

Research Article

Classification of hawthorn fruit based on ripeness level by machine vision

Rahim Azadnia^{1*}, Kamran Kheiralipour², Mostafa Jafrian³

1. PhD student, Department of Biosystems Engineering, Faculty of Agricultural Engineering and Technology, College of Agriculture and Natural Resources, University of Tehran, Karaj, Iran
2. Associate Professor, Mechanical Engineering of Biosystems Department, Ilam University, Ilam, Iran.
3. Department of Agricultural Engineering, Technical and Vocational University (TVU), Tehran, Iran

(Received 12 March 2022, Received in revised form 17 April 2022, Accepted 08 May 2022)

Abstract

Marketability of the produced products largely depends on their appearance. Therefore, the aim of the present study was to develop the required algorithms to extract, select, and classify the images' features of hawthorn samples in order to classify different fruit classes based on the ripeness stages. Six hundred of hawthorn fruit samples were prepared. Afterward, a lighting box was designed and constructed to capture images from hawthorn specimens under controlled lighting conditions. After imaging and saving the images of hawthorn samples, image processing operation in MATLAB Software was done. In this step after image preprocessing, color and texture features were extracted. Through all extracted features, some features were selected as efficient ones by sequential selection method with quadratic base in MATLAB Software. Linear and quadratic discriminant analysis methods were used to classify the efficient features. The obtained results indicated that the methods were able to classify the images of hawthorn samples with same accuracies (98.67 %). Furthermore, accuracy, precision, sensitivity, and specificity parameters were calculated for the classifier models. The results indicated that the accuracy of hawthorn samples by classifier models based on linear and quadratic discriminant analysis models were 98.67 and 99.33 %, respectively in the train step and they were same as 98.67 % in the test step. Also based on the results of the determined parameters, the quadratic discriminant analysis model had better performance than the linear discriminant analysis model.

Keywords: Hawthorn, Ripeness, Classification, Image processing, Discriminant analysis methods.

How to cite this article:

Azadnia, R., Kheiralipour, K., Jafrian, M., (2022). Classification of hawthorn fruit based on ripeness level by machine vision. *Innov. Food Technol.*, 9(4), 331-344.

* Corresponding authors: Rahim.azadnia@ut.ac.ir

مقاله پژوهشی

طبقه‌بندی میوه زالزالک بر مبنای رسیدگی با استفاده از ماشین بینایی

رحیم آزادنیا^{۱*}، کامران خیرعلی پور^۲، مصطفی جعفریان^۳

۱. دانشجوی دکتری، گروه مهندسی مکانیک بیوسیستم، دانشکده مهندسی و فناوری کشاورزی، پردیس کشاورزی و منابع طبیعی کرج، دانشگاه تهران، کرج، ایران
۲. دانشیار، گروه مهندسی مکانیک بیوسیستم، دانشگاه ایلام، ایلام، ایران
۳. گروه مهندسی کشاورزی، دانشگاه فنی و حرفه‌ای، تهران، ایران

(تاریخ ارسال: ۱۴۰۰/۱۲/۲۱، تاریخ آخرین بازنگری: ۱۴۰۱/۰۱/۲۸، تاریخ پذیرش: ۱۴۰۱/۰۲/۱۸)

چکیده

بازارپسندی محصولات تولیدی به‌طور گسترده‌ای به‌ظاهر آنها بستگی دارد. لذا هدف از مطالعه حاضر توسعه الگوریتم‌هایی برای استخراج، انتخاب و طبقه‌بندی ویژگی‌های تصاویر نمونه‌های زالزالک به‌منظور طبقه‌بندی آنها براساس سطح رسیدگی است. تعداد ۶۰۰ نمونه میوه زالزالک تهیه شد. در مرحله بعد یک جعبه نورپردازی به‌منظور تصویربرداری از نمونه‌های زالزالک با نورپردازی کنترل‌شده طراحی و ساخته شد. پس از تصویربرداری و ذخیره تصاویر به‌دست‌آمده، فرآیند پردازش تصویر در نرم‌افزار متلب اجرا شد. در این مرحله بعد از عملیات پیش‌پردازش، ویژگی‌های رنگ و بافت از تصاویر استخراج شد. از بین ویژگی‌های استخراج‌شده تعدادی ویژگی به‌عنوان ویژگی‌های کارا با استفاده از روش انتخاب ترتیبی با پایه درجه دوم در نرم‌افزار متلب انتخاب شدند. از روش‌های تحلیل تفکیک خطی و درجه دوم برای طبقه‌بندی ویژگی‌های کارا استفاده شد. پارامترهای دقت، صحت، حساسیت و خاصیت برای مدل‌های طبقه‌بندی محاسبه شدند. میانگین دقت طبقه‌بندی نمونه‌های مختلف زالزالک با استفاده از روش‌های تحلیل تفکیک خطی و درجه دوم در مرحله آموزش به ترتیب برابر ۹۸/۶۷ و ۹۹/۳۳٪ و در مرحله آزمون با هم مشابه و برابر با ۹۸/۶۷٪ بود. همچنین بر اساس نتایج مربوط به پارامترهای تعیین‌شده، مدل تحلیل تفکیک درجه دوم از مدل تحلیل تفکیک خطی عملکرد بهتری داشت.

واژه‌های کلیدی: زالزالک، رسیدگی، پردازش تصویر، طبقه‌بندی، روش‌های تحلیل تفکیک.

* نویسنده مسئول: Rahim.azadnia@ut.ac.ir

۱. مقدمه

زلزالتک با نام علمی *Crataegus pinnatifida* یکی از پرمصرفترین محصولات باغی است که به صورت تازه و فرآوری شده مورد استفاده قرار می‌گیرد. این میوه علاوه بر عطر و طعم، دارای رنگ جذاب و حاوی مواد غذایی و مغذی زیادی می‌باشد [۱-۲]. زلزالتک دارای خواص دارویی و درمانی همانند اثرات آنتی‌کسیدانی، ضدالتهابی و کاهش چربی خون بوده و در درمان بیماری‌های قلبی عروقی مفید است [۳-۵].

ارزیابی محصولات کشاورزی یکی از مهم‌ترین عملیات در بخش کشاورزی، یعنی مرحله پس از برداشت است. در سال‌های اخیر محققان به طراحی سامانه‌های نوین و هوشمند برای کیفیت‌سنجی و درجه‌بندی محصولات کشاورزی پرداخته‌اند [۶-۷]. در این زمینه فناوری‌هایی همچون ماشین بینایی و پردازش تصویر در حوزه کشاورزی پرکاربرد هستند. این سامانه‌ها جایگزین مناسبی برای درجه‌بندی دستی و تشخیص آزمایشگاهی کیفیت محصولات هستند؛ چرا که مدت زمان و هزینه اجرای عملیات سامانه‌های نوین پایین‌تر است.

در حوزه کشاورزی مطالعات زیادی در زمینه درجه‌بندی و طبقه‌بندی محصولات به کمک پردازش تصویر گزارش شده است [۸-۱۱]. ویژگی‌های ظاهری و بصری محصولات کشاورزی مانند رنگ، اندازه، شکل و بافت در ارزیابی کیفیت محصولات بسیار تأثیرگذار هستند؛ بنابراین توسعه و طراحی یک سامانه هوشمند برای درجه‌بندی محصولات به ویژگی‌های اشاره‌شده بستگی دارد. با بهره‌گیری از روش پردازش تصویر سامانه هوشمندی به منظور درجه‌بندی توت‌فرنگی براساس ویژگی‌های رنگ و شکل طراحی شده که توانسته است با دقت بالای ۸۸٪ توت‌فرنگی را طبقه‌بندی کند [۱۲]. در تحقیقی دیگر محققین سامانه‌ای را برای طبقه‌بندی میوه‌های مختلف با دقت ۹۰٪ طراحی و توسعه دادند [۱۳].


در تحقیق دیگر، سامانه‌ای به منظور طبقه‌بندی میوه‌های سیب سالم و ناسالم براساس شکل و رنگ با دقت ۷۳-۹۶٪ توسعه یافت [۱۴]. الگوریتم هوشمندی به منظور درجه‌بندی میوه سیب براساس ویژگی‌های رنگ با استفاده از روش طبقه‌بندی ماشین بردار پشتیبان پیشنهاد شده است [۱۵]. با توجه به مطالب بالا، طراحی یک سامانه هوشمند برای طبقه‌بندی محصولات کشاورزی به منظور درجه‌بندی و سپس بسته‌بندی با کیفیت و جلوگیری از هدر رفت محصولات کشاورزی یک عملیات ضروری است؛ بنابراین در تحقیق حاضر از فناوری ماشین بینایی به منظور استخراج ویژگی‌های ظاهری رنگ و بافت از تصاویر میوه زلزالتک با هدف طبقه‌بندی آن با استفاده از روش‌های آماری تحلیل تفکیک خطی و درجه دوم مورد استفاده قرار گرفت. از روش پردازش تصویر برای طبقه‌بندی میوه زلزالتک استفاده شده است؛ اما طبقه‌بندی براساس کیفیت بوده است [۱۶]. نوآوری تحقیق حاضر استفاده از فناوری ماشین بینایی برای طبقه‌بندی میوه زلزالتک بر مبنای سطح رسیدگی می‌باشد تا بتوان به طور خودکار میوه نارس، رسیده و بیش رس را از هم تشخیص داد.

۲. مواد و روش‌ها

در تحقیق حاضر به منظور طبقه‌بندی میوه زلزالتک در سه مرحله رسیدگی، عملیات پیش‌پردازش تصویر پس از عملیات جمع‌آوری نمونه‌ها و تصویربرداری اجرا شد.

۱.۲. آماده‌سازی نمونه‌ها

نمونه‌های میوه زلزالتک موجود در پژوهش حاضر در شهرستان سلماس واقع در استان آذربایجان غربی جمع‌آوری شدند. نمونه‌ها بعد از جمع‌آوری به آزمایشگاه منتقل و توسط فرد خبره به سه گروه (۱) رسیده، (۲) نارس و (۳) بیش رس به صورت دستی طبقه‌بندی شدند (شکل ۱).




شکل (۱) نمونه‌های میوه زالزالک.

Fig 1. Hawthorn fruit samples.

تصویربرداری از نمونه‌های جمع‌آوری شده یکی از فرآیندهای مؤثر در طراحی سامانه هوشمند برای جداسازی محصولات کشاورزی براساس رسیدگی میوه محسوب می‌شود. در همین زمینه در تحقیق حاضر یک سامانه تصویربرداری به‌منظور اکتساب تصاویر نمونه‌های جمع‌آوری شده توسعه یافت. مطابق با شکل (۲) اجزا تشکیل‌دهنده سامانه تصویربرداری در این تحقیق شامل: (۱) تلفن همراه (Galaxy A8, SAMSUNG corporation) با مشخصات $2048 \times$

تصویربرداری از نمونه‌های جمع‌آوری شده یکی از فرآیندهای مؤثر در طراحی سامانه هوشمند برای جداسازی محصولات کشاورزی براساس رسیدگی میوه محسوب می‌شود. در همین زمینه در تحقیق حاضر یک سامانه تصویربرداری به‌منظور اکتساب تصاویر نمونه‌های جمع‌آوری شده توسعه یافت. مطابق با شکل (۲) اجزا تشکیل‌دهنده سامانه تصویربرداری در این تحقیق شامل: (۱) تلفن همراه (Galaxy A8, SAMSUNG corporation) با مشخصات $2048 \times$




شکل (۲) طرح واره سامانه تصویربرداری طراحی شده برای تهیه تصاویر زالزالک.

Fig 2. Schematic of designed imaging system for acquire hawthorn images.

شود [۱۷]. مطابق شکل (۳) الگوریتمی طراحی شد تا بر روی تصاویر اصلی نمونه‌های زالک عملیات پیش‌پردازش به‌طور خودکار انجام شود [۱۸-۲۰]. کانال رنگی آبی (B) برای انجام عملیات پیش‌پردازش بر روی تصاویر نمونه‌های زالک مورد استفاده قرار گرفت. انتخاب شد. بعد از عملیات پیش‌پردازش و قطعه‌بندی تصاویر، در گام بعدی ویژگی‌های بافت و رنگ تصاویر استخراج شدند.

۴.۲. عملیات پیش‌پردازش

هدف از انجام عملیات پیش‌پردازش بر روی تصاویر دیجیتال، بهبود کیفیت تصاویر، قطعه‌بندی و حذف پس‌زمینه است تا در مرحله بعد ویژگی‌های مختلفی از تصاویر استخراج شود. این عملیات برای تقویت یکسری از ویژگی داده‌های ورودی و حذف اغتشاشات ناخواسته استفاده می‌شوند تا عملیات پردازش اصلی روی تصاویر بهتر انجام



شکل (۳) عملیات پردازش تصویر.

Fig 3. Image processing operation.

که ۱۹ کانال برای هر تصویر زالک به دست آمد. از هر کانال، هم ویژگی‌های رنگ و هم ویژگی‌های بافت استخراج گردید [۲۱-۲۶].

۵.۲. استخراج ویژگی

در این مطالعه چندین فضای رنگی از طریق تعریف توابع انتقال فضای رنگی RGB مطابق با جدول (۱) به دست آمد و سپس کانال‌های مختلف از هر فضای رنگ جدا شد به‌طوری

جدول (۱) روابط مربوط به فضاهای رنگی مختلف [۲۲-۲۶].

Table 1. Equations of various color spaces [22-26]

فضای رنگی Color space	رابطه Equation	فضای رنگی Color space	رابطه Equation
NRGB	$NR = \frac{R}{R + G + B}$	$C_r C_g C_b$	$C_R = 0.6R - 0.6G - 0.1B$
	$NG = \frac{G}{R + G + B}$		$C_g = -0.3R + 0.3G - 0.1B$
	$NB = \frac{B}{R + G + B}$		$C_b = -0.3R - 0.6G + 0.9B$
I1I2I3	$I1 = \frac{R + G + B}{3}$	XYZ	$X = 0.607R + 0.174G + 0.2B$
	$I2 = \frac{R - B}{2}$		$Y = 0.299R + 0.587G + 0.114B$
	$I3 = \frac{2G - R - B}{4}$		$Z = 0.066G + 1.116B$
L*a*b*	$L^* = 116Y^{1/3} - 16$	HIS	$H = \arctan\left[\frac{\sqrt{3}(G - B)}{(R - G) + (R - B)}\right]$
	$a^* = \left(\frac{X}{0.981}\right)^{1/3} - (Y)^{1/3}$		$S = 1 - \frac{3}{(R + G + B)} [\min(R, G, B)]$
	$b^* = 200 \left((Y)^{1/3} - (Z/1.182)^{1/3} \right)$		$I = \frac{1}{3}(R + G + B)$

می‌گیرد. تحلیل بافت در حالت کلی به چهار دسته ساختاری، بر پایه مدل، تئوری سیگنالی و آماری طبقه‌بندی می‌شوند [۲۲-۲۶]. بر این اساس مطابق با جدول (۳) چندین ویژگی بافت از جمله همبستگی، همگنی، تباین، آنتروپی و انرژی از ماتریس هم‌وقوعی به‌دست‌آمده از تصاویر اصلی زالزالک محاسبه و استخراج شدند. از هر کانال تصویر زالزالک (۱۹ کانال) تعداد ۱۵ (پنج ویژگی بافت و ۱۰ ویژگی رنگ) ویژگی استخراج شد به‌طوری که در مجموع ۲۸۵ ویژگی به دست آمد.

۱.۵.۲. ویژگی‌های رنگ

تعداد ۱۰ ویژگی رنگ شامل حداقل، میانگین، حداکثر، واریانس، انحراف معیار، ضریب تغییرات، میانه، مد، چولگی و کشیدگی از هر کانال رنگی استخراج شد [۲۲-۲۶]. مقادیر پیکسل‌های تصویر زالزالک هر کانال تصویر به‌طور خودکار توسط نرم‌افزار متلب محاسبه شد. روابط مربوط به برخی از این ویژگی‌ها در جدول (۲) آمده است.

۲.۵.۲. ویژگی‌های بافت

تجزیه و تحلیل بافت یکی از اصلی‌ترین روش‌های پردازش تصویر است که در زمینه‌های گوناگونی مورد استفاده قرار

جدول (۲) ویژگی‌های رنگ و بافت استخراج شده از تصاویر زالزالک [۲۲-۲۶].
Table 2. Extracted color and texture features from hawthorn images [22-26].

ویژگی‌های بافت Texture features		ویژگی‌های رنگ Color features	
رابطه Equation	ویژگی Feature	رابطه Equation	ویژگی Feature
$\frac{\sum_{i=1}^{Ng} \sum_{j=1}^{Ng} (1 - \mu_i) P_d(i, j)}{\sigma_i \sigma_j}$	همبستگی Correlation	$\frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N P(i, j)$	میانگین (μ) Mean(μ)
$\sum_{i=1}^{Ng} \sum_{j=1}^{Ng} \frac{P_d(i, j)}{1 + i - j }$	همگنی Homogeneity	$\left[\frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N (P(i, j) - \mu) \right]^{1/2}$	انحراف معیار (σ) Standard deviation(σ)
$-\sum_{i=0}^{Ng} \sum_{j=0}^{Ng} P_d^2(i, j)$	انرژی Energy	$\frac{1}{MN\sigma^3} \sum_{i=1}^M \sum_{j=1}^N [(P(i, j) - \mu)^3]$	چولگی Skewness
$-\sum_{i=0}^{Ng} \sum_{j=0}^{Ng} P_d(i, j) \log P_d(i, j)$	آنترپی Entropy	$\frac{1}{MN\sigma^4} \sum_{i=1}^M \sum_{j=1}^N [(P(i, j) - \mu)^4]$	کشیدگی Elongation
		$\sum_{i=0}^{Ng-1} (i - \mu)^2 P_d$	واریانس Variance

۶.۲. انتخاب ویژگی

تحلیل تفکیک خطی (LDA) و تحلیل تفکیک درجه دوم (QDA) به منظور طبقه‌بندی این ویژگی‌ها استفاده شد. در روش تفکیک خطی مقدار L_{ij} با استفاده از رابطه (۶) محاسبه می‌شود [۲۸]:

$$L_{ij} = (X_i - \bar{X}_k)^T \Sigma_{pooled}^{-1} (X_i - \bar{X}_k) - 2 \log_e \pi_k \quad (۶)$$

که X_i بردار مربوط به نمونه i ام، \bar{X}_k میانگین بردار طبقه k ، $\Sigma_{pooled} X_i$ ماتریس کوواریانس تلفیق شده و π_k احتمال اولیه وقوع طبقه k ام است. مقدار Q_{ij} در روش تحلیل تفکیک درجه دوم با استفاده از واریانس-کوواریانس ماتریس هر طبقه K تخمین زده می‌شود و طبق رابطه (۷) به دست می‌آید [۲۹].

$$Q_{ij} = (X_i - \bar{X}_k)^T \Sigma_{pooled}^{-1} (X_i - \bar{X}_k) - 2 \log_e \pi_k + \log_e |\Sigma_k| \quad (۷)$$

که Σ_k واریانس-کوواریانس ماتریس طبقه K ام و $|\Sigma_k|$

هدف از عملیات انتخاب ویژگی، کاهش تعداد ویژگی‌های استخراج شده و تعیین ویژگی‌های برجسته و کارا برای بهبود عملکرد مدل‌های طبقه‌بند است [۲۷]؛ بنابراین به منظور دستیابی به بهترین عملکرد مدل‌های طبقه‌بند، الگوریتمی در نرم‌افزار متلب براساس روش انتخاب ترتیبی [۶؛ ۲۴؛ ۲۶] توسعه یافت. این روش بر پایه درجه دوم بوده که ویژگی‌ها را هنگام ارزیابی تابع هدف اضافه یا حذف می‌کند [۲۴]. از میان ویژگی‌های استخراج شده تعدادی ویژگی به‌عنوان ویژگی‌های مهم انتخاب و بردار ویژگی به‌عنوان ورودی مدل‌های طبقه‌بند تشکیل گردید.

۷.۲. توسعه مدل‌های طبقه‌بند

برای طبقه‌بندی نمونه‌های زالزالک، بردار ویژگی‌های مهم انتخاب شده از بین ویژگی‌های استخراجی رنگ و بافت مربوط به تصاویر زالزالک استفاده شد. دو مدل طبقه‌بند به روش‌های

که AC دقت، Pr صحت، Se حساسیت، Sp خاصیت، n_{TP} تعداد نمونه‌هایی مثبت بوده که به‌طور صحیح پیش‌بینی شده‌اند، n_{FP} تعداد نمونه‌های مثبت هستند که به اشتباه پیش‌بینی شده‌اند، n_{TN} تعداد نمونه‌هایی منفی هستند که به‌طور صحیح پیش‌بینی شده‌اند و n_{FN} تعداد نمونه‌های منفی هستند که به اشتباه پیش‌بینی شده‌اند.

۳. نتایج و بحث

در حالت کلی از ۶۰۰ نمونه زلزاک تحت شرایط نوری کنترل‌شده تصویربرداری شد. تصاویر به‌دست‌آمده براساس میزان سطح رسیدگی میوه به سه دسته رسیده، نارس و بیش‌رس (از هر گروه ۲۰۰ نمونه) طبقه‌بندی شدند.

۱.۳. انتخاب ویژگی‌های کارا

کاهش متغیرهای ورودی به‌دلیل کثرت تعداد آنها به‌منظور دستیابی به بهترین عملکرد طبقه‌بندی، یک امر مهم محسوب می‌شود؛ بنابراین در این مطالعه به‌منظور انتخاب ویژگی‌های کارا الگوریتمی مبتنی بر روش انتخاب ترتیبی ویژگی‌ها بر پایه درجه دوم در نرم‌افزار متلب کدنویسی شد. تعداد ویژگی‌ها از ۲۸۵ به ۱۴ ویژگی کاهش پیدا کرد. ویژگی‌های کارای انتخاب‌شده در جدول (۳) به‌عنوان داده‌های ورودی مدل‌های طبقه‌بند استفاده شدند.

لگاریتم طبیعی تشخیص واریانس-کواریانس ماتریس Σ_k است. احتمال اولیه (π_k) ، ماتریس کواریانس تلفیق‌شده $(\sum_{pooled} X_i)$ و ماتریس واریانس-کواریانس (Σ_k) با استفاده از روابط (۸) تا (۱۰) به دست می‌آید.

$$\pi_k = \frac{N_k}{N} \quad (8)$$

$$\sum_{pooled} X_i = \frac{1}{N} \sum_{k=1}^k N_k \Sigma_k \quad (9)$$

$$\Sigma_k X_i = \frac{1}{N} \sum_{i=1}^{N_k} (X_i - \bar{X}_k) (X_i - \bar{X}_k)^T \quad (10)$$

درنهایت به‌منظور ارزیابی عملکرد مدل‌های ارائه‌شده، مربع خطای میانگین (MSE) و ضریب تعیین (R^2) با استفاده از روابط (۱۱) و (۱۲) محاسبه شدند.

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_{Estimated} - Y_{Target})^2 \quad (11)$$

$$R^2 = \frac{\sum_{i=1}^n (Y_{Estimated} - Y_{Target})^2}{\sum_{i=1}^n (Y_{Estimated} - Y_{mean})^2} \quad (12)$$

که $Y_{Estimated}$ و Y_{target} به ترتیب مقادیر اندازه‌گیری و پیش‌بینی‌شده هستند. پس از ارائه ماتریس اغتشاش مربوط به دقت مدل‌های پیشنهادشده، مطابق با روابط (۱۳-۱۶) پارامترهای آماری مربوط به عملکرد مدل‌های طبقه‌بند شامل دقت^۱ (AC)، صحت^۲ (Pr)، حساسیت^۳ (Se) و خاصیت^۴ (Sp) محاسبه و برای مقایسه مدل‌ها با هم و تعیین مدل بهینه مورد استفاده قرار گرفتند [۳۰].

$$AC = \frac{n_{TP} + n_{TN}}{n_{TP} + n_{TN} + n_{FP} + n_{FN}} \quad (13)$$

$$Pr = \frac{n_{TP}}{n_{TP} + n_{FP}} \quad (14)$$

$$Se = \frac{n_{TP}}{n_{TP} + n_{FN}} \quad (15)$$

$$Sp = \frac{n_{TN}}{n_{TN} + n_{FP}} \quad (16)$$

1. Accuracy
2. Precision
3. Sensitivity
4. Specificity

جدول (۳) میانگین ویژگی‌های کارای استخراج شده از تصاویر نمونه‌های میوه زالزالک.

Table 3. The mean of the efficient extracted features of the images of hawthorn fruit samples.

سطح رسیدگی نمونه‌های زالزالک			ویژگی
بیش رس Overripe	رسیده Ripe	نارس Unripe	
0.476 ± 0.053b	0.469 ± 0.052b	0.588 ± 0.147a*	حداکثر کانال nb Maximum (nb)
0.126 ± 0.0244a	0.108 ± 0.024b	0.069 ± 0.009c	میانگین سطح خاکستری Gray level mean
0.113 ± 0.0235a	0.098 ± 0.021b	0.080 ± 0.015c	میانگین کانال B Mean (B)
0.882 ± 0.027c	0.937 ± 0.035b	0.956 ± 0.018a	انرژی کانال G Energy(G)
0.842 ± 0.026c	0.87 ± 0.028b	0.926 ± 0.021a	انرژی کانال S Energy(S)
0.929 ± 0.0195c	0.949 ± 0.031b	0.987 ± 0.006a	انرژی کانال I3 Energy(I3)
5.69 ± 0.0191a	5.49 ± 0.141b	5.5 ± 0.169b	آنترپی سطح خاکستری Gray level entropy
7.38 ± 0.244a	7.205 ± 0.228b	7.24 ± 0.115b	آنترپی کانال S Entropy(S)
0.786 ± 0.121a	0.673 ± 0.129b	0.488 ± 0.102c	آنترپی کانال nr Entropy(nr)
-0.0345 ± 0.0086b	-0.0128 ± 0.082a	-0.0721 ± 0.011c	میانه کانال Cb Median(Cb)
0.920 ± 0.013a	0.877 ± 0.026b	0.877 ± 0.027c	همبستگی کانال B Correlation(B)
0.995 ± 0.007b	0.989 ± 0.004c	0.996 ± 0.006a	همبستگی کانال S Correlation(S)
0.405 ± 0.036c	0.475 ± 0.081a	0.445 ± 0.029b	ضریب تغییرات کانال Cr Coefficient of variation (Cr)
0.344 ± 0.107c	0.489 ± 0.287b	2.133 ± 0.801a	ضریب تغییرات کانال H Coefficient of variation (H)

۴.۳. طبقه بندی

برای هر سطح رسیدگی تصویر ۲۰۰ نمونه میوه زالزالک وجود داشته که ۱۵۰ نمونه برای آموزش و ۵۰ نمونه برای آزمون مدل‌های طبقه‌بند استفاده شدند. الگوریتم‌های طبقه‌بند توسعه یافته مبتنی بر روش تحلیل تفکیک در تحقیق حاضر به نحوی کدنویسی شدند که ماتریس اغتشاش و پارامترهای عملکردی آنها برای آموزش و آزمون به صورت جداگانه‌ای محاسبه شوند. نتایج مربوط به مدل‌های طبقه‌بند

نتایج به دست آمده از جدول (۳) نشان می‌دهد که مقادیر میانگین همه ویژگی‌های کارای انتخاب شده از تصاویر مربوط به سطوح مختلف رسیدگی میوه زالزالک متفاوت از هم هستند. وجود تفاوت بین میانگین ویژگی‌های کارای میوه زالزالک شرایط ایده‌آلی را برای مدل‌های طبقه‌بند فراهم کرده تا بتوان به عملکرد مناسبی در طبقه‌بندی و جداسازی نمونه‌های زالزالک با سطح رسیدگی مختلف دست یافت.

در زیربخش‌های ذیل گزارش شده‌اند. مبتنی بر روش تحلیل تفکیک خطی برای داده‌های آموزش و آزمون در جدول (۴) آمده است.

۱.۴.۳. تحلیل تفکیک خطی

دقت طبقه‌بندی و میانگین مربعات خطای مدل طبقه‌بندی

جدول (۴) دقت طبقه‌بندی و میانگین مربعات خطای روش تحلیل تفکیک خطی.

Table 4. Classification accuracy and mean square error of LDA method.

پارامتر/داده Data/Parameter	آموزش Train	آزمون Test
دقت طبقه‌بندی Classification accuracy	98.66	98.66
میانگین مربعات خطا Mean square error	0.0022	0.0067

عمل کرده است؛ چرا که میانگین مربعات خطای آن کمتر از مرحله آزمون با هم مشابه و برابر با ۹۸/۶۷٪ بوده؛ اما از آن میانگین مربعات خطا متفاوت و به ترتیب برابر ۰/۰۰۲۲ و ۰/۰۰۶۷ به دست آمد. با توجه به جدول (۴)، مدل طبقه‌بندی مبتنی بر روش تحلیل تفکیک خطی در مرحله آموزش بهتر

دقت طبقه‌بندی روش تحلیل تفکیک خطی در مرحله آموزش و آزمون با هم مشابه و برابر با ۹۸/۶۷٪ بوده؛ اما از آن میانگین مربعات خطا متفاوت و به ترتیب برابر ۰/۰۰۲۲ و ۰/۰۰۶۷ به دست آمد. با توجه به جدول (۴)، مدل طبقه‌بندی مبتنی بر روش تحلیل تفکیک خطی در مرحله آموزش بهتر

واقعی Actual	رسیده Ripe	50	0	0
	نارس Unripe	0	48	2
	بیش رس Overripe	0	0	50
		رسیده Ripe	نارس Unripe	بیش رس Overripe
		پیش‌بینی شده Predicted		

(ب)

واقعی Actual	رسیده Ripe	149	1	0
	نارس Unripe	0	148	2
	بیش رس Overripe	0	3	147
		رسیده Ripe	نارس Unripe	بیش رس Overripe
		پیش‌بینی شده Predicted		

(الف)

شکل (۵) ماتریس اغتشاش روش تحلیل تفکیک خطی برای داده‌های الف) آموزش و ب) آزمون.

Fig 5. Confusion matrix of LDA method for a) training and b) test data

همان‌طور که از شکل (۵-ب) مشخص است روش تحلیل تفکیک خطی در مرحله آزمون تمام نمونه‌های رسیده و بیش رس زالزالک را به درستی و با دقت ۱۰۰٪ تشخیص داده است در صورتی که در طبقه‌بندی نمونه‌های نارس، تعداد ۲ نمونه از نمونه‌های زالزالک به‌طور نادرست در گروه نمونه‌های بیش رس قرار گرفته است.

مطابق با شکل (۵-الف) روش تحلیل تفکیک خطی در مرحله آموزش توانسته است بهترین دقت طبقه‌بندی را برای نمونه‌های رسیده ارائه دهد. در واقع این روش در مرحله آموزش تنها یک نمونه از میوه‌های رسیده را به اشتباه تشخیص داده است؛ اما برای میوه‌های نارس و بیش رس به ترتیب دو و سه نمونه را به اشتباه طبقه‌بندی نموده است.

۲.۴.۳. تحلیل تفکیک درجه دوم

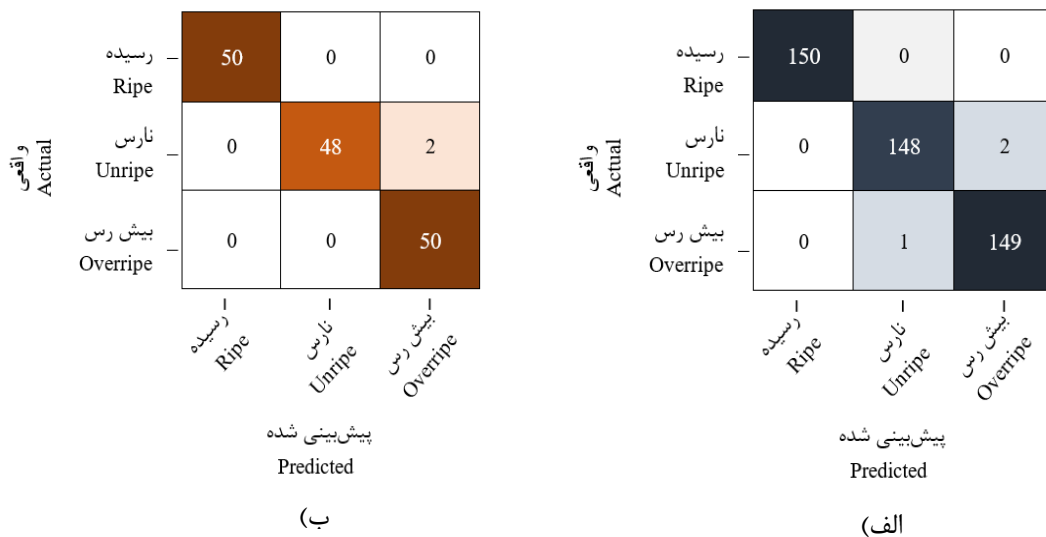
دقت طبقه‌بندی و میانگین مربعات خطای روش تحلیل تفکیک درجه دوم در مراحل آموزش و آزمون در جدول (۵) آمده است. دقت طبقه‌بندی روش تحلیل تفکیک درجه دوم در مرحله آموزش (۹۹/۳۳٪) بهتر از مرحله آزمون (۹۸/۶۶٪) بود. میانگین مربعات خطا برای این روش در مرحله آموزش و آزمون به ترتیب برابر ۰/۰۰۲۲ و ۰/۰۰۶۷ بود.

همانند روش تحلیل تفکیک خطی، روش تحلیل تفکیک خطی در مرحله آموزش بهتر از مرحله آزمون عمل کرده است؛ چرا که میانگین مربعات خطای آن کمتر از مرحله آزمون است. شکل (۶) ماتریس اغتشاش مربوط به روش تحلیل تفکیک درجه دوم را برای هر دو مرحله آموزش و آزمون به‌طور جداگانه نشان می‌دهد.

جدول (۵) دقت طبقه‌بندی و میانگین مربعات خطای روش تحلیل تفکیک درجه دوم.

Table 5. Classification accuracy and mean square error of QDA method.

پارامتر/داده Data/Parameter	آموزش Train	آزمون Test
دقت طبقه‌بندی Classification accuracy	99.33	98.66
میانگین مربعات خطی Mean square error	0.0022	0.0067



شکل (۶) ماتریس اغتشاش روش تحلیل تفکیک درجه دوم برای داده‌های آموزش (الف) و آزمون (ب).

Fig 6. Confusion matrix of QDA method for a) training and b) test data

تحلیل تفکیک درجه دوم و روش تحلیل تفکیک خطی در مرحله آزمون با هم مشابه هستند. مطابق با جداول (۶-۷) به‌منظور ارزیابی دقیق‌تر مدل‌های طبقه‌بندی در تشخیص سطوح مختلف رسیدگی نمونه‌های زالک، میانگین مقادیر پارامترهای طبقه‌بندی از جمله دقت (Ac)، صحت (Pr)، حساسیت (Se) و خاصیت (Sp) نیز

همان‌طور که از ماتریس اغتشاش شکل (۶-الف) مشهود است نمونه‌های رسیده در مرحله آموزش با دقت ۱۰۰٪ طبقه‌بندی شدند و همچنین نمونه‌های بیش رس نیز با نرخ طبقه‌بندی نزدیک به نمونه‌های رسیده پیش‌بینی شدند؛ چرا که تنها یک نمونه از میوه‌های بیش رس به اشتباه تشخیص داده شده است. مطابق با شکل (۶-ب)، ماتریس اغتشاش روش

محاسبه و مورد مقایسه قرار گرفتند.

جدول (۶) نتایج طبقه‌بندی نمونه‌های زالک با استفاده از مدل تحلیل تفکیک خطی

Table 6. Results of hawthorn samples classification using LDA method.

تحلیل تفکیک خطی Linear discriminate analysis								گروه Group
آزمون Test				آموزش Train				
Sp	Se	Pr	Ac	Sp	Se	Pr	Ac	
100	96.16	100	98.67	99.67	96.75	97.33	98.67	رسیده Ripe
98.04	100	96.00	98.67	99.33	97.37	98.67	98.67	نارس Unripe
100	96.16	100	98.67	99.00	98.00	98.00	98.67	بیش رس Overripe
99.3	97.44	98.67	98.67	99.33	97.37	98.67	98.67	میانگین Average

جدول (۷) نتایج عملکرد طبقه‌بندی نمونه‌های زالک با استفاده از مدل تحلیل تفکیک درجه دوم

Table 7. Results of hawthorn samples classification using QDA method.

تحلیل تفکیک درجه دوم Quadratic discriminate analysis								گروه Group
آزمون Test				آموزش Train				
Sp	Se	Pr	Ac	Sp	Se	Pr	Ac	
98.04	100	96.00	98.67	99.34	99.33	98.67	99.33	رسیده Ripe
100	96.16	100	98.67	100	98.04	100	99.33	نارس Unripe
100	96.16	100	98.67	99.67	98.68	99.33	99.33	بیش رس Overripe
99.35	97.44	98.67	98.67	99.67	98.68	99.33	99.33	میانگین Average

همان‌طور که از جداول (۶-۷) مشخص است، میانگین دقت و صحت مدل تحلیل تفکیک درجه دوم در مرحله آموزش (۹۷/۴۴ و ۹۹/۳۵٪ می‌باشد؛ بنابراین، براساس نتایج مربوط به (۹۹/۳۳٪) از آن مدل تحلیل تفکیک خطی (۹۸/۶۷٪) بیشتر است. به همین ترتیب میانگین حساسیت و خاصیت تحلیل تفکیک درجه دوم (به ترتیب برابر با ۹۸/۶۸ و ۹۹/۶۷٪) از آن مدل تحلیل تفکیک خطی (به ترتیب برابر با ۹۷/۳۷ و ۹۹/۳۳٪) بیشتر است. در مرحله آزمون دقت، صحت، حساسیت و خاصیت مدل طبقه‌بند مبتنی بر روش تحلیل تفکیک درجه دوم با مدل تحلیل تفکیک خطی برابر است. میانگین این پارامترها به ترتیب برابر با ۹۸/۶۷، ۹۸/۶۷،

پارامترهای مختلف در مرحله آموزش، مدل تحلیل تفکیک درجه دوم در طبقه‌بندی سطوح مختلف رسیدگی میوه زالک از مدل تحلیل تفکیک خطی اولویت دارد. نتایج به‌دست‌آمده در تحقیق حاضر با نتایج تحقیقاتی پیشین قابل مقایسه است. دقت طبقه‌بندی درجه‌های مختلف رسیدگی گوجه‌فرنگی با استفاده از روش ماشین بردار پشتیبان برابر با ۹۰٪ گزارش شده است [۳۱]. محققین توانسته‌اند با استفاده از روش پردازش تصویر و الگوریتم یادگیری عمیق با دقت ۹۷٪ سه مرحله از رسیدگی خرما را

صورت گرفت. یک الگوریتم پردازش تصویر به منظور حذف پس‌زمینه و استخراج ویژگی‌های رنگ و بافت از تصاویر نمونه‌های زالزالک توسعه یافت. بردار ویژگی‌های کارا با انتخاب ویژگی‌های مؤثر از بین ۲۸۵ ویژگی استخراج‌شده تشکیل گردید. به منظور طبقه‌بندی نمونه‌های زالزالک براساس ویژگی‌های انتخاب‌شده از مدل‌های تحلیل تفکیک خطی و درجه دوم استفاده شد. با محاسبه پارامترهای مربوط به ماتریس اغتشاش مشخص شد که میانگین دقت کلی طبقه‌بندی نمونه‌های مختلف زالزالک با استفاده از روش‌های تحلیل تفکیک خطی و درجه دوم در مرحله آموزش به ترتیب ۹۸/۶۷ و ۹۹/۳۳٪ و در مرحله آزمون با هم مشابه و برابر ۹۸/۶۷٪ است. این نتایج نشان‌دهنده قابلیت مدل‌های پیشنهادشده در طبقه‌بندی نمونه‌های زالزالک است؛ بنابراین به منظور کاهش ضایعات محصولات کشاورزی و افزایش کیفیت درجه‌بندی محصولات کشاورزی می‌توان از الگوریتم هوشمند پیشنهادشده در طراحی و توسعه سامانه‌ها و ماشین‌های خودکار درجه‌بندی در بعد صنعتی استفاده کرد.

طبقه‌بندی نمایند [۳۲]. با استفاده از روش یادگیری عمیق دقت ۹۶/۴٪ در طبقه‌بندی چهار مرحله رسیدگی میوه موز به دست آمده است [۳۳]. براساس نتایج به دست آمده، می‌توان به این نتیجه رسید که روش ارائه‌شده برای طبقه‌بندی میوه زالزالک در تحقیق حاضر می‌تواند جایگزینی مناسبی برای روش‌های دستی طبقه‌بندی این میوه براساس درجه رسیدگی باشد و به‌عنوان یک روش بهینه در سامانه‌های درجه‌بندی خودکار در صنعت استفاده شود.

۴. نتیجه‌گیری

تحقیق حاضر با هدف طبقه‌بندی نمونه‌های میوه زالزالک در سه گروه رسیدگی شامل رسیده، نارس و بیش رس صورت گرفت. این مطالعه شامل مراحل مختلفی از جمله توسعه جعبه نورپردازی، تهیه تصاویر، عملیات پیش‌پردازش تصاویر، استخراج ویژگی‌های رنگ و بافت از تصاویر، انتخاب ویژگی‌های کارا و در نهایت طبقه‌بندی ویژگی‌های کارا است. عملیات تصویربرداری در شرایط نورپردازی کنترل‌شده

منابع

- [1] Özcan, M., Haciseferoğulları, H., Marakoğlu, T. & Arslan, D. (2005). Hawthorn (*Crataegus* spp.) fruit: some physical and chemical properties. *J Food Eng*, 69(4), 409-413.
- [2] Erfani Moghadam^{1*}, J. & Kheiralipour, K. (2015). Physical and nutritional properties of hawthorn fruit (*Crataegus pontica* L.). *AgricEngInt: CIGR J*, 17(1), 232-237.
- [3] Kao, E. S., Wang, C. J., Lin, W. L., Yin, Y. F., Wang, C. P. & Tseng, T. H. (2005). Anti-inflammatory potential of flavonoid contents from dried fruit of *Crataegus pinnatifida* in vitro and in vivo. *J Agric Food Chem*, 53(2), 430-436.
- [4] Chang, W. T., Dao, J. & Shao, Z. H. (2005). Hawthorn: potential roles in cardiovascular disease. *The Am. J. Chin. Med*, 33(01), 1-10.
- [5] Pittler, M. H., Schmidt, K. & Ernst, E. (2003). Hawthorn extract for treating chronic heart failure: meta-analysis of randomized trials. *The Am. J. Chin. Med*, 114(8), 665-674.
- [6] Jahanbakhshi, A. & Kheiralipour, K. (2019). Carrot Sorting Based on Shape using Image Processing, Artificial Neural Network, and Support Vector Machine. *J AGR Machine*, 9(2): 295-307. (In Persian).
- [7] Teimouri, N., Omid, M., Mollazade, K., Mousazadeh, H., Alimardani, R., & Karstoft, H. (2018). On-line separation and sorting of chicken portions using a robust vision-based intelligent modelling approach. *Biosyst Eng*, 167, 8-20.
- [8] Kheiralipour, K., Ahmadi, H., Rajabipour, A. & Rafiee, S. (2018). Thermal Imaging, Principles, Methods and Applications. *Ilam Uni Pub*. Ilam, Iran. (In Persian).
- [9] Kheiralipour, K. & Kazemi, A. 2020. A new method to determine morphological properties of fruits and vegetables by image processing technique and nonlinear multivariate modeling. *Int J Food Prop*, 23(1), 368-374.
- [10] Farokhzad, S., Motlagh, A.M., Moghadam, P.A., Honarmand, S.J. & Kheiralipour, K. (2020). Application of infrared thermal imaging technique and discriminant analysis methods for non-destructive identification of fungal infection of potato tubers. *J Food Measure Charac*, 14 (1), 88-94.
- [11] Wang, A., Zhang, W., & Wei, X. (2019). A review on weed detection using ground-based

- machine vision and image processing techniques. *Comput Electron Agric*, 158, 226-240.
- [12] Liming, X. & Yanchao, Z. (2010). Automated strawberry grading system based on image processing Author links open overlay panel. *Comput Electron Agric*, 71, S32-S39.
- [13] Seng, W. C., & Mirisae, S. H. (2009, August). A new method for fruits recognition system. In *2009 Int Con Elec ENG* (Vol. 1, pp. 130-134). IEEE.
- [14] Sofu, M. M., Er, O., Kayacan, M. C., & Cetişli, B. (2016). Design of an automatic apple sorting system using machine vision. *Comput Electron Agric*, 127, 395-405.
- [15] Mizushima, A. & Lu, R. (2013). An image segmentation method for apple sorting and grading using support vector machine and Otsu's method. *Comput Electron Agric*, 94, 29-37.
- [16] Zandi, M., Ganjloo, A. & Bimakr. M. (2020). Development of quality grading system based on image processing for hawthorn classification during various storage condition (cold, refrigerator and room). *J Food Res*, 30(1): 195-210.
- [17] Sonka, M., Hlavac, V. & Boyle, R. (2014). *Image process anal mach visi*. (4th ed) Cengage Learning. Boston, Massachusetts, US: Springer.
- [18] Mohammadi, V., Kheiralipour, K. & Ghasemi-Varnamkhashti, M. (2015). Detecting maturity of persimmon fruit based on image processing technique. *Sci Hortic*, 184, 123-128.
- [19] Kheiralipour, K. & Pormah, A. 2017. Introducing new shape features for classification of cucumber fruit based on image processing technique and artificial neural networks. *J Food Process Eng*, 40(6), 12558.
- [20] Khazae, Y., Kheiralipour, K., Hosainpour, A. & Javadikia, H. (2019). Development of an algorithm based on image processing technique and sport vector machine to distinct potato from clod and stone. *J Res Mech Agri*, 8(1), 1-11. (In Persian).
- [21] Gonzalez, R. C., & Woods, R. E. (2002). *Digit Image Process* (2nd ed). New Jersey: Prentice Hall Inc.
- [22] Kheiralipour, K. (2012). Implementation and construction of a system for detecting fungal infection of pistachio kernel based on thermal imaging (TI) and image processing technology. Ph.D. Dissertation. Karaj, Iran: *Uni Tehran*. [In Persian].
- [23] Mollazade, K., Omid, M., Tab, F. A., Kalaj, Y. R., Mohtasebi, S. S., & Zude, M. (2013). Analysis of texture-based features for predicting mechanical properties of horticultural products by laser light backscattering imaging. *Comput Electron Agric*, 98, 34-45.
- [24] Salam, S. & Kheiralipour, K. (2021). Development and evaluation of chickpea classification system based on visible image processing technology and artificial neural network. *Innov Food Tech*, 9(2), 181-193.
- [25] Kheiralipour, K., & Marzbani, F. (2016). Pomegranate quality sorting by image processing and artificial neural network. *10th Iranian National Congress on AGR Machi Eng (Biosystems) and Mechanization*. 30-31 August, Mashhad, Iran. [In Persian].
- [26] Azadnia, R. & Kheiralipour, K. (2021). Recognition of leaves of different medicinal plant species using a robust image processing algorithm and artificial neural networks classifier. *J Appl Res Med Aromat Plants*, 100327.
- [27] Chandrashekar, G. & Sahin, F. (2014). A survey on feature selection methods. *Comput Electron Agric*, 40(1), 16-28.
- [28] Dixon, S. J., Heinrich, N., Holmboe, M., Schaefer, M. L., Reed, R. R., Trevejo, J. & Brereton, R. G. (2009). Application of classification methods when group sizes are unequal by incorporation of prior probabilities to three common approaches: *Application to simulations and mouse urinary chemosignals. Chemometrics and Intelligent Laboratory Systems*, 99(2), 111-120.
- [29] Wu, W., Mallet, Y., Walczak, B., Penninckx, W., Massart, D. L., Heuerding, S. & Erni, F. (1996). Comparison of regularized discriminant analysis linear discriminant analysis and quadratic discriminant analysis applied to NIR data. *Anal Chim Acta*, 329(3), 257-265.
- [30] Aggarwal, N. & Agrawal, R. K. (2012). First and second order statistics features for classification of magnetic resonance brain images. *J Signal Process Syst*, 3, 146-153.
- [31] El-Bendary, N., El Hariri, E., Hassanien, A. E. & Badr, A. (2015). Using machine learning techniques for evaluating tomato ripeness. *Expert Syst Appl*, 42(4), 1892-1905.
- [32] Nasiri, A., Taheri-Garavand, A., & Zhang, Y. D. (2019). Image-based deep learning automated sorting of date fruit. *Postharvest Biol Technol*, 153, 133-141.
- [33] Saranya, N., Srinivasan, K. & Kumar, S. P. (2021). Banana ripeness stage identification: a deep learning approach. *J Ambient Intell Humaniz Comput*. <https://doi.org/10.1007/s12652-021-03267-w>.