

Bulk Raisin Classification using Gray Level Co-occurrence Matrix

MOSTAFA KHOJASTEHNZHAND^{*1}, HAMED RAMEZANI²

1. Mechanical Engineering Department, Faculty of Engineering, University of Bonab, Bonab, Iran

2. Department of Biosystems Engineering, Faculty of Agricultural Engineering, Tarbiat Modares University, Tehran, Iran

(Received: Jan. 27, 2019- Revised: May. 6, 2019- Accepted: Aug. 3, 2019)

ABSTRACT

Raisin is one of the most important agricultural products. In this study, by using the machine vision approach, the quality of bulk raisin was evaluated in two different conditions. In the first case, six classes of good and bad raisins mixture, and in the latter case, 15 classes of good, bad and woody raisins have been studied. Classification results with Linear Discriminate Analysis (LDA) and Support Vector Machine (SVM) showed that the best classification accuracy of 6 classes was obtained by linear SVM method with an accuracy of 85.55%. The results for classifying 15 classes including good, bad and wood showed that the best result was obtained by linear SVM method but with a lower accuracy of 63.55%. The results showed that the GLCM method was able to detect the class of raisin bulk product and could replace the expert in raisin processing plants.

Keywords: Raisin, Support vector machine, Classification, Linear discrimination analysis, Machine vision

استفاده از ماتریس هم-رخدادی سطح خاکستری برای طبقه بندی کشمش توده‌های

مصطفی خجسته نژاد^{۱*}، حامد رضائی^۲

۱. گروه مهندسی مکانیک، دانشکده فنی و مهندسی، دانشگاه بناب، بناب، ایران

۲. گروه مهندسی مکانیک بیوسیستم، دانشکده کشاورزی، دانشگاه تربیت مدرس، تهران، ایران

(تاریخ دریافت: ۱۳۹۷/۱۱/۷ - تاریخ بازنگری: ۱۳۹۸/۲/۱۶ - تاریخ تصویب: ۱۳۹۸/۵/۱۲)

چکیده

کشمش یکی از محصولات مهم کشاورزی است. در این تحقیق با استفاده از روش بینایی اقدام به کیفیت سنجی محصول توده‌های کشمش در دو حالت متفاوت شده است. در حالت اول، ۶ طبقه ترکیبی از کشمش خوب و بد و در حالت دوم ۱۵ طبقه ترکیبی از کشمش خوب، بد و چوب و خار و خاشاک مورد بررسی قرار گرفته است. نتایج طبقه‌بندی با روش‌های LDA و SVM نشان دادند که بهترین دقت طبقه‌بندی ۶ طبقه، با روش SVM خطی حاصل شد که دارای دقت ۸۵/۵۵ درصد بوده است. نتایج حاصل برای طبقه‌بندی ۱۵ طبقه شامل کشمش خوب، بد و خار و خاشاک نشان داد که بهترین نتیجه باز با روش SVM خطی ولی با دقتی پایین‌تر در حدود ۶۳/۵۵ درصد حاصل گردید. نتایج نشان داد که روش GLCM بصورت قابل قبولی قادر به تشخیص طبقه محصول توده‌های کشمش بوده و می‌تواند جایگزین فرد خبره در کارخانه‌های فرآوری کشمش شود.

واژه‌های کلیدی: کشمش، ماشین بردار پشتیبان، طبقه‌بندی، تحلیل تفکیک خطی، ماشین بینایی

مقدمه

کشمش یکی از محصولات مهم کشاورزی است که از خشک کردن انگور (*Vitis Vinifera*) بدست می‌آید. محصولات جانبی که از انگور بدست می‌آید شامل آبغوره، سرکه (Gardé-Cerdán et al., 2007)، شیر انگور (Esmailia et al., 2007)، شربت و کشمش (Pangavhane & Sawhney, 2002) است. طعم، مزه و مواد مغذی موجود در انگور از عوامل مهم مقبولیت این محصول هم بصورت تازه‌خوری و هم به صورت فرآوری شده آن است (Jairaj et al., 2009; Pangavhane & Sawhney, 2002). از آنجائیکه نگهداری طولانی مدت انگور به دلیل درصد رطوبت بالای آن مقدور نیست، معمولاً حالت خشک شده آن مورد داد و ستد و تجارت قرار می‌گیرد. با این عمل ضمن حفظ کیفیت غذایی، فسادپذیری آن کاهش می‌یابد. علاوه بر مزیت ذکر شده، تبدیل انگور به کشمش باعث کاهش اثرات سموم باقیمانده بر روی انگور نیز می‌شود (Cabras et al., 1997 & 1998). که متأسفانه در سال‌های اخیر به دلیل استفاده بی‌رویه از سموم غیرمجاز در مرحله داشت انگور بازارهای جهانی این محصول با تهدید جدی مواجه گردیده است. کشمش حاوی کربوهیدرات‌ها، آهن، ویتامین‌ها، مواد معدنی مورد نیاز (Ghrai et al., 2013; Gurak et al., 2010) و مقادیر مهمی از ترکیبات فعال زیستی از جمله فنول‌ها می‌باشد (Hogan et al., 2009). براساس آمار ارائه شده،

تولید انگور در ایران، طی سال‌های ۱۳۹۱ تا ۱۳۹۵ از مقدار ۲/۳۹ میلیون تن به مقدار ۳/۴۵ میلیون تن افزایش پیدا کرده و رشد ۴۴ درصدی را نشان می‌دهد. البته مقدار تولید این محصول طی سال‌های مختلف با نوسان مواجه بوده است، به طوری که در سال ۱۳۹۶ به ۳/۲۰ میلیون تن کاهش پیدا کرده است که این مقدار کاهش به دلیل تغییرات جوی و آب و هوایی مناطق تولید کننده انگور بوده است. افزایش تولید در طی ۶ سال نشانگر اهمیت توجه جدی به صنایع تبدیلی و راهکارهای صادراتی این محصول می‌باشد. ایران بعد از کشورهای ترکیه، آمریکا و چین، با تولید ۱۶۰ هزار تن کشمش در سال ۲۰۱۷-۲۰۱۸ مقام چهارم را به خود اختصاص داده است. علی‌رغم مقام چهارمی در تولید این محصول، به دلیل مصرف پایین آن در داخل کشور، ایران با صادرات ۱۴۰ هزار تن در سال ۲۰۱۷-۲۰۱۸ بعد از کشور ترکیه، بزرگترین کشور صادر کننده کشمش در جهان محسوب می‌شود (Agricultural Statistics, 2017). محصول کشمش معمولاً بعد از تولید توسط کشاورز، بصورت توده‌ای به کارخانجات فرآوری که وظیفه شستشو، خشک کردن مجدد، دم‌گیری، درجه‌بندی و بسته‌بندی محصول را دارند، فروخته می‌شود. کشاورزان و تولیدکنندگان کشمش به منظور کسب سود بیشتر، محصول کشمش را با درصد رطوبت بالاتر از حد استاندارد و با کمترین عمل تمیزکاری بر روی چوب و دمچه‌های باقیمانده بر روی دانه‌های

علف هرز متداول در مزارع ایران شده است که نتایج قابل قبولی بدست آمده است (Ebrahimi *et al.*, 2014). علی رغم اینکه در تحقیقات متناوبی، از روش بینایی ماشین برای تعیین کیفیت و درجه بندی کشمش استفاده گردیده است، ولی در زمینه بررسی کیفیت محصول توده‌ای کشمش، تحقیقات محدودی انجام گرفته است. در این راستا، براساس چین و چروک روی سطح کشمش و شکل ظاهری آن اقدام به طبقه بندی محصول به سه کلاس مختلف با دقت قابل قبولی شده است (Okamura *et al.*, 1993). عباسقلی پور و همکاران نیز، با تبدیل فضای رنگی قرمز، سبز و آبی (RGB) به فضای رنگی اصل رنگ، اشباع و شدت روشنایی (HSI) و تلفیق با ژنتیک الگوریتم اقدام به دسته بندی نمونه‌ها به دو دسته خوب و بد نموده‌اند (Abbasgolipour *et al.*, 2011). در تحقیق مشابه دیگری نیز با استفاده از ماشین بردار پشتیبان (SVM) اقدام به کلاس بندی محصول کشمش به ۴ دسته متفاوت شده است (Yu *et al.*, 2011). همانطور که ذکر گردید، تحقیقات نامبرده اقدام به کلاس بندی محصول نموده‌اند. در تحقیقی که توسط کریمی و همکاران (Karimi *et al.*, 2017) ارائه گردیده است، محصول توده‌ای کشمش با ترکیبات متفاوتی از کشمش خوب و بد مورد تجزیه و تحلیل قرار گرفته است. بطوریکه با استفاده از خصوصیات استخراجی از بافت تصاویر اخذ شده، نمونه‌هایی با خلوص ۵۰ تا ۱۰۰ درصد کشمش خوب، با استفاده از شبکه عصبی مصنوعی (ANN) و تحلیل مولفه‌های اصلی (PCA) کلاس بندی شده است. نتایج تحقیق نشان می‌دهد که استفاده از ماتریس هم رخدادی سطح خاکستری (GLCM) برای تشخیص و اندازه گیری پارامترهای بافت تصویر بطور موفقیت آمیزی عمل کرده است. اما چون محصول توده‌ای کشمش که توسط کشاورز به کارخانه فرآوری و بسته بندی عرضه می‌گردد، علاوه بر کشمش بد، شامل چوب، خار و خاشاک و مواد زائد دیگری نیز است، کیفیت سنجی و طبقه بندی کشمش توده‌ای شامل کشمش خوب، بد و مواد زائد (که شامل خار و خاشاک و چوب و دم کشمش است) مورد انتظار است. استفاده از ماتریس هم-رخدادی سطح خاکستری به منظور استخراج خصوصیات بافت تصویری، در طبقه بندی، درجه بندی و اندازه گیری کیفیت نهایی محصولات مختلف بطور موفقیت آمیزی انجام شده است (Guevara-Hernandez & Gomez-Gil, 2011; Chowdhury *et al.*, 2015; Mokhtar *et al.*, 2015). بر اساس توضیحات ارائه شده و توانایی‌های روش غیر مخرب بینایی ماشین، در این تحقیق سعی شده است با استفاده از ماتریس هم-رخدادی سطح خاکستری اقدام به طبقه بندی محصول توده‌ای کشمش که شامل کشمش خوب، کشمش بد و مواد زائد (خار و خاشاک و دم کشمش) است،

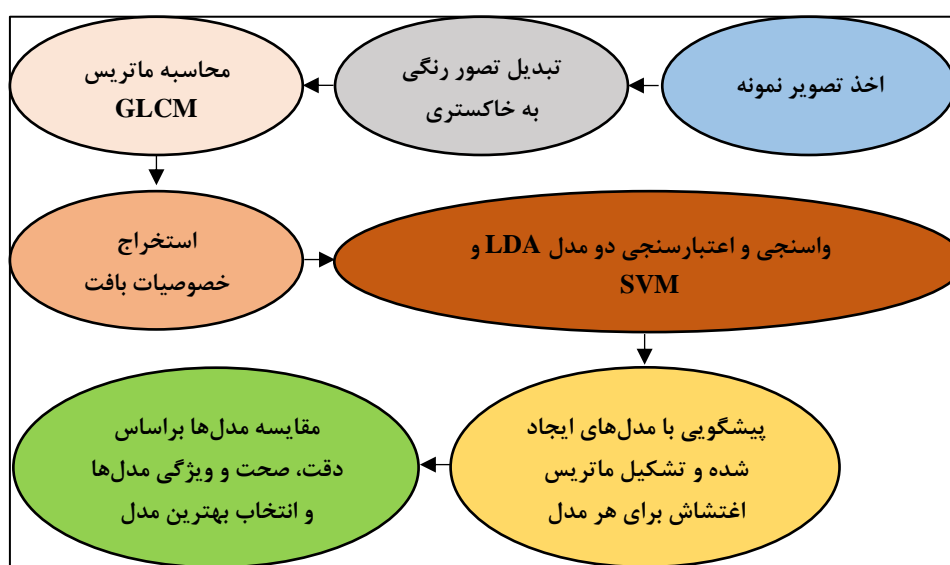
آن به کارخانه عرضه می‌کنند. خریدار محصول نیز براساس کیفیت ظاهری محصول و بر اساس تجربه اقدام به قیمت گذاری محصول می‌نماید. اما این روش قیمت گذاری و کیفیت سنجی دارای ایراداتی از جمله تصمیم گیری مبتنی بر علائق شخصی و حدس و گمان می‌باشد. با پیشرفت علم و تکنولوژی، ارائه روش‌های جدید غیر مخرب برای تعیین کیفیت محصولات کشاورزی و صنایع غذایی در سال‌های اخیر گسترش یافته است. بطوریکه این روش‌ها با غلبه برضعف روش‌های سنتی مرسوم، عملکرد موفقیت آمیزی از خود ارائه داده‌اند. روش ماشین بینایی نیز به عنوان یکی از روش‌های غیر مخرب، کاربردهای زیادی در بخش کنترل کیفیت مواد غذایی و محصولات کشاورزی داشته است. روش بینایی ماشین، با الهام از چشم انسان و در فضاهای رنگی متفاوت، اقدام به استخراج خصوصیات رنگی نمونه مورد نظر کرده و عمل شناسایی یا طبقه بندی را انجام می‌دهد. تحقیقات گسترده‌ای بر روی درجه بندی محصولات مختلف با استفاده از روش بینایی ماشین انجام گرفته است. در سال‌های اخیر از سامانه‌های ماشین بینایی برای درجه بندی، طبقه بندی یا تشخیص عیب و نقص محصولات مختلف کشاورزی استفاده شده است که از آن جمله می‌توان به کلاس بندی و تشخیص عیب سیب (Unay *et al.*, 2011; Yimyam & Clark, 2016;)، پرتقال (Pham & Lee, 2015)، برنج و پنبه (Bai *et al.*, 2013)، توت فرنگی (Liming & Yanchao 2010)، گندم (Olgun *et al.*, 2016; Jiang *et al.*, 2016) و ... غیره اشاره نمود. در تحقیقات انجام گرفته، بنا بر هدف تحقیق، خصوصیتی از محصول جهت بررسی انتخاب شدند که از این خصوصیات می‌توان به خصوصیات رنگ (Veernagouda Ganganagowder & Kamath, 2017)، شکل (Su *et al.*, 2018)، طیف (Sun *et al.*, 2017) و بافت (Guanjun *et al.*, 2019; Wang *et al.*, 2019) محصول اشاره کرد. انتخاب خصوصیت بافت محصول با اهداف مختلفی انجام می‌پذیرد. در برخی موارد از این خصوصیت در مورد محصولاتی همچون سیب و پرتقال برای تشخیص ناحیه آسیب دیده (Unay *et al.*, 2011; Yimyam & Clark, 2016) و یا تشخیص علف هرز در بین گیاهان دیگر (Rehman *et al.*, 2019; Wang *et al.*, 2019) و یا در بین محصولات دانه‌ای همچون گندم یا برنج (Guevara-Hernandez & Gomez-Gil, 2011) مورد استفاده قرار می‌گیرد. در محصولات دانه‌ای به دلیل تفاوت رنگ و بافت دانه‌های آسیب دیده با دانه‌های سالم، از استخراج خصوصیت بافت نمونه توده‌ای اقدام به تعیین درصد کیفیت محصول می‌شود. در تحقیقی، با استفاده از ۵۲ خصوصیت رنگ، بافت و شکل، اقدام به ارزیابی خلوص چهار رقم بذر گندم در ترکیب با شش نوع بذر

ماشین بردار پشتیبان (SVM) اقدام به طبقه‌بندی نمونه‌ها و مقایسه نتایج گردیده است. در پایان براساس برخی پارامترها، بهترین مدل از نظر دقت و صحت پیشگویی طبقه‌بندی، معرفی گردیده است. تمامی مراحل اخذ تصویر و استخراج خصوصیات بافت نمونه از روی ماتریس GLCM در محیط برنامه نرم‌افزار متلب Matlab R2013b، و تمامی مراحل مدل‌سازی و استخراج نتایج با استفاده از برنامه The Unscrambler X 10.4 انجام پذیرفته است. در ادامه تمامی مراحل تحقیق با جزئیات بیشتر توضیح داده می‌شود.

شود. نتایج تحقیق می‌تواند در کارخانجات خشکبار به منظور ارزش‌گذاری و کیفیت سنجی محصول توده‌ای در حین خرید مورد استفاده قرار گیرد.

مواد و روش‌ها

شکل ۱ روندنمای کلی تحقیق حاضر را نشان می‌دهد. در این تحقیق ابتدا تصاویر نمونه‌های اخذ شده، به تصاویر سطح خاکستری تبدیل شده و خصوصیات بافتی آنها از روش ماتریس هم‌رخدادی سطح خاکستری استخراج گردیده است. در ادامه با استفاده از دو مدل طبقه‌بندی تحلیل افتراق خطی (LDA) و



شکل ۱- روندنمای طبقه‌بندی محصول کشمش با استفاده از روش GLCM

تهیه نمونه

برای آماده سازی نمونه‌های مورد آزمایش، ابتدا به میزان ۱۰ کیلوگرم کشمش انگوری طلایی از تولید کننده محلی در سال ۱۳۹۷ خریداری گردید. نمونه توده‌ای تهیه شده، ابتدا پاکسازی شده و به سه گروه کشمش خوب، کشمش بد و چوب و خار و خاشاک تقسیم گردید. به منظور اینکه درصد هر کدام از سه گروه اشاره شده در طبقه‌های انتخابی مشخص گردد، از یک پیمانانه مشخص برای انتخاب گروه‌ها، استفاده گردید. طبقه‌های مورد نظر بصورت ترکیبی از سه گروه کشمش خوب، بد و خاروخاشاک با درصدهای ترکیب مشخص تهیه گردیدند. براساس ترکیبات مختلف سه گروه اشاره شده، تعداد ۱۵ طبقه مختلف براساس درصدی از سه گروه، آماده تصویربرداری شد. به منظور اینکه از تصادفی بودن قرارگیری دانه‌های کشمش و خار و خاشاک در هر طبقه اطمینان حاصل شود، ابتدا آنها را در داخل یک پلاستیک ریخته و با برهم زدن کامل، در داخل ظرفی به ابعاد mm^2

150×150 به ارتفاع ۲۰ mm ریخته شده و سپس سطح نمونه در داخل ظرف مسطح گردید. شکل ۲، پانزده طبقه تشکیل شده به همراه نام طبقه‌ها و درصد محصول خوب، بد و خار و خاشاک آنرا نشان می‌دهد. در این جدول حرف G، نشان دهنده درصد کشمش خوب، حرف B، نشان دهنده درصد کشمش بد و حرف W، نشان دهنده درصد چوب و خار و خاشاک است. بعنوان مثال برای تهیه نمونه G80B10W10 با استفاده از پیمانانه مورد نظر، ۸ پیمانانه از گروه کشمش خوب، ۱ پیمانانه از کشمش بد و ۱ پیمانانه نیز از چوب و خار و خاشاک در داخل پلاستیک ریخته و با به هم زدن کامل آنها، در داخل ظرف تصویربرداری ریخته شدند. همانطور که در قسمت مقدمه نیز بیان گردید، هدف از تهیه هر طبقه، تهیه نمونه‌های توده‌ای تولید شده توسط کشاورز به منظور تعیین درجه تمیزی از طریق طبقه‌بندی آنها قبل از ورود به کارخانه بوده است تا خلوص توده‌های کشمش مشخص شود.



شکل ۲- طبقه‌های مورد استفاده از کشمش توده‌ای

مقابل، با استفاده از لامپ LED که بصورت حلقه‌ای به دور دوربین نصب می‌گردید، استفاده شد. دوربین استفاده شده از نوع CMOS مدل Logitech C920 HD pro Webcam با وضوح 480×640 پیکسل با سرعت ۳۰ فریم بر ثانیه بوده که در مرکز حلقه لامپ LED نصب شده و از طریق کابل‌های رابط به رایانه متصل گردید. تصاویر اخذ شده با انتقال به رایانه شخصی، ذخیره شده و مورد استفاده قرار گرفتند.

سامانه ماشین بینایی

در این سامانه از یک عدد دوربین، رایانه شخصی، سامانه نورپردازی و محفظه تصویربرداری برای حذف نورهای محیطی و فراهم نمودن شرایط یکسان تصویربرداری استفاده گردید. جعبه سیاه مورد نظر از جنس MDF به ابعاد $40 \times 40 \times 50$ سانتی‌متر مطابق شکل ۳ ساخته شد. شکل ۳ محل نصب دوربین و سامانه نورپردازی را در آن نشان می‌دهد. در این سامانه از نورپردازی از



شکل ۳- سامانه ماشین بینایی

ماتریس هم‌رخدادی سطح خاکستری

یکی از ابزارهای مفید رنگی در روش بینایی ماشین، استفاده از هیستوگرام تصویر است. در این روش، نمودار فراوانی هر سطح رنگی ترسیم شده و اطلاعات مورد نیاز استخراج می‌گردد. اما استفاده تنها از هیستوگرام تصویر، هیچ نوع اطلاعاتی را در زمینه توزیع سطوح رنگی (یا خاکستری) در کل تصویر ارائه نمی‌دهد.

اخذ تصاویر


هر طبقه تهیه شده که در داخل ظرف ریخته شده است، در مقابل دوربین قرار گرفته و با بستن درب جعبه نورپردازی، تصویر نمونه اخذ گردید. در ادامه همان طبقه در داخل پلاستیک ریخته شده و با برهم زدن مجدد آن و ریختن به ظرف، تصویر بعدی اخذ گردید. برای هر طبقه، تعداد ۵۰ عدد تصویر اخذ شد که جهت تشکیل پایگاه داده مورد مطالعه، استفاده گردید.

ماتریس هم‌رخدادی یک تصویر با استفاده از شعاع d و زاویه θ تعریف می‌شود. معمولاً d را در محدوده ۱ و ۲ انتخاب می‌کنند. از آنجائیکه هر پیکسل دارای ۸ همسایه در θ برابر صفر، ۴۵، ۹۰، ۱۳۵، ۱۸۰، ۲۲۵، ۲۷۰ و ۳۱۵ درجه است، و همسایه در $\theta=0$ درجه و $\theta=180$ درجه برای تعریف ماتریس هم‌رخدادی مشابه است، بنابراین انتخاب زاویه ممکن است به ۴ پیکسل مجاور در θ برابر صفر، ۴۵، ۹۰ و ۱۳۵ درجه تنزل پیدا کند (افقی، مورب سمت راست، عمودی و قطر چپ). علاوه بر پارامترهای شعاع و زاویه مورد استفاده برای تعریف ماتریس هم‌رخدادی، پارامتر تعداد سطوح خاکستری نیز قابل تعریف است. که در این تحقیق برای تعریف ماتریس هم‌رخدادی، از فاصله شعاعی برابر ۱، با چهار زاویه صفر، ۴۵، ۹۰ و ۱۳۵ به همراه تعداد سطوح خاکستری ۲۵۶ استفاده گردید که برای هر زاویه، یک ماتریس جدید استخراج شد.

استخراج ویژگی‌های بافتی

پس از ایجاد ماتریس هم‌رخدادی، شاخص‌های انرژی، کنتراست، همبستگی و آنتروپی تعریف شده در جدول ۱ از روی این ماتریس محاسبه شدند. همانطور که در جدول ۱ نیز اشاره شده است، ویژگی‌های نامبرده شده براساس روابط تعریف شده، براساس آمار و احتمال وقوع هر سطح خاکستری در ماتریس هم‌رخدادی عمل می‌نمایند (Haralick et al., 1973).

بعنوان مثال دو شکل نشان داده شده در شکل ۴ دارای هیستوگرام یکسانی هستند. در حالی که توزیع سطوح خاکستری در دو شکل کاملاً متفاوت است.



شکل ۴- دو نوع توزیع سطوح خاکستری متفاوت با یک نمودار هیستوگرام

Haralick et al. (1973) برای بررسی ساختار بافت‌های مختلف، ویژگی‌هایی بر اساس ماتریس هم‌رخدادی پیشنهاد کرده‌اند که از موفق‌ترین روش‌های بررسی خواص بافت‌های مختلف است. در روش ماتریس هم‌رخداد سطح خاکستری، فرض می‌شود که اطلاعات تصویر بافت به وسیله یک ماتریس خاص ارائه می‌شود. این روش مبتنی بر دستکاری سطوح خاکستری از یک تصویر است. در این روش علاوه بر بررسی سطح خاکستری پیکسل مورد نظر، سطوح خاکستری پیکسل‌های همسایگی آن نیز مورد بررسی قرار می‌گیرد و با ایجاد یک ماتریس جدید از سطوح خاکستری همسایگی‌های پیکسل در زوایا و فواصل مختلف، اقدام به شناسایی و تعریف خصوصیات تصویر می‌شود. ماتریس هم‌رخدادی یک ماتریس مربعی است که اندازه آن برابر با تعداد سطوح خاکستری است (Renzetti, & Zortea, 2011).

جدول ۱- چهار ویژگی استخراج شده از ماتریس هم‌رخدادی نمونه‌ها	
ویژگی	رابطه
انرژی	$f_1 = \sum_i \sum_j p(i, j)^2$
کنتراست	$f_2 = \sum_{n=0}^{N_g-1} n^2 \left\{ \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i, j) \right\}, i - j = n$
همبستگی	$f_3 = \frac{\sum_i \sum_j (ij) p(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y}$
آنتروپی	$f_4 = - \sum_i \sum_j p(i, j) \log(p(i, j))$

ماتریس از ضرب تعداد نمونه در هر طبقه در تعداد طبقه‌ها بدست آمده است و تعداد ستون نیز از چهار ویژگی نامبرده شده در جدول ۱ در راستای ۴ زاویه همسایگی (صفر، ۴۵، ۹۰ و ۱۳۵ درجه) به دست آمده است.

مدل‌های طبقه‌بندی

مدل‌های مختلفی برای طبقه‌بندی نمونه‌های مختلف مورد

در این روابط، P نشان‌دهنده احتمال وقوع، μ میانگین نمونه، σ انحراف معیار، n و m تعداد سطر و ستون و g در روابط نشان‌دهنده تعداد سطح خاکستری^۱ هستند. پس از استخراج ویژگی‌های نامبرده شده در جدول ۱ از هر ماتریس، پایگاه داده‌ای به ابعاد ۷۵۰ ردیف در ۱۶ ستون تشکیل شد که بعنوان پایگاه داده تحقیق حاضر مورد استفاده قرار گرفت. تعداد ردیف‌های

نمودارهای توزیع فراوانی برای مدلسازی LDA از دو PC استفاده گردید. از هر طبقه، ۷۰ درصد نمونه‌ها بعنوان نمونه آموزشی، و ۳۰ درصد مابقی بعنوان نمونه آزمون مورد استفاده قرار گرفت. انتخاب نمونه‌های آموزشی و آزمون کاملاً بصورت تصادفی انجام پذیرفت.

اعتبارسنجی مدل‌ها و انتخاب بهترین مدل

مدل‌های طبقه‌بندی براساس نمونه‌های آموزشی واسنجی شده و با استفاده از روش Continues Block مورد اعتبارسنجی قرار گرفتند. مقایسه قسمت واسنجی و اعتبارسنجی براساس دقت تشخیص طبقه‌بندی انجام پذیرفت. در مرحله آزمون مدل‌ها، با تشکیل ماتریس اغتشاش اقدام به استخراج نرخ تشخیص طبقه مطلوب و نامطلوب، علاوه بر پارامتر صحت داده‌ها شد. حساسیت و ویژگی دو پارامتر اندازه‌گیری مهم برای بررسی مدل‌های طبقه‌بندی می‌باشند. نرخ تشخیص طبقه مطلوب طبقه I عبارتست از نسبتی از نمونه‌های طبقه I که به عنوان طبقه I طبقه‌بندی می‌شوند. نرخ تشخیص طبقه نامطلوب طبقه I نیز نسبتی از نمونه‌های طبقه II که به اشتباه به عنوان طبقه I طبقه‌بندی شده‌اند می‌باشد. مقادیر نرخ تشخیص طبقه مطلوب و نامطلوب طبقه‌ها و نرخ طبقه‌بندی صحیح طبق روابط ۱ الی ۳ قابل محاسبه می‌باشد (Karimi et al., 2017).

$$\text{نرخ تشخیص طبقه مطلوب} = \frac{TP}{TP + FN} \quad (\text{رابطه ۱})$$

$$\text{نرخ تشخیص طبقه نامطلوب} = \frac{TN}{TN + FP} \quad (\text{رابطه ۲})$$

$$\text{Correct Classification Rate (CCR)} = \frac{TP + TN}{TP + TN + FP + FN} \quad (\text{رابطه ۳})$$

که در این روابط TP، TN، FP و FN برای یک مدل کلاس بندی کننده دو کلاسه، بترتیب تعداد تشخیص صحیح کلاس I، تعداد تشخیص درست کلاس II، تعداد تشخیص نادرست کلاس I و تعداد تشخیص نادرست کلاس II می‌باشد.

نتایج و بحث

در قسمت بررسی نتایج، مدلسازی طبقه‌بندی برای دو حالت مورد ارزیابی قرار گرفت. حالت اول شامل طبقه‌بندی ۶ طبقه متفاوت تشکیل شده از گروه کشمش‌های خوب و بد می‌باشد که شامل طبقه‌های A الی F نمونه‌های تهیه شده می‌باشد. در این حالت، طبقه‌های انتخابی فاقد گروه چوب و خار و خاشاک بود. حالت

استفاده قرار گرفته است که این مدل‌ها، می‌توانند به طبقه‌بندی‌های بانظارت، بدون نظارت، خطی یا غیرخطی تقسیم بندی شوند. هدف استفاده از مدل‌های مختلف، آموزش مدل با تعداد نمونه مشخص و سپس آزمون مدل برای انتخاب بهترین مدل پیشگویی است تا بتواند بصورت یک ماشین خودکار اقدام به طبقه‌بندی نمونه‌ها نماید. در این تحقیق از مدل‌های طبقه‌بندی ماشین بردار پشتیبان (SVM) و تحلیل افتراقی خطی (LDA) استفاده گردید. ماشین بردار پشتیبان یکی از روش‌های یادگیری با نظارت است که از آن برای طبقه‌بندی و رگرسیون استفاده می‌شود. این روش از جمله روش‌های نسبتاً جدیدی است که در سال‌های اخیر کارآیی خوبی نسبت به روش‌های قدیمی‌تر برای طبقه‌بندی از جمله شبکه‌های عصبی مصنوعی نشان داده است. مبنای کاری دسته‌بندی کننده SVM دسته‌بندی خطی داده‌ها است و برای این منظور خطی را انتخاب می‌کند که حاشیه اطمینان بیشتری داشته باشد. حل معادله پیدا کردن خط بهینه برای داده‌ها به وسیله روش‌های Quadratic Programming (QP) که روش‌های شناخته شده‌ای در حل مسائل بهینه سازی مقید هستند صورت می‌گیرد. SVM از تکنیکی که kernel trick نامیده می‌شود، برای تبدیل داده‌ها استفاده می‌کند و سپس بر اساس این تبدیل، مرز بهینه بین خروجی‌های ممکن را پیدا می‌کند (Karimi et al., 2017). در این تحقیق طبقه بند SVM در دو حالت خطی^۱ و عملکرد پایه شعاعی^۲ مورد استفاده قرار گرفت. روش LDA نیز یک روش آماری است که با استفاده از تفکیک کننده مختلفی مانند خطی، درجه دوم^۳ و فاصله ماهالانوبیس^۴ اقدام به طبقه‌بندی نمونه‌ها می‌نماید. البته به منظور کاهش ابعاد ماتریس ورودی، ابتدا با استفاده از روش تحلیل مولفه‌های اصلی (PCA) اقدام به کاهش ابعاد شد. در مواردی که تعداد خصوصیات اندازه‌گیری شده برای هر نمونه مورد آزمایش بیش از اندازه باشد، با تحلیل مولفه‌های اصلی، به جای خصوصیات اندازه‌گیری شده، از مولفه‌هایی بنام مولفه‌های اصلی^۵ (PC) یا متغیرهای جانبی^۶ (LV) استفاده می‌گردد. در این تحلیل، با نگاشت فضای اصلی به فضای مولفه‌های اصلی، اقدام به رسم نمودار جدیدی از توزیع نمونه‌ها می‌شود که محور اولین PC، بیشترین توزیع فراوانی داده‌ها را به نمایش می‌گذارد. دومین PC در جایگاه بعدی برای نمایش توزیع فراوانی داده‌ها می‌باشد. با این تحلیل می‌توان با نگاشت داده‌های از فضای خصوصیات اندازه‌گیری شده به فضای مولفه‌های اصلی، نمودار توزیع داده‌ها را بررسی نمود. با بررسی

4. Mahalanobis
5. Principle Component
6. Latent Variable

1. Linear
2. Radial Basis Functions
3. Quadratic

مربوطه نیز می‌تواند از دلایل این نوع طبقه‌بندی باشد. در تحقیقی که به بررسی چندین نوع ماتریس متفاوت پرداخته شده است، دقت مدل SVM برای طبقه‌بندی کشمش خوب و بد، به طور میانگین ۸۸ درصد گزارش شده است که نتایج تحقیق حاضر را تایید می‌نماید (Karimi et al., 2017). دقت، نرخ تشخیص طبقه مطلوب و نامطلوب برای حالتی که ۵۰ درصد نمونه کشمش خوب و ۵۰ درصد آن کشمش بد بود، برابر ۱۰۰ درصد بدست آمد که بهترین حالت طبقه بند را نشان می‌دهد. نرخ تشخیص طبقه نامطلوب محاسبه شده برای طبقه‌های متفاوت نیز بالای ۹۳ درصد محاسبه شد که برای یک مدل طبقه‌بند نتیجه بسیار عالی را نشان می‌دهد.

در بررسی حالت دوم، یعنی طبقه‌بندی ۱۵ طبقه مختلف نمونه کشمش فله‌ای، نتایج متفاوت‌تری حاصل گردید. همانگونه که در جدول ۴ نیز نشان داده شده است، تنها مدل قابل اطمینان در این حالت، مدل SVM خطی با صحت و اسنجهی و اعتبارسنجی و اعتبارسنجی بترتیب ۷۲/۹۵ و ۶۶/۸۵ بوده است. علی‌رغم ضعیف بودن این نتایج نسبت به حالت اول، با توجه به طبقه بندی نمونه‌ها به ۱۵ طبقه مختلف و همین‌طور ترکیب آنها با چوب و خار و خاشاک، نتایج این مدل نیز می‌تواند جایگزین مناسبی برای افراد خیره در تعیین کیفیت کلی کشمش توده‌ای باشد. البته همانگونه که در جدول ۵ نیز مشخص است، اکثر نمونه‌هایی که در طبقه خود پیش بینی نشده‌اند، در طبقه کناری خود که ۱۰ درصد از نظر ترکیب کشمش خوب، بد و خار و خاشاک با هم اختلاف داشتند، قرار گرفته است. از جمله دلایل ضعیف بودن نتایج در حالت دوم، می‌توان به هم اندازه نبودن چوب و خار و خاشاک با کشمش‌های خوب و بد نیز اشاره کرد که علی‌رغم به هم زدن مناسب آنها حین تصویربرداری، ولی در برخی مواقع، تصویر گویای کامل توزیع گروه‌های مختلف محصول نبود. از طرف دیگر به دلیل شباهت رنگ چوب و خار و خاشاک به کشمش خوب، نتایج ضعیف‌تر حاصل گردیده است. براساس مدل SVM خطی، ماتریس اغتشاش پیشگویی مدل در جدول ۵ نشان داده شده است.

جدول ۴- نتایج و اسنجهی و اعتبارسنجی دو نوع طبقه‌بند LDA و SVM برای حالت دوم

مدل	صحت و اسنجهی	صحت اعتبارسنجی
LDA	خطی	۴۴/۷۶
	درجه دوم	۴۸/۷۶
	Mahalanobis	۴۶/۴۸
SVM	خطی	۷۲/۹۵
	عملکرد پایه شعاعی	۴۲/۷۶

دوم بررسی نتایج شامل تمامی طبقه‌های انتخابی بود که در ادامه نتایج هر دو حالت بررسی شده، ارائه می‌گردد. جدول ۲ نتایج و اسنجهی و اعتبارسنجی با استفاده از دو مدل SVM و LDA را برای بررسی ۶ طبقه حالت اول نشان می‌دهد. همانطور که در جدول نیز نشان داده شده است، هر ۵ حالت مدل‌های مورد بررسی دارای صحت قابل قبولی هم در مرحله و اسنجهی و هم در مرحله اعتبارسنجی بودند. اما از آنجائیکه صحت اعتبارسنجی، قابل اطمینان بودن مدل را بیان می‌نماید و از طرف دیگر با لحاظ نمودن صحت و اسنجهی مدل‌ها، بهترین مدل، مدل SVM خطی انتخاب شد. در ادامه بررسی مدل انتخابی، نمونه‌های آزمون ۶ طبقه اول جهت بررسی صحت و دقت پیشگویی مدل‌ها مورد بررسی قرار گرفتند. جدول ۳ ماتریس اغتشاش مدل SVM خطی برای آزمون را نمایش می‌دهد.

جدول ۲- نتایج و اسنجهی و اعتبارسنجی دو نوع طبقه‌بند LDA و SVM برای حالت اول

مدل	صحت و اسنجهی	صحت اعتبارسنجی
LDA	خطی	۸۶/۲۵
	درجه دوم	۸۶/۲۵
	ماهانوبیس	۸۵/۵۰
SVM	خطی	۸۴/۵۰
	عملکرد پایه شعاعی	۹۶/۶۷

جدول ۳- ماتریس اغتشاش آزمون مدل SVM خطی برای حالت اول

میانگین F	E	D	C	B	A	طبقه
۰	۰	۰	۰	۴	۱۱	A
۰	۰	۰	۰	۱۱	۴	B
۰	۰	۰	۱۵	۰	۰	C
۰	۲	۱۱	۱	۱	۰	D
۰	۱۴	۱	۰	۰	۰	E
۱۵	۰	۰	۰	۰	۰	F
۱۰۰	۹۲/۳۳	۷۲/۳۳	۱۰۰	۷۲/۳۳	۷۲/۳۳	نرخ تشخیص طبقه مطلوب
۱۰۰	۸۵/۸۳	۸۷/۵۰	۹۱/۶۷	۹۳/۷۵	۶۸/۷۵	دقت (TCR)
۱۰۰	۹۶/۸۹	۹۶/۱۰۰	۹۸/۶۶	۹۲/۳۳	۹۴/۶۷	نرخ تشخیص طبقه نامطلوب

همانگونه که در این جدول نیز مشخص است، صحت یا همان حساسیت کلی مدل برابر ۸۵/۵۵ درصد به دست آمده است که برای طبقه‌بندی محصولات کشاورزی قابل قبول و استناد می‌باشد. البته نتایج برای طبقه‌های A و B و D نسبت به دیگر طبقه‌ها ضعیف بود. اما همانطوریکه از ماتریس اغتشاش نیز مشخص است ۴ نمونه از طبقه A به عنوان طبقه B تشخیص داده شده است که با توجه به اینکه اختلاف این دو طبقه معادل با ۱۰ درصد کشمش‌های بد است و احتمال قرار گیری نمونه‌ها در داخل ظرف

جدول ۵- ماتریس اغتشاش آزمون مدل SVM خطی برای حالت دوم

طبقه	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	میانگین
A	۱۱	۴	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰
B	۴	۹	۰	۰	۰	۰	۰	۰	۰	۲	۰	۰	۰	۰	۰	۰
C	۰	۰	۱۴	۰	۰	۰	۰	۰	۰	۰	۱	۰	۰	۰	۰	۰
D	۰	۰	۱	۷	۴	۰	۰	۰	۰	۰	۳	۰	۰	۰	۰	۰
E	۰	۰	۰	۰	۱۵	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰
F	۰	۰	۰	۰	۰	۱۴	۰	۰	۰	۰	۱	۰	۰	۰	۰	۰
G	۰	۰	۰	۰	۰	۰	۱۲	۲	۰	۰	۰	۰	۰	۰	۰	۰
H	۰	۰	۰	۰	۰	۰	۲	۱۲	۰	۰	۰	۰	۱	۰	۰	۰
I	۰	۰	۰	۰	۰	۰	۰	۴	۴	۰	۰	۰	۲	۵	۰	۰
J	۱	۰	۰	۰	۰	۰	۰	۰	۰	۱۲	۲	۰	۰	۰	۰	۰
K	۰	۰	۰	۰	۰	۰	۰	۰	۰	۲	۵	۷	۰	۰	۰	۰
L	۰	۰	۰	۱	۰	۱	۰	۰	۰	۱	۲	۱۰	۰	۰	۰	۰
M	۰	۰	۰	۰	۰	۰	۰	۲	۱	۰	۰	۰	۷	۴	۱	۰
N	۰	۰	۰	۰	۰	۴	۰	۱	۱	۰	۰	۰	۵	۲	۱	۰
O	۰	۰	۰	۰	۱	۲	۰	۰	۴	۰	۰	۰	۰	۰	۸	۰
طبقه تشخیص طبقه مطلوب	۷۳/۳۳	۶۰	۹۳/۳۳	۴۶/۶۷	۱۰۰	۹۳/۳۳	۸۰	۸۰	۲۶/۶۷	۸۰	۳۳/۳۳	۶۷/۶۷	۴۶/۶۷	۲۰	۵۳/۳۳	۶۳/۵۵
دقت TCR	۶۸/۷۵	۶۹/۳۳	۹۳/۳۳	۸۷/۵	۷۵	۶۶/۶۷	۸۵/۷۱	۵۴/۵۴	۴۰	۷۵	۴۱/۶۷	۵۵/۵۵	۴۶/۶۷	۲۵	۸۰	۶۱/۳۱
طبقه نا تشخیص طبقه مطلوب	۹۱/۱۱	۹۱/۵۵	۹۳/۷۱	۹۳/۸۹	۹۱/۱۱	۹۰/۳۲	۹۲/۴۴	۸۸/۷۸	۹۰/۶۷	۹۰/۶۷	۹۰/۳۲	۸۹/۳۳	۸۹/۷۱	۸۹/۳۳	۹۲/۴۴	۹۰/۹۰

از چالش‌های بزرگ مابین کشاورزان و صاحبان کارخانه فرآوری مطرح بوده است. بدین منظور با استفاده از قابلیت ماتریس هم-رخدادی سطح خاکستری اقدام به ایجاد ماتریس‌های جدید جهت استخراج ویژگی‌های بافت تصویری شد. نتایج نشان داد زمانیکه از این روش برای تشخیص طبقه‌های تشکیل شده از کشمش و خوب استفاده می‌گردد، نتایج قابل قبول و اطمینانی حاصل می‌شود. اما زمانیکه طبقه‌های مورد نظر شامل ترکیبی از کشمش خوب و بد و خار و خاشاک است، نتایج پیشگویی ضعیفتر از حالت اولیه است و در تشخیص برخی از طبقه‌ها کاملاً ناتوان عمل می‌نماید. پیشنهاد می‌شود، به منظور افزایش دقت طبقه‌بندی در حالت دوم، ابتدا با استفاده از الگوریتم‌هایی مانند تبدیل موجک، خار و خاشاک موجود در تصویر حذف شده و سپس از روی تصویر باقیمانده اقدام به طبقه‌بندی طبقه‌های موجود نمود.

سپاسگزاری

نویسنده مقاله، نهایت تقدیر و تشکر خود را از مدیریت پژوهشی دانشگاه بناب، به دلیل حمایت‌های مالی و علمی طی قرارداد پژوهشی شماره ۱۹۱۴/آپ/د/۹۶ اعلام می‌دارد.

همان‌طور که در جدول ۵ نشان داده شده است، مدل SVM خطی قابلیت پیشگویی طبقه‌های D, I, M و N را نداشته و نتایج ضعیفی حاصل شده است. ولی در بقیه طبقه‌ها دقت پیشگویی بالاتر از ۵۰ درصد بوده است بطوریکه میانگین صحت طبقه‌بند ۶۳/۵۵ درصد حاصل گردیده است.

نتایج تحقیق نشان می‌دهد که استفاده از ماتریس هم-رخدادی سطح خاکستری، برای تشخیص طبقه‌های کشمش خوب و بد با دقت قابل قبولی می‌تواند مورد استفاده قرار گیرد. ولی استفاده از ماتریس GLCM به همراه مدل SVM خطی نتایج نسبتاً ضعیفی از خود نشان داد بطوریکه در ۴ طبقه از ۱۵ طبقه تشکیل شده مدل پیشگویی ناتوان بود.

نتیجه‌گیری کلی

کشمش یکی از مهمترین محصولات کشاورزی صادراتی ایران است که هر ساله ارزش زیادی را به همراه دارد. محصول کشمش بعد از تولید توسط کشاورز، جهت انجام عمل شستشو، درجه‌بندی و بسته‌بندی آن به کارخانه فرآوری انتقال داده می‌شود. قیمت‌گذاری محصول توده‌ای کشمش همیشه بعنوان یکی

REFERENCES

- 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.
- Agricultural Statistics. (2017). Ministry of Agriculture, Deputy Director of Economic and Planning, ICT Center. Retrieved December 20, 2018, from <https://usda.library.cornell.edu>.
- Bai, X., Cao, Z., Wang, Y., Yu, Z., Zhang, X. & Li, C. (2013). Crop segmentation from images by morphology modeling in the CIE L* a* b* color space. *Computers and Electronics in Agriculture*, 99, 21-34.
- Cabras, P., Angioni, A., Garau, V. L., Minelli, E. V., Cabitza, F. & Cubeddu M. (1997). Residues of some pesticides in fresh and dried apricots. *Journal of Agricultural and Food Chemistry*, 45, 3221-3222
- Chowdhury, S., Verma, B. & Stockwell, D. (2015). A novel texture feature based multiple classifier technique for roadside vegetation classification. *Expert Systems with Applications*, 42 (12), 5047-5055.
- Ebrahimi, E., Mollazade, K. & Babaei, S. (2014). Toward an automatic wheat purity measuring device: A machine vision-based neural networks-assisted imperialist competitive algorithm approach. *Measurement*, 55, 196-205.
- Esmailia, M., Sotudeh-Gharebaghb, R., Croninc, K., Mousavia, M.A.E. & Rezazadehd, G. (2007). Grape Drying: A Review. *Food Reviews International*, 23 (3), 257-280.
- Gardé-Cerdán, T., Arias-Gil, M., Marsellés-Fontanet, A.R., Ancín-Azpilicueta, C. & Martín-Belloso, O. (2007). Effects of thermal and non-thermal processing treatments on fatty acids and free amino acids of grape juice. *Food Control*, 18, 473-479.
- Ghrai F., Lahouar L., Amira A., Brahmi F., Ferchichi A., Achour L. & Said S. (2013). Physicochemical composition of different varieties of raisins (*Vitis vinifera* L.) from Tunisia. *Industrial Crops and Products*, 43, 73-77.
- Guanjun, B., Mimi, J., Yi, X., Shibo, C., & Qinghua, Y. (2019). Cracked egg recognition based on machine vision. *Computers and Electronics in Agriculture*, 158, 159-166.
- Guevara-Hernandez, F. & Gomez-Gil, J. (2011). A machine vision system for classification of wheat and barley grain kernels. *Spanish Journal of Agricultural Research*, 9 (3), 672-680.
- Gurak, P.D., Cabral, L.M.C., Rocha-Leão, M.H.M., Matta, V.M. & Freitas. S.P. (2010). Quality evaluation of grape juice concentrated by reverse osmosis. *Journal of Food Engineering*, 96, 421-426.
- Haralick, R. M., Shanmugam, K. & Dinstein, I. H. (1973). Textural features for image classification. *Systems, Man and Cybernetics. IEEE Transactions on*, 6, 610-621.
- Jairaj, K.S., Singh, S.P. & Srikanth, K.A. (2009). Review of solar dryers developed for grape drying. *Solar Energy*, 83, 1698-1712.
- Jiang, G., Wang, X., Wang, Z. & Liu, H. (2016). Wheat rows detection at the early growth stage based on Hough transform and vanishing point. *Computers and Electronics in Agriculture*, 123, 211-223.
- Karimi, N., Kondrood, R. R. & Alizadeh, T. (2017). An intelligent system for quality measurement of Golden Bleached raisins using two comparative machine learning algorithms. *Measurement*, 107, 68-76.
- Liming, X. & Yanchao, Z. (2010). Automated strawberry grading system based on image processing. *Computers and Electronics in Agriculture*, 71, S32-S39.
- Mokhtar, U., El Bendary, N., Hassenian, A.E., Emary, E., Mahmoud, M.A., Hefny, H. & Tolba, M.F. (2015). SVM-based detection of tomato leaves diseases. In: *Intelligent Systems' 2014*. Springer, Cham, pp. 641-652.
- Okamura, N. K., Delwiche, M. J. & Thompson, J. F. (1993). Raisin grading by machine vision. *Transactions of the ASAE (USA)*.
- Olgun, M., Onarcan, A.O., Özkan, K., Işık, Ş., Sezer, O., Özgişi, K. & Koyuncu, O. (2016). Wheat grain classification by using dense SIFT features with SVM classifier. *Computers and Electronics in Agriculture*, 122, 185-190.
- Pangavhane, D.R. & Sawhney, R.L. (2002). Review of research and development work on solar dryers for grape drying. *Energy Conversion and Management*, 43, 45-61.
- Pham, V.H. & Lee, B.R. (2015). An image segmentation approach for fruit defect detection using k-means clustering and graph-based algorithm. *Vietnam Journal of Computer Science*, 2 (1), 25-33.
- Rehman, T. U., Zaman, Q. U., Chang, Y. K., Schumann, A. W., & Corscadden, K. W. (2019). Development and field evaluation of a machine vision based in-season weed detection system for wild blueberry. *Computers and Electronics in Agriculture*, 162, 1-13.
- Renzetti, F. R. & Zortea, L. (2011). Use of a gray level co-occurrence matrix to characterize duplex stainless steel phases microstructure. *Frattura ed Integrità Strutturale*, 16(1), 43-51.
- Su, Q., Kondo, N., Li, M., Sun, H., Al Riza, D. F., & Habaragamuwa, H. (2018). Potato quality grading based on machine vision and 3D shape analysis. *Computers and electronics in agriculture*, 152, 261-268.
- Sun, Y., Gu, X., Sun, K., Hu, H., Xu, M., Wang, Z. & Pan, L. (2017). Hyperspectral reflectance imaging combined with chemometrics and successive projections algorithm for chilling injury classification in peaches. *LWT- Food Science and Technology*

- Technology*, 75, 557–564.
- Unay, D., Gosselin, B., Kleynen, O., Leemans, V., Destain, M. & Debeir, O. (2011). Automatic grading of bi-colored apples by multispectral machine vision. *Computers and Electronics in Agriculture*, 75 (1), 204–212
- Veernagouda Ganganagowder, N. & Kamath, P. (2017). Intelligent classification models for food products basis on morphological, colour and texture features. *Acta Agronómica*, 66 (4).
- Wang, A., Zhang, W., & 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.
- Yimyam, P. & Clark, A.F. (2016). 3D reconstruction and feature extraction for agricultural produce grading. In: *Paper Presented at the Knowledge and Smart Technology (KST), 2016 8th International Conference on*, pp. 136–141.
- 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.