUC برای طبقه‌بند های Linear SVM، Quadratic SVM، Cubic SVM و Fine Gaussian SVM و Coarse Gaussian SVM به ترتیب ۰/۹۶، ۰/۹۸، ۰/۹۷، ۰/۸۵ و ۰/۹۸ بود. این نتایج نشان داد که طبقه‌بند Fine Gaussian SVM در تفکیک زعفران اصلی از تقلبی بر اساس ویژگی‌های استخراج شده ناموفق بود. هرچه AUC به یک نزدیکتر باشد، عملکرد کلی تشخیصی طبقه‌بندی شده بهتر نیز خواهد بود (Hu et al., 2016). کیانی و همکاران (Kiani et al., 2017) از یک سیستم بینایی ماشین و بینی الکترونیک برای تشخیص زعفران تقلبی از زعفران خالص استفاده کردند. آنها به این نتیجه رسیدند که رنگ و بوی زعفران تقلبی با زعفران واقعی متفاوت است و می‌تواند معیار خوبی برای تشخیص نمونه‌های تقلبی از اصلی باشد. نتایج نشان داد که ویژگی‌های مورفولوژی و بافت تصویر

تشکر و قدردانی

این پژوهش در قالب یک طرح پژوهشی با کد Pr986101 مرکز تحقیقاتی غذا و دارو سازمان غذا و دارو انجام گرفته است. لذا لازم است از حمایت‌های بیدریغ سرکار خانم دکتر ادیب، خانم دکتر خسروخاور و جناب آقای دکتر شعبی کمال تشکر را بنمایم.

SVM مقدار ۹۷ درصد بدست آمد. این طبقه‌بند قادر بود که ۹۹ درصد از نمونه‌های زعفران واقعی را به درستی تشخیص دهد. بنابراین نتایج حاصل از این طبقه‌بندی نشان داد که این روش با قابلیت تشخیص زعفران واقعی از تقلبی، به عنوان یک روش هوشمند، آسان، ارزان، سریع، غیرمخرب و با دقت، قابل استفاده است. در مطالعات آینده استفاده از تکنیک یادگیری عمیق می‌تواند دقت شناسایی زعفران واقعی از زعفران تقلبی را بهبود ببخشد.

منابع

- Aghamohamadian-Sharbat, M., Pourreza, H.R., and Banaee, T. 2016. A novel curvature-based algorithm for automatic grading of retinal blood vessel tortuosity. *IEEE Journal of Biomedical and Health Informatics* 20: 586-595.
- Amirvaresi, A., Nikounezhad, N., Amirahmadi, M., Daraei, B., and Parastar, H. 2021. Comparison of near-infrared (NIR) and mid-infrared (MIR) spectroscopy based on chemometrics for saffron authentication and adulteration detection. *Food Chemistry* 344: 128647.
- Amirvaresi, A., Rashidi, M., Kamyar, M., Amirahmadi, M., Daraei, B., and Parastar, H. 2020. Combining multivariate image analysis with high-performance thin-layer chromatography for development of a reliable tool for saffron authentication and adulteration detection. *Journal of Chromatography A* 1628: 461461.
- Bhooma, V., Nagasathiya, K., Vairamani, M., and Parani, M. 2020. Identification of synthetic dyes magenta III (new fuchsin) and rhodamine B as common adulterants in commercial saffron. *Food Chemistry* 309: 125793.
- Cen, H., Lu, R., Zhu, Q., and Mendoza, F. 2016. Nondestructive detection of chilling injury in cucumber fruit using hyperspectral imaging with feature selection and supervised classification. *Postharvest Biology and Technology* 111: 352-361.
- de Oliveira, E.M., Leme, D.S., Barbosa, B.H.G., Rodarte, M.P., and Pereira, R.G.F.A. 2016. A computer vision system for coffee beans classification based on computational intelligence techniques. *Journal of Food Engineering* 171: 22-27.
- Farag, M.A., Hegazi, N., Dokhalahy, E., and Khattab, A.R. 2020. Chemometrics based GC-MS aroma profiling for revealing freshness, origin and roasting indices in saffron spice and its adulteration. *Food Chemistry* 331: 127358.
- Faucitano, L., Huff, P., Teuscher, F., Garipey, C., and Wegner, J. 2005. Application of computer image analysis to measure pork marbling characteristics. *Meat Science* 69: 537-543.
- Feizi, J., and Hemmati Kakhki, A. 2006. Identification of colored styles as one of the saffron adulteration with HPLC. *Iranian Journal Food Science and Technology Research* 2 (2). (In Persian with English Summary).
- Hagh-Nazari, S., and Keifi, N. 2006. Saffron and

- various fraud manners in its production and trades. II International Symposium on Saffron Biology and Technology 739: 411-416.
- Heidarbeigi, K., Mohtasebi, S.S., Rafiee, S., Ghasemi-Varnamkhasti, M., Rezaei, K., and Rodriguez-Mendez, M.L. 2015. An electronic tongue design for the detection of adulteration in saffron samples. *Iranian Journal of Biosystems Engineering* 46: 405-413. (In Persian with English Summary).
- Hu, M.H., Dong, Q.L., and Liu, B.L. 2016. Classification and characterization of blueberry mechanical damage with time evolution using reflectance, transmittance and intertance imaging spectroscopy. *Computers and Electronics in Agriculture* 122: 19-28.
- Huang, M., Tang, J., Yang, B., and Zhu, Q. 2016. Classification of maize seeds of different years based on hyperspectral imaging and model updating. *Computers and Electronics in Agriculture* 122: 139-145.
- Javanmardi, N., Bagheri, A., Moshtaghi, N., Sharifi, A., and Hemati Kakhki, A. 2011. Identification of Safflower as a fraud in commercial Saffron using RAPD/SCAR. *Journal of Cell and Molecular Research* 3: 31-37.
- Jolliffe, I. 2011. Principal Component Analysis. *International Encyclopedia of Statistical Science*. Springer, p. 1094-1096.
- Kiani, S., Minaei, S., and Ghasemi-Varnamkhasti, M. 2017. Integration of computer vision and electronic nose as non-destructive systems for saffron adulteration detection. *Computers and Electronics in Agriculture* 141: 46-53.
- Koocheki, A., and Milani, E. 2020. Saffron adulteration. *Saffron*. Elsevier, p. 321-334.
- Kuo, T.Y., Chung, C.L., Chen, S.Y., Lin, H.A., and Kuo, Y.F. 2016. Identifying rice grains using image analysis and sparse-representation-based classification. *Computers and Electronics in Agriculture* 127: 716-725.
- Nasirahmadi, A., Sturm, B., Olsson, A.C., Jeppsson, K.H., Müller, S., Edwards, S., and Hensel, O. 2019. Automatic scoring of lateral and sternal lying posture in grouped pigs using image processing and Support Vector Machine. *Computers and Electronics in Agriculture* 156: 475-481.
- Pantazi, X., Moshou, D., and Tamouridou, A. 2019. Automated leaf disease detection in different crop species through image features analysis and one class classifiers. *Computers and Electronics in Agriculture* 156: 96-104.
- Pourreza, A., Pourreza, H., Abbaspour-Fard, M.H., and Sadrnia, H. 2012. Identification of nine Iranian wheat seed varieties by textural analysis with image processing. *Computers and Electronics in Agriculture* 83: 102-108.
- Rastegaripour, F., and Mohammadi, N. 2018. Investigating factors affecting currency saffron in Iran with emphasis on packaging and branding. *Journal of Saffron Research* 6: 51-73. (In Persian with English Summary).
- Siedliska, A., Baranowski, P., and Mazurek, W. 2014. Classification models of bruise and cultivar detection on the basis of hyperspectral imaging data. *Computers and Electronics in Agriculture* 106: 66-74.
- Taheri-Garavand, A., and Yousefian, M. 2020. Application of computer vision on non-destructive detection of grape syrup adulteration. *Innovative Food Technologies* 7: 479-495.
- Wang, A., Zhang, W., and Wei, X. 2019. A review on weed detection using ground-based machine vision and image processing techniques.

- Computers and Electronics in Agriculture 158: 226-240.
- Xie, C., Yang, C., and He, Y. 2017. Hyperspectral imaging for classification of healthy and gray mold diseased tomato leaves with different infection severities. Computers and Electronics in Agriculture 135: 154-162.

Application of Computer Vision on Non-Destructive Detection of the Authentic and Adulterated Saffron

Behrouz Akbari Adergani¹, Morteza Mohammadzadeh Moghadam^{2}, Mehdi Karimi Noghabi³, Mojtaba Mohammadpour⁴, Mohammad Khalilian-Movahhed⁵*

Submitted: 11 August 2021

Accepted: 6 November 2021

Akbari Adergani, B., Mohammadzadeh Moghadam, M., Karimi Noghabi, M., Mohammadpour, M., Khalilian-Movahhed, M. 2022. Application of Computer Vision on Non-Destructive Detection of the Authentic and Adulterated Saffron. *Saffron Agronomy & Technology*, 9(4): 409-429.

Abstract

Saffron is one of the most expensive spices in the world. Saffron is a spice that is widely cheated. The development of techniques based on simple, inexpensive, appropriate, and fast tools in the food industry is essential for detecting adulteration such as saffron adulterated. In the present study, the combination of image processing and Support vector machine (SVM) method has been used for fast and non-destructive evaluation of distinguishing authentic saffron from adulterated saffron. After preparing images from pure and counterfeit saffron and separate stigmas, the images entered the pre-processing stages, and finally, statistical features related to the texture of the images and morphological features, including 105 features, were extracted. In order to increase the speed and accuracy of classification, PCA principal component analysis method was used to reduce the properties of the feature matrix. Also, the images were classified into two classes using different SVM kernel functions. Also, the images were classified into two classes using different SVM kernel functions. Then statistical indicators such as accuracy, precision, sensitivity, specificity, and AUC were calculated to evaluate the classification. The values of these indices for classification with SVM cubic kernel for authentic saffron were 97, 98, 99, 93, and 97%, and for adulterated saffron, 97, 93, 83, 97.5, and 97% were obtained, respectively. The results of this classification showed that this system, as an intelligent, fast, non-destructive, and accurate method, can distinguish the authentic saffron from adulterated saffron.

Keywords: Saffron, fraud, Image processing, SVM

1- Professor, Food and Drug Laboratory Research Center, Food and Drug Administration, Ministry of Health and Medical Education, Tehran, Iran

2-Assistant Professor, Food and Drug Control Laboratory Office, Food and Drug Deputy, Gonabad University of Medical Sciences, Gonabad, Iran

3- Assistant Professor, Food and Drug Control Laboratory Office, Food and Drug Deputy, Gonabad University of Medical Sciences, Gonabad, Iran

4- Assistant Professor, Department of Electrical & Computer Engineering, Faculty of Engineering, University of Gonabad, Gonabad, Iran

5- PhD Student, Department of Food Science and Technology, Ferdowsi University of Mashhad, Mashhad, Iran

(*- Corresponding author Email: mohammadzade.m@gmu.ac.ir)

DOI: 10.22048/jsat.2021.299151.1433