



طبقه بندی میوه پایا بر مبنای رسیدگی، با استفاده از یادگیری ماشین و رویکرد یادگیری انتقالی

محمد قربانی^۱، مصطفی قاضی‌زاده احسانی^{۲*}، کاظم جعفری نعیمی^۳

۱- دانشجوی دکتری مکانیک بیوسیستم، دانشکده کشاورزی، دانشگاه شهید باهنر کرمان، کرمان، ایران

۲- استادیار گروه مهندسی کامپیوتر، دانشکده فنی مهندسی، دانشگاه شهید باهنر کرمان، کرمان، ایران

۳- دانشیار گروه مهندسی مکانیک بیوسیستم، دانشکده کشاورزی، دانشگاه شهید باهنر کرمان، کرمان، ایران

* ایمیل نویسنده مسئول: mghazizadeh@uk.ac.ir

(تاریخ دریافت: ۱۴۰۲/۱۰/۴ - تاریخ پذیرش: ۱۴۰۲/۱۲/۲۹)

چکیده

درجه بندی و بسته بندی میوه‌ها بر اساس بازرسی‌های بصری می‌تواند زمان بر، مخرب و غیر قابل اطمینان باشد. هدف از پژوهش انجام شده ارائه یک روش طبقه‌بندی هوشمند، سریع و قابل اطمینان جهت تشخیص میزان رسیدگی میوه پایا در سه سطح نارس، نیمه رسیده و رسیده می‌باشد. تعداد کل تصاویر مورد استفاده در این مقاله ۳۰۰ تصویر می‌باشد که برای هر کدام از سطوح تعداد ۱۰۰ تصویر جمع‌آوری گردیده است. در این پژوهش استفاده از دو رویکرد یادگیری ماشین و یادگیری انتقالی برای طبقه بندی وضعیت میزان رسیدگی میوه پایا پیشنهاد شده است. رویکرد یادگیری ماشین شامل استفاده از سه توصیف گر ویژگی و سه طبقه بندی کننده مختلف می‌باشد که عبارت اند از: الگوریتم دو دویی محلی (LBP)، ماتریس هم رخداد سطح خاکستری (GLCM)، هیستوگرام گرادیان‌های جهت دار (HOG)، الگوریتم طبقه بندی-k نزدیک ترین همسایه (KNN)، ماشین بردار پشتیبان (SVM)، و الگوریتم طبقه بندی کننده بیزی ساده (Naïve Bayes). روش‌های یادگیری انتقالی شامل استفاده از شش مدل یادگیری عمیق از پیش آموزش داده شده Alexnet, VGG19, Resnet18, Resnet50, Resnet101, Googlenet می‌باشد. طبقه بندی کننده KNN با استفاده از توصیف گر ویژگی HOG توانسته است به صحت ۹۵/۴ درصد و زمان آموزش ۳:۵۲ ثانیه دست پیدا کند. طبقه بندی کننده مبتنی بر رویکرد یادگیری انتقالی VGG19 با بدست آوردن صحت ۱۰۰ درصدی و زمان آموزش ۱۰:۴۲ ثانیه توانست عملکرد بهتری را در میان سایر شبکه‌های یادگیری عمیق ثبت کند. دو روش طبقه بندی با استفاده از روش‌های یادگیری ماشین و یادگیری انتقالی توانسته‌اند هر کدام صحت ۹۵/۴ و ۱۰۰ درصدی را بدست بیاورند که به ترتیب ۷/۰ و ۶ درصد بیشتر از روش‌های پیشنهادی موجود می‌باشد.

واژه‌های کلیدی: گل محمدی، برداشت مکانیزه، دستگاه قابل حمل، سوخت مصرفی، زمان برداشت

مقدمه

بازارپسند متحمل خسارت می شوند (Khodaei *et al.*, 2018). برای درجه بندی میوه‌ها روش‌های گوناگونی وجود دارد. روش‌های دستی و مکانیکی با توجه با آسیب‌هایی مانند لهیدگی که به میوه وارد می‌کنند کمتر مورد توجه هستند. درحالی‌که روش‌های غیرمخرب به دلیل دخالت کمتر توسط انسان و پایین‌تر بودن هزینه‌ها، راحت‌تر و با صرفه‌تر بوده و در حال حاضر بدلیل کاهش صدمات وارده به محصول مورد توجه هستند (Baigvand *et al.*, 2015). بینایی ماشین یکی از روش‌های نوین و غیرمخربی است که برای درجه بندی میوه‌ها براساس خصوصیات ظاهری مورد توجه قرار گرفته است (Mohammadi *et al.*, 2015). در حوزه کشاورزی مطالعات زیادی در زمینه درجه بندی و طبقه بندی محصولات به کمک پردازش تصویر گزارش شده است (Kheiralipour, Wang, Farokhzad *et al.*, 2020; Wang, Farokhzad *et al.*, 2020; Wang, Farokhzad *et al.*, 2020). ویژگی‌های ظاهری و بصری محصولات کشاورزی مانند رنگ، اندازه، شکل و بافت در ارزیابی کیفیت محصولات بسیار تاثیرگذار هستند. بنابراین توسعه و طراحی یک سامانه هوشمند برای درجه بندی محصولات به ویژگی‌های اشاره شده بستگی دارد (Azadnia *et al.*, 2022). در سال‌های اخیر تعدادی از محققان مطالعاتی را بر روی پیش‌بینی میزان رسیدگی میوه‌های مختلف انجام دادند. یک مدل فازی برای طبقه‌بندی سطوح متفاوت رسیدگی میوه آناناس پیشنهاد شده است.

پاپایا (*Carica papaya*) میوه‌ای با ارزش غذایی بالا و منبع غنی برای ویتامین‌های A و C می‌باشد (Pereira *et al.*, 2018). میوه پاپایا مخصوص مناطق گرمسیری است و در جنوب و جنوب شرقی ایران کشت می‌شود (sbaj.ir). استان سیستان و بلوچستان با سطح زیر کشت ۵۰ هکتار بزرگترین تولیدکننده میوه پاپایا در کشور ایران به شمار می‌رود (sbaj.ir). طبقه‌بندی میوه‌ها و ارزیابی کیفیت آن‌ها با استفاده از بازرسی‌های بصری باعث بروز خطا به دلیل وجود تأثیرات خارجی مانند خستگی، تعصبات و پیش‌داوری‌های شخصی و غلط می‌شود (Savakar *et al.*, 2015). با وجود اپراتورهای حرفه‌ای و افراد خبره و صاحب نظر، طبقه بندی میوه‌ها در صنعت میوه بدلیل وجود تفاوت در ادراکات بصری منجر به وجود تفاوت‌ها و تناقضاتی می‌شود. از این رو یک سیستم خودکار برای تجزیه و تحلیل میوه‌ها و ارائه اطلاعات قابل اعتماد تر مورد نیاز است (Damez *et al.*, 2008). کیفیت مصرف میوه‌ها و تعیین زمان نگهداری آن‌ها قبل از مصرف به میزان زیادی به شناسایی میزان رسیدگی آن‌ها وابسته است (Magwaza *et al.*, 2015). تعیین این خواص به کمک کارشناسان انسانی زمان‌بر و مخرب خواهد بود، بنابراین تکنیک‌هایی سریع، هوشمند و غیرمخرب در این حوزه‌ی کاربردی مورد نیاز است (Medina *et al.*, 2014). امروزه بسیاری از تولیدکنندگان داخلی به دلیل عدم توانایی در عرضه محصول خود به نحو

از یک نوار نقاله که میوه‌های انبه بر روی آن در حال حرکت کردن هستند فیلم برداری می‌کند، سپس تعداد ۲۷ ویژگی از فریم سیگنال‌های ویدیویی جمع‌آوری شده استخراج می‌شود. این محققان در پژوهش خود از تکنیک حذف ویژگی‌های اضافی و طبقه‌بندی‌کننده ماشین بردار پشتیبان برای اهداف طبقه‌بندی استفاده کرده‌اند. در این سیستم تعداد ۱۶۴۰۰ تصویر مورد ارزیابی قرار گرفت که محققین توانسته‌اند به صحت ۹۶ درصد دست پیدا کنند (Nandi *et al.*, 2014). یک مدل دیگر که براساس تصویربرداری چندطیفی بیان گردیده به منظور ارزیابی کیفیت و طبقه‌بندی میزان رسیدگی میوه‌های توت‌فرنگی پیشنهاد شده است. در پژوهش آن‌ها از دو روش تجزیه و تحلیل مولفه اصلی با شبکه عصبی پس‌انتشار و الگوریتم طبقه‌بندی ماشین بردار پشتیبان استفاده شده است. نتایج ارزیابی‌ها نشان می‌دهند که محققین توانسته‌اند به کمک طبقه‌بندی‌کننده ماشین بردار پشتیبان به صحت ۱۰۰ درصد دست یابند، این صحت بدست آمده برای مرحله رسیدگی میوه توت‌فرنگی بوده و از مجموعه‌ای از داده‌ها که شامل ۲۸۰ تصویر می‌باشد بدست آمده است (Liu *et al.*, 2014). یک سیستم حسگر غیرمخرب و غیرتهاجمی برای پیش‌بینی میزان رسیدگی میوه دورین پیشنهاد شده است، در این روش از مفهوم ارتباط بی‌سیم با ضریب Rician k-factor برای پیش‌بینی میزان رسیدگی میوه دورین استفاده شده است، محققان در این روش توانسته بودند به صحت ۹۲/۷ درصد دست

در این تحقیق ویژگی‌های مورد نظر از کانال‌های رنگی hue و فضای رنگی lab استخراج شده‌اند و مجدداً از بهینه‌سازی‌های ازدحام ذرات برای بهینه‌سازی مدل فازی استفاده شده و در نتایج خود به صحت ۹۳/۱۱ درصد دست یافته‌اند (Marimuthu *et al.*, 2017). در تحقیقی دیگر به منظور طبقه‌بندی میزان رسیدگی میوه موز در سه سطح، از دو الگوریتم خودکار یعنی شدت رنگ متوسط و الگوریتم استخراج ویژگی‌های محلی استفاده شده است. به منظور استخراج ویژگی‌ها از توصیف-گرهای ویژگی مانند ماتریس هم-رخداد سطح خاکستری (GLCM) و ویژگی‌های هندسی به منظور طبقه‌بندی استفاده شده است. الگوریتم‌ها با تعداد ۱۲۰ تصویر از میوه‌های موز که شامل ۴۰ تصویر از میوه‌های نارس، ۴۰ تصویر از میوه‌های رسیده و ۴۰ تصویر هم از میوه‌های کاملاً رسیده است مورد بررسی قرار گرفتند. تجزیه و تحلیل‌ها نشان می‌دهند که ویژگی‌های میانگین رنگ و مساحت سطح میوه موز سهم اصلی را در این پژوهش تشکیل می‌دهند. الگوریتم شدت رنگ به کار گرفته شده توانسته است سه مرحله رسیدگی میوه موز را با صحت ۹۹/۱ درصد طبقه‌بندی کند، همچنین دلیل ناکارآمدی الگوریتم استخراج ویژگی محلی ناتوانی در طبقه‌بندی میوه‌های موز رسیده و بیش از حد رسیده گزارش شده است (Prabha *et al.*, 2015). سیستم دیگری برای طبقه‌بندی میوه‌های انبه بر اساس میزان رسیدگی آن‌ها به چهار دسته طراحی شده است. در این سیستم یک دوربین

(2018) آن ها انجام گرفته است. که نشان از توانایی بالای تکنیک های عنوان شده می باشد. در ادبیات پیشین پژوهشی (Pereira et al., 2018) تنها یک مورد پیش بینی میزان رسیدگی میوه پاپایا بر اساس تکنیک پردازش تصویر با استفاده از الگوریتم طبقه بندی کننده جنگل تصادفی انجام شده است. در پژوهش انجام گرفته شده توسط آن محققین از ۱۱۴ نمونه میوه پاپایا و تصاویر تهیه شده از میوه ها استفاده شده است. ۲۱ ویژگی از تصاویر پاپایا به صورت دستی استخراج شده و الگوریتم طبقه بندی کننده توانسته بود میزان رسیدگی میوه پاپایا را بر اساس سه سطح رسیدگی با صحت ۹۴/۷ درصد طبقه بندی کند. در این پژوهش یک مدل طبقه بندی کننده به منظور طبقه بندی میزان رسیدگی میوه پاپایا در سه سطح یعنی نارس، نیمه رسیده و رسیده با استفاده از الگوریتم یادگیری ماشین و رویکرد یادگیری انتقالی پیشنهاد شده است. رویکرد یادگیری ماشین شامل استفاده از سه مجموعه توصیفگر ویژگی و سه مدل طبقه بندی کننده می باشد، همچنین در رویکرد یادگیری انتقالی از شش مدل یادگیری عمیق از پیش آموزش داده شده استفاده شده است.


مواد و روش ها

طبقه بندی سطوح رسیدگی یا میزان رسیدگی میوه پاپایا در دو رویکرد، یعنی یادگیری ماشین و یادگیری انتقالی انجام می گیرد. مراحل مختلف رسیدگی میوه بر اساس جنبه های بصری رنگ میوه تعریف می شود. این جنبه های بصری و مراحل

پیدا کنند (Leekl et al., 2016). در یک پژوهش دیگر مدل طبقه بندی کننده ای به منظور بررسی میزان رسیدگی میوه آلو بر اساس تکنیک پردازش تصویر پیشنهاد شده است، به منظور ارزیابی میزان رسیدگی میوه آلو از ویژگی های کیفی خارجی مانند رنگ، بافت، و اندازه استفاده شده است. علاوه بر این تجزیه و تحلیل آزمایش ها نشان می دهد که ویژگی های رنگی (شاخص های استخراجی با استفاده از کانال های رنگی rgb) ویژگی های برجسته تری نسبت به ویژگی های بافت و اندازه هستند. نتایج آزمایش از آنالیز تصاویر صحت ۹۹/۶۶ درصد را در پژوهش هایشان گزارش داده است (Kaur et al., 2018). در دهه های گذشته فعالیت ها و پژوهش های زیادی در مورد جنبه های گوناگون صنعت میوه مانند تشخیص عیوب (Devi et al., 2013) ارزیابی کیفیت میوه ها (Jadhav et al., 2012; Patel et al., 2013) درجه بندی (Alohali, 2011) و پیش بینی حجم و وزن میوه ها (Omid et al., 2010) گزارش شده و انجام شده است. برای اهدافی مانند طبقه بندی میوه ها بینایی کامپیوتر (Zhang et al., 2014; zhang et al., 2012) پردازش تصویر (Dubey et al., 2015) و تکنیک هایی مانند یادگیری عمیق (Sharma et al., 2019) Ji et al., 2019; Guo et al., 2019; Asad et al., 2019) و یادگیری ماشین (Behera et al., 2018) Huang et al., 2018) به طور گسترده استفاده می شود، علاوه بر این در یکی دو سال گذشته تحقیقاتی به منظور تشخیص میوه ها بر روی درختان (Rocha et al., 2010) طبقه بندی و درجه بندی (Kavdir et al., 2004; Alohali et al., 2011; Gongal et al.,

مختلف رسیدگی آن در شکل (۱) و جدول (۱) آورده شده است.
جدول ۱- ویژگی های بصری میوه پاپایا در مراحل مختلف رسیدگی

مراحل رسیدگی	توضیحات
ناررسیده	پوست میوه کاملاً سبز بوده و فاقد هرگونه رنگ زرد یا نارنجی می باشد.
نیمه رسیده	پوست میوه ها دارای نواحی سبز رنگ، زرد رنگ و نارنجی رنگ که نشانه هایی از رسیدگی میوه می باشند است.
رسیده	پوست میوه کاملاً دارای نواحی زرد یا نارنجی روشن بوده و ممکن است دارای نواحی سبز رنگ باشد یا نباشد.



شکل ۱- مراحل مختلف رسیدگی میوه پاپایا الف: پاپایا رسیده ب: پاپایا نیمه رسیده ج: پاپایا نارس

یاهو و بینگ جمع‌آوری گردیده است. تصاویر میوه پاپایا بر اساس ویژگی‌های بصری توضیح داده شده در جدول (۱) به سه سطح نارسیده، نیمه رسیده و رسیده طبقه بندی می‌شوند. همه نمونه‌ها با سطوح متفاوت مقطع عرضی و طولی تصویربرداری شده و جمع‌آوری شده اند. تعداد کل تصاویر مورد استفاده در این پژوهش ۳۰۰ تصویر بوده که برای هرکدام از سطوح متفاوت رسیدگی ۱۰۰ تصویر تهیه شده است. همه تصاویر پس از جمع‌آوری به اندازه ۲۲۷×۲۲۷×۳ تغییر اندازه داده شده اند و بدون هیچ گونه تغییری در فضای رنگی، به فرمت jpg و در فضای رنگی RGB ذخیره شده اند.

جزئیات جمع‌آوری نمونه‌ها و مدل‌های طبقه بندی کننده در دو رویکرد پیشنهادی در بخش‌های فرعی مناسب به طور کامل شرح داده شده اند.

جمع‌آوری داده‌ها

به منظور ارزیابی بهتر سامانه و هم‌چنین دسترسی نداشتن به مزارع کشت محصول پاپایا و زمان بردن تصویربرداری از مراحل مختلف رسیدگی میوه در فصل‌های مختلف سال لازم دانسته شد که از تصاویر تهیه شده توسط سایر محققین که مورد تایید نیز می‌باشند، استفاده شود. بنابراین تصاویر مورد نیاز برای پردازش از پایگاه داده Data.mendly.com و موتورهای جستجوی گوگل،

توصیف گر برای مناطق مختلفی از تصویر هیستوگرام‌هایی را با استفاده از اندازه جهت گرایان ایجاد می کند (Dalal et al., 2005). ماتریس الگوریتم دودویی محلی تنها از یک جهت برای محاسبه گرایان‌های اطراف یک پیکسل مورد نظر استفاده می کند. این توصیف گر بر روی ساختار محلی همسایگی یک پیکسل تمرکز کرده و با استفاده از آستانه گذاری پیکسل های همسایه نسبت به پیکسل مرکزی آن را به صفر و یک تبدیل می کند. سپس کد دودویی اختصاص یافته به همسایگی ها را به عدد صحیح تبدیل کرده و الگوی دودویی محلی را بدست می آورد (Ojala et al., 2002). ماتریس هم رخداد سطح خاکستری یک روش آماری برای توصیف بافت تصاویر می باشد. این ماتریس میزان احتمال مشترک وقوع دو سطح رنگ مختلف را در یک فاصله و زاویه مشخص در تصاویر سطح خاکستری نشان می-دهد (Haralick et al., 1973). برای استخراج ویژگی‌هایی مانند: کنتراست، همبستگی، انرژی، همگنی، میانگین، انحراف معیار، آنتروپی و واریانس از این ماتریس استفاده شده که روابط هر کدام از آنها در جدول (۲) آورده شده است.

تقسیم بندی تصاویر به منظور استفاده در فرآیندهای آموزش، آزمایش و اعتبارسنجی به ترتیب ۷۰، ۲۰ و ۱۰ درصد کل نمونه ها در نظر گرفته شده است.

رویکرد یادگیری ماشین

رویکرد یادگیری ماشین شامل دو مرحله است. یک مرحله شامل استخراج ویژگی و مرحله دیگر طبقه بندی تصاویر می باشد. ویژگی های مورد نظر که بیشتر مربوط به جنبه‌های بافتی تصاویر هستند با استفاده از توصیف گرهای ویژگی هیستوگرام گرایان های جهت دار، ماتریس هم رخداد سطح خاکستری و الگوریتم دودویی محلی از تصاویر نمونه استخراج می شوند. هر کدام از این توصیف گرهای ویژگی به ترتیب ۵۹، ۱۳ و ۳۷ ویژگی بافتی را از تصاویر استخراج کرده و به صورت یک بردار 1×59 ، 1×13 و 1×37 خروجی می دهند. توصیف گرهای ویژگی هیستوگرام گرایان‌های جهت دار و الگوریتم دودویی محلی تلاش می کنند که از یک نوع اطلاعات برای استخراج ویژگی استفاده کنند و آن هم محاسبه گرایان‌های اطراف یک پیکسل مورد نظر است. تفاوت اصلی این دو توصیف گر نیز در نحوی استفاده از همین گرایان‌های استخراج شده است (Aggarwal, 2018).

استخراج ویژگی

توصیف گر ویژگی هیستوگرام گرایان های جهت دار بر روی ساختار یا شکل یک شی تمرکز می کند، این توصیف گر از هر نوع توصیف گر لبه ای بهتر عمل می کند زیرا از اندازه و زاویه گرایان ها برای محاسبه ویژگی ها استفاده می کند. این

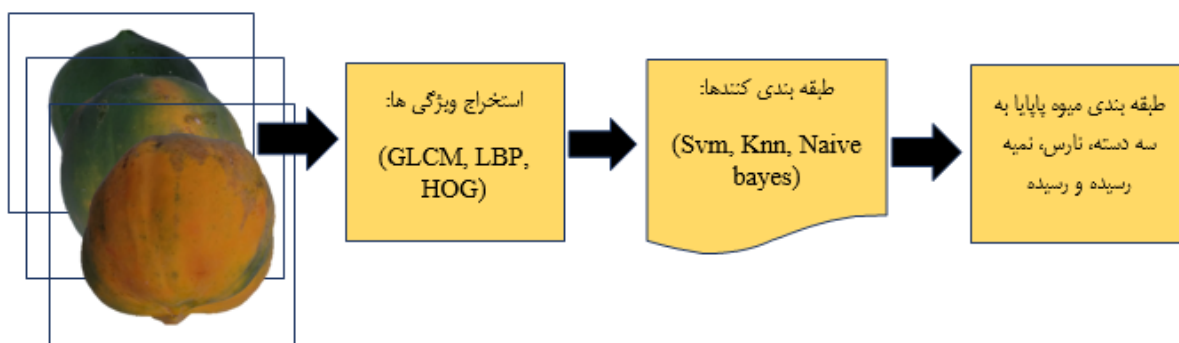
جدول ۲- ویژگی های استخراج شده از ماتریس هم رخداد سطح خاکستری

رابطه	ویژگی
$\sum_{i,j=1}^n (i-j)^2 p(i,j)$	کنتراست Haralick et al .,1973
$\sum_{i,j=1}^n \frac{(i-\mu_i)(j-\mu_j)p(i,j)}{\sigma_i\sigma_j}$	همبستگی Haralick et al .,1973
$\sum_{i,j=1}^n p(i,j)^2$	انرژی Haralick et al .,1973
$\sum_{i,j=1}^n \frac{p(i,j)}{1+(i-j)}$	همگنی Haralick et al .,1973
$\frac{1}{n} \left(\sum_{i=1}^n x_i \right)$	میانگین Haralick et al .,1973
$\sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \mu_i)^2}$	انحراف معیار Haralick et al .,1973
$\sum_{i,j=1}^n p_{i,j} \log_2 p_{i,j}$	آنترپی Haralick et al .,1973
$\frac{1}{n} \sum_{i=1}^n (x_i - \mu_i)^2$	واریانس Haralick et al .,1973

μ_i, μ_j و σ_i, σ_j به ترتیب میانگین سطری و ستونی ماتریس GLCM، μ_i و μ_j به ترتیب میانگین سطر و ستون ماتریس GLCM، $\sigma_i \neq 0$ و $\sigma_j \neq 0$ به ترتیب انحراف معیار سطری و ستونی ماتریس GLCM، x_i - شدت پیکسل های موجود در منطقه مورد نظر

بندی کننده ماشین بردار پشتیبان، k -نزدیک ترین همسایه و طبقه بندی کننده بیزی ساده استفاده شده است. مراحل مختلف رویکرد یادگیری ماشین در شکل (۲) نشان داده شده است

طبقه بندی کننده ها از این ویژگی های استخراج شده برای اهداف آموزشی و آزمایشی استفاده می کنند. همان طور که قبلا عنوان شده است در پژوهش انجام شده از سه طبقه-

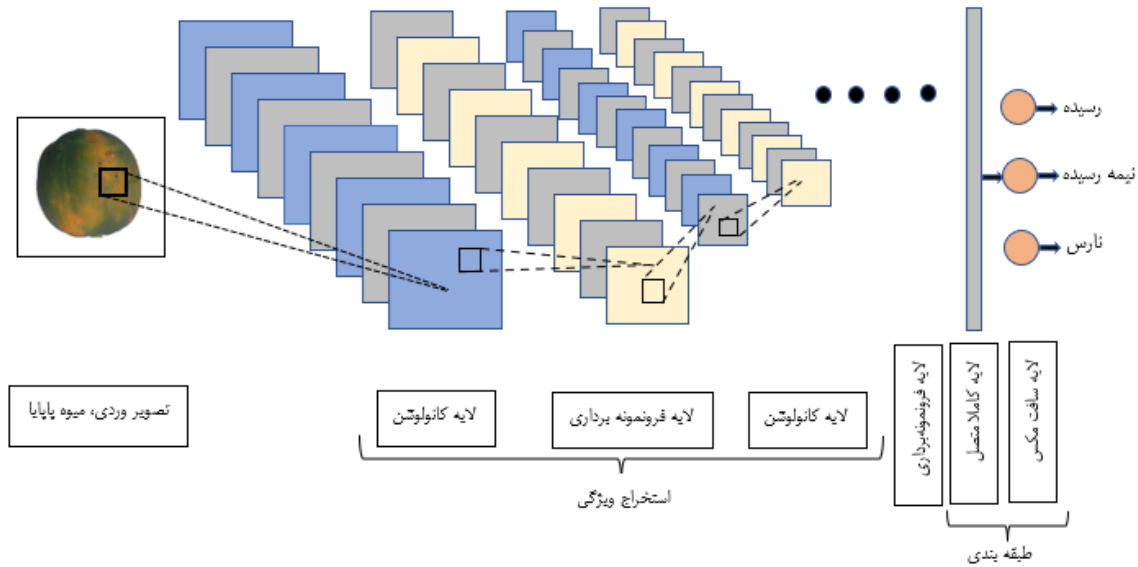


شکل ۲- رویکرد یادگیری ماشین برای طبقه بندی میزان رسیدگی میوه پاپایا

رویکرد یادگیری انتقالی

صورت گرفته مدل‌های شبکه عصبی کانولوشن از پیش آموزش دیده بر اساس رویکرد یادگیری انتقالی مجدداً تنظیم دقیق شده تا برای اهداف طبقه‌بندی مورد نظر مورد استفاده قرار بگیرند. در این مقاله از شش شبکه از پیش آموزش داده شده برای اهداف طبقه بندی میزان رسیدگی میوه پاپایا استفاده شده است. این شبکه‌ها عبارت‌اند از: Google Resnet50, net, Alex net, VGG19, Resnet18, Resnet101 شبکه‌های از پیش آموزش داده شده یک شبکه عصبی کانولوشن بوده که بر روی بیش از یک میلیون تصویر از پایگاه داده ImageNet آموزش داده شده‌اند (Challenge, 2012). نمایی از ساختار یک شبکه عصبی کانولوشن در شکل (۳) آورده شده است.

در هنگام ساخت یک سیستم بینایی برای حل یک موضوع خاص، نیاز است که در مرحله اول مقدار زیادی داده جمع‌آوری شده، سپس توسط افراد خبره برچسب زنی شوند تا شبکه آماده آموزش شود. ولی اگر بتوان از یک شبکه عصبی موجود که توسط پژوهشگر دیگری آموزش داده شده و تنظیم دقیق شده است برای نقطه شروع یک فعالیت جدید استفاده شود، آن‌گاه هم در زمان آموزش و هم در صحت و دقت شبکه عصبی بهبود حاصل می‌گردد. از این مفهوم در یادگیری ماشین تحت عنوان یادگیری انتقالی یاد می‌شود. یادگیری انتقالی یکی از مهمترین تکنیک‌های یادگیری عمیق است. در پژوهش



شکل ۳- مدل یک شبکه عصبی کانولوشن

را در ۱۰۰۰ دسته‌شی طبقه‌بندی کنند. Alex net در سال ۲۰۱۲ معرفی شده است. اندازه تصاویر ورودی به این شبکه $۲۲۷ \times ۲۲۷ \times ۳$ می باشد. اولین لایه کانولوشن در این شبکه دارای ۹۶ فیلتر با اندازه ۱۱×۱۱ و گام ۴ بوده که بر روی تصاویر ورودی جهت استخراج ویژگی اعمال می شود. ابعاد تصاویر از این لایه به اندازه ۵۵×۵۵ کاهش پیدا کرده و تصاویر به یک لایه فرورنمونه برداری بیشینه با اندازه فیلتر ۳×۳ و گام ۲ اعمال می شوند؛ و در نهایت یک لایه مسطح سازی حجم، ابعاد را به ۹۲۱۶ پارامتر تغییر داده و به دو لایه کاملاً متصل که هر کدام دارای ۴۰۹۶ نورون است تحویل می‌دهد. لایه طبقه بندی کننده سافت مکس با ۱۰۰۰ نورون که به تعداد کلاس های خروجی می باشد، به عنوان لایه آخر در این شبکه استفاده می شود. Alex net دارای ۶۰ میلیون پارامتر و ۶۵ هزار نورون می باشد. شبکه از پیش آموزش داده شده VGG19 در سال ۲۰۱۴ در دانشگاه اکسفورد توسعه داده شده است. این شبکه با ساده

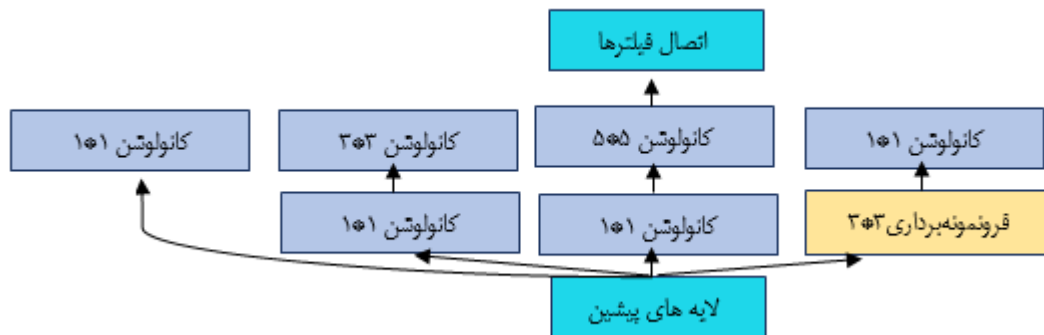
شبکه‌های عصبی باقیمانده در سال ۲۰۱۵ توسط تیم مایکروسافت توسعه داده شده اند (EL-Gendy, 2020). معماری ابداعی مفهومی تحت عنوان اتصالات گذری و بلوک‌های باقیمانده را معرفی می‌کند. در حالت عادی ماتریس تصاویر ورودی پس از عبور از لایه‌های کانولوشن و نرمال سازی به یک تابع فعال سازی از نوع واحد یکسوشده‌ی خطی (Relu) در لایه‌های پنهان می رسد، اما در شبکه‌های باقیمانده ماتریس تصاویر ورودی علاوه بر عبور از مسیر اصلی از یک مسیری فرعی نیز عبور کرده و ورودی را درست قبل از تابع فعال سازی آخرین لایه کانولوشن به مسیر اصلی اضافه کرده و آنگاه تابع فعال‌سازی را به هر دو مسیر اعمال می‌کند. با استفاده از این تکنیک می‌توان شبکه‌های خیلی عمیق را ساخت و مشکل محو گرادیان را حل نمود. Resnet18, Resnet50, Resnet101 سه نوع از شبکه‌های عصبی باقیمانده هستند که به ترتیب دارای ۱۰۱، ۵۰ و ۱۸ لایه پنهان بوده که می‌توانند تصاویر

Alex net برخوردار است. مشخص دن اندازه فیلتر ها امکان لایه های فرورنومه برداری از تصمیماتی است که عمدتا با سعی و خطا گرفته می شود. در google net به جای انتخاب اندازه فیلتر مطلوب در لایه کانولوشن و این که لایه فرورنومه برداری در کجا قرار بگیرند همه آن ها در یک بلوک قرار داده شده و اصطلاحی تحت عنوان مدول- های تکوین را به وجود می آورند. این مدول ها هزینه های محاسباتی به وجود آمده که ناشی از استفاده از فیلترهایی با اندازه بزرگ است را کاهش می دهند. در این مدول ها از یک لایه کانولوشن 1×1 موسوم به لایه گلوگاهی قبل از لایه های کانولوشن 3×3 و 5×5 و پس از لایه فرورنومه برداری بیشینه استفاده می شود تا یک مدول تکوین با کاهش ابعاد ایجاد شود (EL-Gendy, 2020). نمایی از یک شبکه عصبی کانولوشن Google Net و مدول تکوین آن در شکل های (۴) و (۵) آورده شده است.

بودن آن شناخته می شود برای اینکه فقط از لایه های کانولوشن 3×3 که بر روی هم انباشته شده اند و شبکه عصبی کانولوشن عمیق را تولید می کند، ساخته می شود. لایه فرورنومه برداری بعد از هر لایه کانولوشن باعث کاهش ابعاد و اندازه در تصاویر خروجی از لایه کانولوشن می شود. در این شبکه دولایه کاملا متصل که هر کدام دارای 4096 گره می باشند، توسط یک طبقه بندی کننده سافت مکس دنبال می شوند. Vgg16 و Vgg19 دو شبکه عصبی کانولوشن بوده که به ترتیب هر کدام دارای 16 و 19 لایه پنهان در ساختار خود می باشند. google net یک مدل از پیش آموزش دیده است که در زیر مجموعه ای از پایگاه داده Image Net که در چالش های تصویری در مقیاس بزرگ استفاده می شود، آموزش دیده است. هم چنین این شبکه در سال 2014 معرفی شده است. Google net از یک معماری کاملا متفاوت نسبت به Vgg, Resnet,

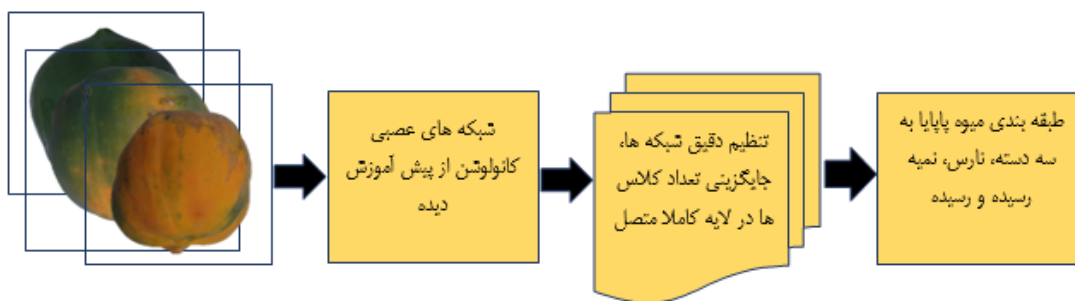


شکل ۴. شبکه عصبی کانولوشن Google Net



شکل ۵- مدول تکوین

مراحل مختلف رویکرد یادگیری انتقالی در شکل (۶) نشان داده شده است.



شکل ۶- رویکرد یادگیری انتقالی برای طبقه بندی میزان رسیدگی میوه پاپایا

گرفتند. آزمایش های تجربی و آنالیز تصاویر به وسیله نرم افزار MatlabR2022b بر روی یک لپ تاپ با مشخصات ارائه شده در جدول (۳) اجرا شده است.

در این مطالعه عملکرد مدل های طبقه بندی کننده برای طبقه بندی میزان رسیدگی میوه پاپایا بر اساس دو رویکرد یادگیری ماشین و یادگیری انتقالی مورد بررسی قرار

جدول ۳- مشخصات سخت افزاری لپ تاپ استفاده شده

مشخصات

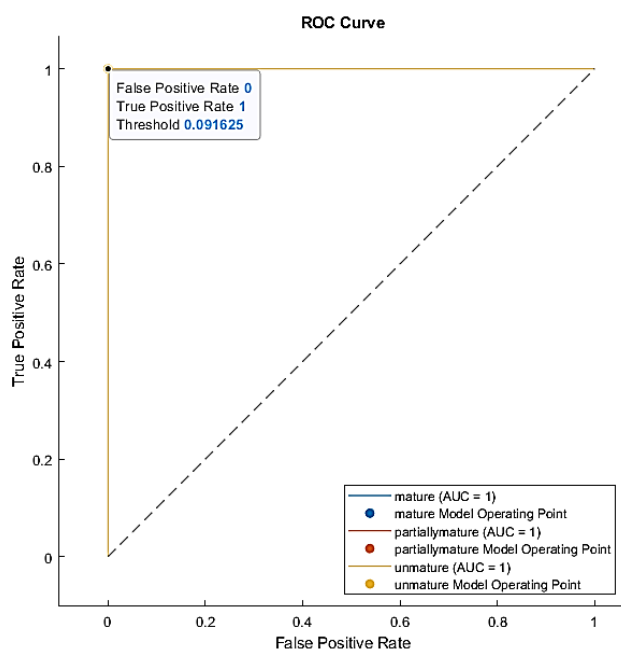
Laptop AsusN53 Core i7 (8GB\750HDD\Windows10\2GB graphics) Equipped with NVIDIA G-force GT 550M CUDA

جدول ۴- مقایسه عملکرد مدل‌های طبقه‌بندی کننده مختلف بر اساس رویکرد یادگیری ماشین

ویژگی	طبقه‌بندی کننده	صحت (درصد)	AUC	زمان آموزش (ثانیه)
الگوریتم دودویی محلی	K-نزدیکترین همسایه	۹۱/۶	۱	۴:۱۳
	ماشین بردار پشتیبان	۸۹/۷	۰/۹۵	۴:۴۸
	بیزی ساده	۷۸/۳	۰/۸۳	۵:۳۲
هیستوگرام گرادیان جهت‌دار	K-نزدیکترین همسایه	۹۵/۴	۱	۳:۲۸
	ماشین بردار پشتیبان	۹۱/۴	۱	۳:۴۵
	بیزی ساده	۹۲/۷	۱	۳:۸۷
ماتریس هم-رخداد سطح خاکستری	K-نزدیکترین همسایه	۹۳/۶	۱	۵:۸۷
	ماشین بردار پشتیبان	۸۸/۴	۰/۹۳	۶:۱۲
	بیزی ساده	۸۳/۲	۰/۸۹	۶:۸۷



شکل ۷- عملکرد طبقه‌بندی کننده k-نزدیک ترین همسایه در پیش بینی برجسب کلاس‌ها

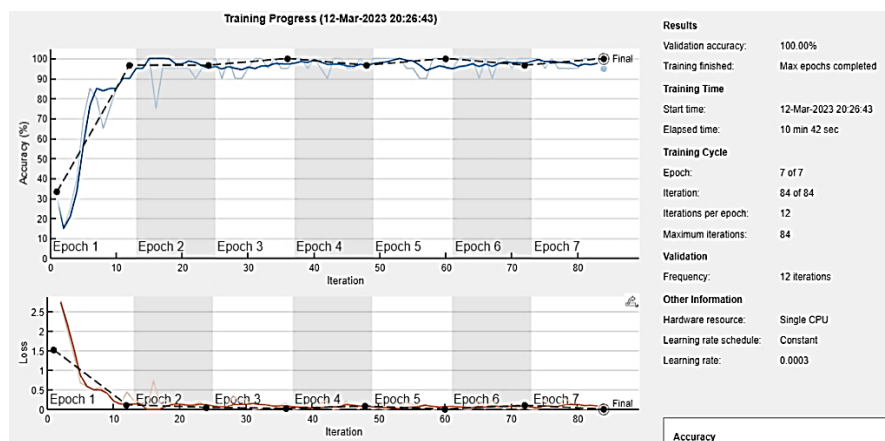


شکل ۸- منحنی دقت - بخاطر آوری

نتایج بر اساس رویکرد یادگیری انتقالی

به منظور طبقه بندی میزان رسیدگی میوه پاپایا شبکه های عصبی کانولوشن از پیش آموزش داده شده بر اساس رویکرد یادگیری انتقالی، تنظیم دقیق شده اند و برای اهداف طبقه بندی میوه پاپایا مورد استفاده قرار گرفتند. در رویکرد یادگیری انتقالی فرآیندهای قابل تنظیم برای مدل های از پیش آموزش داده شده مانند: اندازه بچ، تعداد تکرارها در آزمون اعتبارسنجی، تعداد کل دوره های آموزش و نرخ یادگیری اولیه به ترتیب ۰/۰۰۰۳، ۷، ۱۲، ۲۰ و در نظر گرفته شد. علاوه بر این از روش فرودگردیان استوکاستیک همراه با مونتوم (SGDM) به عنوان روش یادگیری برای بروزرسانی اوزان و آموزش مدل استفاده شده است. برای ایجاد مدلی با قابلیت تعمیم بالا و همچنین جلوگیری از

مشکل بیش برآزش و ساخت مدلی مستحکم و قابل اطمینان لازم است تا داده های جمع آوری شده در مجموعه داده تقویت شوند، در این پژوهش از تکنیک تقویت داده ها برای رسیدن به این اهداف استفاده شده است. چرخش [۹۰؛۹۰-] انتقال [۳۰؛۳۰-] و تغییر مقیاس [۱،۱؛۰/۹] سه عملیاتی است که به منظور تقویت داده ها در این پژوهش بر روی تصاویر مورد استفاده قرار گرفته اند. پس از تنظیم فرآیندهای تقویت داده ها و اجرای آزمایشات مشخص شد که شبکه از پیش آموزش داده شده VGG19 توانسته است عملکرد بهتری را نسبت به سایر شبکه ها از خود نشان دهد. در شکل (۹) عملکرد این شبکه در زمان آموزش و اعتبارسنجی نشان داده شده است.



شکل ۹ - عملکرد شبکه VGG19 در زمان آموزش و اعتبارسنجی

درصدی دست پیدا کنند اما زمان رسیدن به این صحت برای مدل VGG19 کمتر از سایر مدل ها است. علاوه بر این شبکه VGG19 توانسته است تنها در ۷ تکرار به این صحت و زمان آموزش برسد که بهترین عملکرد در میان سایر مدل ها می باشد.

شبکه از پیش آموزش داده شده VGG19 توانسته است در مدت زمان ۱۰:۴۲ ثانیه به صحت ۱۰۰ درصد عملکرد برای داده های اعتبارسنجی دست پیدا کند. اگرچه سایر مدل های از پیش آموزش داده شده توانسته اند به این صحت ۱۰۰

نتایج عملکردی سایر شبکه‌ها بر اساس رویکرد یادگیری انتقالی در جدول (۵) نشان داده شده است، همچنین ماتریس آشفتگی و خروجی شبکه VGG19 که پیش‌بینی برچسب کلاس‌های میزان

جدول ۵- مقایسه عملکرد مدل‌های طبقه‌بندی کننده مختلف براساس رویکرد یادگیری انتقالی

شبکه از پیش آموزش داده شده	صحت	تعداد تکرار در رسیدن به حداکثر صحت اعتبارسنجی	زمان آموزش (ثانیه)
ResNet101	۱۰۰	۱۶	۱۵:۶۸
ResNet50	۱۰۰	۲۰	۱۷:۳۵
ResNet18	۹۸/۷	۱۵	۱۴:۳۰
VGG19	۱۰۰	۱۲	۱۰:۴۲
Google Net	۱۰۰	۱۴	۱۳:۸۷
Alex Net	۹۹/۹	۱۵	۱۵:۴۵

جدول ۶- ماتریس آشفتگی در عملکرد شبکه vgg19

کلاس‌های پیش‌بینی	رسیده	۲۰	۰	۰	۱۰۰٪
	نیمه رسیده	۰	۲۰	۰	۱۰۰٪
	نارس	۰	۰	۲۰	۱۰۰٪
	کلاس‌های واقعی	۱۰۰	۱۰۰	۱۰۰٪	۱۰۰٪
		رسیده	نیمه رسیده	نارس	
		۳۳,۳۳٪ رسیده	۰,۰٪	۰,۰٪	۰,۰٪
		۰,۰٪	۳۳,۳۳٪	۰,۰٪	۰,۰٪
		۰,۰٪	۰,۰٪	۳۳,۳۳٪	۰,۰٪
		۰,۰٪	۰,۰٪	۰,۰٪	۰,۰٪

نارس نیمه رسیده رسیده
کلاس‌های واقعی

unmature, 100%



partiallymature, 100%



mature, 100%



شکل ۱۰- عملکرد شبکه Vgg19 در پیش‌بینی برچسب کلاس‌ها

نتیجه‌گیری و پیشنهادات

در این پژوهش یک مدل طبقه‌بندی کننده برای طبقه‌بندی میزان رسیدگی میوه پایا در دو رویکرد یادگیری ماشین و یادگیری انتقالی پیشنهاد شده است. در رویکرد یادگیری ماشین از توصیف‌گرهای ویژگی هیستوگرام گرادیان‌های جهت دار، الگوریتم دودویی محلی و ماتریس هم رخداد سطح خاکستری همراه با طبقه‌بندی کننده‌های k -نزدیکترین همسایه، ماشین بردار پشتیبان و طبقه‌بندی کننده بیزی ساده که هر کدام عملکردی متفاوت از خود نشان داده اند، استفاده شده است. طبقه‌بندی کننده k -نزدیک‌ترین همسایه همراه با توصیف‌گر ویژگی HOG توانست با به دست آوردن صحت $95/4$ درصد بهترین عملکرد را در میان سایر طبقه‌بندی کننده های یادگیری ماشین به خود اختصاص دهد. علاوه بر این، این طبقه‌بندی کننده با ثبت $Auc=1$ و زمان آموزش $3:28$ ثانیه بهترین نتیجه را بر اساس این سنجه های ارزیابی در بین سایر مدل‌های طبقه‌بندی کننده‌های یادگیری ماشین بدست آورده است. در رویکرد یادگیری انتقالی شبکه از پیش آموزش داده شده vgg19 توانسته است با بدست آوردن صحت 100 درصد و زمان آموزش $10:42$ ثانیه بهترین عملکرد را در بین سایر شبکه ها به خود اختصاص بدهد. به طور کلی می‌توان نتیجه گرفت که در بین رویکردهای یادگیری ماشین و یادگیری انتقالی شبکه vgg19 از لحاظ همه سنجه های ارزیابی عملکرد بهتری را داشته است. از آن جایی که شبکه از پیش آموزش داده شده vgg19 بر مبنای یادگیری انتقالی عمل می‌کند دیگر نیازی به فرآیندهای زمان بر و خسته

کننده‌ای مانند استخراج ویژگی و انتخاب ویژگی‌ها نمی‌باشد. اگرچه رویکرد یادگیری انتقالی نیاز به ایجاد معماری‌های پیچیده شبکه، زمان آموزش زیاد و مجموعه داده‌های بزرگ برای آموزش دارند، اما همه‌ی این موارد فقط یک بار اتفاق می‌افتد و زمانی که شبکه آموزش داده شد، دیگر نیازی به اجرای مجدد این فرآیندهای خسته کننده نیست. از طرفی رویکرد یادگیری ماشین نیز دارای محدودیت‌هایی از قبیل استخراج ویژگی‌ها به صورت دستی، انتخاب ویژگی‌ها به صورت تجربی، اجرای مکرر آزمایش‌ها به صورت سعی و خطا تا رسیدن به بهترین صحت در نتایج و استفاده از افراد خبره برای برچسب زنی کلاس واقعی داده‌ها می باشد، تمام سعی و تلاش محققین در فایق آمدن بر این محدودیت‌ها با به کار بردن تکنیک‌های جدید است. با این حال صحت بدست آمده در این پژوهش با پژوهش‌های قبلی قابل مقایسه است که می‌توان به مواردی از جمله: طبقه‌بندی میوه پایا بر مبنای میزان رسیدگی آن با صحت $94/7$ درصد (Pereira *et al.*, 2018)، طبقه‌بندی میزان رسیدگی میوه گوجه فرنگی با استفاده از ماشین بردار پشتیبان با صحت 90 درصد (El-Bendary *et al.*, 2015)، طبقه‌بندی سه مرحله رسیدگی میوه خرما با استفاده از تکنیک پردازش تصویر و الگوریتم یادگیری عمیق با صحت 97 درصد (Nasiri *et al.*, 2019) و طبقه‌بندی چهار مرحله رسیدگی میوه موز با استفاده از الگوریتم یادگیری عمیق با صحت $96/4$ (Saranya *et al.*, 2021) اشاره کرد. بر اساس نتایج بدست آمده می‌توان عنوان کرد که طبقه بندی میوه پایا بر اساس میزان رسیدگی آن با استفاده از

الگوریتم‌های پیشنهادی می‌تواند جایگزینی مناسب
برای روش‌های سنتی طبقه‌بندی این میوه باشد،
همچنین به منظور کاهش ضایعات محصولات
کشاورزی و افزایش کیفیت درجه‌بندی محصولات
می‌توان از الگوریتم پیشنهادی در بعد صنعتی نیز
استفاده کرد.

REFERENCES

- Aggarwal, C.C., 2018. Neural networks and deep learning. *Springer*, 10 (978), p.3.
- Al Ohali, Y., 2011. Computer vision based date fruit grading system: Design and implementation. *Journal of King Saud University-Computer and Information Sciences*, 23(1), pp.29-36.
- Asad, M.H. and Bais, A., 2020. Weed detection in canola fields using maximum likelihood classification and deep convolutional neural network. *Information Processing in Agriculture*, 7(4), pp.535-545.
- Azadnia, R., Kheiralipour, K. and Jafarian, M., 2022. Classification of hawthorn fruit based on ripeness level by machine vision. *Innovative Food Technologies*, 9(4), pp.331-344.
- Baigvand, M., Banakar, A., Minaei, S., Khodaei, J. and Behroozi-Khazaei, N., 2015. Machine vision system for grading of dried figs. *Computers and Electronics in Agriculture*, 119, pp.158-165.
- Behera, S.K., Rath, A.K. and Sethy, P.K., 2021. Maturity status classification of papaya fruits based on machine learning and transfer learning approach. *Information Processing in Agriculture*, 8(2), pp.244-250.
- Challenge, I.L.S.V.R., 2012. Available online: <http://www.image-net.org/challenges.LSVRC/2012/>(Last visited on 9 Dec. 2020).
- Dalal, N. and Triggs, B., 2005, June. Histograms of oriented gradients for human detection. In *2005 IEEE computer society conference on computer vision and pattern recognition (CVPR'05)* (Vol. 1, pp. 886-893). Ieee.
- Damez, J.L. and Clerjon, S., 2008. Meat quality assessment using biophysical methods related to meat structure. *Meat science*, 80(1), pp.132-149.
- Devi, P.L. and Varadarajan, S., 2013. Defect fruit image analysis using advanced bacterial foraging optimizing algorithm. *IOSR J Comput Eng*, 14(1), pp.22-6.
- Dubey, S.R. and Jalal, A.S., 2015. Application of image processing in fruit and vegetable analysis: a review. *Journal of Intelligent Systems*, 24(4), pp.405-424.
- El-Bendary, N., El Hariri, E., Hassanien, A.E. and Badr, A., 2015. Using machine learning techniques for evaluating tomato ripeness. *Expert Systems with Applications*, 42(4), pp.1892-1905.
- El-Gendy, M. 2020. Deep learning for vision system. (1th ed). Translated by Ayub Turkian. Tehran. Niaze- Danesh Publications. (In Farsi)
- Farokhzad, S., Modaress Motlagh, A., Ahmadi Moghadam, P., Jalali Honarmand, S. and Kheiralipour, K., 2020. Application of infrared thermal imaging technique and discriminant analysis methods for non-destructive identification of fungal infection of potato tubers. *Journal of Food Measurement and Characterization*, 14, pp.88-94.
- Gongal, A., Karkee, M. and Amatya, S., 2018. Apple fruit size estimation using a 3D machine vision system. *Information Processing in Agriculture*, 5(4), pp.498-503.
- Guo, X., Zhao, X., Liu, Y. and Li, D., 2019. Underwater sea cucumber identification via deep

- residual networks. *Information Processing in Agriculture*, 6(3), pp.307-315.
- Haralick, R.M., Shanmugam, K. and Dinstein, I.H., 1973. Textural features for image classification. *IEEE Transactions on systems, man, and cybernetics*, (6), pp.610-621.
- Huang, T., Yang, R., Huang, W., Huang, Y. and Qiao, X., 2018. Detecting sugarcane borer diseases using support vector machine. *Information processing in agriculture*, 5(1), pp.74-82.
- Jadhav, R.S. and Patil, S.S., 2013. A fruit quality management system based on image processing. *IOSR Journal of Electronics and Communication Engineering (IOSR-JECE)*, 8(6), pp.01-05.
- Ji, M., Zhang, L. and Wu, Q., 2020. Automatic grape leaf diseases identification via UnitedModel based on multiple convolutional neural networks. *Information Processing in Agriculture*, 7(3), pp.418-426.
- Kaur, H., Sawhney, B.K. and Jawandha, S.K., 2018. Evaluation of plum fruit maturity by image processing techniques. *Journal of Food Science and Technology*, 55, pp.3008-3015.
- Kavdir, I. and Guyer, D.E., 2004. Comparison of artificial neural networks and statistical classifiers in apple sorting using textural features. *Biosystems engineering*, 89(3), pp.331-344.
- Kheiralipour, K., Ahmadi, H., Rajab pour, A. & Rafiee, S. 2018. Thermal Imaging, Principles, Methods and Applications. *Ilam Uni Pub*. Ilam, Iran. (In Farsi).
- Kheiralipour, K. and Kazemi, A., 2020. A new method to determine morphological properties of fruits and vegetables by image processing technique and nonlinear multivariate modeling. *International Journal of Food Properties*, 23(1), pp.368-374.
- Khodaei, J., BehrooziKhazaei, N. & HosseinzadehRendi, A. 2018. Classification of Strawberry Based on Maturity Rate and Size Using Machine Vision. *Biosystem Engineering of Iran*, 50 (1), 145-154 (In Farsi).
- Leekul, P., Chivapreecha, S., Phongcharoenpanich, C. and Krairiksh, M., 2016. Rician k-factors-based sensor for fruit classification by maturity stage. *IEEE Sensors Journal*, 16(17), pp.6559-6565.
- Liu, C., Liu, W., Lu, X., Ma, F., Chen, W., Yang, J. and Zheng, L., 2014. Application of multispectral imaging to determine quality attributes and ripeness stage in strawberry fruit. *PloS one*, 9(2), p.e87818.
- Magwaza, L.S. and Opara, U.L., 2015. Analytical methods for determination of sugars and sweetness of horticultural products A review. *Scientia Horticulturae*, 184, pp.179-192.
- Marimuthu, S. and Roomi, S.M.M., 2017. Particle swarm optimized fuzzy model for the classification of banana ripeness. *IEEE Sensors Journal*, 17(15), pp.4903-4915.
- Medina JD, Gutierrez GV, Garcia HS. Pawpaw. (2014). Post-harvest operation. Compendium on Post-harvest Operations. Link: <http://www.fao.org/fileadmin/user_upload/inpho/docs/Postharvest Compendium- Pawpaw Papaya_.pdf>.
- Mohammadi, V., Kheiralipour, K. and Ghasemi-Varnamkhasti, M., 2015. Detecting maturity of persimmon fruit based on image processing technique. *Scientia Horticulturae*, 184, pp.123-128.
- Nandi, C.S., Tudu, B. and Koley, C., 2014. A machine vision-based maturity prediction system for sorting of harvested mangoes. *IEEE Transactions on Instrumentation and measurement*, 63(7), pp.1722-1730.
- Nasiri, A., Taheri-Garavand, A. and Zhang, Y.D., 2019. Image-based deep learning automated sorting of date fruit. *Postharvest biology and technology*, 153, pp.133-141.
- Ojala, T., Pietikainen, M. and Maenpaa, T., 2002. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *IEEE Transactions on pattern analysis and*

- machine intelligence*, 24(7), pp.971-987.
- Omid, M., Khojastehnazhand, M. and Tabatabaefar, A., 2010. Estimating volume and mass of citrus fruits by image processing technique. *Journal of food Engineering*, 100(2), pp.315-321.
- Patel, K.K., Kar, A., Jha, S.N. and Khan, M.A., 2012. Machine vision system: a tool for quality inspection of food and agricultural products. *Journal of food science and technology*, 49, pp.123-141.
- Pereira, L.F.S., Barbon Jr, S., Valous, N.A. and Barbin, D.F., 2018. Predicting the ripening of papaya fruit with digital imaging and random forests. *Computers and Electronics in Agriculture*, 145, pp.76-82.
- Rocha, A., Hauagge, D.C., Wainer, J. and Goldenstein, S., 2010. Automatic fruit and vegetable classification from images. *Computers and Electronics in Agriculture*, 70(1), pp.96-104.
- Saranya, N., Srinivasan, K. and Kumar, S.P., 2022. Banana ripeness stage identification: a deep learning approach. *Journal of Ambient Intelligence and Humanized Computing*, 13(8), pp.4033-4039.
- Savakar, D.G. and Anami, B.S., 2015. Grading of bulk food grains and fruits using computer vision. *Journal of Agricultural Engineering and Biotechnology*, 3(1), p.1.
- Sharma, P., Berwal, Y.P.S. and Ghai, W., 2020. Performance analysis of deep learning CNN models for disease detection in plants using image segmentation. *Information Processing in Agriculture*, 7(4), pp.566-574.
- Surya Prabha, D. and Satheesh Kumar, J., 2015. Assessment of banana fruit maturity by image processing technique. *Journal of food science and technology*, 52, pp.1316-1327.
- 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, pp.226-240.
- Zhang, Y. and Wu, L., 2012. Classification of fruits using computer vision and a multiclass support vector machine. *sensors*, 12(9), pp.12489-12505.
- Zhang, Y., Wang, S., Ji, G. and Phillips, P., 2014. Fruit classification using computer vision and feedforward neural network. *Journal of Food Engineering*, 143, pp.167-177. DataMendly <<http://www.Data.Mendly.com>> Sbj.ir <<http://www.Sbj.ir>>



Classification of Papaya fruit Based on Maturity, Using Machine Learning and Transfer Learning Approach

Mohammad Ghorbani¹, Mostafa Ghazizadeh Ehsaei^{2*} and Kazem Jafari naeimi³

¹ Biosystems Engineering Dept., Faculty of Agriculture, Shahid Bahonar University of Kerman, Kerman, Iran.

² Assistant Professor, computer Engineering Department, Faculty of Engineering, Shahid Bahonar University of Kerman, kerman, Iran

³ Biosystems Engineering Dept., Faculty of Agriculture, Shahid Bahonar University of Kerman, Kerman, Iran.

* Corresponding Author's Email: mghazizadeh@uk.ac.ir

(Received: December. 25, 2023 – Accepted: March. 19, 2024)

ABSTRACT

Grading and packing fruits based on visual inspections can be time-consuming, destructive, and unreliable. The objective of the conducted research is to provide an intelligent, fast and reliable classification method to detect the maturity of papaya fruit in three levels: immature, partially mature and mature. The total number of images used in this article is 300 images, 100 images have been collected for each level. In this paper, the use of two approaches, machine learning and transfer learning, is proposed to classify papaya fruit maturity status. The machine learning approach includes the use of three feature descriptors and three different classifiers, which are: local binary pattern (LBP), Gray Level Cooccurrence Matrix (GLCM), histogram of oriented gradients (HOG), k-nearest neighbor (KNN) classification algorithm, support vector machine (SVM) and Naïve Bayes classification algorithm. Transfer learning methods include the use of six pre-trained deep learning models Alex net, Google net, Resnet101, Resnet50, Resnet18, VGG19. KNN classifier using HOG feature descriptor has achieved 95.4% accuracy and 3:52 seconds training time. The classifier based on transfer learning approach VGG19 was able to record better performance among other deep learning networks by obtaining 100% accuracy and training time of 10:42 seconds. Two classification methods using machine learning and transfer learning methods have been able to obtain accuracy of 95.4% and 100%, respectively, which are 0.7% and 6% more than the existing proposed methods.

Keywords: Feature descriptors, Grading, Machine learning, Maturity, Transfer learning