

شناسایی و تخمین میزان فرایند دانه‌سازی در پرتقال رقم والنسیا با استفاده از طیف‌سنجی مادون‌قرمز نزدیک و ماشین بردار پشتیبان

محسن بهپور بله‌سور^۱ و رحمان فرخی تیمورلو^{۲*}

چکیده

پدیده کاراندازشناسی دانه‌سازی شدن مرکبات یکی از مسائل کیفی در بازارهای مصرف است که به‌صورت چشمی قابل تشخیص نیست. یکی از روش‌های کاربردی جهت بررسی غیرمخرب بافت داخلی محصولات کشاورزی، روش طیف‌سنجی مرئی و مادون‌قرمز نزدیک (Vis-NIR) است. در این مقاله ابتدا سیگنال‌های مادون‌قرمز نزدیک در طول موج ۱۱۰۰-۲۰۰ نانومتر برای هر نمونه به‌صورت تماسی ثبت شد. میزان بازتاب در حالت برهم‌کنش محاسبه و بعد از نرمال‌سازی سیگنال، از روش میانگین‌گیری متحرک و Savitzky Golay برای هموارسازی سیگنال استفاده شد. نهایتاً از هر طیف، ۷ کمیت آماری استخراج و انتخاب شدند. برای نشان دادن شدت و میزان فرایند دانه‌سازی در بافت داخلی پرتقال‌ها، پنج سطح تعریف شد که شامل سطوح A، B، C، D و E بودند. ابتدا میزان دانه‌سازی شدن بر اساس میزان خشکی و شکل ظاهری ناحیه خشک شده به روش مخرب تعریف شد و سپس از ماشین بردار پشتیبان (SVM) برای تخمین محتوای رطوبتی و تشخیص سطوح دانه‌سازی شدن پرتقال‌ها استفاده گردید. نتایج نشان داد که با افزایش و توسعه شدت فرایند دانه‌سازی، کیسه‌های آب‌میوه سفت‌تر، خشک‌تر و بزرگ‌تر شده و محتوای آبی آن‌ها کاهش یافت که بیش‌ترین محتوای رطوبتی پرتقال ۹۰/۹۷٪ در حالت بدون ضایعه دانه‌سازی و کم‌ترین آن ۸۳/۳۶٪ در حالت دانه‌سازی شدن بیش از ۷۵٪ بافت آن مشاهده شد. بررسی‌ها نشان داد که با توسعه فرایند دانه‌سازی در پرتقال، میزان جذب در ناحیه ۹۵۰-۴۰۰ نانومتر به‌طور محسوسی کاهش و اختلاف شدت جذب در ناحیه ۸۵۰-۵۷۰ نانومتر برای طبقه‌های مختلف دانه‌سازی شدن بیشینه بود. نتایج تشخیص سطوح فرایند دانه‌سازی نشان داد که دقت کلی ماشین بردار پشتیبان به ازای هسته‌های خطی، چندجمله‌ای و پایه شعاعی گوسی به ترتیب برابر با ۹۲/۵۰٪، ۹۶/۵۰٪ و ۹۵/۰۰٪ بود که به ازای SVM با هسته چندجمله‌ای، حساسیت این طبقه‌بند در تشخیص سطوح مختلف دانه‌سازی شدن برای شدت A، B، C، D و E به ترتیب برابر با ۹۸/۰٪، ۹۱/۴۰٪، ۹۷/۳۰٪، ۹۶/۸۰٪ و ۹۵/۷۰٪ بود.

واژه‌های کلیدی: پرتقال، فرایند دانه‌سازی، بررسی غیرمخرب، طبقه‌بندی، طیف‌سنجی، هوش مصنوعی.

ارجاع: بهپور بله‌سور م. و فرخی تیمورلو ر. ۱۴۰۳. شناسایی و تخمین میزان فرایند دانه‌سازی در پرتقال رقم والنسیا با استفاده از طیف‌سنجی مادون‌قرمز نزدیک و ماشین بردار پشتیبان. نشریه پژوهش‌های مکانیک ماشین‌های کشاورزی. ۳۲: ۵۳-۶۳. <https://dx.doi.org/10.22034/JRMAM.2024.14669.694>

۱- دانشجوی دکتری گروه مهندسی بیوسیستم، دانشکده کشاورزی، دانشگاه ارومیه.

۲- دانشیار گروه مهندسی بیوسیستم، دانشکده کشاورزی، دانشگاه ارومیه.

* نویسنده مسئول: r.farrokhi@urmia.ac.ir

تاریخ پذیرش: ۱۴۰۳/۰۴/۲۸

تاریخ دریافت: ۱۴۰۲/۱۱/۰۴

مقدمه

مرکبات از مهم‌ترین میوه‌های گرمسیری و نیمه‌گرمسیری جهان هستند (Food and Agriculture Organization, 2018). درخت پرتقال در بین دیگر مرکبات، بیش‌تر کشت شده و عمر اقتصادی آن بین ۵۰ تا ۶۰ سال است، به‌طوری که رتبه سوم میزان تولید در بین محصولات باغی کشور مربوط به پرتقال با ۵/۰۷ میلیون تن است و استان‌های مازندران با سهم ۶۱/۷٪ درصدی، فارس با سهم ۱۲/۸ درصدی و جنوب استان کرمان با سهم ۱۲ درصدی در رتبه‌های اول تا سوم تولیدکنندگان پرتقال کشور قرار دارند (Ahmadi et al., 2017).

برخی از عوامل ایجاد ضایعات در مرکبات، ناهنجاری‌های کاراندام‌شناسی و بیماری‌های آسیب‌شناسی هستند. ناهنجاری‌های کاراندام‌شناسی نتیجه عملکرد ناقص فرآیندهای کاراندام‌شناسی درون بافت‌های میوه هستند. اما مهم‌ترین ناهنجاری‌های کاراندام‌شناسی قبل از برداشت مرکبات شامل یخ‌زدگی، دانه‌سازی شدن، ترکیدگی، ترک خوردن میان‌بر پوست، پفکی شدن، آفتاب‌سوختگی و لکه‌های سطحی روشن و تیره است (Fattahi Moghadam & Faqih Nasiri, 2015).

مطالعات منتشر شده نشان می‌دهد که تغییر در ترکیبات آرمیوه محصولات دانه‌سازی شده باعث کاهش وزن، کاهش درصد گوشت، کاهش قند، کاهش اسید، کاهش عصاره میوه و درصد ماده جامد محلول^۱ می‌شود، چون بخشی از ترکیبات آرمیوه در حین پدیده فرایند دانه‌سازی صرف ساخت و سخت شدن دیواره سلولی می‌شود (Ritenour et al., 2004; Xiong et al., 2017). از جمله روش‌های استفاده شده در تحقیقات گذشته جهت آشکارسازی علائم و نشانه‌های دانه‌سازی شدن می‌توان به طیف‌سنجی تراگسیلی مرئی و مادون‌قرمز نزدیک (Sun et al., 2020)، طیف‌سنجی مادون‌قرمز نزدیک و تحلیل و بررسی کمومتری (Theanjumpol et al., 2019; Jiménez et al., 2012; Mogollón, 2020) و مادون‌قرمز (Munera et al., 2017; Wang et al., 2020)، رزونانس مغناطیسی هسته‌ای^۲ (Sonego et al., 1995) و تصویربرداری فراطیفی (Jie et al., 2020) اشاره کرد.

در یک تحقیق از مدل‌های یادگیری ماشین جهت طبقه‌بندی سطوح فرایند دانه‌سازی در نارنگی استفاده کردند (Theanjumpol et al., 2019). آن‌ها در این تحقیق با استفاده از داده‌های طیف‌سنجی ثبت شده در مد برهم‌کنش، پنج سطح فرایند دانه‌سازی در نارنگی را بررسی کردند و در نهایت توانستند با دقت ۷۸/۴۰٪ توسعه این بیماری در نارنگی را طبقه‌بندی کنند. از دیگر کاربردهای روش‌های یادگیری ماشین در حوزه کیفیت‌سنجی محصولات باغی و کشاورزی می‌توان به کاربرد شبکه عصبی کانولوشنی (Jie et al., 2020) و نزدیک‌ترین همسایگی k جهت تشخیص دانه‌سازی شدن در مرکبات اشاره کرد. یکی از الگوریتم‌های پرکاربرد یادگیری ماشین جهت طبقه‌بندی، ماشین بردار پشتیبان است. فرایند آموزش این روش برخلاف شبکه‌های عصبی مصنوعی به تعداد ورودی‌ها وابسته نیست و حتی برای شرایطی که تعداد ورودی از تعداد داده‌ها بیش‌تر است، عملکرد مناسب‌تری دارد و کم‌تر دچار بیش‌برازش می‌شود (Cervantes et al., 2020). محققان در یک روش مبتنی بر PCA-SVM جهت شناسایی و طبقه‌بندی سطح فرایند دانه‌سازی در پوملو ارائه کردند که با دقت ۹۵/۵۰٪ توانست سطوح فرایند دانه‌سازی را طبقه‌بندی کند (Sun et al., 2020; Mogollón et al., 2020).

یکی از این روش‌های غیرمخرب، روش‌های طیف‌سنجی مرئی و مادون‌قرمز نزدیک است که می‌تواند اختلالات داخلی را در یک مقطع از میوه‌ها تشخیص دهد (Law, 2006; Magwaza, 2013; Wang et al., 1988). روش طیف‌سنجی به روش برهم‌کنش برای تشخیص اختلالات داخلی محصولات کشاورزی شامل اندازه‌گیری شدت تابش عبور کرده از بافت آسیب‌دیده یا از دست دادن انرژی در طول موج‌های خاص است. مقدار پرتویی که از طریق میوه عبور می‌کند با خواص نور پراکندگی بافت‌ها تغییر می‌کند که به نوبه خود باعث تغییر در ترکیب طیف انتقالی می‌شود. لذا در این تحقیق فرض بر این است که با تغییر بافت پرتقال و رخ دادن پدیده فرایند دانه‌سازی، شدت و رفتار طیف عبوری از آن نیز تغییر کند. بنابراین هدف اصلی از پیشنهاد تحقیق حاضر بررسی امکان تشخیص پدیده کاراندام‌شناسی دانه‌سازی شدن مرکبات با استفاده از روش غیرمخرب طیف‌سنجی مرئی و مادون‌قرمز نزدیک و مدل‌های یادگیری ماشین (سه مدل)

1- Total Soluble Solids (TSS)

2- Nuclear magnetic Resonanc (NMR)

در معادله بالا، R_λ ، S_λ ، Ref_λ و D_λ به ترتیب بازتاب (/)، شدت نور خروجی از نمونه، شدت نور خروجی مرجع و شدت نور خروجی تیره در طول موج λ هستند. سپس طیف‌های ثبت شده توسط کاوش‌گر توسط روش حداقل-حداکثر نرمال‌سازی شد. به‌منظور نرمال‌سازی طیف‌ها از را معادله (۲) استفاده گردید که در این معادله S و S_{norm} به ترتیب طیف جذبی اولیه و نرمال شده هستند (Henderi, 2021).

$$S_{norm} = \frac{R_\lambda - \min(S)}{\max(S) - \min(S)} \quad (2)$$

سطوح دانه‌سازی شدن


به‌منظور انجام آزمون‌های تعیین سطوح فرایند دانه‌سازی، در این تحقیق از پرتقال رقم والنسیا به دلیل حساسیت بالای این رقم به پدیده فرایند دانه‌سازی استفاده شد. پرتقال رقم والنسیا از اواسط خردادماه تا اواخر آبان ماه قابل برداشت است. پدیده فرایند دانه‌سازی در این محصول به‌شدت تحت تأثیر دو مشخصه اصلی، یعنی زمان برداشت محصول و مدت‌زمان انبارداری قرار دارد (Jia *et al.*, 2018). به عبارت دیگر، میوه‌هایی که بیش از دو ماه در انبار نگهداری می‌شوند و یا در اواخر فصل برداشت می‌شوند، به‌طور ویژه حساسیت بیشتری به فرایند دانه‌سازی دارند (Theanjumpol *et al.*, 2019). در این تحقیق، ۲۰۰ نمونه پرتقال به‌صورت کاملاً تصادفی از آخرین برداشت باغات مرکبات (اواخر آبان ماه ۱۴۰۲) در شهر ساری استان مازندران تهیه شد. پس از تهیه پرتقال‌ها و بدون دوره انبارداری، از هر نمونه عملیات طیف‌سنجی انجام شد. سپس با استفاده از آزمون مخرب و بر اساس نظر سه کارشناس خبره، سطح فرایند دانه‌سازی در هر نمونه تعیین شد و داده‌ها ثبت شدند. در این تحقیق پنج سطح برای پدیده دانه‌سازی شدن بررسی شد که شامل سطوح A، B، C، D و E هستند. تعریف سطوح فرایند دانه‌سازی با استناد به مراجع (Theanjumpol *et al.*, 2019) انجام شد. در این تحقیق سطوح فرایند دانه‌سازی برای نارنگی تعریف شدند. در جدول ۱ سطوح تعریف شده برای دانه‌سازی شدن بر اساس میزان خشکی و شکل ظاهری ناحیه خشک شده نمونه‌های بررسی شده به روش مخرب تعریف شده است.

است. از مهم‌ترین اهداف این تحقیق بررسی اثر تغییرات سطوح فرایند دانه‌سازی در پرتقال بر طیف‌های مادون‌قرمز نزدیک و هم‌چنین پیاده‌سازی مدلی مبتنی بر یادگیری ماشین جهت طبقه‌بندی سطوح فرایند دانه‌سازی در پرتقال است.

مواد و روش‌ها

سامانه اکتساب داده

در شکل ۱، مجموعه استفاده شده جهت ثبت سیگنال‌های مادون‌قرمز نزدیک نمایش داده شده است. طیف‌سنج استفاده شده در سیستم ثبت طیف مدل UV-VIS-NIR Model V900 ساخت شرکت تراهرتز دانشگاه کاشان است. این سامانه متشکل از منبع نور، فیبر نوری، کاوشگر، طیف‌سنج PDA با آشکارساز CCD است که قابلیت ثبت طیف الکترومغناطیس در محدوده ۱۱۰۰-۲۰۰ نانومتر را دارد. منبع نور این دستگاه متشکل از لامپ دوتریوم و هالوژن با محدوده طیفی ۴۲۰-۱۷۰ نانومتر و ۲۵۰۰-۳۵۰ نانومتر بوده و از فیبر نوری به قطر ۲۰۰ میکرون جهت انتقال نور از منبع به نمونه استفاده شد.



شکل ۱- سامانه طیف‌سنجی مادون‌قرمز نزدیک

طیف‌سنجی از نمونه‌ها به‌صورت تماسی انجام شد. برای این منظور دو ناحیه از پرتقال انتخاب و با فاصله ۱۸۰ درجه طیف‌سنجی انجام گرفت و میانگین طیف‌های ثبت شده به‌عنوان داده نهایی ثبت شد. برای هر نمونه فرایند طیف‌سنجی دو مرتبه انجام شد. بعد از این که کاوش‌گر بر روی سطح پرتقال‌ها قرار داده شد، نرم‌افزار سامانه بر اساس معادله (۱)، میزان بازتاب در مد برهم‌کنش را به دست آورد:

$$R_\lambda = \frac{S_\lambda - D_\lambda}{Ref_\lambda - D_\lambda} \times 100 \quad (1)$$

روش محاسبه میانگین متحرک برای سه روز متوالی نشان داده شده است:

$$S_{MA} = \frac{S_{norm_1} + S_{norm_2} + S_{norm_3}}{3} \quad (3)$$

از طرف دیگر و با توجه به این که محققین زیادی استفاده از روش Savitzkey Golay را جهت هموارسازی سیگنال‌های مادون‌قرمز نزدیک پیشنهاد داده‌اند (Carvalho *et al.*, 2017; Shi *et al.*, 2021; Zhang & Mouazen, 2023) لذا در این تحقیق الگوریتم Savitzkey Golay بر روی هر طیف اعمال شد. در این فیلتر هدف یافتن مقدار هموار شده g_i در نقطه x_i از طریق میانگین‌گیری از داده‌های مجاور آن است. به‌منظور پیاده‌سازی این فیلتر، فرض بر این است که $\Delta x = x_{i+1} - x_i$ فرمول ریاضی فیلتر Savitzkey Golay در معادلات (۴) و (۵) ارائه شده است (Moghaddam *et al.*, 2022):

$$p_i(x) = \sum_{k=0}^M b_k \left(\frac{x - x_i}{\Delta x} \right)^k \quad (4)$$

$$\sum_{j=i-nl}^{i+nr} (p_i(x_j) - f_j)^2 = \min \quad (5)$$

که در معادلات فوق $p_i(x)$ چند جمله‌ای درجه m است که توسط تعداد نقاط $n_l + n_r + 1$ توسط معادله کم‌ترین مربعات برازش می‌شود و بعد از برازش چند جمله‌ای $p_i(x)$ بر روی تعدادی از نقاط x_i مقدار هموار شده $g_i = p_i(x)$ محاسبه می‌شود.

استخراج کمیت‌های آماری

استخراج ویژگی در فرایند پردازش طیف به معنای تبدیل سیگنال‌های طیفی به ویژگی‌های قابل استفاده کمی برای تحلیل و بررسی است؛ بنابراین در این تحقیق از هر طیف ۷ کمیت آماری جهت کمی‌سازی طیف‌ها استخراج شد. در معادلات (۶) تا (۱۲) معادلات ریاضی ویژگی‌های استخراجی از طیف‌ها ارائه شده است. در تمامی روابط $x(n)$ نمونه n ام طیف و N تعداد تمامی نمونه‌های هر طیف است.

$$Mean = \frac{\sum_{n=1}^N x(n)}{N} \quad (6)$$

$$Standard\ deviation = \sqrt{\frac{\sum_{n=1}^N (x(n) - TF_1)^2}{N}} \quad (7)$$

جدول ۱- سطوح دانه‌سازی شدن مورد مطالعه در این تحقیق

سطوح دانه‌سازی شده	A	B	C	D	E
درصد حجم خشک نمونه (%)	۰	۲۵-۱	۵۰-۲۶	۷۵-۵۱	>۷۵

در ادامه طیف‌های مادون‌قرمز نزدیک برای هر پرتقال در مد برهم‌کنش ثبت شد. سپس هر نمونه از وسط برش داده شده و سطح داخلی آن از لحاظ وجود دانه‌سازی شدن بر اساس معیار جدول ۱، بررسی شد. برای این منظور سه کارشناس خبره و براساس مقادیر ارائه شده در جدول ۱، سطح رخ دادن فرایند دانه‌سازی در هر پرتقال را تعیین کردند و در نهایت براساس مجموع آراء کارشناسان در خصوص سطوح فرایند دانه‌سازی، سطح دانه‌سازی شدن برای هر نمونه تعیین شد. نتایج بررسی سطوح دانه‌سازی شدن توسط سه کارشناس مختلف نشان داد که ۷۴ پرتقال در طبقه A، ۳۵ پرتقال در طبقه B، ۳۷ پرتقال در طبقه C، ۳۱ پرتقال در طبقه D و ۲۳ پرتقال در طبقه E دسته‌بندی شدند. سپس محتوای رطوبتی هر پرتقال جهت تعیین میزان آبمیه اندازه‌گیری شد. میزان رطوبت هر پرتقال بر اساس روش AOAC (2000) اندازه‌گیری شد (Association of Official Analytical Chemists, 2000). به‌منظور اندازه‌گیری رطوبت، ابتدا پوست هر نمونه کنده شد و ۲۰ گرم از گوشت پرتقال به‌طور تصادفی انتخاب شد. سپس نمونه به مدت زمان ۹۶ ساعت در دمای ۷۰ درجه سانتی‌گراد در آون خشک شد تا وزن نمونه ثابت بماند. سپس به‌منظور بررسی اثر سطوح دانه‌سازی شدن بر وزن پرتقال‌ها، تجزیه واریانس و مقایسه میانگین به روش چند دامنه‌ای دانکن انجام شد.

پردازش طیف‌ها

با توجه به اینکه سیگنال‌های خام ثبت شده نرمال شده (S_{norm})، دچار مشکلاتی از قبیل نوفه، خطا و اطلاعات اضافی هستند؛ لذا باید این طیف‌ها پیش‌پردازش شده تا اثر پراکنش نور، ناهمواری سطحی نمونه‌ها، نوفه‌های آشکار ساز و ... از طیف حذف شود. در این تحقیق ابتدا طیف‌های ثبت شده توسط روش میانگین‌گیری متحرک^۲ به سه نقطه همسایگی، هموارسازی^۳ شدند. در معادله (۳)،

1- Association of Official Analytical Chemists

2- Moving Average

3- Smoothing

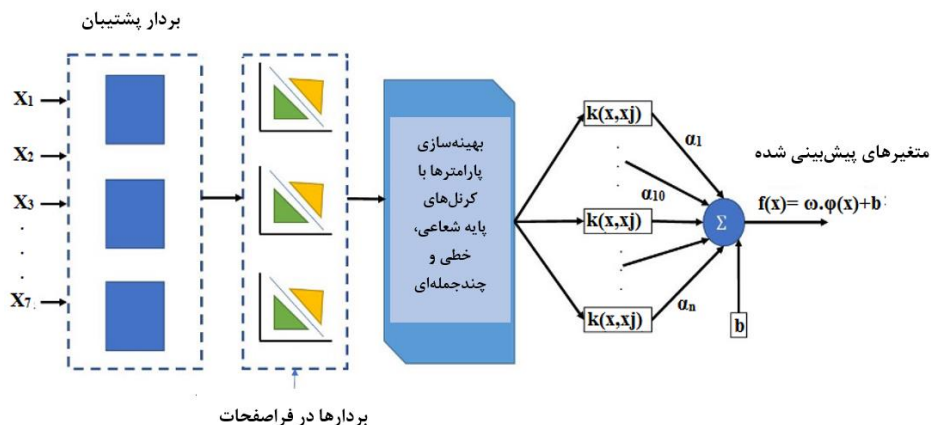
پایاده‌سازی مدل طبقه‌بند است. هرچه مقدار گاما بیشتر باشد، الگوریتم تلاش می‌کند برازش را دقیقاً بر اساس مجموعه داده‌های تمرینی انجام دهد؛ که در این تحقیق مقدار شاخص گاما برابر با ۱۰ در نظر گرفته شد. آخرین شاخص قابل تنظیم در مدل‌سازی ماشین بردار پشتیبان، شاخص جریمه برای خطا است. این شاخص، برقراری تعادل بین مرزهای تصمیم‌گیری هموار و طبقه‌بندی نقاط داده تمرینی را کنترل می‌کند که در این تحقیق مقدار آن ۵ در نظر گرفته شد. مقادیر گاما و شاخص جریمه به‌صورت آزمون و خطا انتخاب شدند که محدوده تغییر آن‌ها $1 < C < 5$ و $1 < \gamma < 20$ است.

در شکل ۲، معماری ماشین بردار پشتیبان استفاده شده در این تحقیق نشان داده شده است. ورودی‌های این مدل، همان ۷ ویژگی استخراجی از طیف‌های هموارسازی شده هستند که با X_1 تا X_7 نمایش داده شده اند. خروجی مدل ماشین بردار پشتیبان نیز طبقه‌های مختلف فرایند دانه‌سازی پرتقال هستند که وابسته به ضرایب α یا ضرایب لاگرانژ به ازای هسته‌های مختلف هستند. $k(x, x_j)$ نیز همان هسته یا تابع هسته ماشین بردار پشتیبان است که در این تحقیق از سه مدل مختلف هسته استفاده شد. در معادلات (۱۳) تا (۱۵) هسته‌های مختلف ارائه شده است:

$$\text{Linear} = (x, x_j) \quad (13)$$

$$\text{RBF} = \exp\left(-\gamma \frac{\|x_i - x_j\|^2}{2}\right) \quad (14)$$

$$\text{poly} = (x_i \cdot x_j)^q \quad (15)$$



شکل ۱- معماری ماشین بردار پشتیبان استفاده شده در این تحقیق

$$\text{Root mean square} = \sqrt{\frac{\sum_{n=1}^N (x(n))^2}{N}} \quad (8)$$

$$\text{Max} = \max(|x(n)|) \quad (9)$$

$$\text{Variance} = \frac{\sum_{n=1}^N (x(n) - F)^2}{N} \quad (10)$$

$$\text{Skewness} = \frac{\sum_i^N (x_i - \text{mean})^3}{(N-1)STD} \quad (11)$$

$$\text{Kurtosis} = \frac{\sum_i^N (x_i - \text{mean})^4}{STD^4} \quad (12)$$

مدل تشخیص سطح دانه‌سازی شدن

ماشین بردار پشتیبان به تعداد داده و همچنین ویژگی‌های ورودی به مدل وابسته نبوده و برخلاف سایر مدل‌های یادگیری ماشینی، کمتر مستعد رخ دادن بیش‌برازش در طی آموزش مدل است (Campbell & Ying, 2022). همچنین حساسیت این مدل به نوفه و داده‌های پرت کمتر بوده و به‌واسطه هسته‌های غیرخطی، امکان تبدیل غیرخطی ویژگی‌های ورودی را فراهم می‌کند (Cervantes et al., 2020). بنابراین در این تحقیق از ماشین بردار پشتیبان به ازای هسته‌های مختلف جهت تشخیص سطوح فرایند دانه‌سازی استفاده شد. ورودی مدل‌های تشخیص سطح فرایند دانه‌سازی همان کمیت‌های آماری مستخرج از طیف‌ها هستند.

در این تحقیق سه شاخص اصلی در پایاده‌سازی ماشین بردار پشتیبان بررسی شدند که شامل نوع هسته، شاخص گاما و ضریب جریمه هستند. هسته‌های استفاده شده در این تحقیق شامل هسته خطی (linear)، پایه شعاعی گوسی (rbf) و چندجمله‌ای (poly) بودند. شاخص گاما یا ضریب هسته برای rbf و poly شاخص دیگر در

آموزش و ارزیابی مدل SVM

در این تحقیق از روش 5-Fold جهت ارزیابی مدل SVM استفاده شد. در جدول ۲، تعداد داده‌های هر طبقه در هر تکرار برای روش 5-Fold ارائه شده است. مجموع داده‌ها در هر تکرار ۴۰ داده بود که یک گروه برای آزمون و چهار گروه برای آموزش ماشین بردار پشتیبان به کار برده شد و در نهایت براساس مجموع پنج تکرار، ماتریس اغتشاش و شاخص‌های ارزیابی ماشین بردار پشتیبان محاسبه شدند. خروجی مدل‌های یادگیری ماشین به صورت ماتریس اغتشاش نمایش داده می‌شود. هر ماتریس اغتشاش با چهار آرایه نمایش داده می‌شود که در جدول ۳، این آرایه‌ها نمایش داده شده اند. با توجه به آرایه‌های موجود در ماتریس اغتشاش، می‌توان سه شاخص ارزیابی برای مدل را محاسبه نمود. در جدول ۴ رابطه محاسبه این شاخص‌ها ارائه شده است (Kumari et al., 2019).

جدول ۲- تعداد داده‌های هر طبقه در هر تکرار

	سطح فرایند دانه‌سازی					
	جمع	E	D	C	B	A
Fold-1	۴۰	۴	۷	۷	۷	۱۵
Fold-2	۴۰	۵	۶	۷	۷	۱۵
Fold-3	۴۰	۵	۶	۷	۷	۱۵
Fold-4	۴۰	۴	۶	۸	۷	۱۵
Fold-5	۴۰	۵	۶	۸	۷	۱۴
Total		۲۳	۳۱	۳۷	۳۵	۷۴

جدول ۲- ماتریس اغتشاش

مقادیر واقعی	
مثبت (۱)	منفی (۰)
مثبت (۱)	غلط مثبت FP
منفی (۰)	غلط منفی FN

مقادیر پیش‌بینی شده

جدول ۳- شاخص‌های ارزیابی مدل تشخیص سطوح دانه‌سازی

اندازه‌گیری	نتیجه
حساسیت	$TPR=TP/(TP+FN)$
بودن اختصاصی	$SPC=TN/(FP+TN)$
دقت	$ACC=(TP+TN)/(TP+TN+FP+FN)$

نتایج و بحث

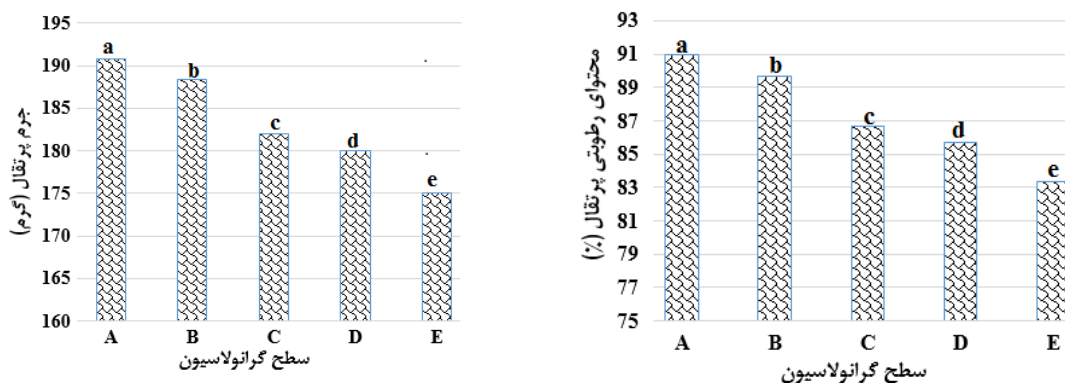
بررسی و محتوای رطوبتی نمونه‌های دانه‌سازی شده و شکل ظاهری

در جدول ۵ نتایج تجزیه واریانس اثر شدت دانه‌سازی شدن بر وزن و محتوای رطوبتی پرتقال‌های مورد مطالعه ارائه شده است. نتایج نشان داد که سطوح دانه‌سازی شدن بر وزن پرتقال و محتوای رطوبتی آن در سطح احتمال ۹۹٪ معنادار بود. در شکل ۳، نتایج مقایسه میانگین اثر سطوح فرایند دانه‌سازی بر وزن و محتوای رطوبتی پرتقال بر اساس آزمون چند دامنه‌ای دانکن ارائه شده است. نتایج مقایسه میانگین‌ها نشان داد با افزایش سطح فرایند دانه‌سازی در پرتقال‌ها، میزان وزن نمونه‌ها و همچنین محتوای رطوبتی آن‌ها تغییر کرد؛ به طوری که به ازای نمونه بدون پدیده دانه‌سازی، بالاترین جرم و محتوای رطوبتی مشاهده شد و با افزایش سطح دانه‌سازی شدن پرتقال، جرم و محتوای رطوبتی آن به طور معناداری کاهش یافت. (Van Dael et al., 2016; Theanjumpol et al., 2019) و در تحقیقی که بر روی لیمو و نارنگی انجام دادند به این نتیجه رسیدند که توسعه فرایند دانه‌سازی بر محتوای رطوبتی محصول دارای تأثیر معنادار و با نتایج ارائه شده در این بخش هم‌راستا است.

جدول ۴- تجزیه واریانس اثر سطح فرایند دانه‌سازی بر خواص وزن و محتوای رطوبتی پرتقال

میانگین مربعات	درجه آزادی	منبع
MC (%)	M (gr)	
۰/۵۵۵ ^{ns}	۲/۲۷۱ ^{ns}	تکرار
۴۶/۸۶۳ ^{**}	۲۰۲/۸۱۳ ^{**}	سطح دانه‌سازی
۰/۳۱۶	۱/۳۷۹	خطا
	۲۵	کل
۰/۹۶۱	۰/۹۶۱	a. R Squared

ns عدم معنی‌داری* و ** به ترتیب معنی‌داری در سطح احتمال ۰/۰۵ و ۰/۰۱



شکل ۲- مقایسه میانگین اثر سطح فراینددانه سازی بر وزن و محتوای رطوبتی پرتقال

در بالا،
با نتایج ارائه شده در این بخش همخوانی داشته و نشان می‌دهد که با توسعه سطح فراینددانه‌سازی میزان رطوبت پرتقال کاهش معناداری داشته است.



شکل ۳- اثر سطح فراینددانه‌سازی بر بافت داخلی پرتقال

بررسی طیف‌های مادون قرمز نزدیک

در شکل ۵ نمودار طیف جذبی نمونه‌های مختلف پرتقال در سطوح مختلف دانه‌سازی شدن نشان داده شده است. در تمامی طیف‌های ضبط شده از نمونه‌های مختلف پرتقال، شدت جذب در ناحیه ۱۸۰ تا ۳۵۰ نانومتر و همچنین در ناحیه ۹۵۰ تا ۱۱۰۰ نانومتر بیشینه است و بین سطوح مختلف دانه‌سازی شدن در این ناحیه هیچ اختلافی مشاهده نشد. شدت جذب در ناحیه ۳۵۰ تا ۵۵۰ با شیب تندی کاهش و مجدداً از ۵۵۰ تا ۹۵۰ افزایش یافت. بررسی طیف‌های جذبی نشان داد که در محدوده ۶۵۰ تا ۷۰۰ نانومتر دو نقطه اوج مشاهده شد که مقدار اوج اول از اوج دوم کمتر بوده اما مقدار این اوج‌ها برای طبقه‌های مختلف فراینددانه‌سازی متفاوت است، به طوری که مقدار متوسط اوج دوم با توسعه شدت فراینددانه‌سازی کاهش یافته است و مقدار جذب در اوج دوم برای طبقه‌های A، B، C، D و E به ترتیب برابر با ۰/۴۱، ۰/۳۶، ۰/۳۱، ۰/۲۸ و ۰/۲۳ بود. همچنین شدت اوج ایجاد شده در طول موج ۹۸۰ نانومتر با افزایش سطح فراینددانه‌سازی کاهش یافت. در طول موج ۶۸۰ و ۹۸۰ نانومتر دو نقطه اوج

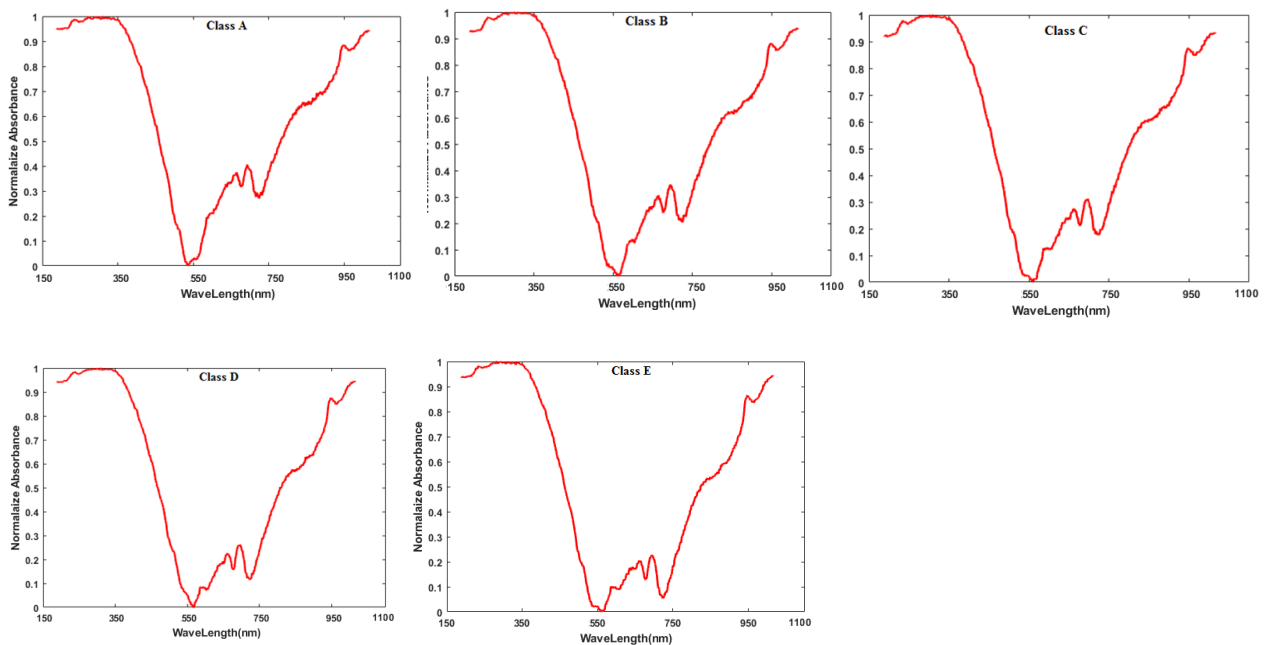
در شکل ۴، شکل ظاهری بافت داخلی پرتقال برای سطوح مختلف فراینددانه‌سازی نشان داده شده است. با توسعه بیماری توده‌های جامد یا بلوری در پالپ میوه مشاهده شد و افزایش یافت. همان طور که در شکل ۴ قابل مشاهده است با پیشرفت فراینددانه‌سازی، بافت داخلی پرتقال به تدریج سخت و محکم شد که این تغییر باعث می‌شود که میوه کمتر آبدار و تازه به نظر برسد. با افزایش و توسعه شدت فراینددانه‌سازی، کاهش محتوای رطوبتی پرتقال‌ها بیشتر شده است به طوری که بیشترین محتوای رطوبتی پرتقال ۹۷/۹۰٪ در حالت بدون ضایعه دانه‌سازی و کمترین آن ۸۳/۳۶٪ در حالت دانه‌سازی شدن بیش از ۷۵٪ بافت آن مشاهده شد. همچنین بررسی شکل ظاهری پالپ‌های پرتقال نشان داد که با افزایش شدت فراینددانه‌سازی در پرتقال، تغییر رنگ در پالپ مشاهده شد به طوری که رنگ پالپ‌ها غیریکنواخت و کرخت شد.

با توسعه سطح فراینددانه‌سازی در محصولات مختلف، برخی ویژگی‌های محصول مانند محتوای جامدات محلول (SSC^۱)، اسیدیته قابل تیتراسیون (TA^۲) و محتوای رطوبتی (MC^۳) محصول کم می‌شود (Sun et al., 2020) و این ویژگی‌ها معمولاً در میوه‌های سالم و با کیفیت بالا به مقدار بیشتری یافت می‌شوند. به عبارتی دیگر، میوه‌های دچار پدیده فراینددانه‌سازی، به طور قابل توجهی از نظر این مشخصات ضعیف‌تر هستند و این امر می‌تواند تأثیر منفی بر کیفیت و طعم میوه داشته باشد. (Wang et al., 2014). همچنین در تحقیقاتی معلوم شد که در میوه‌های دانه‌سازی شده، میزان آب‌میوه به علت تشکیل ژل در آبدانک‌ها کاهش می‌یابد (Ritenour et al.,

1- Soluble Solids Content
2- Titratable Acidity
3- Moisture Content

داد که با توسعه این پدیده در پرتقال، میزان جذب در ناحیه ۴۰۰ نانومتر تا ۹۵۰ نانومتر به‌طور محسوسی کاهش پیدا کرد، به‌طوری که در ناحیه ۵۷۰ نانومتر تا ۸۵۰ نانومتر، اختلاف شدت جذب برای طبقه‌های مختلف دانه‌سازی شدن در شکل کاملاً مشخص است که این نتایج توسط Theanjumol *et al.* (2019) در بررسی فرایند دانه‌سازی در نارنگی نیز گزارش شده است. بنابراین نتایج این بخش نشان داد که تحلیل و بررسی طیف‌های مادون‌قرمز نزدیک، ابزاری غیرمخرب جهت تخمین محتوای رطوبتی پرتقال و شدت فرایند دانه‌سازی در آن است.

مشاهده شد که دلیل آن ناشی از جذب کروفیل a در پرتقال است که نتایج مشابهی توسط محققان (Jamshidi *et al.*, 2014) ارائه شده است. لذا طول موج ۶۸۰ و ۹۸۰ نانومتر، معیاری مناسب جهت تخمین محتوای آبی نمونه است. از طرفی نتایج بخش قبل نشان داد که با افزایش سطح فرایند دانه‌سازی از A تا E، محتوای رطوبتی پرتقال ۳۶/۸٪ کاهش یافت بنابراین میزان جذب در طول موج ۶۸۰ و ۹۸۰ نانومتر به ازای طبقه‌های مختلف فرایند دانه‌سازی متفاوت و نشان دهنده همبستگی بین نتایج این بخش و بخش قبل است. بررسی طیف‌های نمایش داده‌شده به ازای سطوح مختلف فرایند دانه‌سازی نشان



شکل ۴- نمودار طیف جذبی نمونه‌های مختلف پرتقال در سطوح مختلف دانه‌سازی شدن

نشان داد که حساسیت این مدل در پیش‌بینی نمونه‌های بدون فرایند دانه‌سازی ۹۷/۳۰ درصد است. همچنین حساسیت این مدل در تشخیص سطوح A، B، C، D و E به ترتیب برابر با ۸۵/۷۰، ۹۴/۶۰، ۸۰/۶۰ و ۱۰۰ درصد بود. با تغییر نوع هسته، دقت مدل ماشین بردار پشتیبان نیز تغییر کرد، به‌طوری که دقت کلی ماشین بردار پشتیبان به ازای هسته پایه شعاعی گوسی برابر با ۹۵ درصد بود. حساسیت این مدل در تشخیص طبقه‌های A، B، C، D و E به ترتیب برابر با ۹۷/۳۰، ۹۱/۴۰، ۹۴/۶۰، ۹۰/۳۰ و ۱۰۰ درصد بود.

پیش‌بینی سطوح فرایند دانه‌سازی

به‌منظور طبقه‌بندی سطوح فرایند دانه‌سازی در پرتقال، مدل ماشین بردار پشتیبان با سه هسته خطی، چندجمله‌ای و پایه شعاعی گوسی با شاخص‌های $C = 5$ و $\gamma = 10$ توسعه داده شد. در شکل ۶ ماتریس اغتشاش هر سه مدل جهت طبقه‌بندی سطوح فرایند دانه‌سازی نشان داده‌شده است. نتایج نشان داد که دقت کلی ماشین بردار پشتیبان به ازای هسته‌های خطی، چندجمله‌ای و پایه شعاعی گوسی جهت تشخیص سطوح دانه‌سازی شدن پرتقال به ترتیب برابر با ۹۲/۵۰، ۹۶/۵۰ و ۹۵/۰۰ درصد مشاهده شد. دقت ماشین بردار پشتیبان با هسته خطی

به ازای SVM با هسته چندجمله‌ای، حساسیت این طبقه‌بند در تشخیص پرتقال‌های بدون پدیده دانه‌سازی ۹۸/۶۰ درصد و میزان حساسیت این مدل در تشخیص سطوح مختلف دانه‌سازی شدن برای شدت B، C، D و E به ترتیب برابر با ۹۱/۴۰، ۹۷/۳۰، ۹۶/۸۰ و ۹۵/۷۰ درصد بود. مقایسه نتایج نشان داد که هسته چندجمله‌ای دارای دقت بیشتری جهت طبقه‌بندی سطوح دانه‌سازی شدن پرتقال بر اساس ویژگی‌های استخراجی از طیف جذبی است. بررسی ماتریس اغتشاش نشان می‌دهد که در حالت A، طبقه‌بند به اشتباه یک طیف را در سطح B طبقه‌بندی کرده است. در طبقه B، ماشین بردار پشتیبان به اشتباه دو طیف را مربوط به حالت A طبقه‌بندی کرده است. این نتایج نشان داد که معمولاً خطای مدل طبقه‌بندی، برای سطوح دانه‌سازی شدن مجاور هم بوده است که این موضوع ناشی از نزدیک بودن سطوح تعریف شده برای دانه‌سازی شدن نمونه‌ها است. در تحقیقی که توسط Theanjumpol et al. (2019) انجام شد، بالاترین دقت طبقه‌بندی سطوح فرایند دانه‌سازی در نارنگی برابر با

۹۵/۵ درصد به دست آمد. در تحقیقی از الگوریتم نزدیک‌ترین همسایه جهت طبقه‌بندی سطوح فرایند دانه‌سازی در پرتقال و لیمو استفاده کردند که دقت نهایی روش پیشنهادی به ترتیب برابر با ۹۵/۷۰ و ۹۳/۶۰ درصد بود (Van Dael et al., 2016; Jie et al., 2020). از یک شبکه عصبی کانولوشنی برای طبقه‌بندی سطوح فرایند دانه‌سازی در مرکبات استفاده کردند که به دقت نهایی ۸۸/۰۲ درصد دست یافتند (Jie et al., 2020). در مجموع نتایج طبقه‌بندی سطوح فرایند دانه‌سازی در پرتقال نشان داد که روش پیشنهادی منجر به بهبود نتایج در مقایسه با سایر روش‌های خطی و غیرخطی برای طبقه‌بندی فرایند دانه‌سازی در میوه‌ها شده است (Sharma et al., 2004; Suphamitmongkol et al., 2013; Theanjumpol et al., 2019)؛ بنابراین نتایج این تحقیق کاربرد استفاده از روش غیرمخرب مادون‌قرمز نزدیک و مدل ماشین بردار پشتیبان برای شناسایی فرایند دانه‌سازی در مرکبات را تأیید می‌کند.

		SVM-Linear Kernel					Specificity
Output Class	A	72 36.0%	5 2.5%	0 0.0%	0 0.0%	0 0.0%	93.5% 6.5%
	B	2 1.0%	30 15.0%	0 0.0%	0 0.0%	0 0.0%	93.8% 6.3%
	C	0 0.0%	0 0.0%	35 17.5%	6 3.0%	0 0.0%	85.4% 14.6%
	D	0 0.0%	0 0.0%	2 1.0%	25 12.5%	0 0.0%	92.6% 7.4%
	E	0 0.0%	0 0.0%	0 0.0%	0 0.0%	23 11.5%	100% 0.0%
Sensitivity		97.3% 2.7%	85.7% 14.3%	94.6% 5.4%	80.6% 19.4%	100% 0.0%	92.5% 7.5%
		Target Class					Accuracy

		SVM-RBF Kernel					Specificity
Output Class	A	72 36.0%	3 1.5%	0 0.0%	0 0.0%	0 0.0%	96.0% 4.0%
	B	2 1.0%	32 16.0%	0 0.0%	0 0.0%	0 0.0%	94.1% 5.9%
	C	0 0.0%	0 0.0%	35 17.5%	3 1.5%	0 0.0%	92.1% 7.9%
	D	0 0.0%	0 0.0%	2 1.0%	28 14.0%	0 0.0%	93.3% 6.7%
	E	0 0.0%	0 0.0%	0 0.0%	0 0.0%	23 11.5%	100% 0.0%
Sensitivity		97.3% 2.7%	91.4% 8.6%	94.6% 5.4%	90.3% 9.7%	100% 0.0%	95.0% 5.0%
		Target Class					Accuracy

		SVM-Polynomial					Specificity
Output Class	A	73 36.5%	2 1.0%	0 0.0%	0 0.0%	0 0.0%	97.3% 2.7%
	B	1 0.5%	32 16.0%	0 0.0%	0 0.0%	0 0.0%	97.0% 3.0%
	C	0 0.0%	1 0.5%	36 18.0%	1 0.5%	0 0.0%	94.7% 5.3%
	D	0 0.0%	0 0.0%	1 0.5%	30 15.0%	1 0.5%	93.8% 6.3%
	E	0 0.0%	0 0.0%	0 0.0%	0 0.0%	22 11.0%	100% 0.0%
Sensitivity		98.6% 1.4%	91.4% 8.6%	97.3% 2.7%	96.8% 3.2%	95.7% 4.3%	96.5% 3.5%
		Target Class					Accuracy

شکل ۵- ماتریس اغتشاش خروجی مدل‌های مختلف ماشین بردار پشتیبان جهت طبقه‌بندی سطوح فرایند دانه‌سازی در پرتقال

نانومتر بیشینه بود اما بین سطوح مختلف دانه‌سازی شدن در این نواحی هیچ اختلافی مشاهده نشد؛ اما شدت جذب در ناحیه ۳۵۰ تا ۵۵۰ با شیب تندی کاهش و مجدداً از ۵۵۰ تا ۹۵۰ افزایش یافت. همچنین با توسعه فرایند دانه‌سازی در پرتقال، میزان جذب در ناحیه ۴۰۰ نانومتر تا ۹۵۰ نانومتر به‌طور محسوسی کاهش پیدا کرد که در ناحیه ۵۷۰ نانومتر تا ۸۵۰ نانومتر، اختلاف شدت جذب برای طبقه‌های مختلف دانه‌سازی شدن بیشینه بود.

۳- نتایج تشخیص سطوح فرایند دانه‌سازی نشان داد که دقت کلی ماشین بردار پشتیبان به ازای هسته‌های خطی،

نتیجه‌گیری

در این تحقیق نتایج زیر به دست آمد:

- ۱- با افزایش و توسعه شدت فرایند دانه‌سازی، کیسه‌های آب‌میوه سفت‌تر، خشک‌تر و بزرگ‌تر شده و محتوای آبی آن‌ها کاهش یافت که بیش‌ترین محتوای رطوبتی پرتقال ۹۰/۹۷ درصد در حالت بدون پدیده دانه‌سازی و کم‌ترین آن ۸۳/۳۶ درصد در حالت دانه‌سازی شدن بیش از ۷۵ درصد بافت آن مشاهده شد.
- ۲- بررسی طیف‌های مادون‌قرمز نزدیک نشان داد که شدت جذب در ناحیه ۱۸۰ تا ۳۵۰ نانومتر و ۹۵۰ تا ۱۱۰

- Destructive Quality Assessment of Oranges Using NIRS. *Journal of Agricultural Engineering Research*, 15(2): 27-44. doi:<https://doi.org/10.22092/jaer.2014.100188>
- Jia, N., Liu, J., Sun, Y., Tan, P., Cao, H., Xie, Y., Wen, B., Gu, T., Liu, J., Li, M., & Huang, Y. (2018). Citrus sinensis MYB transcription factors CsMYB330 and CsMYB308 regulate fruit juice sac lignification through fine-tuning expression of the Cs4CL1 gene. *Plant science*, 277: 334-43. <https://doi.org/10.1016/j.plantsci.2018.10.006>
- Jie, D., Wu, S., Wang, P., Li, Y., Ye, D., & Wei, X. (2020). Research on Citrus grandis Granulation Determination Based on Hyperspectral Imaging through Deep Learning. *Food Analytical Methods*, 14(2): 280-289. doi:<https://doi.org/10.1007/s12161-020-01873-6>
- Jiménez-Jiménez, F., Castro-García, S., Blanco-Roldán, G. L., Agüera-Vega, J., & Gil-Ribes, J. A. (2012). Non-destructive determination of impact bruising on table olives using Vis-NIR spectroscopy. *biosystems engineering*, 113(4): 371-378. doi:<https://doi.org/10.1016/j.biosystemseng.2012.09.007>
- Kumari, N., Bhatt, A., Dwivedi, R. K., & Belwal, R. (2019). Performance analysis of support vector machine in defective and non defective mangoes classification. *International Journal of Engineering and Advanced Technology (IJEAT)*, 8(4): 1563-1572. Retrieved from <https://www.ijeat.org/wp-content/uploads/papers/v8i4/D6669048419.pdf>
- Law, S. E. (2006). Scatter of near-Infrared Radiation by Cherries as a Means of Pit Detection. *Journal of Food Science*, 38(1): 102-107. doi:<https://doi.org/10.1111/j.1365-2621.1973.tb02788.x>
- Magwaza, L. S. (2013). *Non-destructive prediction and monitoring of postharvest quality of citrus fruit*. (Doctor of Philosophy). Stellenbosch Retrieved from <https://scholar.sun.ac.za/bitstreams/245500e7-09a3-4606-9132-f90227a6b317/download>
- Moghaddam, S., Goudarzi, A. R., Oskooi, B., & Azad, A. (2022). GPR Random noise attenuation using Savitzky-Golay filter in the dual-tree complex wavelet domain. *Journal Of Research on Applied Geophysics*, 7(4): 361-379.
- Mogollon, M., Jara, A., Contreras, C., & Zoffoli, J. P. (2020). Quantitative and چندجمله‌ای و پایه شعاعی گوسی به ترتیب برابر با ۹۵/۵۰، ۹۲/۵۰ و ۹۶/۵۰ درصد بود که به ازای SVM با هسته چندجمله‌ای، حساسیت این طبقه‌بند در تشخیص سطوح مختلف دانه‌سازی شدن برای شدت A، B، C، D و E به ترتیب برابر با ۹۸/۰، ۹۱/۴۰، ۹۷/۳۰، ۹۶/۸۰ و ۹۵/۷۰ درصد بود.

منابع

- Ahmadi, K., Abadzadeh, H., Abdshah, H., Hatami, F., & Hosseinpour, R. (2017). *Agricultural Statistics of 1396: Horticultural Products* (Vol. 3). Tehran: Information Technology and Communications of the Ministry of Agriculture Jihad.
- Association of Official Analytical Chemists. (2000). *Official Methods of Analysis* (17th ed.). Gaithersburg, MD, USA: The Association of Official Analytical Chemists.
- Campbell, C., & Ying, Y. (2022). *Learning with support vector machines*: Springer Nature.
- Carvalho, L. C., Morais, C. L. M., Lima, K. M. G., Leite, G. W. P., Oliveira, G. S., Casagrande, I. P., Teixeira, G. H. A. (2017). Using Intact Nuts and Near Infrared Spectroscopy to Classify Macadamia Cultivars. *Food Analytical Methods*, 11(7): 1857-1866. doi:<https://doi.org/10.1007/s12161-017-1078-9>
- Cervantes, J., Garcia-Lamont, F., Rodríguez-Mazahua, L., & Lopez, A. (2020). A comprehensive survey on support vector machine classification: Applications, challenges and trends. *Neurocomputing*, 408: 189-215.
- Fattahi Moghadam, J., & Faqih Nasiri, M. (2015). Solutions for picking, storing, grading and packing citrus fruits. 1-22. Retrieved from https://agrilib.areeo.ac.ir/book_4479.pdf
- Food and Agriculture Organization. (2018). *World Food and Agriculture-Statistical Pocketbook 2018*. Rome: FAO.
- Henderi, H. (2021). Comparison of Min-Max normalization and Z-Score Normalization in the K-nearest neighbor (kNN) Algorithm to Test the Accuracy of Types of Breast Cancer. *IJIS: International Journal of Informatics and Information Systems*, 4(1): 13-20. doi:<https://doi.org/10.47738/ijis.v4i1.73>
- Jamshidi, B., Minaei, S., Mohajerani, E., & Ghassemian, H. (2014). Effect of Spectral Pre-Processing Methods on Non-

- Theanjumpol, P., Wongzeewasakun, K., Muenmanee, N., Wongsaipun, S., Krongchai, C., Changrue, V., & Kittiwachana, S. (2019). Non-destructive identification and estimation of granulation in 'Sai Num Pung' tangerine fruit using near infrared spectroscopy and chemometrics. *Postharvest Biology and Technology*, 153: 13-20. doi:https://doi.org/10.1016/j.postharvbio.2019.03.009
- Van Dael, M., Lebotsa, S., Herremans, E., Verboven, P., Sijbers, J., Opara, U., & Nicolaï, B. (2016). A segmentation and classification algorithm for online detection of internal disorders in citrus using X-ray radiographs. *Postharvest Biology and Technology*, 112: 205-214.
- Wang, S. Y., Wang, P. C., & Faust, M. (1988). Non-destructive detection of watercore in apple with nuclear magnetic resonance imaging. *Scientia horticulturae*, 35(3-4): 227-234. doi:https://doi.org/10.1016/0304-4238(88)90116-1
- Wang, X.-Y., Wang, P., Qi, Y.-P., Zhou, C. P., Yang, L.-T., Liao, X.-Y., & Chen, L. S. (2014). Effects of granulation on organic acid metabolism and its relation to mineral elements in Citrus grandis juice sacs. *Food chemistry*, 145: 984-990.
- Wang, Z., Künnemeyer, R., McGlone, A., & Burdon, J. (2020). Potential of Vis-NIR spectroscopy for detection of chilling injury in kiwifruit. *Postharvest Biology and Technology*, 164: 111160. doi:https://doi.org/10.1016/j.postharvbio.2020.111160
- Xiong, B., Ye, Sh., Xia Q., & Liao L. (2017). *Exogenous spermidine alleviates fruit granulation in a Citrus cultivar (Huangguogan) through the antioxidant pathway*. *Acta Physiologiae Plantarum*, 39(4): 1-8. DOI:10.1007/s11738-017-2397-6
- Zhang, J., & Mouazen, A. M. (2023). Fractional-order Savitzky-Golay filter for pre-treatment of on-line vis-NIR spectra to predict phosphorus in soil. *Infrared Physics & Technology*, 131: 104720. doi:https://doi.org/10.1016/j.infrared.2023.104720
- qualitative VIS-NIR models for early determination of internal browning in 'Cripps Pink' apples during cold storage. *Postharvest Biology and Technology*, 161: 111060.
- Munera, S., Besada, C., Aleixos, N., Talens, P., Salvador, A., Sun, D. W., & Blasco, J. (2017). Non-destructive assessment of the internal quality of intact persimmon using colour and VIS/NIR hyperspectral imaging. *LWT*, 77: 241-248. doi:https://doi.org/10.1016/j.lwt.2016.11.063
- Ritenour, M. A., Albrigo, L. G., Burns, J. K., & Miller, W. M. (2004). Granulation in Florida citrus. *Proceedings of the Florida State Horticultural Society*, 117, 358-361.
- Sharma, R. R., Singh, R., & Saxena, S. K. (2006). Characteristics of citrus fruits in relation to granulation. *Scientia horticulturae*, 111(1): 91-96. doi:https://doi.org/10.1016/j.scienta.2006.09.007
- Sharma, R., & Saxena, S. (2004). Rootstocks influence granulation in Kinnow mandarin (Citrus nobilis × C. deliciosa). *Scientia horticulturae*, 101(3): 235-242.
- Shi, X., Yao, L., & Pan, T. (2021). Visible and Near-Infrared Spectroscopy with Multi-Parameters Optimization of Savitzky-Golay Smoothing Applied to Rapid Analysis of Soil Cr Content of Pearl River Delta. *Journal of Geoscience and Environment Protection*, 9(3): 75-83. doi:https://doi.org/10.4236/gep.2021.93006
- Sonego, L., Ben-Arie, R., Raynal, J., & Pech, J. C. (1995). Biochemical and physical evaluation of textural characteristics of nectarines exhibiting woolly breakdown: NMR imaging, X-ray computed tomography and pectin composition. *Postharvest Biology and Technology*, 5(3): 187-198. doi:https://doi.org/10.1016/0925-5214(94)00026-O
- Sun, X., Xu, S., & Lu, H. (2020). Non-Destructive Identification and Estimation of Granulation in Honey Pomelo Using Visible and Near-Infrared Transmittance Spectroscopy Combined with Machine Vision Technology. *Applied Sciences*, 10(16): 5399. doi:https://doi.org/10.3390/app10165399
- Suphamitmongkol, W., Nie, G., Liu, R., Kasemsumran, S., & Shi, Y. (2013). An alternative approach for the classification of orange varieties based on near infrared spectroscopy. *Computers and electronics in agriculture*, 91: 87-93. doi:https://doi.org/10.1016/j.compag.2012.11.014

