



بررسی تاثیر پوشش دهی با امولسیون صمغ فارسی حاوی روغن شاهدانه بر تغییرات جرم و حجم انگور طی نگهداری در سردخانه با استفاده از سیستم های بینایی ماشین و یادگیری ماشین

علی گنجلو^۱، محسن زندی^{۲*}، ماندانا بی مکر^۱، ابوالفضل قره باغی^۳

۱- دانشیار، گروه علوم و مهندسی صنایع غذایی، دانشکده کشاورزی، دانشگاه زنجان، زنجان، ایران

۲- استادیار، گروه علوم و مهندسی صنایع غذایی، دانشکده کشاورزی، دانشگاه زنجان، زنجان، ایران

۳- دانش آموخته کارشناسی، گروه علوم و مهندسی صنایع غذایی، دانشکده کشاورزی، دانشگاه زنجان، زنجان، ایران

چکیده

اطلاعات مقاله

در این پژوهش تاثیر پوشش خوراکی صمغ فارسی (۰، ۱/۵ و ۳ درصد) حاوی روغن شاهدانه (۰، ۰/۰۷۵ و ۰/۱۵ درصد) بر تغییرات جرم و حجم طی نگهداری در دمای ۴ درجه سلسیوس به مدت ۲۸ روز بررسی گردید. سیستم بینایی ماشین به همراه انواع روش های یادگیری ماشین برای استخراج تصویر انگور از تصویر و تخمین جرم و حجم بر اساس خصیصه های تصویر (طول، عرض، ارتفاع و سطح) استفاده شد. برای پیش بینی جرم و حجم حبه انگور ۴ مدل یادگیری ماشین شامل رگرسیون خطی (LR)، شبکه عصبی مصنوعی (ANN)، ماشین بردار پشتیبان بر پایه تابع شعاعی (RBF-SVR) و ماشین بردار پشتیبان بر پایه تابع خطی (LBF-SVR) توسعه یافت. به منظور بررسی کارایی مدل های توسعه یافته داده های تخمین جرم و حجم انگور با داده های تجربی مقایسه گردید. جرم و حجم طی نگهداری در کل تیمارها کاهش یافت. از طرفی تغییرات جرم و حجم با افزایش غلظت صمغ فارسی و روغن شاهدانه کاهش یافت. بر اساس نتایج ارزیابی مدل، عملکرد پیش بینی مدل RBF-SVR در مقایسه با مدل های LR، ANN و LBF-SVR دقیق تر بود و توانست جرم و حجم را به ترتیب با ضریب تبیین ۰/۹۹۸ و ۰/۹۸۹ تخمین بزند که نشان دهنده همبستگی خوب بین نتایج واقعی و پیش بینی است. این نتایج تأیید می نماید که مدل SVR ابزاری قابل قبول در تخمین جرم و حجم انگور پوشش دار شده طی نگهداری در دمای سردخانه است.

تاریخ های مقاله:

تاریخ دریافت: ۹۹/۰۹/۱۴

تاریخ پذیرش: ۹۹/۱۱/۰۷

کلمات کلیدی:

پوشش دهی،

پردازش تصویر،

ماشین بردار پشتیبان،

شبکه عصبی مصنوعی،

پیش بینی.

DOI: 10.52547/fsct.18.04.13

* مسئول مکاتبات:

Zandi@znu.ac.ir

۱- مقدمه

اندازه، شکل، حجم و جرم مواد غذایی شامل میوه‌ها، غلات، آجیل‌ها و سبزی‌ها نقشی اساسی و مهمی طی فراوری مواد غذایی و میزان پذیرش مصرف‌کننده دارند؛ این خصیصه‌ها به‌عنوان ویژگی‌های کیفی ظاهری محصولات غذایی است [۱-۴]. در بسیاری از موارد اندازه، شکل، جرم و حجم مواد غذایی طی فراوری تغییر می‌نمایند؛ به‌عنوان مثال تغییر حجم توده میوه‌ها و سبزی‌ها طی فرآیند خشک‌شدن [۱، ۳، ۵] یا تغییر جرم و حجم میوه‌ها و سبزی‌ها طی نگهداری در سردخانه یا انبار [۶-۹]؛ همچنین ممکن است این خصیصه‌ها در درجه کیفی محصول نهایی موثر باشند؛ به‌عنوان مثال اندازه برنج یک ویژگی بسیار مهم می‌باشد که به‌طور قابل توجهی بر پذیرش مصرف‌کننده از درجه کیفی و قیمت آن تأثیر می‌گذارد [۲] و یا اندازه مغز بادام یا پسته در صنعت آجیل‌ها نقش مهمی در تعریف درجه کیفی آن در سطح بین‌المللی در این صنعت دارد [۱۰، ۱۱]. از این رو تخمین حجم، جرم و اندازه در صنعت غذا بسیار حائز اهمیت می‌باشد. اندازه‌گیری این خصیصه‌ها با استفاده از روش‌های معمول مانند استفاده از ترازو یا اندازه‌گیری ابعاد و یا روش‌های جایجایی مایع و جامد اگرچه دارای دقت مناسبی هستند ولی اغلب زمان‌بر، ناکارآمد و نامقرون به صرفه می‌باشند [۳، ۱۱]. اخیراً، استفاده از سیستم‌های ترکیبی ماشین بینایی^۱ به همراه تکنیک یادگیری ماشین^۲ برای تخمین اندازه، حجم و جرم میوه‌ها، غلات، آجیل‌ها و سبزی‌ها به‌منظور جداسازی کیفی یا بررسی تغییرات آنها طی نگهداری یا فراوری به‌کار گرفته شده است [۶، ۱۰-۱۴].

سیستم بینایی ماشین که با تکیه بر تجزیه و تحلیل تصویر عمل می‌نماید از روش‌های جدیدی مبتنی بر هوش مصنوعی است که به‌طور روزافزونی در صنعت غذا به‌کار برده می‌شود [۸]. تحولات اخیر در فناوری‌های تصویربرداری و تجزیه و تحلیل آن سبب افزایش دقت و کارایی این سیستم‌ها گردیده است [۲]. سیستم‌های بینایی ماشین به‌عنوان بخشی جدایی‌ناپذیر از صنایع غذایی برای ارزیابی کیفی سریع، دقیق، غیر مخرب و ارزان در حال توسعه است و به‌طور گسترده‌ای برای بازرسی کیفی و

تخمین جرم، ابعاد، شکل، حجم و تغییرات آنها در بسیاری از انواع مواد غذایی استفاده می‌گردد [۴، ۹]. برخی از محققان از تکنیک‌های بر پایه تجزیه و تحلیل تصویر برای تخمین خصیصه‌های شکلی، حجمی و جرمی استفاده نموده‌اند؛ از آن جمله می‌توان به پیش‌بینی اندازه تخم‌مرغ با کمک بینایی ماشین و شبکه عصبی مصنوعی (ANN)^۳ [۴]، طبقه‌بندی شکلی سبب‌زمنی با استفاده از سیستم بینایی ماشین و با کمک تصاویر دو بعدی و سه بعدی [۹، ۱۵]، استفاده از تکنیک پردازش تصویر به‌منظور تخمین جرم و حجم میوه‌هایی نظیر پرتقال، سیب و لیمو [۱۶]، تخمین اندازه و جرم آجیل‌هایی نظیر پسته و بادام [۱۰، ۱۱]، [۱۳، ۱۷]، استفاده از بینایی ماشین و الگوریتم یادگیری ماشین برای تخمین جرم و حجم گوجه‌فرنگی گیلانی [۶، ۱۸]، استفاده از بینایی ماشین به‌منظور تخمین تغییرات حجم برگه سبب طی فرآیند خشک کردن [۳، ۵]، تخمین اندازه دانه‌های غلات مانند برنج با استفاده از روش پردازش تصویر [۲، ۱۲، ۱۴] و تعیین نسبت شکلی^۴ و وزن ملون‌های زرد با کمک سیستم بینایی ماشین [۱۹] اشاره نمود.

پژوهش‌های پیشین نشان دادند که استفاده از تکنیک یادگیری ماشین مانند شبکه عصبی مصنوعی و ماشین بردار پشتیبان (SVM)^۵ سرعت عملکرد سیستم بینایی ماشین و قابلیت اطمینان به آن را بهبود بخشیده است و ترکیب این دو روش با هم می‌تواند سیستمی قدرتمند برای فرایندهای پیش‌بینی و طبقه‌بندی در مواد غذایی ایجاد نماید [۲، ۴، ۱۱]. یادگیری ماشین به‌عنوان زیر مجموعه‌ای از هوش مصنوعی این امکان را فراهم می‌آورد تا با توسعه مدل‌های مختلف از داده‌ها برای یادگیری خود استفاده نماید؛ مدل‌های یادگیری ماشین روشی منحصر به فرد برای ایجاد یک سیستم مدل پیش‌بینی در قالب یک مجموعه داده شناخته شده را ارائه می‌دهند [۱۲]. یوتای و همکاران (۲۰۱۹) جرم میوه انبه را با دقت بالای ۹۷ درصد توسط شبکه عصبی مصنوعی و سیستم پردازش تصویر تخمین زدند. این تخمین با استفاده از طول، عرض، ضخامت و سطح انبه انجام شد [۲۰]. جرم و حجم گوجه‌فرنگی گیلانی با کمک تصاویر دو بعدی و سه بعدی و

3. Artificial Neural Networks (ANN)
4. Shape ratio
5. Support Vector Machine (SVM)

1. Machine vision
2. Machine learning

بهترین تکنیک و تعیین کمیت خطاها و عدم قطعیت مرتبط با پیش‌بینی‌ها انجام پذیرفت. الگوریتم ماشین یادگیری توسعه یافته در این مطالعه می‌تواند ابزاری بسیار مفید جهت بررسی تغییرات ظاهری انگور در سرخانه باشد.

۲- مواد و روش‌ها

۲-۱- تهیه مواد اولیه، پوشش‌دار کردن خوشه‌های

انگور و نگهداری

انگور، صمغ فارسی و روغن شاهدانه از بازار محلی (زنجان، ایران) تهیه گردید. خوشه‌های انگور سالم پس از شستشو، ضدعفونی کردن سطحی (با محلول هیپوکلریت سدیم ۰/۱ درصد به مدت ۱۵ دقیقه) و خشک‌شدن آب سطحی آن، مورد استفاده قرار گرفت. محلول صمغ فارسی با سه غلظت ۰، ۱/۵ و ۳ درصد از طریق انحلال آرام صمغ در آب و همزدن توسط یک همزن مغناطیسی به مدت ۳ ساعت در دمای اتاق و در نهایت آب‌گیری به مدت یک شب در دمای یخچال، تهیه گردید. برای تهیه محلول پوشش‌دهی ابتدا گلیسرول (۰/۳ درصد وزنی/حجمی) و سپس روغن شاهدانه با غلظت‌های ۰، ۰/۰۷۵ و ۰/۱۵ درصد (وزنی/حجمی) و توئین ۸۰ (با غلظتی مشابه روغن شاهدانه) به ترتیب در دمای اتاق به محلول صمغ فارسی تهیه‌شده، اضافه گردید و همزدن با کمک همزن مغناطیسی به مدت ۳۰ دقیقه بعد از افزودن گلیسرول و روغن شاهدانه (به همراه توئین ۸۰) انجام شد. امولسیون نهایی با استفاده از هم‌وزنایزر (M-TOPS-SR30، کره جنوبی) با سرعت ۱۵۰۰۰ دور در دقیقه به مدت ۵ دقیقه تهیه گردید. پوشش‌دار کردن خوشه‌های انگور به روش غوطه‌وری در دمای اتاق به مدت ۵ دقیقه و در دو مرحله با فاصله زمانی ۲ دقیقه انجام شد و محلول اضافه از طریق قرار دادن خوشه‌ها روی یک توری فلزی حذف گردید. پس از خشک شدن کامل پوشش سطحی، خوشه‌ها به مدت ۲۸ روز در دمای 1 ± 4 درجه سلسیوس و رطوبت نسبی ۶۵ درصد نگهداری شدند.

ماشین بردار پشتیبان با دقت بالای ۹۶ درصد در پژوهشی توسط نیالا و همکاران (۲۰۱۹) پیش‌بینی گردید [۱۸]. تلفیق موفقیت‌آمیز روش بینایی ماشین و یادگیری ماشین برای تخمین جرم، وزن، حجم و شکل توسط سایر محققان نیز ارائه شده است [۲، ۴، ۱۱-۱۳، ۱۷].

انگور یکی از محصولات باغی رایج در جهان است که متعلق به خانواده *Vitaceae* می‌باشد. این میوه نافرازگرا روی بوته می‌رسد و پس از برداشت تقریباً مواد نشاسته‌ای جهت تبدیل شدن به قندهای ساده ندارد، از این رو طی نگهداری فعالیت فیزیولوژیکی اندکی دارد [۲۱، ۲۲]. با این حال این میوه پس از برداشت و طی نگهداری به کاهش آب (چروکیدگی حبه) و آلودگی‌های قارچی بسیار حساس است و معمولاً چروکیدگی و ریزش حبه‌ها، قهوه‌ای شدن چوب خوشه و پوسیدگی میوه از عوامل اصلی کاهش کیفیت میوه در مراحل پس از برداشت می‌باشد و کاهش بیش از ۵ درصد رطوبت انگور، سبب چروکیدگی حبه آن می‌گردد. عمر نگهداری میوه‌ها به شدت تحت تأثیر شرایط نگهداری می‌باشد [۲۱، ۲۳]. فرآیندهای پس از برداشت نظیر استفاده از پوشش‌های خوراکی سبب کاهش سرعت تغییرات فیزیکی و شیمیایی انگور می‌گردد [۲۴]؛ صمغ فارسی یکی از ترکیبات پلی‌ساکاریدی مناسب به‌عنوان پوشش می‌باشد که از ترشحات موجود در پوسته درخت بادام به‌دست می‌آید؛ این صمغ به سبب خواص چسبندگی مناسب پوششی یکنواخت و شفاف ایجاد می‌نماید [۲۵-۲۷] و سبب کاهش از دست دادن رطوبت می‌گردد؛ افزودن روغن شاهدانه به پوشش صمغ فارسی نیز به دلیل ماهیت آبگریزی سبب بهبود خواص ممانعت‌کنندگی پوشش می‌گردد و به دلیل خواص ضد میکروبی از آلودگی‌های قارچی می‌کاهد.

هدف کلی این مطالعه طراحی و توسعه روش جدیدی مبتنی بر فناوری بینایی ماشین و سیستم ماشین یادگیری برای پیش‌بینی دقیق جرم و حجم انگور پوشش‌دار شده با صمغ فارسی حاوی روغن شاهدانه طی نگهداری در سردخانه می‌باشد. بدین منظور از تکنیک‌های ANN، SVM و رگرسیون خطی (LR) استفاده شد. در نهایت مقایسه آماری بین این روش‌ها جهت انتخاب

۲-۲- اندازه گیری جرم، حجم و تغییرات آن

قبل از انجام تصویربرداری جرم هر یک از حبه های انگور بر حسب گرم با استفاده از یک ترازو دیجیتال با دقت ± 0.01 گرم (رادوگ، لهستان) اندازه گیری شد. با داشتن جرم حبه انگور در روز ۱ (W_0) و روز ۲۸ (W) میزان تغییرات آن (WL)، بر حسب درصد) محاسبه گردید (رابطه ۱):

$$WL (\%) = ((W - W_0) / W_0) \times 100$$

مقدار حجم واقعی با استفاده از اصل جابجایی آب اندازه گیری شد. برای این منظور، تک تک حبه های انگور در بشر یک لیتری لبریز از آب فرو برده شد و با اندازه گیری حجم آب خارج شده با استفاده از استوانه مدرج، حجم میوه بر حسب سانتی متر مکعب به دست آمد. تغییرات حجم نیز مانند تغییرات جرم محاسبه گردید.

۲-۳- سیستم ماشین بینایی

۲-۳-۱- عکس برداری

سیستم بینایی ماشین از یک دوربین (سونی، مدل DSC-H5، ژاپن)، دو لامپ SMD با زاویه ۴۵ درجه (۱۵ وات، مهتابی) و دو پنل LED مهتابی (۲۰ وات) به همراه ۱۲ نوار LED مهتابی، محفظه عکس برداری (جعبه سفید)، پایه نگهدارنده دوربین، رایانه با پردازنده مرکزی Intel i7 و سیستم عامل ویندوز ۱۰ و همچنین ۸ گیگابایت حافظه موقت و سیستم کنترل از راه دور روشنایی تشکیل شده است. برای نورپردازی در پژوهش حاضر از دو لامپ SMD و پنل LED مهتابی سقفی استفاده گردید تا اولاً از هرگونه بازتاب از سطح پیش زمینه جلوگیری شود و ثانیاً از ایجاد نقاط یا لبه بازتاب کننده نور در سطح میوه جلوگیری شود تا میزان نویز به حداقل ممکن برسد. عکس برداری در فاصله ۲۵ سانتی متری از نمونه و با فاصله کانونی ۱۸ میلی متری انجام پذیرفت و عکس های خام با فرمت TIFF و وضوح 3072×2304 در کامپیوتر ذخیره گردید. کاغذ مربع استاندارد با

ابعاد ۵۰ میلی متر به عنوان مرجع برای تبدیل پیکسل به طول و مساحت در کنار حبه های انگور قرار داده شد.

۲-۳-۲- پیش پردازش

فرایند پیش پردازش با کمک نرم افزار متلب R2019a (Mathworks، ایالات متحده آمریکا) انجام پذیرفت؛ در گام اول تقطیع تصویر صورت پذیرفت تا اطمینان حاصل شود که تصاویر فقط شامل حبه انگور و پس زمینه هستند. در محیط RGB و با کمک فیلتر میانه و گوسین نویز تصاویر که ناشی از انعکاس یا نوسان نور هستند، حذف گردید و تصاویر تا حدودی هموار می گردد در ادامه با حذف پس زمینه به روش اوتسو، تصاویر با استفاده از میانگین مقادیر R، G و B (رابطه ۲) پیکسل ها به عنوان مقیاس خاکستری (GS) تبدیل به تصاویر خاکستری. مقیاس بندی خاکستری تصویر به ما این امکان را می دهد تا از یک مقدار آستانه واحد برای ایجاد یک تصویر دودویی (باینری) استفاده نمود (شکل ۱). حد آستانه خصوصیتی است که شرایط آزمون را در پردازش تصویر بهینه سازی می نماید و به عواملی مانند سطح روشنایی، رنگ جسم (انگور) و بازتاب از سطح پس زمینه بستگی دارد [۱۱]:

$$GS = (R + G + B) / 3 \quad (\text{رابطه ۲})$$

در نهایت تصویر دودویی با مقیاس هر پیکسل با مقدار آستانه از تصویر در مقیاس خاکستری به دست آمد. در فرایند آستانه گیری پس از تعیین حد آستانه، حبه انگور به عنوان پیکسل های سفید (مقدار مقیاس خاکستری بالاتر از حد آستانه) و پس زمینه تیره به عنوان پیکسل های سیاه (مقدار خاکستری کمتر از حد آستانه) شناخته می شود و تصاویر RGB به تصاویر دودویی تبدیل می گردد (شکل ۱). به عبارت دیگر مقدار مقیاس خاکستری محاسبه شده برای هر پیکسل اگر کمتر از حد آستانه باشد، به جای آن مقدار صفر و اگر بیشتر از حد آستانه باشد، به جای آن مقدار یک قرار داده می شود. الگوریتم پردازش تصویر به طور خودکار مقدار آستانه را تنظیم می کند.




Fig 1 (a) RGB image, (b) Background removal, (c) Grayscale image, (d) Thresholding, (e) calculation for length and width.

نتایج نشان داد که مساحت محاسبه شده از بیضی گون (A) بزرگتر از مساحت به دست آمده با استفاده از نرم افزار (A_s) است؛ از این رو مساحت به دست آمده با استفاده از نرم افزار (بر حسب میلی متر مربع) با مساحت به دست آمده از بیضی گون مقایسه گردید (رابطه ۵) و ضریب تصحیحی (CF) برای هر تصویر به دست آمد که این ضریب تصحیح برای تصحیح حجم محاسبه شده (V_c) برای بیضی گون استفاده شد (رابطه ۶):

$$CF = A_s / A \quad (\text{رابطه ۵})$$

$$V_c = CF \times V \quad (\text{رابطه ۶})$$

تغییرات حجم انگور (ΔV) بر حسب درصد) طی نگهداری نیز با استفاده از حجم تصحیح شده در روزهای ۱ (V_{c1}) و ۲۸ (V_{c28}) نگهداری محاسبه گردید (رابطه ۷):

$$\Delta V = ((V_{c28} - V_{c1}) / V_{c1}) \times 100 \quad (\text{رابطه ۷})$$

برای محاسبه میزان چروکیدگی سطحی (S_k) از سطح تصاویر در روزهای ۱ (A₁) و ۲۸ (A₂₈) نگهداری در حبه انگور با کمک رابطه ۸ استفاده گردید:

$$S_k = A_{28} / A_1 \quad (\text{رابطه ۸})$$

۲-۴-سیستم یادگیری ماشین

۲-۴-۱-رگرسیون خطی (LR)

رگرسیون خطی به عنوان اولین روش یادگیری ماشین است که برای تخمین میزان جرم و حجم حبه های انگور مورد استفاده قرار

۲-۳-۳-استخراج خصیصه

مساحت هر حبه انگور با استفاده از تصاویر دودویی و با کمک جعبه ابزار پردازش تصویر نرم افزار متلب R2019a (Mathworks، آمریکا) بر حسب توابع دوام پیکسل استخراج گردید. اندازه مشخص کاغذ مربع استاندارد برای کالیبراسیون و تبدیل اندازه پیکسل حبه انگور به بعد دنیای واقعی استفاده شد. با استفاده از نرم افزار و با کمک اطلاعات کانتور، مستطیل کمینه ای روی حبه انگور محصور گردید (شکل ۱). تعداد پیکسل طول و عرض این مستطیل نشان دهنده طول (L) و عرض (W_d) حبه انگور بر حسب پیکسل می باشد. این طول و عرض با کمک کاغذ مربع استاندارد از پیکسل به میلی متر تبدیل شد. تعداد پیکسل در میلی متر به وضوح تصویر بستگی دارد. برای محاسبه ضخامت از تصویر در جهت دیگر استفاده گردید و با محاط کردن مستطیل دیگری مقدار ضخامت (h) و عرض انگور محاسبه گردید که به ترتیب معادل طول و عرض مستطیل محاط شده جدید بود (شکل ۱). از آنجائی که شکل حبه انگور بیضی گون می باشد. مساحت (A) و حجم (V) آن با فرض بیضی گون بودن از روابط ۳ و ۴ به دست آمد:

$$A = \pi \times L \times W_d \quad (\text{رابطه ۳})$$

$$V = 1.33 \times \pi \times L \times W_d \times h \quad (\text{رابطه ۴})$$

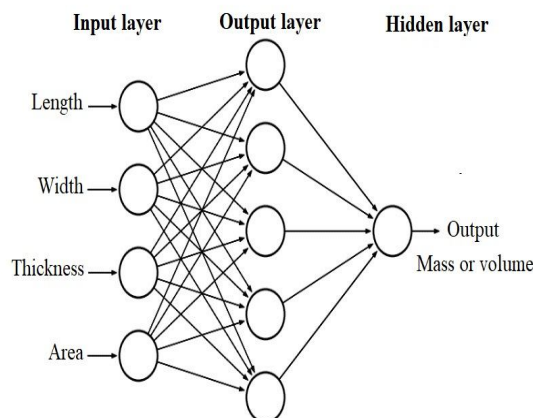


Fig 2 MLP structure.

۲-۴-۳- ماشین بردار پشتیبان (SVM)

در این پژوهش برای پیش‌بینی حجم و جرم به کمک پردازش تصویر از SVM استفاده گردید؛ SVM یک نوع سیستم یادگیری نظارت شده می‌باشد که عملکرد آن به مجموعه داده‌های آموزش و آزمایش بستگی دارد و هم برای طبقه‌بندی (SVM) و هم برای تخمین و برآورد تابع برازش داده‌ها در مسائل رگرسیون (SVR) به کار می‌رود (شکل ۲)، به طوری که کمترین خطا در طبقه‌بندی داده‌ها و یا تابع برازش رخ دهد. هدف SVR که مدل رگرسیونی SVM می‌باشد، این است که تابع $f(x)$ را برای الگوهای آموزشی x طوری تشخیص دهد که بیشینه حاشیه را از مقادیر آموزشی y داشته باشد. به عبارت دیگر مدل SVR مدلی است که منحنی با ضخامت ϵ را به داده‌ها برازش می‌دهد به نحوی که کمترین خطا در داده‌های آزمون صورت گیرد [۲۸]. انتخاب تابع کرنل^{۱۱} موضوع بسیار مهمی است که بر اساس اطلاعات آزمون و رگرسیون و اطلاعات نظری انجام می‌پذیرد. توابع کرنل خطی و تابع پایه شعاعی (RBF)^{۱۲} از مهم‌ترین توابع کرنل هستند. به طور کلی رگرسیون‌گیری به شیوه خطی به ندرت اتفاق می‌افتد و در عمل نحوه قرارگیری داده‌ها به صورت غیرخطی می‌باشد. تنظیم شاخص‌های مدل تأثیر زیادی در دقت پیش‌بینی دارد، شاخص‌های SVR برای تابع RBF شامل شاخص‌های هسته گاما (γ)، شاخص اپسیلون (ϵ) و تنظیم (C) است که C خطای مربوط به انحراف بیشتر از ϵ را کنترل می‌کند و برای کنترل سادگی تابع هسته و شاخص‌های تابع هسته مانند γ

گرفت؛ رگرسیون خطی چند متغیره به‌عنوان نوعی رگرسیون خطی رابطه بین شاخص‌های ورودی ($X_1, X_2, X_3, \dots, X_n$) متغیر مستقل را با شاخص یا شاخص‌های خروجی (Y) متغیر وابسته به‌طور همزمان مورد بررسی قرار می‌دهد:

$$Y = a + B_1X_1 + B_2X_2 + B_3X_3 + \dots + B_nX_n + e \quad (\text{رابطه ۹})$$

در این رابطه $B_1, B_2, B_3, \dots, B_n$ برابر ضرایب مدل، a برابر ثابت مدل و e نیز برابر خطای مدل رگرسیونی است. شاخص‌های ورودی در این پژوهش طول، عرض، ضخامت و سطح و شاخص خروجی نیز جرم و حجم حبه‌های انگور می‌باشد. این فرایند با کمک جعبه ابزار برازش منحنی نرم‌افزار متلب (Mathworks) R2019a، ایالات متحده آمریکا) انجام پذیرفت.

۲-۴-۲- شبکه عصبی مصنوعی (ANN)

در میان معماری‌های مختلف ANN، شبکه‌های پرسپترون چند لایه (MLP)^{۱۳} (شکل ۳) معمولاً برای طبقه‌بندی، درجه‌بندی و پیش‌بینی کیفیت مورد استفاده قرار می‌گیرند [۴]. ساختار MLP از یک لایه ورودی، یک یا چند لایه مخفی و یک لایه خروجی تشکیل شده است. عملاً زمانی که تابع فعال‌سازی غیرخطی باشد، وجود لایه پنهان مفید است. MLP معمولاً توسط الگوریتم انتشار مجدد خطا آموزش می‌بیند. شاخص‌های طول، عرض، ضخامت و مساحت حبه‌های انگور به‌عنوان شاخص‌های ورودی انتخاب شدند در حالی که خروجی ANN جرم و حجم حبه‌های انگور بود. پیکربندی ANN نقش مهمی در دقت محاسبات دارد. از این‌رو از یک لایه پنهان با تعداد نورون ۲ تا ۳۰ به همراه تابع آستانه‌ای سیگموئید لگاریتمی و تان‌اکسون^۹ و تابع آموزشی مومنتوم^{۱۰} به‌منظور آموزش شبکه استفاده گردید. در فرایند پیش‌بینی از اطلاعاتی استخراجی از ۲۰۰ تصویر (شامل ۱۰ تیمار در دو زمان نگهداری) استفاده گردید که ۶۵ درصد داده‌ها برای آموزش، ۱۵ درصد برای آزمون مدل و ۲۰ درصد برای اعتبارسنجی آن مورد استفاده قرار گرفت. این فرایند با کمک جعبه ابزار ANN نرم‌افزار متلب (Mathworks) R2019a، ایالات متحده آمریکا) انجام پذیرفت.

11. Support vector regression
12. Kernel function
13. Radial basis function

8. Multilayer perceptron
9. TanhAxon
10. Momentum

$$\text{RMSE} = ((1/n) \times \sum (o_i - p_i)^2)^{0.5} \quad (\text{رابطه } ۱۳)$$

$$R^2 = (\sum (o_i - O) \times (p_i - P)) / (\sum (o_i - O)^2 \times \sum (p_i - P)^2) \quad (\text{رابطه } ۱۴)$$

$$\text{Bias} = (1/n) \times \sum (o_i - p_i) \quad (\text{رابطه } ۱۵)$$

۳- نتایج و بحث

۳-۱- تغییرات جرم و حجم طی نگهداری انگور

و بررسی تاثیر پوشش دهی

نتایج حاصل از اندازه گیری تغییرات جرم و حجم مشخص نمود که جرم و حجم انگور در تمام نمونه‌ها با گذشت زمان از روز ۱ تا روز ۲۸ به طور معنی داری ($p < 0.05$) کاهش یافت. از دست دادن رطوبت به عنوان عامل اصلی این تغییرات است [۳۱]؛ استفاده از پوشش دهی می تواند میزان از دست دادن رطوبت و در نتیجه تغییرات جرم و حجم را کاهش دهد. همان طور که انتظار می رفت، با افزایش سطح روغن شاهدانه و صمغ فارسی تغییرات جرم و حجم به طور معنی داری ($p < 0.05$) کاهش یافت (شکل های ۴ و ۵).

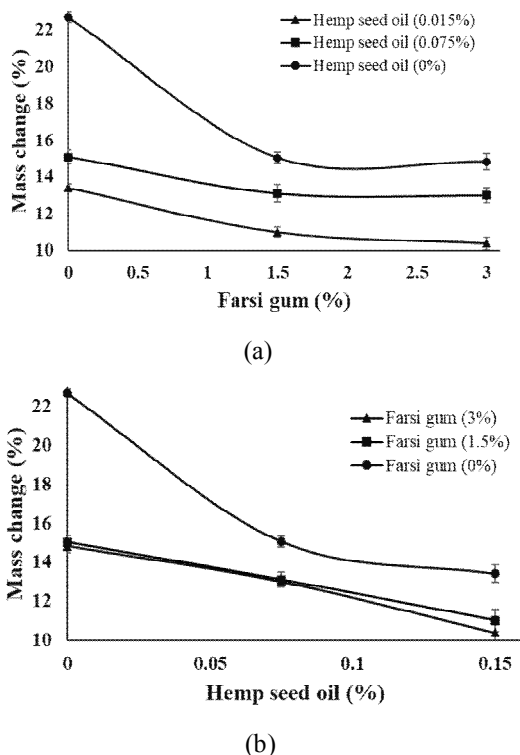


Fig 4 Mass change of coated grape during storage time based on (a) Farsi gum changes and (b) Hemp seed oil changes.

می باشد و هر چقدر مقدار آن بزرگ تر شود، خطای آموزش کم تر خواهد شد و از طرفی قدرت تعمیم دهی مدل نیز کم می شود. برای مطالعه حاضر از سه تابع هسته شامل RBF (رابطه ۱۰) و خطی (رابطه ۱۱) برای SVR استفاده شد [۲۹، ۳۰].

$$K(x, x') = \exp(-(\|x - x'\|^2) / (2\gamma^2)) \quad (\text{رابطه } ۱۰)$$

$$K(x, x') = x - x' \quad (\text{رابطه } ۱۱)$$

که $\|x - x'\|$ به عنوان فاصله اقلیدسی مربع شکل بین دو بردار ویژگی x و x' مشخص شد و γ گسترش توزیع در تابع هسته می باشد. رابطه ۱۰ تحت عنوان کرنل گوسی^{۱۴} شناخته می شود که به عنوان تابعی از RBF می باشد. در این مدل شاخص های طول، عرض، ضخامت و مساحت به عنوان ورودی می باشد که از آنها برای پیش بینی جرم و حجم استفاده می گردد؛ بدین منظور از اطلاعات استخراجی از ۲۰۰ تصویر (شامل ۱۰ تیمار در دو زمان نگهداری) استفاده گردید که ۷۵ درصد داده ها برای آموزش و ۲۵ درصد برای آزمون استفاده گردید.

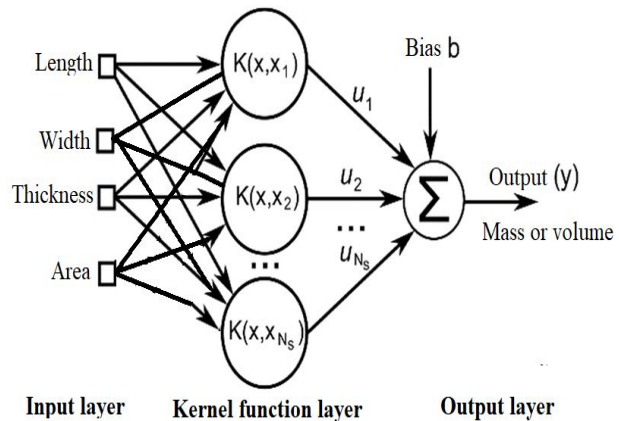


Fig 3 SVR structure.


۲-۴-۴- ارزیابی سیستم یادگیری ماشین

عملکرد مدل با مجموعه داده های آزمایش با استفاده از چهار شاخص شامل مجموع مربعات خطا (SSE)^{۱۵} (رابطه ۱۲)، میانگین ریشه مربعات خطا (RMSE)^{۱۶} (رابطه ۱۳)، ضریب تعیین (R^2) (رابطه ۱۵) و بایاس^{۱۷} (رابطه ۱۶) ارزیابی شد. این شاخص های ارزیابی با استفاده از داده های پیش بینی شده (O) و میانگین آن (O) و داده های آزمایشگاهی (p) و میانگین آن (P) محاسبه گردید [۲۹، ۱۰].


$$\text{SSE} = \sum (o_i - p_i)^2 \quad (\text{رابطه } ۱۲)$$

14. Gaussian kernel
15. Sum of Square Errors (SSE)
16. Root Mean Square Error (RMSE)
17. Bias

مشابه‌ای با تغییرات حجم و جرم نشان داد (شکل ۶). نتایج نشان داد که با افزایش صمغ فارسی و روغن شاهدانه میزان چروکیدگی سطحی به طور معنی داری ($p < 0.05$) کاهش می‌یابد.



(a)




(b)

Fig 6 Surface shrinkage change of coated grape during storage time based on (a) Farsi gum changes and (b) Hemp seed oil changes.


۲-۳- پیش‌بینی جرم

پیش‌بینی جرم نقش موثری در ارزیابی کیفی میوه طی نگهداری در سردخانه، فراوری و عرضه به بازار برای کمک به مکانیزه شدن فرایندها دارد. در این پژوهش از چهار روش SVR-Linear, SVR-RBF, ANN و بر پایه متغیرهای طول، عرض، ضخامت و سطح به عنوان متغیر مستقل و جرم به عنوان متغیر وابسته بهره گرفته شد. شکل ۷ نتایج حاصل از پیش‌بینی جرم را نسبت به جرم واقعی برای هر چهار مدل نشان می‌دهد.

همان‌طور که مشاهده می‌گردد، هر چهار مدل با عملکرد نسبتاً موفق قادر به پیش‌بینی جرم بودند. متوسط جرم اندازه‌گیری شده ۱/۹۳ گرم بود در حالی‌که متوسط جرم پیش‌بینی شده توسط



(a)



(b)

Fig 5 Volume change of coated grape during storage time based on (a) Farsi gum changes and (b) Hemp seed oil changes.

نتایج نشان داد که در دو سطح ۱/۵ یا ۳ درصد صمغ فارسی تفاوت معنی داری ($p < 0.05$) در کاهش این تغییرات وجود ندارد، ولی تمام سطوح روغن شاهدانه بر میزان تغییرات جرم و حجم به طور معنی داری ($p < 0.05$) موثر بودند. افزایش میزان روغن شاهدانه به سبب خاصیت آبریزی آن سبب افزایش خاصیت ممانعت کنندگی در برابر بخار آب و بهبود خصوصیات فیزیکی پوشش می‌گردد [۳۲]. اثرات ضد میکروبی روغن شاهدانه در کنار بهبود خصوصیات فیزیکی و ممانعت کنندگی سبب کاهش تغییرات فیزیکی و شیمیایی و فعالیت میکروبی و در نتیجه کاهش از دست دادن رطوبت می‌گردد [۳۳-۳۵]. از آنجائی‌که با افزایش غلظت صمغ فارسی تا حد مشخصی خصوصیات چسبندگی محلول صمغ فارسی افزایش می‌یابد در نتیجه لایه نسبتاً نفوذناپذیر در برابر اکسیژن [۲۵، ۲۷] روی جبهه انگور ایجاد می‌گردد و در نتیجه سرعت از دست دادن رطوبت کاهش می‌یابد. بررسی نتایج چروکیدگی سطحی حاصل از تصویر نیز نتایج

ضرایب مدل نهایی LR برای طول، عرض، ضخامت و سطح به ترتیب برابر ۰/۳۲۱۱، ۰/۱۰۲۸، ۰/۹۴۳۱ و ۰/۲۹۳۴ بود که توانست جرم را با ضریب تبیین برابر ۰/۹۲۸ پیش‌بینی کند که نشان‌دهنده دقت پیش‌بینی نسبتاً خوب آن است. این مدل در پیش‌بینی روابط خطی بین متغیرها عملکرد مناسبی دارد؛ برای پیش‌بینی روابط غیرخطی نیاز به استفاده از سایر مدل‌ها می‌باشد. نتایج شاخص‌های مدل حاصل از پیکربندی‌های مختلف ANN با کمک شبکه‌های پرسپترون چند لایه در جدول ۱ نشان داده شده است.

همان‌طور که در جدول ۱ مشاهده می‌گردد، بهترین شبکه‌های پرسپترون چند لایه در مرحله آموزش شبکه‌ای با تابع آموزش لونیگ-مارکوآت و پیکربندی ۴-۱۱-۱ بود که ضریب تبیین برابر ۰/۹۷۸ داشت. همچنین در مرحله آزمون هم شبکه‌ای با تابع آموزش لونیگ-مارکوآت و پیکربندی ۴-۸-۱ بهترین عملکرد را داشت که توانست جرم را با دقت ۰/۹۹۳ پیش‌بینی نماید. شبکه‌های پرسپترون چند لایه توانست موفق‌تر از LR عمل نماید؛ علت این امر شاید به سبب توانایی شبکه‌های پرسپترون چند لایه در پیش‌بینی روابط غیر خطی در کنار روابط خطی باشد. ایده اصلی SVR این است که فضای ورودی اصلی (که معمولاً مربوط به متغیر پیش‌بینی کننده غیر خطی است) به‌منظور حل مشکلات طبقه‌بندی غیرخطی از طریق نگاشت داده‌های آموزشی اصلی به یک فضای ویژگی با ابعاد بالا با یک تابع هسته (مثلاً RBF) ترسیم شود؛ از تابع پایه شعاعی که بیشتر استفاده می‌شود به‌عنوان هسته استفاده شده است و شاخص‌های ϵ و C از طریق آزمون و خطا به‌دست آمد.

بعد از انتخاب ورودی، عملیات پیش‌بینی توسط SVR با استفاده از ورودی به ازای دو تابع هسته RBF و تابع خطی انجام شد. در مطالعه حاضر، مقدار γ بر اساس مقدار حداقل RMSE بهینه شد. مقدار بهینه شده γ برای تابع هسته RBF به‌صورت ۰/۵ به‌دست آمده است. شاخص‌های ϵ و C نیز برای تابع هسته RBF و تابع خطی به ترتیب ۰/۰۳۹۸، ۰/۳۹۷ و ۰/۰۱۵۴ و ۰/۲۴۱۱ برای مدل پیشنهادی به‌دست آمد.

چهار روش LR، SVR-Linear، SVR-RBF و ANN به ترتیب برابر ۱/۹۶، ۱/۹۰، ۱/۹۳ و ۱/۹۴ گرم بود.

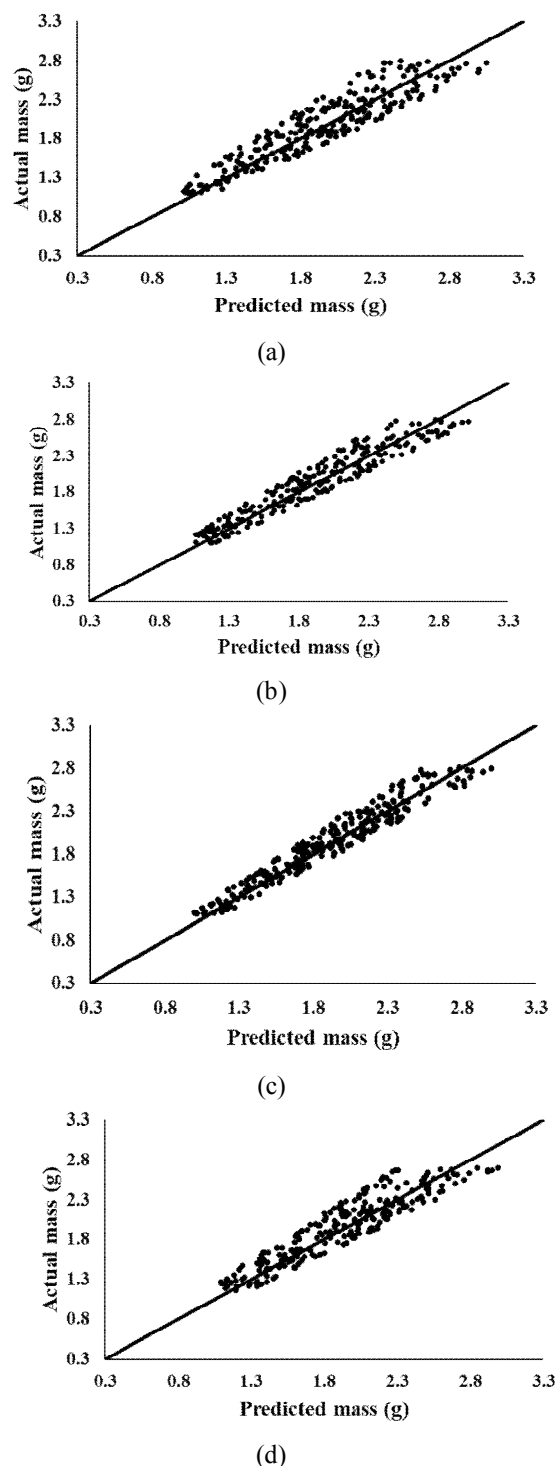


Fig 7 Predicted mass via (a) LR, (b) ANN, (c) SVR-RBF and (d) SVR-Linear versus actual mass (measured).

Table 1 Some of the best MLP neural network topologies to predict mass

Learning function	Topology	Training		Test	
		R ²	RMSE	R ²	RMSE
Levenberg-Marquardt	4-3-1	0.942	0.141	0.991	0.032
	4-8-1	0.929	0.163	0.993	0.026
	4-17-1	0.961	0.129	0.989	0.047
	4-11-1	0.978	0.108	0.979	0.074
Momentum	4-6-1	0.951	0.132	0.984	0.062
	4-13-1	0.973	0.112	0.989	0.039
	4-19-1	0.938	0.152	0.985	0.054
	4-23-1	0.963	0.122	0.982	0.071

جرم نشان داد. عملکرد مدل‌های پیشنهادی SVR، LR و شبکه‌های پرسپترون چند لایه با استفاده از مجموعه داده یکسان با هم مقایسه شد. در این حالت از ϵ ورودی یکسان برای هر سه الگوریتم مدل برای پیش‌بینی مقدار جرم حبه انگور استفاده شد. در مطالعه تطبیقی از شاخص‌های ارزیابی عملکرد مدل شامل SSE، RMSE، R²، بایاس و همبستگی استفاده شد. نتایج عملکرد مدل مقایسه‌ای در جدول ۲ خلاصه شده است.

مهم‌ترین کار در توسعه مدل، تقسیم داده‌ها به آموزش و آزمایش بود. مجموعه داده‌ها به گونه‌ای در آموزش و آزمایش تقسیم شده‌اند که توزیع هر دو مجموعه داده باید یکسان باشد. نتایج پیش‌بینی نشان داد که روش SVR با تابع هسته RBF کارایی بهتری نسبت به تابع خطی داشت؛ به طوری که در معیار دقت پیش‌بینی، تابع هسته RBF با ضریب تبیین برابر ۰/۹۹۸ عملکرد بهتری نسبت به تابع خطی با ضریب تبیین ۰/۹۷۳ در پیش‌بینی

Table 2 Model assessment result for mass prediction.

Index				
Bias	R ²	RMSE	SSE	Model
0.067	0.928	0.176	24.342	LR
0.026	0.993	0.026	4.657	MLP
0.011	0.998	0.018	3.287	SVR-RBF
0.054	0.973	0.116	15.761	SVR-Linear

به‌عنوان مثال ویدیارتی و همکاران (۲۰۲۰) توانستند با استفاده از مدل یادگیری ماشین جمع شده تجمعی^{۱۸} جرم مغز بادام را پیش‌بینی کنند [۱۰]، همین محققان توانستند جرم مغز پسته را با کمک الگوریتم یادگیری ماشین جنگل تصادفی^{۱۹} تخمین بزنند [۱۱].

۳-۳-۳- پیش‌بینی حجم

حجم واقعی حبه‌های انگور مورد استفاده برای پیش‌بینی برابر ۲/۴۴ سانتی‌متر مکعب با انحراف معیار ۰/۲۸ سانتی‌متر مکعب بود. پیش‌بینی حجم با استفاده از خصوصیات پردازش تصویر شامل طول، عرض، ضخامت و سطح تصویر با کمک چهار روش LR، SVR-Linear، SVR-RBF و ANN انجام پذیرفت. شکل ۸ حجم پیش‌بینی شده توسط این روش‌ها نسبت به حجم واقعی را نشان می‌دهد.


مقدار SSE نزدیک به صفر نشان‌دهنده دارای مولفه خطای تصادفی کوچک‌تر مدل و مفید بودن آن برای پیش‌بینی است. مقدار RMSE برای یک مدل ایده‌آل صفر می‌گردد. بایاس نیز نشان‌دهنده انحراف متوسط مقادیر برآورد شده از مقادیر مشاهده شده است که می‌تواند مثبت یا منفی باشد [۱۰، ۲۹، ۳۰]. همان‌طور که در جدول ۲ مشاهده می‌گردد، بر اساس شاخص‌های ارزیابی تمام روش‌ها نسبت به روش LR برتری داشتند و در این میان روش SVR با تابع هسته RBF و نیز روش شبکه‌های پرسپترون چند لایه عملکرد بهتری نشان دادند که احتمالاً به دلیل رابطه غیرخطی بین خصوصیات ابعادی حبه انگور با جرم باشد. چنین استدلالی با توجه به عملکرد بهتر تابع هسته RBF نسبت به تابع خطی قابل قبول به نظر می‌رسد. استفاده موفقیت‌آمیز از سیستم پردازش تصویر و سیستم یادگیری ماشین در پیش‌بینی جرم توسط سایر محققان گزارش شده است؛

18. Stack ensemble machine learning model

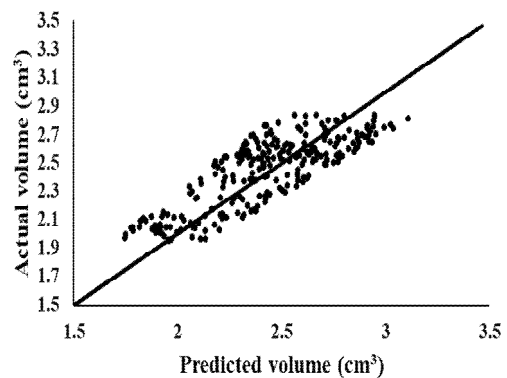
19. Random forest machine learning

نتایج نشان داد که پراکندگی حجم پیش‌بینی شده در روش LR و SVR-Linear بیشتر بود، به طوری که انحراف معیار این دو روش به ترتیب برابر ۰/۳۸ و ۰/۳۵ بود. انحراف معیار نتایج حجم پیش‌بینی شده توسط دو روش SVR-RBF و ANN نیز برابر ۰/۲۹ و ۰/۳۰ بود. پراکندگی بیشتر حجم پیش‌بینی شده نشان دهنده از دقت کمتر در پیش‌بینی نسبت به حجم واقعی است. در پیش‌بینی حجم همانند جرم، مدل‌هایی که به صورت غیرخطی عمل می‌نمایند عملکرد بهتری نشان دادند که بیانگر ارتباط غیرخطی حجم با داده‌های ورودی است.


نتایج حاصل از تخمین حجم با روش LR مدلی را با ضرایب ۰/۲۹۴۱، ۰/۱۸۷۳، ۰/۷۴۳۱ و ۰/۹۸۷۳ به ترتیب برای طول، عرض، ضخامت و سطح تصویر پیشنهاد داد؛ این مدل توانست با ضریب تبیین بالاتر از ۰/۸۷۸ حجم را پیش‌بینی نماید و با توجه به ضرایب بزرگ‌تر سطح و ضخامت در مدل LR نهایی، تاثیر این شاخص‌های ورودی در پیش‌بینی حجم بیشتر می‌باشد. توسعه مدل ANN منجر به ایجاد شبکه شبکه‌های پرسپترون چند لایه با پیکربندی ۱-۸-۴ و تابع آموزش مومنتوم گردید که توانست با دقت ۰/۹۷۷ حجم را پیش‌بینی نماید. عملکرد این پیکربندی در مرحله آموزش نیز با ضریب تبیین برابر ۰/۹۵۲ مناسب بود. این پیکربندی شبکه‌ای با ۴ ورودی (طول، عرض، ضخامت و سطح)، یک لایه مخفی (با ۸ نورون) و یک خروجی (حجم حبه انگور) می‌باشد. نتایج حاصل از مدل‌سازی با ANN برای پیکربندی‌های مختلف در جدول ۳ نشان داده شده است. پیش‌بینی‌های مدل ANN بسیار نزدیک‌تر به خط پیش‌بینی کامل نسبت به مدل LR است (شکل ۸)؛ بنابراین، مدل ANN ظرفیت تعمیم قابل توجهی نسبت به مدل LR نشان می‌دهد. این دقت پیش‌بینی بالاتر ANN را می‌توان به توانایی کلی آن در تقریب غیرخطی بودن سیستم نسبت داد، در حالی که مدل LR محدود به یک چند جمله‌ای مرتبه اول یا دوم است. ایجاد مدل ANN نیاز به تعداد زیادی محاسبات تکراری دارد، در حالی که مدل LR فقط یک محاسبه تک مرحله‌ای دارد، از این رو مدل ANN دارای زمان محاسباتی بالاتر نسبت به مدل LR می‌باشد.




(a)



(b)



(c)



(d)

Fig 8 Predicted volume via (a) LR, (b) ANN, (c) SVR-RBF and (d) SVR-Linear versus actual volume (measured).

Table 3 Some of the best MLP neural network topologies to predict volume

Learning function	Topology	Training		Test	
		R ²	RMSE	R ²	RMSE
Levenberg-Marquardt	4-4-1	0.924	0.275	0.952	0.203
	4-16-1	0.941	0.225	0.974	0.149
	4-13-1	0.939	0.218	0.968	0.154
	4-9-1	0.939	0.222	0.970	0.139
Momentum	4-7-1	0.944	0.209	0.971	0.132
	4-22-1	0.921	0.292	0.954	0.185
	4-8-1	0.952	0.201	0.977	0.111
	4-4-1	0.940	0.218	0.961	0.167

شاخص‌های ارزیابی نشان داد که مقدار SSE ، $RMSE$ و بایاس روش SVR با تابع هسته RBF نسبت به سایر مدل‌ها کمتر است و در نتیجه قابلیت بالاتری در پیش‌بینی حجم دارد. در بین مدل‌ها، روش LR پائین‌ترین عملکرد را داشت که نشان از ارتباط پیچیده بین طول، عرض، ضخامت و سطح تصویر با حجم می‌باشد. نتایج مشابه‌ای در استفاده از روش تخمین حجم مواد غذایی با کمک خصوصیات استخراجی از تصویر و سیستم یادگیری ماشین توسط محققان مختلف برای انار [۳۶]، هلو [۳۷]، تخم‌مرغ [۳۸، ۳۹] و سیب درختی [۳، ۴۰] گزارش شده است.

همان‌طور که پیش‌تر گفته شد، مقدار γ بر اساس مقدار حداقل $RMSE$ بهینه شد. مقدار بهینه شده γ برای تابع هسته RBF به صورت 0.03 به دست آمده است. شاخص‌های E و C نیز در مدل پیشنهادی برای تابع هسته RBF و تابع خطی به ترتیب 0.0465 و 0.05348 و 0.0329 و 0.3831 به دست آمد. نتایج پیش‌بینی نشان داد مشابه پیش‌بینی جرم، روش SVR با تابع هسته RBF کارایی بهتری نسبت به تابع خطی داشت؛ ضریب تبیین، تابع هسته RBF و تابع خطی به ترتیب برابر 0.989 و 0.969 بود که باز هم رابطه غیرخطی بین خصوصیات استخراجی از تصویر با حجم را تأیید می‌نماید. مقایسه روش‌های مختلف با استفاده از

Table 4- Model assessment result for mass prediction.

Index				
Model	SSE	Model	SSE	Model
0.143	0.878	0.275	55.473	LR
0.071	0.977	0.111	13.591	MLP
0.049	0.989	0.078	10.121	SVR-RBF
0.116	0.969	0.198	46.353	SVR-Linear

۴- نتیجه‌گیری کلی

نمونه‌ها با گذشت زمان از روز ۰ تا روز ۲۸ به‌طور معنی‌داری ($p < 0.05$) کاهش یافت و استفاده از پوشش‌دهی توانست میزان از دست دادن رطوبت و در نتیجه تغییرات جرم و حجم را کاهش دهد. افزایش سطح روغن شاهدانه و صمغ فارسی سبب کاهش معنی‌دار ($p < 0.05$) تغییرات جرم و حجم گردید. افزایش روغن شاهدانه سبب افزایش اثرات ضد میکروبی و بهبود خصوصیات فیزیکی و ممانعت‌کنندگی می‌گردد و افزایش غلظت صمغ فارسی نیز باعث افزایش خصوصیات چسبندگی محلول صمغ فارسی می‌شود. نتایج تخمین جرم و حجم نشان داد که هر چهار مدل عملکرد نسبتاً موفقی داشتند. در این میان روش SVR با تابع هسته RBF و نیز روش MLP عملکرد بهتری نشان دادند

در پژوهش حاضر پس از بررسی تغییرات حجم و جرم حبه انگور پوشش‌دهی شده با مقادیر مختلف صمغ فارسی و روغن شاهدانه، حجم و جرم با استفاده از سیستم بینایی ماشین همراه با انواع مدل یادگیری ماشین با سطح اطمینان بالایی پیش‌بینی گردید. برای این منظور پس از پیش‌پردازش تصاویر و حذف نویز، خصوصیات نظیر طول، عرض، ضخامت و مساحت سطح از آنها استخراج گردید. از این خصیصه‌های استخراجی از تصویر با کمک چهار روش LR ، SVR -Linear، SVR -RBF و ANN جرم و حجم پیش‌بینی گردید. نتایج اندازه‌گیری تغییرات جرم و حجم مشخص نمود که جرم و حجم انگور در تمام

- [7] Zandi, M., et al., Application of neural-fuzzy inference system (ANFIS) and fuzzy logic for prediction of physicochemical changes and classification of coated sweet lemon during storage (In persian). *Iranian Food Science and Technology Research Journal*, 2021. 17(2).
- [8] Zandi, M., A. Ganjloo, and M. Bimakr, Computer Vision System Applied to Classification of Medlar (*Mespilus germanica*) during ripening stage at cold storage (In persian). *Innovative Food Technologies (JIFT)*, 2020. 7(3).
- [9] Su, Q., et al., Potato feature prediction based on machine vision and 3D model rebuilding. *Computers and Electronics in Agriculture*, 2017. 137: p. 41-51.
- [10] Vidyarthi, S.K., R. Tiwari, and S.K. Singh, Stack ensemble model to measure size and mass of almond kernels. *Journal of Food Process Engineering*, 2020. 43(4): p. e13374.
- [11] Vidyarthi, S.K., et al., Prediction of size and mass of pistachio kernels using random Forest machine learning. *Journal of Food Process Engineering*, 2020. 43(9): p. e13473.
- [12] Bejagam, K.K., et al., Machine-learned coarse-grained models. *The journal of physical chemistry letters*, 2018. 9(16): p. 4667-4672.
- [13] Halac, D., E. Sokic, and E. Turajlic. Almonds classification using supervised learning methods. in 2017 XXVI International Conference on Information, Communication and Automation Technologies (ICAT). 2017. IEEE.
- [14] Whan, A.P., et al., GrainScan: a low cost, fast method for grain size and colour measurements. *Plant methods*, 2014. 10(1): p. 23.
- [15] Su, Q., et al., Potato quality grading based on machine vision and 3D shape analysis. *Computers and electronics in agriculture*, 2018. 152: p. 261-268.
- [16] Vivek Venkatesh, G., et al., Estimation of volume and mass of axi-symmetric fruits using image processing technique. *International Journal of Food Properties*, 2015. 18(3): p. 608-626.
- [17] Nouri-Ahmadabadi, H., et al., Design, development and evaluation of an online grading system for peeled pistachios equipped with machine vision technology and support

که احتمالاً به دلیل رابطه غیر خطی بین خصوصیات ابعادی حبه انگور با جرم یا حجم باشد. چنین استدلالی با توجه به عملکرد بهتر تابع هسته RBF نسبت به تابع خطی قابل قبول به نظر می‌رسد. این نتایج نشان داد که مدل SVR با تابع هسته RBF ابزاری امیدوار کننده برای تخمین میزان جرم و حجم می‌باشد.

۵-تقدیر و تشکر

مقاله حاضر حاصل از پروژه کارشناسی و طرح پژوهشی مصوب گروه علوم و مهندسی صنایع غذایی دانشگاه زنجان با عنوان "استفاده از سامانه‌های میکرومولسیون و نانوامولسیون حاوی صمغ فارسی و روغن شاهدانه برای نگهداری انگور (بهینه‌سازی، مدل‌سازی و پردازش تصویر)" مورخ ۱۳۹۸/۰۷/۱۵ می‌باشد. از دانشکده کشاورزی دانشگاه زنجان که با فراهم آوردن امکانات تحقیق ما را یاری کردند، سپاسگزار می‌نمایم.

۶-منابع

- [1] Prakash, B., Mathematical modeling of moisture movement within a rice kernel during convective and infrared drying. 2011, University of California, Davis.
- [2] Singh, S.K., S.K. Vidyarthi, and R. Tiwari, Machine learnt image processing to predict weight and size of rice kernels. *Journal of Food Engineering*, 2020. 274: p. 109828.
- [3] Wang, D., et al., Computer vision for bulk volume estimation of apple slices during drying. *Drying Technology*, 2017. 35(5): p. 616-624.
- [4] Soltani, M., M. Omid, and R. Alimardani, Egg volume prediction using machine vision technique based on pappus theorem and artificial neural network. *Journal of food science and technology*, 2015. 52(5): p. 3065-3071.
- [5] Martynenko, A. and M.A. Janaszek, Texture changes during drying of apple slices. *Drying Technology*, 2014. 32(5): p. 567-577.
- [6] Ganjloo, A., et al., Indirect Estimation of Mass and Shape Ratio Changes of Aloe vera gel Coated Cherry Tomatoes Using Image Processing Technique (In persian). *Innovative Food Technologies (JIFT)*, (2021) In press.

- [28] Chang, C.-C. and C.-J. Lin, LIBSVM: A library for support vector machines. *ACM transactions on intelligent systems and technology (TIST)*, 2011. 2(3): p. 1-27.
- [29] Patel, A.K., S. Chatterjee, and A.K. Gorai, Development of a machine vision system using the support vector machine regression (SVR) algorithm for the online prediction of iron ore grades. *Earth Science Informatics*, 2019. 12(2): p. 197-210.
- [30] Qu, C., et al., A moisture content prediction model for deep bed peanut drying using support vector regression. *Journal of Food Process Engineering*, 2020: p. e13510.
- [31] Ciccicarese, A., et al., Effectiveness of pre- and post-veraison calcium applications to control decay and maintain table grape fruit quality during storage. *Postharvest Biology and Technology*, 2013. 75: p. 135-141.
- [32] Khorram, F., A. Ramezani, and S.M.H. Hosseini, Shellac, gelatin and Persian gum as alternative coating for orange fruit. *Scientia Horticulturae*, 2017. 225: p. 22-28.
- [33] Salaria, M., et al., Physical, Barrier and Antimicrobial Properties of Sodium Caseinate-based Edible Film Containing Hemp Seed oil (in persian). *Journal of Innovative Food Technologies (JIFT)* 2018. 5(3): p. 485-497.
- [34] Leizer, C., et al., The composition of hemp seed oil and its potential as an important source of nutrition. *Journal of Nutraceuticals, functional & medical foods*, 2000. 2(4): p. 35-53.
- [35] Cozmuta, A.M., et al., Preparation and characterization of improved gelatin films incorporating hemp and sage oils. *Food Hydrocolloids*, 2015. 49: p. 144-155.
- [36] Arendse, E., et al., Non-destructive characterization and volume estimation of pomegranate fruit external and internal morphological fractions using X-ray computed tomography. *Journal of Food Engineering*, 2016. 186: p. 42-49.
- [37] Pereira, T.M., P.D. Gaspar, and M.P. Simões. Fruit recognition and classification based on SVM method for production prediction of peaches. in *IV Balkan Symposium on Fruit Growing. IV Balkan Symposium on Fruit Growing (BSFG 2019)*.
- [38] Siswanto, J., M. Hilman, and M. Widiastri. Computer vision system for egg vector machine. *Information Processing in Agriculture*, 2017. 4(4): p. 333-341.
- [18] Nyalala, I., et al., Tomato volume and mass estimation using computer vision and machine learning algorithms: Cherry tomato model. *Journal of Food Engineering*, 2019. 263: p. 288-298.
- [19] Calixto, R.R., et al., A computer vision model development for size and weight estimation of yellow melon in the Brazilian northeast. *Scientia Horticulturae*, 2019. 256: p. 108521.
- [20] Utai, K., et al., Mass estimation of mango fruits (*Mangifera indica* L., cv. 'Nam Dokmai') by linking image processing and artificial neural network. *Engineering in Agriculture, Environment and Food*, 2019. 12(1): p. 103-110.
- [21] Sheng, K., et al., Comparison of postharvest UV-B and UV-C treatments on table grape: Changes in phenolic compounds and their transcription of biosynthetic genes during storage. *Postharvest Biology and Technology*, 2018. 138: p. 74-81.
- [22] Zhou, X., et al., The biocontrol of postharvest decay of table grape by the application of kombucha during cold storage. *Scientia Horticulturae*, 2019. 253: p. 134-139.
- [23] Jia, X., et al., Storage quality of "Red Globe" table grape (*Vitis vinifera* L.): Comparison between automatic periodical gaseous SO₂ treatments and MAP combined with SO₂ pad. *Journal of Food Processing and Preservation*, 2020. 44(8): p. e14507.
- [24] Cazón, P., et al., Polysaccharide-based films and coatings for food packaging: A review. *Food Hydrocolloids*, 2017. 68: p. 136-148.
- [25] Joukar, F., et al., Effect of Farsi gum-based antimicrobial adhesive coatings on the refrigeration shelf life of rainbow trout fillets. *LWT*, 2017. 80: p. 1-9.
- [26] Dehghani, P., et al., Shelf-life extension of refrigerated rainbow trout fillets using total Farsi gum-based coatings containing clove and thyme essential oils emulsions. *Food Hydrocolloids*, 2018. 77: p. 677-688.
- [27] Shahbazi, Y. and N. Shavisi, Application of active Kurdi gum and Farsi gum-based coatings in banana fruits. *Journal of Food Science and Technology*, 2020: p. 1-11.

- Telecommunications and Information Technology (ECTI-CON). 2017. IEEE.
- [40] Ziaratban, A., M. Azadbakht, and A. Ghasemnezhad, Modeling of volume and surface area of apple from their geometric characteristics and artificial neural network. *International Journal of Food Properties*, 2017. 20(4): p. 762-768.
- volume prediction using backpropagation neural network. in *IOP Conference Series: Materials Science and Engineering*. 2017.
- [39] Thipakorn, J., R. Waranusast, and P. Riyamongkol. Egg weight prediction and egg size classification using image processing and machine learning. in *2017 14th International Conference on Electrical Engineering/Electronics, Computer,*



Evaluation the Effect of Farsi Gum Containing Hemp seed oil Coating on Mass and Volume Changes of Grape during cold Storage using Machine Vision and Machine Learning Systems

Ganjloo, A. ¹, Zandi, M. ^{2*}, Bimakr, M. ¹, Ghareh Baghi, A. ³

1. Associate Professor, Department of Food Science and Engineering, Faculty of Agriculture, University of Zanjan, Zanjan, Iran
2. Assistant Professor, Department of Food Science and Engineering, Faculty of Agriculture, University of Zanjan, Zanjan, Iran
3. BSc Graduate, Department of Food Science and Engineering, Faculty of Agriculture, University of Zanjan, Zanjan, Iran

ARTICLE INFO

ABSTRACT

Article History:

Received 2020/ 12/ 04
Accepted 2021/ 01/ 26

Keywords:

Coating,
Image processing,
Support vector machine,
Artificial neural network,
Prediction.

DOI: 10.52547/fsct.18.04.13

*Corresponding Author E-Mail:
Zandi@znu.ac.ir

In this study, the effects of Farsi gum (0, 1.5% and 3%) coating containing hemp seed oil (0, 0.075% and 0.15%) on mass and volume changes of grape were investigated during storage at 4°C for 28 days. Machine vision system with learning machine methods was used to detect coated grapes from an image and estimate their mass and volume based on the image features (length, width, height and area). Four machine learning models, including linear regression (LR), artificial neural networks (ANN), radial basis function support vector regression (RBF-SVR) and Linear basis function support vector regression (LBF-SVR) were developed to predict the mass and volume of the single grape. The estimated grape mass and volume by these methods was compared statistically with actual values. The mass and volume in all treatments showed a decreasing pattern during the cold storage. The results indicated that mass and volume change decrease with Farsi gum and hemp seed oil increasing. Furthermore, according to the model evaluation results, the prediction performance of RBF-SVR model had achieved better predictive accuracy compared with the results of LR, ANN and LBF-SVR models, with R² of 0.998 and 0.989 for mass and volume estimation, respectively, which also showed a good agreement between actual and predicted values. These results revealed that SVR model was a promising tool for estimating the mass and volume of grape during storage.