

شناسایی ژنوتیپ‌های سیب‌زمینی پس از دوره انبارمانی با استفاده از ترکیب روش‌های پردازش تصویر و شبکه عصبی مصنوعی

رویا فرهادی^۱، امیرحسین افکاری سیاح^{۲*}، بهاره جمشیدی^۳ و احمد موسی پور گرجی^۴

- ۱ و ۲- به ترتیب: دانشجوی دکتری مهندسی مکانیک بیوسیستم؛ و دانشیار گروه مهندسی بیوسیستم، دانشکده کشاورزی و منابع طبیعی، دانشگاه محقق اردبیلی، اردبیل، ایران
 - ۳- دانشیار موسسه تحقیقات فنی و مهندسی کشاورزی، سازمان تحقیقات، آموزش و ترویج کشاورزی، کرج، ایران
 - ۴- استادیار موسسه تحقیقات اصلاح و تهیه نهال و بذر، سازمان تحقیقات، آموزش و ترویج کشاورزی، کرج، ایران
- تاریخ دریافت: ۹۷/۱۰/۱۵؛ تاریخ پذیرش: ۹۸/۴/۱۰

چکیده

برای ایجاد اطمینان از عرضه پیوسته سیب‌زمینی به مصرف‌کنندگان و صنایع فرآوری این محصول، ذخیره‌سازی آن ضروری است. هنگام ذخیره‌سازی، تغییرات فیزیولوژیکی و اتلاف آب در سیب‌زمینی باعث می‌شود رنگ، شکل، اندازه و بافت آن تغییر کند. بنابراین، برای تعیین کیفیت محصول نیاز به روش‌های دقیق و سریع خواهد بود. در این مطالعه، از روش ماشین بینایی و شبکه عصبی مصنوعی برای کلاسه‌بندی و مدل‌سازی دو نمونه سیب‌زمینی ذخیره شده در شرایط ثابت و متغیر استفاده شد. از بین ۲۹ پارامتر اندازه‌گیری شده مربوط به ویژگی‌های رنگ، بافت و مورفولوژیکی، سه ویژگی طول قطر بزرگ، فشردگی و مساحت (از ویژگی‌های مورفولوژیکی)، دو ویژگی L^* و b^* (از ویژگی‌های رنگی) و ۲ ویژگی میانگین کنتراست و میانگین سطح خاکستری (از ویژگی‌های بافت) به عنوان پارامترهای اصلی انتخاب شدند. در میان الگوریتم‌های آموزشی، الگوریتم آموزشی لونبرگ-مارکوارت (LM) با کمترین میانگین مربعات خطا $RMSE = 0.12$ و بیشترین ضریب تبیین $R^2 = 0.95$ درصد مدلی بهینه در طبقه‌بندی (کلاسه‌بندی) دو نمونه سیب‌زمینی انبار شده در انبار غیرفنی و فنی شناخته شد. در انبار غیرفنی و فنی، دقت شناسایی ژنوتیپ اگر با به ترتیب ۸۹/۲ و ۸۷/۶ درصد و دقت شناسایی ژنوتیپ کلون ۸-۹۷۰۰۹-۳۹۷ به ترتیب ۹۲/۴ و ۹۰/۳ درصد به دست آمد.

واژه‌های کلیدی

تغییرات فیزیولوژیکی، طبقه‌بندی، کیفیت، ماشین بینایی

مقدمه

استفاده می‌شود، سیب‌زمینی انبار شده است که مناسب بودن آنها نه فقط به کیفیت این محصول به هنگام برداشت، بلکه به پاسخ آنها به شرایط ذخیره‌سازی بستگی دارد. سیب‌زمینی در صنعت فرآوری باید الزاماتی چند داشته باشد، از جمله: پایین بودن مقدار قند، بالا بودن ماده خشک، بالا بودن وزن مخصوص، بالابودن آنتی‌اکسیدان‌ها، آهسته بودن سرعت کاهش وزن، روشن بودن رنگ

سیب‌زمینی یکی از محصولات مهم کشاورزی است که در سبد غذایی مردم نقش اساسی دارد. این محصول در صنایع غذایی به محصولاتی متنوع از جمله سیب‌زمینی پخته، فرنچ فرایز، سیب‌زمینی سرخ شده، سیب‌زمینی چیپس، نشاسته سیب‌زمینی و غیره تبدیل می‌شود (Pedreschi, 2012). بخش عمده‌ای از سیب‌زمینی که در صنعت فرآوری

غذایی ضروری است. روش‌های دستی به دلیل نداشتن قابلیت کنترل خودکار، بسیار خسته‌کننده، سخت و پرهزینه هستند و به راحتی تحت تأثیر عوامل محیطی قرار می‌گیرند (Razmjooy *et al.*, 2012). امروزه سیستم‌های ماشین بینایی، خودکار، غیرمخرب و مقرون به صرفه هستند و به طور ایده‌آل برای بازرسی‌های معمول و تضمین کیفیت در صنایع غذایی و محصولات مرتبط کاربرد دارند. این فناوری اجازه می‌دهد تا بازرسی‌ها به طور خودکار و ارزیابی بصری با استفاده از دوربین‌های دیجیتال و تکنیک‌های تجزیه و تحلیل تصویر صورت پذیرد و روشی غیرمخرب برای اندازه‌گیری الگوهای رنگ در سطوح رنگی غیریکنواخت است، این فناوری برای تعیین ویژگی‌های فیزیکی دیگر مانند ویژگی‌های بافت تصویر، عناصر مورفولوژیکی و نقص‌ها به کار می‌رود (Pedreschi *et al.*, 2004; Mendoza & Aguilera, 2004). علاوه بر این، سیستم‌های ماشین بینایی نه تنها اندازه، شکل، رنگ و بافت اشیا را تشخیص می‌دهند، بلکه ویژگی‌های شمارشی اشیا یا صحنه‌ای که در حال تصویربرداری است نیز ارائه می‌دهند و قادرند اشیا را در نور غیرقابل مشاهده برای انسان بررسی کنند.

دستاوردهای ماشین بینایی برای بازرسی کیفی سیب‌زمینی چشمگیرند. با آخرین دستگاه‌های تصویربرداری مانند دوربین‌های CCD، دوربین‌هایی که با پرتوهای فرابنفش کار می‌کنند، دوربین‌های فراطیفی، NMR و ایکس-ری نه تنها ویژگی‌های فیزیکی مانند طول، عرض و جرم را می‌توان پیش‌بینی کرد، بلکه نقص‌های خارجی (پوست سبز، جوانه‌های بیدار شده، پوسیدگی، کبودی و آسیب مکانیکی) و داخلی (قلب سیاه، آسیب ناشی از سرمازدگی و حفره داخلی) را نیز می‌توان بررسی کرد (Dacal-Nieto *et al.*, 2009; Rady & Guyer, 2015). سو و همکاران (Su *et al.*, 2017) بر اساس

پوست و بیدار نشدن جوانه‌های آن (Connor *et al.*, 2001). نیاز به انبارهای مناسب برای ذخیره‌کردن طولانی‌مدت غده‌های سیب‌زمینی به این معناست که شرایط ذخیره‌سازی می‌تواند در تعیین کیفیت غده سیب‌زمینی فرآوری شده نقش مهمی بازی کند. سیب‌زمینی در انبار ممکن است شیرین شود، بپوسد، آب خود را از دست بدهد و جوانه‌هایش رشد کنند. همچنین، شرایط نگهداری پس از برداشت می‌تواند تغییرات گسترده‌ای در ترکیبات شیمیایی غده سیب‌زمینی و در نتیجه تغییر در ویژگی‌های کیفی محصول نهایی ایجاد کند (Spychalla *et al.*, 1990). بنابراین، مدیریت غده‌های سیب‌زمینی در تمام مراحل زنجیره تولید و ذخیره‌سازی مهم است زیرا می‌تواند بر کیفیت نهایی محصولات مشتق شده از سیب‌زمینی تأثیر بسزایی داشته باشد (Gomez-Galindo *et al.*, 2007).

تغییرات سیب‌زمینی در انبار به رقم، شرایط انبار (میزان دما، رطوبت نسبی، تهویه، نور) و شرایط محیطی بستگی دارد. ذخیره‌سازی سیب‌زمینی به منظور تأمین مستمر مواد خام، برای مصارف خانگی و صنعتی بسیار ضروری است، تغییرات شیمیایی و فیزیکی این محصول در انبار نیز گریزناپذیر است، با این همه در مبادله‌های تجاری این محصول چند ویژگی در نظر گرفته می‌شود که نشان از کیفیت بالای آن دارد: شکل خوب، رنگ روشن، یکنواختی، سفتی، عاری بودن از خاک، نداشتن کبودی (نقاط سیاه و سفید)، پوسته نشدن، نداشتن ترک، بیدار نشدن جوانه‌ها، نداشتن آسیب‌های ناشی از حمله حشرات، نداشتن پوسیدگی، نداشتن رنگ سبز و عاری بودن از نقص‌های دیگر است (ElMasry *et al.*, 2012).

با افزایش انتظارات برای محصولات غذایی دارای استانداردهای کیفی و ایمنی بالا، نیاز به تعیین دقیق، سریع و هدفمند ویژگی‌های محصولات

تشخیص کیفیت است.

با توجه به اهمیت تشخیص سریع و غیرمخرب ارقام در هر مرحله از مراحل پس از برداشت و اینکه ویژگی‌های ظاهری و بافت محصول طی این دوره تا حدی نسبت به غده‌های تازه برداشت شده تغییر می‌کنند، این تحقیق در پی بررسی امکان تشخیص و طبقه‌بندی ژنوتیپ‌های سیب‌زمینی بر اساس تغییرات ظاهری و بافت آنها به کمک ماشین بینایی و شبکه عصبی مصنوعی، پس از مرحله انبارمانی است. بررسی‌ها این نتیجه را به دست داده که تا کنون پژوهشی در زمینه تشخیص و طبقه‌بندی ارقام سیب‌زمینی بعد از دوره انبارمانی صورت نگرفته است. هدف از این پژوهش استفاده از سیستم ماشین بینایی برای تحلیل تشخیص و طبقه‌بندی (کلاسه‌بندی) دو ژنوتیپ سیب‌زمینی ذخیره شده در دو انبار با دمای متفاوت با استخراج ویژگی‌های رنگی، شکلی و بافت این دو ژنوتیپ از روی تصاویر آنها با کمک پردازش تصویر است.

مواد و روش

سیب‌زمینی

پانصد عدد سیب‌زمینی به نسبت مساوی از دو ژنوتیپ آگریا و کلون ۸-۳۹۷۰۰۹ (که از این پس فقط کلون نامیده می‌شود) به کار گرفته شدند؛ این دو ژنوتیپ در نیمه اول اردیبهشت و در شرایط یکسانی در ایستگاه تحقیقات کشاورزی آلاروق شهرستان اردبیل کشت و در نیمه دوم مهرماه برداشت شده بودند. این دو نمونه از نظر شکل و ظاهر و نوع مصرف (تازه‌خوری یا استفاده در صنعت فرآوری) و طول دوره انبارمانی متفاوت‌اند. مشخصات مورفولوژیکی و ظاهری غده‌ها در ژنوتیپ آگریا در حالت تازه (زمان برداشت) از این قرار است: شکل غده بیضی کشیده، پوست صاف تا نیمه صاف، رنگ پوست و گوشت زرد؛ این مشخصات در ژنوتیپ کلون

کارکرد ماشین بینایی ویژگی‌هایی از قبیل طول، عرض، ضخامت و حجم سیب‌زمینی را به عنوان عوامل مرتبط با پیش‌بینی طبقه‌بندی توده محاسبه کردند و به این نتیجه رسیدند که پردازش تصویر روش بالقوه موثر برای طبقه‌بندی غیرمخرب پس از برداشت است، به ویژه برای محصولاتی که در آن ویژگی‌های اندازه، شکل و سطح مهم هستند.

الملاحی و همکاران (Al-Mallahi *et al.*, 2010) با استفاده از سیستم ماشین بینایی مبتنی بر تصویربرداری با پرتو فرا بنفش به تشخیص غده‌های سیب‌زمینی پرداختند و به این نتیجه رسیدند که ۹۸/۷۹ درصد غده‌ها با موفقیت شناسایی شده‌اند. زمان مورد نیاز برای جداسازی شیء‌ها در هر تصویر حدود ۹۴ میلی‌ثانیه بود که نشان می‌دهد سیستم ماشین بینایی در کاربرد عملی در هنگام جابه‌جایی غده‌ها روی نوار نقاله توان بالایی دارد.

امیری پریان و همکاران (Amiri-Parian *et al.*, 2008) حجم سیب‌زمینی را با روش ماشین بینایی از طریق تقسیم تصویر به شکل مخروط ناقص با مقطع بیضی با دقت بالا (خطای حدود ۸/۱۵ درصد) نسبت به روش رابطه تجربی (خطای ۲۰/۵) برآورد کردند.

توکلی و نجف‌زاده (Tavakoli & Najafzadeh, 2015) از تکنیک پردازش تصویر برای جدا کردن سیب‌زمینی شکسته در خط مرتب‌سازی استفاده کردند و به این نتیجه رسیدند که ماشین بینایی سیستمی است کارآمد برای تعیین ویژگی‌های کیفی محصولات کشاورزی مانند سیب‌زمینی و روشی است غیرمخرب و غیرتهاجمی برای کنترل کیفیت محصولات غذایی.

مندوزا و همکاران (Mendoza *et al.*, 2007) ویژگی‌های رنگی و بافتی تراشه‌های سیب‌زمینی را با استفاده از ماشین بینایی بررسی کردند و به این نتیجه رسیدند که ویژگی‌های بافتی نسبت به ویژگی‌های رنگی حاوی اطلاعات بیشتری برای

R2014b. دوربین در ارتفاع ۳۰ سانتی‌متری که بهترین فاصله برای عکس‌برداری در فضای بسته است (Dowlati *et al.*, 2012) و با وضوح 3072×2304 پیکسل قرار داده شد. در محفظه نورپردازی مورد استفاده در این تحقیق از ترکیب دو نوع لامپ شامل سه ردیف دیودهای نورانی به صورت حلقوی و ۴ لامپ فلورسنت به فاصله ۹۰ درجه از هم استفاده شد (Basati *et al.*, 2018). نحوه قرارگیری لامپ‌ها به گونه‌ای بود که باعث پخش یکنواخت نور در کل محفظه می‌شد و سایه هم ایجاد نمی‌شد (شکل ۱). برای پس‌زمینه تصویر نیز از کاغذ سیاه استفاده شد. بعد از تصویربرداری از تمام نمونه‌ها، برای استخراج ویژگی‌های رنگی، مورفولوژیکی و بافتی آنها پردازش تصویرها آغاز شد.

الگوریتم استفاده شده برای استخراج ویژگی‌های تصاویر حاصل از دو نمونه سیب‌زمینی انبار شده در دو نوع انبار با شرایط مختلف و طبقه‌بندی این ژنوتیپ‌ها در چهار گروه، به صورت شکل ۲ است.

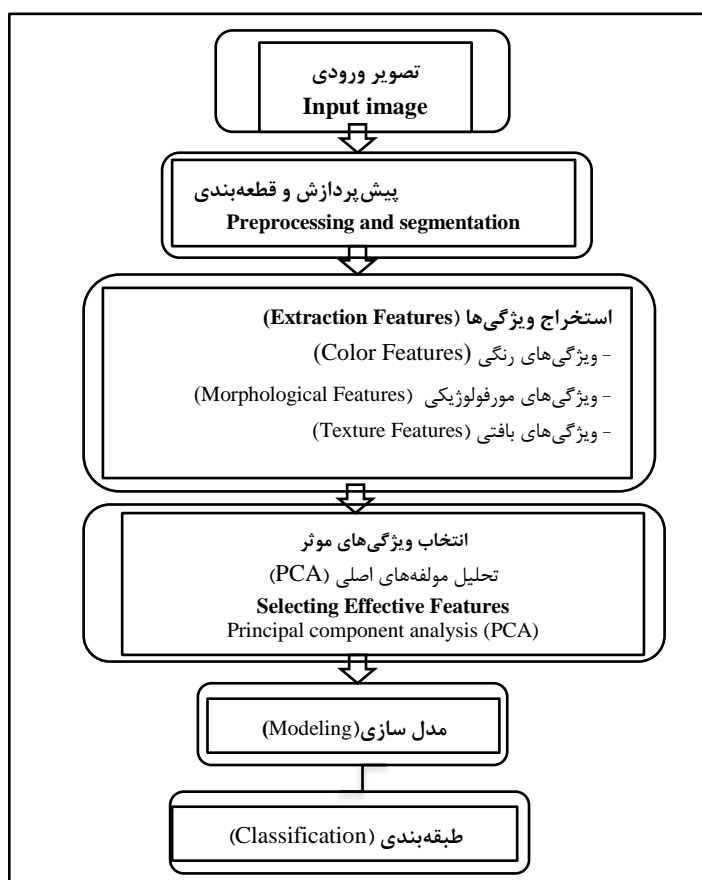
این گونه است: شکل غده تخم‌مرغی مایل به گرد، رنگ گوشت زرد روشن و پوست زرد. غده‌های سالم پس از برداشت به مدت دو هفته در دمای اتاق برای گذراندن دوره التیام بخشی قرار داده شدند. سپس یک قسمت از آنها به انبار غیرفنی با دمای متغیر ۱۵-۱۰ درجه سلسیوس و با رطوبت نسبی ۹۰ درصد و قسمت دیگر به انبار فنی با دمای ثابت ۷ درجه سلسیوس و رطوبت نسبی ۹۵ درصد انتقال داده شدند. نمونه‌ها به مدت سه ماه (بدون احتساب دوره التیام بخشی) در انبار نگهداری و پس از آن برای بررسی ویژگی‌های رنگ، بافت و شکل به آزمایشگاه بیوفیزیک دانشگاه محقق اردبیلی انتقال داده شدند.

سامانه تصویربرداری

برای تهیه تصاویر نمونه‌هایی که به صورت افقی برش خورده بودند از سامانه تصویربرداری استفاده شد که به طور ویژه برای این کار ساخته شده و شامل این بخش‌ها بود: محفظه نوردهی، دوربین عکاسی SONY مدل SC-W12 با رزولوشن ۷ مگاپیکسل، رایانه و نرم‌افزار MATLAB



شکل ۱- الف) محفظه نورپردازی و ب) شماتیکی از محفظه نورپردازی و موقعیت قرارگیری لامپ‌ها در آن
 Fig. 1. a) Lighting chamber and b) Schematic of lighting chamber and the standing position of lamps in it



شکل ۲- الگوریتم استفاده شده برای استخراج ویژگی های تصاویر حاصل از دو نمونه سیب زمینی انبار شده در دو نوع انبار
Fig. 2. The used algorithm to extract the properties of images from two stored potato samples in two types of storage

پیش پردازش تصاویر


پیش پردازش به منظور به دست آوردن تصویری بهبود یافته نسبت به تصویر اصلی است و برای استخراج اطلاعات دقیق تر و صحیح تر لازم خواهد بود. در مرحله اول، هدف جدا کردن سیب زمینی از پس زمینه است تا پردازش های بعدی فقط روی سیب زمینی متمرکز شود. این عمل که قطعه بندی نامیده می شود، بر اساس تفاوت شدت رنگ بین پس زمینه و شیء (نمونه) پیش می رود. پس از خواندن فایل تصویری (شکل ۳-ا)، با کمک روش اتسوا^۱، یکی از متداول ترین و موثرترین روش ها در انتخاب خودکار آستانه، با بیشینه کردن واریانس بین گروهی و کمینه کردن واریانس داخل گروهی پیکسل های تصویر، برای استخراج شیء از پس زمینه (Razmjoooy *et al.*, 2012)، تصویر RGB به تصویر

خاکستری تبدیل شد (شکل ۳-ب) و با دستور Graythresh با هدف آستانه گیری از کل تصویر، تصویر به صورت سیاه و سفید درآمد (شکل ۳-ج). در این فرم تصویر (که هر پیکسل فقط مقدار صفر یا یک را می تواند داشته باشد)، نمونه سیب زمینی دارای مقدار یک و زمینه صفر شد. سپس تصاویر باینری شده برچسب گذاری شدند.

در عملیات برچسب گذاری (که محدوده آن از یک تا تعداد شیء های درون تصویر باینری است) هر شیء یک عدد خاص به خود می گیرد. بعد از برچسب زنی، شیء ها شمارش شدند تا اگر بر اثر وجود نویز تعداد آنها در هر تصویر بیشتر از یک (سیب زمینی) باشد، نویزها در فیلترینگ از تصویر حذف شوند و فقط تصویر مربوط به سیب زمینی باقی بماند. این کار از طریق مساحت گیری صورت گرفت؛

به‌دست آمد و پردازش نهایی روی این تصویر دنبال شد (شکل ۳-d). برای پردازش تصاویر از نرم‌افزار MATLAB R2014b استفاده شد و ویژگی‌های استخراج شده از تصاویر به سه بخش اصلی ویژگی‌های رنگی، مورفولوژیکی و بافتی تقسیم شدند.

مساحت نوزها، در مقایسه با مساحت سیب‌زمینی، بسیار ناچیز بود و با استفاده از این ویژگی، شیء دارای مساحت بیشینه نگه داشته شد و بقیه شیء‌ها (با مساحت کمتر و به مفهومی دیگر نوزها) حذف شدند. برای پر کردن حفره‌ها نیز از دستور imfill استفاده شد. سرانجام، تصویر سیاه و سفید یکنواختی



شکل ۳- مراحل مختلف پیش‌پردازش تصاویر
Fig. 3. Different stages of image preprocessing

(Sun, 2004; Brosnan & Sun, 2004). در این تحقیق هر سه ویژگی رنگی، مورفولوژیکی و بافتی استفاده و با کد نویسی و به کمک دستورهای موجود در نرم‌افزار MATLAB استخراج شدند.

ویژگی‌های رنگی

دلیل انتخاب ویژگی‌های رنگی این است که رنگ در درک کیفیت محصولات کشاورزی و غذا بسیار مهم است و غذاها و میوه‌ها از طریق خواص ظاهریشان قیمت‌گذاری می‌شوند. در این مقاله سه فضای رنگی RGB، HSV و $L^*a^*b^*$ بررسی شده است. در ابتدا، تصاویر ارسال شده به رایانه بر اساس مدل رنگی RGB هستند. در مدل RGB هر تصویر بر اساس ماتریس‌های سه‌گانه با لایه‌های رنگ قرمز R، سبز G و آبی B مشخص می‌شود. پس از آن با انتخاب نوع مدل رنگی لازم است تا

استخراج ویژگی‌های تصاویر

از آنجا که ویژگی‌های رنگی، مورفولوژیکی و بافتی برای شناسایی محصولات کشاورزی با اهمیت‌اند و اطلاعات تعیین‌کننده‌ای برای ارزیابی کیفیت مواد غذایی، بازرسی و درجه‌بندی محصولات دارند، در این تحقیق این سه ویژگی برای هر سیب‌زمینی استخراج شده است. اخیراً نیز ترکیب این ویژگی‌ها برای کاربرد در صنایع غذایی به منظور افزایش کارایی روش‌های پیشنهادی ارائه شده است. به طور معمول، با افزایش تعداد ویژگی‌های استفاده شده، عملکرد روش‌های ارائه شده نیز می‌تواند افزایش یابد. بنابراین، برای جمع‌آوری اطلاعات بیشتر در مورد کیفیت محصولات کشاورزی و غذا از روی تصاویر، چندین ویژگی مربوط به سیستم درجه‌بندی محصولات غذایی باید پردازش شود (Du

طول موج‌های مختلف، مانند قسمت‌های قابل مشاهده و طیف فرورسرخ (مادون قرمز) تعریف شود (Haralick *et al.*, 1973). بافت تصویر و ویژگی‌های بافتی نقش مهمی در تحلیل تصویر دارند (Li *et al.*, 1999). این ویژگی‌ها اطلاعات مختصری از نقشه‌های قوی مربوط به ویژگی‌های بصری (براق بودن بافت، منظم بودن، وجود یک جهت خاص و غیره) و ویژگی‌هایی را تعریف می‌کنند که نمی‌توانند از نظر بصری متمایز باشند (Basset *et al.*, 2000). شکل ۴، سیبزمینی ذخیره شده در شرایط نامناسب (شکل ۴-الف) و در شرایط کنترل شده (شکل ۴-ب) را نشان می‌دهد. در این مقاله، ویژگی‌های بافت سیبزمینی شامل ۶ ویژگی جدول ۱ تعریف شده‌اند.

ویژگی‌های مورفولوژیکی (شکلی)

تجزیه و تحلیل شکل، برای بازرسی شیء‌ها از زاویه‌های مختلف متداول است. پارامترهای مورفولوژیکی مانند مساحت، محیط، میزان فشردگی (چگالی)، طول محور بزرگ، طول محور کوچک، نسبت ابعاد، فشردگی و گردی متداول‌ترین ویژگی‌های استخراج شده از شکل برای طبقه‌بندی یا شناسایی محصول‌اند (Blascoa *et al.*, 2009) که در این تحقیق استخراج شدند.

محاسبات برای تبدیل تصویر به حالت HSV یا $L^*a^*b^*$ دنبال شود، در حالی که تصویر اولیه همچنان بر اساس مدل RGB است.

مولفه‌های فضای رنگی HSV شامل H، فام رنگ از صفر تا ۳۶۰ درجه، S یا متوسط اشباع از صفر تا ۱ و V مجموع روشنایی یک جسم از صفر تا ۱، طبق روشی محاسبه شدند که دو و سان (Du & Sun, 2005) ارائه داده‌اند. مولفه‌های فضای رنگی $L^*a^*b^*$ نیز که رابطه‌ای غیرخطی با فضای رنگی RGB دارد، با توجه به معادلات هوانگ و همکاران (Huang *et al.*, 2013) به دست آمد. در فضای رنگی $L^*a^*b^*$ ، مولفه روشنایی است که دامنه‌ای از صفر (سیاه) تا ۱۰۰ (سفید) دارد، و پارامترهای a^* (از سبز به قرمز) و b^* (از آبی به زرد) دارای مقادیر متغیر از ۱۲۰- تا ۱۲۰ هستند (Mendoza *et al.*, 2007).

ویژگی‌های بافت

روش تجزیه و تحلیل بافت تصویر می‌تواند تفاوت‌های مکانیکی حسی را در انواع سیبزمینی و پیش‌بینی ویژگی‌های مکانیکی حسی را در سیبزمینی طبقه‌بندی کند. معنای کلمه بافت در پردازش تصویر کاملاً متفاوت از معنای معمول بافت در غذاهاست. بافت تصویر می‌تواند به عنوان سازمان فضایی (فاصله‌ای) تغییرات شدت در یک تصویر در



شکل ۴- الف) سیبزمینی ذخیره شده در شرایط نامناسب و ب) شرایط کنترل شده

Fig. 4. a) Stored potatoes under unsuitable conditions and b) controlled conditions

جدول ۱- ویژگی‌های اندازه‌گیری شده بافت سیب‌زمینی با پردازش تصویر
Table 1- Measured properties of potato texture by image processing

نام ویژگی Feature	شرح ویژگی Feature Description
متوسط سطح خاکستری (Average gray level (Agl))	$\sum_{i=0}^{L-1} z_i p(z_i)$
میانگین کنتراست (Average contrast (Ac))	$\sqrt{\mu_2(z)}$
همواری (Smoothness)	$1 - \frac{1}{(1 + \sigma^2)}$
Third moment (Thm)	$\sum_{i=0}^{L-1} (z_i - m)^3 p(z_i)$
یکنواختی (Uniformity)	$\sum_{i=0}^{L-1} p^2(z_i)$
آنترپی (Entropy)	$-\sum_{i=0}^{L-1} p(z_i) \log_2 p(z_i)$

z_i : متغیر تصادفی مربوط به شدت، $p(z_i)$: هیستوگرام سطوح شدت در یک ناحیه، L : تعداد سطوح شدت، m : میانگین مقادیر شدت

شبکه‌های پیش‌خور هستند در جعبه ابزار Neural Network نرم‌افزار MATLAB نسخه R2014b استفاده شد. در این مطالعه، لایه ورودی دارای ۷ نرون شامل Length Axis Major، Compactness، Area، L^* ، b^* و Average contrast (Ac) و Average gray level (Agl) است. لایه خروجی دارای چهار نرون ژنوتیپ اگر یا در انبار غیرفنی، اگر یا در انبار فنی، کلون در انبار غیرفنی و کلون در انبار فنی است که به ترتیب با اعداد باینری ۱۰۰۰، ۰۱۰۰، ۰۰۱۰ و ۰۰۰۱ نشان داده شده‌اند. تعداد لایه‌های پنهان تا حد امکان باید کم انتخاب شود. ابتدا شبکه با یک لایه پنهان آموزش داده شد تا در صورت عملکرد نامناسب، تعداد لایه‌های پنهان افزایش یابد. سرانجام تعداد لایه‌های مخفی و تعداد گره‌های آن با توجه به عملکرد شبکه عصبی انتخاب شد. قبل از آموزش و اعتبارسنجی به منظور کاهش خطای تخمین و مدت زمان محاسبه، داده‌ها نرمال‌سازی شدند (Sola & Sevilla, 1997). از بین الگوریتم‌های آموزش پس انتشار خطا، از الگوریتم یادگیری لونیگ-مارکوارت (که عملکرد بهتر و سریع‌تری نسبت به الگوریتم‌های دیگر دارد)، کاهش گرادیان با سرعت یادگیری تطبیقی و

تحلیل مولفه‌های اصلی (PCA)


به دلیل زیاد بودن پارامترهای مورد بررسی و صرفه‌جویی در وقت و بالا بردن دقت تجزیه و تحلیل، در این تحقیق از روش آنالیز مولفه‌های اصلی (PCA) برای گزینش مولفه‌های اصلی از میان پارامترهای اولیه و حذف اطلاعات کم‌اهمیت استفاده شد.

طبقه‌بندی (کلاسه‌بندی)

شبکه عصبی روش شبیه‌سازی و الهام‌گرفته از سیستم مغز انسان است که در سیستم‌های غیرخطی و نامعین، که روابط بین اجزا و پارامترهای سیستم به خوبی شناخته شده نیست، قادر به تحلیل و شبیه‌سازی است (Kohzadi et al., 1995). برای کلاسه‌بندی دو نمونه سیب‌زمینی انبار شده در دو انبار غیرفنی و فنی با دماهای مختلف از روش شبکه عصبی پرسپترون چند لایه (MLP) استفاده شد که یکی از مهم‌ترین ساختارهای شبکه‌های عصبی مصنوعی و مجموعه‌ای هستند از واحدهای حسی که لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی (شکل ۵) را تشکیل می‌دهند. در این پژوهش، برای طبقه‌بندی ورودی‌ها با توجه به کلاس‌های هدف، از شبکه‌های تشخیص الگو که

تعداد نورون‌ها از ۱۰ تا ۳۰ با فواصل چهارتایی تغییر داده شد و در هر دور، تا حصول دقت حداکثر، آموزش شبکه ادامه یافت. ضریب آموزش ۰/۱ و ثابت مومنتوم ۰/۱ برای پارامترهای آموزش در نظر گرفته شد. بهترین توپولوژی (ساختار) شبکه عصبی بر اساس معیار ضریب تبیین R^2 میانگین خطای مطلق MAE^2 و میانگین مربعات خطاها $RMSE^3$ مشخص شد و سرانجام توپولوژی دارای بیشترین مقدار R^2 و کمترین مقادیر MAE و $RMSE$ به‌عنوان مناسب‌ترین توپولوژی انتخاب شد.

الگوریتم بیزین و تابع انتقال tansig استفاده شد. از میان داده‌های مربوط به ۵۰۰ سیب‌زمینی، ۷۰ درصد داده‌ها برای آموزش شبکه عصبی، ۱۵ درصد برای مرحله اعتبارسنجی و ۱۵ درصد برای مرحله آزمون استفاده شد. برای غلبه بر مشکلات شبکه‌های پیشرفته‌تر، از آموزش‌های کنترل شده استفاده شد. از کمترین خطای تست در سراسر دوره آموزش برای عملکرد آزمون مدل ANN استفاده شد. برای تعیین تعداد بهینه نورون در لایه مخفی شبکه عصبی که کاری است دشوار و معمولاً با آزمون و خطا به دست می‌آید (Omid et al., 2010)،



شکل ۵- ساختار شبکه عصبی برای طبقه‌بندی دو نمونه سیب‌زمینی در دو انبار غیرفنی و فنی

Fig. 5. Neural network structure for classification of two potato samples in non-technical and technical storage

ذخیره‌سازی غده دچار جوانه‌زنی و اتلاف آب خواهد شد که تاثیر زیادی بر شکل و اندازه آن خواهد داشت. مشخص شده است اگر غده‌ها برای دوره‌ای چند ماهه ذخیره شوند، به دلیل از دست دادن رطوبت دچار کاهش قطر می‌شوند که به چروکیدگی و تغییر در اندازه غده می‌انجامد (Pringle et al., 2009). یزدان‌پناه گنگچین و ضیایی‌فر (Yazdanpanah-Gangachin & Ziaiiifar, 2014) به این نتیجه رسیدند که شاخص‌های فضای رنگی $L^*a^*b^*$ ملاک مناسبی برای بررسی کیفیت چیپس سیب‌زمینی است. احسنی و همکاران (Ahsani et al., 2014) نیز مجموعه‌ای از مولفه‌های رنگ و بافت تصاویر سیب‌زمینی را به‌عنوان بهترین پارامترها برای ارزیابی کیفیت سیب‌زمینی انتخاب کردند.

نتایج و بحث

انتخاب ویژگی‌ها

نتایج تحلیل مولفه‌های اصلی به صورت جدول ۲ به دست آمد. همان‌طور که مشاهده می‌شود، از میان ۲۹ ویژگی، دو پارامتر L^* و b^* (از میان ویژگی‌های رنگی)، سه پارامتر Length Axis Major، Compactness و Area (از میان ویژگی‌های مورفولوژیکی) و دو پارامتر Average contrast (Ac) و Average gray level (Agl) (از میان ویژگی‌های بافتی) به‌عنوان ویژگی‌هایی انتخاب شدند که می‌توانستند بیشترین تاثیر را در شناسایی ۴ نمونه سیب‌زمینی داشته باشند. ویژگی‌های مورفولوژیکی بیشترین تعداد ویژگی موثر در این طبقه‌بندی را دارند زیرا سیب‌زمینی در دوره

1- Coefficient of Determination
3- Root Mean Square Error

2- Mean Absolute Error

جدول ۲- نتایج تحلیل مولفه‌های اصلی
Table 2. Principal Component Analysis results

منبع Reference	توضیحات ویژگی Feature description	نام ویژگی Name of feature	ویژگی Feature
Huang <i>et al.</i> , 2013	مولفه روشنایی از آبی به زرد	L* b*	ویژگی‌های رنگی Color feature
Gonzalez <i>et al.</i> , 2004	با شمارش پیکسل‌های موجود در هر ناحیه محاسبه می‌شود	مساحت	
Shouche <i>et al.</i> , 2001	$\frac{4\pi(\text{مساحت})}{(\text{محیط})^2}$ طول قطر بزرگ یک بیضی که گشتاورهای	فشرده‌گی (تراکم)	ویژگی‌های شکلی Shape features
ElMasry <i>et al.</i> , 2012	مرکزی ثانویه نرمال شده یکسانی با ناحیه مورد نظر دارد و بر حسب پیکسل است	طول محور بزرگ	
Gonzalez <i>et al.</i> , 2004	$\sum_{i=0}^{L-1} z_i p(z_i)$ $\sum_{i=0}^{L-1} (z_i - m)^2 p(z_i)$	میانگین سطح خاکستری میانگین کنتراست (وضوح)	ویژگی‌های بافتی Textural features

z_i : متغیر تصادفی مربوط به شدت، $p(z_i)$: هیستوگرام سطوح شدت در هر ناحیه، L : تعداد سطوح شدت، m : میانگین مقادیر شدت

بالاتری دارد. کمترین دقت عملکرد در الگوریتم آموزشی بیزین با ضریب تعیین ۶۹/۳۶ درصد دیده شد.

در نتیجه، مدل شبکه عصبی با الگوریتم یادگیری لورنبرگ مارکوارت با داشتن ۷ نرون در لایه ورودی، ۲۲ نرون در لایه مخفی و ۴ نرون در لایه خروجی با داشتن کمترین میانگین مربعات خطا ۰/۰۱۲ و بیشترین ضریب تعیین (تبیین) ۹۵/۰۱ درصد به عنوان مدلی بهینه در طبقه‌بندی ژنوتیپ‌های سیب‌زمینی ذخیره شده در دو دمای متفاوت شناخته شد. در تحقیقات مشابه، حافظی و همکاران (Hafezi *et al.*, 2016) در پژوهشی در زمینه سرعت فرآیند خشک کردن ورقه‌های سیب‌زمینی و جعفرلو و فرخی تیمورلو (Jafarlou & Farrokhi-Teimourlou, 2014) برای برآورد حجم سیب به این نتیجه رسیدند که الگوریتم لورنبرگ-مارکوارت نتایج بهتری نسبت به دیگر الگوریتم‌های آموزشی دارد.

نتایج طبقه‌بندی (کلاسه‌بندی) از طریق شبکه عصبی

از میان توپولوژی‌های مختلف مربوط به طبقه‌بندی شبکه عصبی، توپولوژی ۴-۲۲-۷ با میانگین ضریب تبیین ($R^2 = 0/86$)، میانگین مربعات خطاها ($RMSE = 0/0053$) و میانگین خطای مطلق ($MAE = 0/0077$) بیشترین دقت را در طبقه‌بندی دو نمونه سیب‌زمینی، بعد از ذخیره‌سازی در دو دمای مختلف، داشت.

این توپولوژی، به دلیل همین دقت بالاتر، برای بررسی عملکرد شبکه عصبی انتخاب شد (جدول ۳).

نتایج حاصل از عملکرد الگوریتم‌های مختلف آموزشی شبکه عصبی مصنوعی در جدول ۴ نشان می‌دهد که الگوریتم آموزشی لورنبرگ-مارکوارت (LM) با ۹۵/۰۱ درصد تشخیص صحیح نسبت به توابع، در طبقه‌بندی ژنوتیپ‌های سیب‌زمینی ذخیره شده در دو دمای مختلف دقت

جدول ۳- نتایج طبقه بندی (کلاسه بندی) شبکه عصبی

Table 3. Neural network classification results

R ²	MAE	RMSE	کلاس Class	توپولوژی شبکه عصبی Neural Network Topology
0.914	0.0023	0.0013	1000	
0.850	0.0162	0.010	0100	
0.834	0.0059	0.0042	0010	7-22-4
0.875	0.0065	0.0054	0001	
0.860	0.0077	0.0053	میانگین	

جدول ۴- عملکرد الگوریتم های مختلف آموزشی در طبقه بندی دو ژنوتیپ سیب زمینی ذخیره شده در دو دمای متفاوت

با استفاده از شبکه عصبی مصنوعی

Table 4- Performance of different educational algorithms for classification of two potato genotypes stored at two different temperatures using Artificial Neural Network

RMSE	R ²	تعداد لایه مخفی Number of hidden layers	الگوریتم آموزشی Educational Algorithm
0.012	0.9501	22	LM
0.028	0.8342	22	کاهش گرادیان Gradient Descent
0.105	0.6936	22	الگوریتم بیزین Bayesian Algorithm
0.043	0.7237	22	تابع انتقال tansig Function tansig

به ترتیب ۹۲/۴ و ۹۰/۳ درصد است. محققان با کمک تکنیک های ماشین بینایی و شبکه عصبی چهار کلاس بادام را با دقت ۹۶/۹۲ (Teimouri *et al.*, 2016) واریته های برنج را با دقت ۹۰/۵ درصد (Zhao-Yan & Fang, 2005) و گوجه فرنگی را با دقت ۹۵-۸۱ درصد (Izadi *et al.*, 2014) طبقه بندی کردند.

نتایج حاصل از طبقه بندی دو نمونه سیب زمینی انبار شده در دو نوع انبار به کمک شبکه عصبی MLP با الگوریتم آموزش لونیبرگ-مارکوارت (LM) در جدول ۵ دیده می شود. در این جدول، میزان شناسایی سیب زمینی ژنوتیپ اگر یا در انبار غیرفنی و فنی به ترتیب ۸۹/۲ و ۸۷/۶ درصد، و در مورد سیب زمینی ژنوتیپ کلون در انبار غیرفنی و فنی

جدول ۵- نتایج شناسایی صحیح (درصد) نمونه های سیب زمینی مورد مطالعه

Table 5. Results of correct identification (percentage) of studied potato samples

0001	0010	0100	1000	طبقه بندی Classification
2.2%	3.2%	5.4%	89.2%	1000
5.2%	2.3%	87.6%	4.9%	0100
3.6%	92.4%	2.2%	1.8%	0010
90.3%	1.8%	3.8%	4.1%	0001

شکل و بافت نمونه باشد در صنایع غذایی بسیار مفید است، زیرا در حال حاضر می‌توان مقدار زیادی از اطلاعات را از اندازه گیری‌های سطح پیکسل به دست آورد و این امکان را برای توصیف بهتر مواد غذایی و بهبود کنترل کیفیت فراهم کرد. بنابراین، در کنار استفاده از ویژگی‌های ذکر شده در این مطالعه، یک ابزار مدل‌سازی مانند شبکه عصبی برای ایجاد یک سیستم ارزیابی غیرمخرب و دقیق نیز لازم است.

نتیجه‌گیری

توانایی ماشین بینایی به همراه شبکه عصبی مصنوعی در تشخیص نمونه‌های سیب‌زمینی انبار شده در دو نوع انبار با شرایط مختلف بررسی شد. نتایج بررسی‌ها نشان می‌دهد که سیستم ماشین بینایی با سرعت و دقت بالا بر اساس ویژگی‌های رنگی، مورفولوژیکی و بافتی می‌تواند تغییرات موجود در دو نمونه سیب‌زمینی را که در شرایط مختلف انبار شده‌اند بعد از دوره سه ماهه انبارمانی تشخیص دهد. بالاترین دقت طبقه‌بندی مربوط به ژنوتیپ کلون موجود در انبار غیرفنی و در حدود ۹۲/۴ درصد به دست آمده است. دلیل بالا بودن این میزان دقت می‌تواند تلف شدن کمتر رطوبت در سیب‌زمینی‌هایی باشد که در محیط کنترل شده و مناسب نگهداری می‌شوند. این سیب‌زمینی‌ها از لحاظ ظاهری کمتر دچار افت کیفی می‌شوند. بدین ترتیب با شرایط کنترلی ذکر شده در این تحقیق می‌توان سیب‌زمینی را تا ۶ ماه نگهداری کرد. فناوری ماشین بینایی، سطح بالایی از انعطاف‌پذیری و تکرارپذیری را با هزینه نسبتاً کم و با عملکرد و دقت نسبتاً بالا فراهم می‌کند بنابراین پیشنهاد می‌شود از این فناوری به دلیل غیرمخرب بودن و دقت و سرعت بالا و استفاده کمتر از نیروی انسانی، علاوه بر

نتایج مربوط به شبکه عصبی نشان داد که این سیستم توانایی بالایی در تشخیص بر اساس رنگ، شکل و بافت را دارد. در میان الگوریتم‌های مختلف آموزشی، الگوریتمی که بهترین عملکرد را در محاسبه ویژگی‌های ذکر شده نشان داد، الگوریتم آموزشی لوبنبرگ-مارکوارت (LM) با کمترین میانگین مربعات خطا ۰/۰۱۲ و بیشترین ضریب تعیین (تبیین) ۹۵/۰۱ درصد بود که نسبت به توابع دیگر در طبقه‌بندی ژنوتیپ‌های سیب‌زمینی دقت بیشتری دارد و عملکردی خوب در مدت زمانی کوتاه برای آزمایش‌های آینده تضمین می‌کند. میزان تشخیص نمونه‌ها بین ۸۷/۶ تا ۹۲/۴ درصد بود. محققان زیادی برای طبقه‌بندی سیب‌زمینی از ماشین بینایی استفاده کرده‌اند از جمله سو و همکاران (Su et al., 2017) با دقت طبقه‌بندی ۹۳ درصد، ژو و همکاران (Zhou et al., 1998) با دقت طبقه‌بندی ۸۶/۵ درصد (که تقریباً نزدیک است به نتایج به دست آمده از این مطالعه)، الملاحی و همکاران (Al-Mallahi et al., 2010) با دقت طبقه‌بندی ۹۸/۷۹ درصد، المصری و همکاران (ElMasry et al., 2012) با دقت طبقه‌بندی ۹۶/۲ درصد و احسنی و همکاران (Ahsani et al., 2014) با دقت طبقه‌بندی ۹۸/۰۱ درصد نتایج بهتری نسبت به این مطالعه برای طبقه‌بندی سیب‌زمینی مبتنی بر ماشین بینایی به دست آوردند. باید توجه داشت که در زمان استفاده از این سیستم برای غده کامل سیب‌زمینی، نقص‌ها و مشکلاتی همچون وجود گل و لای روی نمونه، قرارگرفتن نمونه‌ها روی هم و جهت‌گیری‌های مختلف نمونه ممکن است تاثیر منفی بر طبقه‌بندی و تشخیص نمونه‌ها داشته باشد و دقت کار را پایین آورد که این نقص را می‌توان در شبکه عصبی با انتخاب صحیح پارامترها و معماری خوب حل کرد. به طور حتم برای بررسی کیفیت محصولات، سیستمی که بر حسب اندازه‌گیری رنگ،

تشخیص ارقام سیب‌زمینی برای تشخیص انواع پس از برداشت، درجه‌بندی و جداسازی در صنعت آسیب‌های ناشی از مراحل کاشت، برداشت و بسته‌بندی و ... استفاده شود.

مراجع

- Ahsani, M. J., Mahna, F., & Shokohi-Rostami, A. (2014). *An effective method for assessing the quality of potato based machine vision. National Conference on Computer Engineering and Information Technology Management*. May 29. Tehran, Iran. (in Persian)
- Al-Mallahi, A., Kataoka, T., Okamoto, H., & Shibata, Y. (2010). Detection of potato tubers using an ultraviolet imaging-based machine vision system. *Journal of Biosystems Engineering*, 105, 257- 265.
- Amiri-Parian, J., Khoshtaghaza, M. H., Kabir, E., & Minaei S. (2008). Volume estimation of potatoes using image processing. *Journal of Agricultural Engineering Research*, 8(4), 113-126.
- Basati, Z., Rasekh, M., & Abbaspour-gilandeh, Y. (2018). Using different classification models in wheat grading utilizing visual features. *International Agrophysics*, 32, 1-11.
- Basset, O., Buquet, B., Abouelkaram, S., Delachartre, P., & Culioli, J. (2000). Application of texture image analysis for the classification of bovine meat. *Food Chemistry*, 69(4): 437-445.
- Blascoa, J., Aleixos, N., Gómez-Sanchi's, J., & Molto, E. (2009). Recognition and classification of external skin damage in citrus fruits using multispectral data and morphological features. *Biosystems Engineering*, 103, 137-145.
- Brosnan, T., & Sun, D. (2004). Improving quality inspection of food products by computer vision-a review. *Journal of Food Engineerig*, 61, 125–135.
- Connor, C. J., Fisk, K. J., Smith, B. J., & Melton L. D. (2001). Fat uptake in french fries as affected by different potato varieties and processing. *Journal of Food Science*, 66(6), 903-908.
- Dacal-Nieto, A., Vázquez-Fernández, E., Formella, A., Martin, F., & Torres-Guijarro, S. (2009). *A genetic algorithm approach for feature selection in potatoes classification by computer vision. Industrial Electronics, 35th Annual Conference of Industrial Electronics*. Nov. 3-5. Portugal. 48, 1955–1960.
- Dowlati, M., Guardia M., & Mohtasebi S. S. (2012). Application of machine-vision techniques to fish-quality assessment. *Trac Trends in Analytical Chemistry*, 40, 168-179.
- Du, C. J., & Sun, D. W. (2004). Recent developments in the applications of image processing techniques for food quality evaluation. *Trends in Food Science and Technology*, 15, 230-249.
- Du, C. J., & Sun, D. W. (2005). Comparison of three methods for classification of pizza topping using different colour space transformations. *Journal of Food Engineering*, 68(3), 277-287.
- ElMasry, G., Cubero, S., Moltó, E., & Blasco, J. (2012). In-line sorting of irregular potatoes by using automated computer-based machine vision system. *Journal of Food Engineering*, 112, 60-68.

- Gomez-Galindo, F., Sjöholm, I., Rasmusson, A., Widell, S., & Kaack, K. (2007). plant stress physiology: opportunities and challenges for the food industry. *Critical Reviews in Food Science & Nutrition*, 47, 749-763.
- Gonzalez, R. C., Woods, R. E., & Eddins, S.L. (2004). *Digital Image Processing Using MATLAB*. Prentice-Hall Press, USA.
- Hafezi, N., Sheikhe-Davoodi, M. J., & Sajjadih, S. M. (2016). A study of drying rate of sliced potatoes during radiation-vacuum drying process using regression and Artificial Neural Network models. *Journal of Biosystem Engineering*, 47(2), 279-289. (in Persian)
- Haralick, R. M., Shanmugam, K., & Dinstein, I. (1973). Textural features for image classification. *IEEE Transactions on Systems, Man and Cybernetics SMC*, 3(6), 610-621.
- Huang, Z. K., Hou, L. Y., & Li, Z. H. (2013). Image clustering using graph cuts in LAB color space. *International Journal of Digital Content Technology and its Applications*, 7(12), 1-7.
- Izadi, H., Kamgar, S., & Raoufat, M. H. (2014). Tomato grading system using machine vision technology and neuro-fuzzy networks (ANFIS). *Journal of Agricultural Machinery*, 6(1): 49-59. (in Persian)
- Jafarlou, M., & Farrokhi Teimourlou, R. (2014). Estimation of apple volume and its shape indentation using image processing technique and neural network. *Journal of Agricultural Machinery*, 4(1), 57-64. (in Persian)
- Kohzadi, N., Boyd, M., Kaastra, I., Kermanshahi, B., & Scuse, D. (1995). Neural networks for forecasting: An introduction. *Canadian Journal of Agricultural Economics*, 43, 463-474.
- Li, J., Tan, J., Martz, F. A., & Heymann, H. (1999). Image textural features as indicators of beef tenderness. *Meat Science*, 53(1): 17-22.
- Mendoza, F., & Aguilera, J. M. (2004). Application of image analysis for classification of ripening bananas. *Journal of Food Science*, 69, 471-477.
- Mendoza, F., Dejmek, P., & Aguilera, J. M. (2007). Colour and image texture analysis in classification of commercial potato chips. *Food Research International*, 40, 1146-1154.
- Omid, M., Mahmoudi, A., & Omid M. H. (2010). Development of pistachio sorting system using Principal Component Analysis (PCA) assisted Artificial Neural Network (ANN) of impact acoustics. *Expert Systems with Applications*, 37, 7205-7212.
- Pedreschi, F. (2012). Frying of potatoes: physical, chemical, and microstructural changes. *Drying Technology*, 30, 707-725.
- Pedreschi, F., Mery, D., Mendoza, F., & Aguilera, J. M. (2004). Classification of potato chips using pattern recognition. *Journal of Food Science*, 69(6), 264-270.
- Pringle, B., Bishop, C., & Clayton, R. (2009). *Potatoes Postharvest*. First Edition. CABI, UK.
- Rady, A. M., & Guyer D. E. (2015). Rapid and/or nondestructive quality evaluation methods for potatoes: A review. *Computer and Electronic in Agriculture*, 117, 31-48.
- Razmjoooy, N., Mousavi, B. S., & Soleymani, F. (2012). A real-time mathematical computer method for potato inspection using machine vision. *Journal of Computers and Mathematics with Applications*, 63(1), 268-279.
- Shouche, S. P., Rastogi, R., Bhagwat, S. G., & Sainis J. K. (2001). Shape analysis of grains of Indian wheat varieties. *Computers and Electronics in Agriculture*, 33, 55-76.

- Sola, J., & Sevilla, J. (1997). Importance of data normalization for the application of neural networks to complex industrial problems. *IEEE Transactions on Nuclear Science*, 44(3), 1464-1468.
- Spychalla, J. P., & Desborough, S. L. (1990). Fatty acids, membrane permeability, and sugars of stored potato tubers. *Plant Physiology*, 94, 1207-1213.
- Su, Q., Kondo, N., Li, M., Sun, H., & Al Riza, F. D. (2017). Potato feature prediction based on machine vision and 3D model rebuilding. *Computers and Electronics in Agriculture*, 137, 41-51.
- Tavakoli, M., & Najafzadeh, M. (2015). Application of the image processing technique for separating sprouted potatoes in the sorting line. *Journal of Applied Environmental and Biological Sciences*, 4(11S), 223-227.
- Teimouri, N., Omid, M., Mollazade, K., & Rajabipour, A. (2016). Separation of touching almonds and their quality classification by combining image processing and artificial neural networks techniques. *Journal of Biosystem Engineering*, 46(4), 355-362. (in Persian)
- Yazdanpanah-Gangachin, M., & Ziaifar, A. M. (2014). Evaluation of potato chips color using image processing. *Journal of Food Research*. 24(2), 239-247. (in Persian)
- Zhao-Yan, L., & Fang, C. (2005). Identification of rice seed varieties using neural network. *Journal of Zhejiang University Science*. 6B(11), 1095-1100.
- Zhou, L., Chalana, V., & Kim, Y. (1998). PC-based machine vision system for real-time computer-aided potato inspection. *Image Computing Systems Laboratory, Department of Electrical Engineering*, 9(6), 423-433.



Research Paper

Identify of Potato Genotypes by Combining Machine Vision Techniques and Neural Networks after the Storage Period

R. Farhadi, A. H. Afkari-Sayyah*, B. Jamshidi and A. Mosapour-Gorji

*Corresponding Author: Associate Professor, Department of Biosystem Engineering, Faculty of Agricultural and Natural Resources, University of Mohaghegh-Ardabili, Ardabil, Iran. Email: acafkari@gmail.com

Received: 5 January 2019, Accepted: 1 July 2019

Abstract

Potato storage is essential to ensure the continued supplying of potatoes to consumers and the potato processing industry. During storage, physiological changes and water loss lead to changes in color, shape, size, and texture of potatoes. Therefore, there is a need for a quick and accurate method to measure the quality of the product. In this study, machine vision and neural network methods were used in classification and modeling of two stored potato samples (Agria and Clone 8-397009) under constant and variable conditions. Among 29 measured parameters relating to color, texture and morphological features of potato, some features were selected as the main parameters to monitor the changes in product during storage period: Major Axis Length, Compactness, and area (morphological features), L^* and b^* (color features) and Average contrast (A_c) and Average gray level (A_{gl}) (texture features). Among the training algorithms, Levenberg–Marquardt (LM) training algorithm with the lowest root mean square error ($RMSE=0.012$) and the highest coefficient of determination ($R^2=95.01$) were considered as an optimal model for classification of two samples stored in non-technical and technical storage. The accuracy of identification of the Agria genotype was 89.2% and 87.6%, and the accuracy of the genotype Clone 8-397009 was 92.4% and 90.3%, in non-technical and technical storage respectively.

Keywords: Classification, Machine Vision, Physiological Changes, Quality