



## Fruit Recognition and Classification Using Deep Learning (Case Study Date Plant)

---

Maryam Talkhabi, Mahboobeh Shamsi and Majid Aghaei

EasyChair preprints are intended for rapid dissemination of research results and are integrated with the rest of EasyChair.

January 5, 2022

## تشخیص و طبقه بندی میوه ها با استفاده از یادگیری عمیق (مطالعه موردی گیاه خرما)

مریم تلخابی<sup>۱</sup>، محبوبه شمس<sup>۲\*</sup>، مجید آقایی<sup>۳</sup>  
<sup>۱،۲،۳</sup>دانشکده برق و کامپیوتر، دانشگاه صنعتی قم، تهران، ایران.

### چکیده

شبکه عصبی کانولوشنی با ساختار منحصر به فرد برای استخراج ویژگی ها و کلاسبندی یک تکنولوژی جدید در زمینه بینایی ماشین می باشد. امروزه یکی از چالشهای موجود استفاده از یادگیری عمیق در بخش کشاورزی و برداشت محصول و بسته بندی بر اساس کیفیت برای مصارف داخلی همچون کمک به صادرات می باشد. در این مطالعه روشی جدید برای تشخیص خرماهای سالم مورد بررسی قرار گرفته و همچنین جداسازی و تشخیص اینکه خرما در کدام مرحله از رسیدن می باشد. مجموعه داده این تحقیق با استفاده از دوربین تلفن همراه تحت شرایط کنترل نشده از خرماهای شاهانی که خرماهای خاص ایران می باشد جمع آوری شده است. این مجموعه داده شامل تصاویری در چهار کلاس می باشد که سه کلاس خلال و رطب و تمر مربوط به مراحل بلوغ خرما و یک کلاس مربوط به خرماهای معیوب می باشد. در این تحقیق از روشهای شبکه عصبی کانولوشنی و شبکه های از پیش آموزش داده شده نظیر VGG16 و Resnet استفاده شده و با اضافه کردن تصاویر بدست آمده از هیستوگرام گرادیان جهت گرا به مدل و همچنین با استفاده از تکنیکی که برای پیدا کردن بهترین نرخ یادگیری دقت ۹۸٪ بدست آمد.

**کلمات کلیدی:** یادگیری عمیق، شبکه عصبی کانولوشنی، هیستوگرام گرادیان جهت گرا، کلاسبندی، میوه خرما، مراحل بلوغ.

### تاریخچه مقاله:

تاریخ ارسال: ۱۴۰۰/۱۰/۰۶

تاریخ اصلاحات:

تاریخ پذیرش:

تاریخ انتشار:

### Keywords:

Deep Learning  
 Convolutional neural network  
 Histogram Of Oriented Gradient  
 Classification  
 Date fruit  
 Maturity stages

\*ایمیل نویسنده مسئول:

shamsi@qut.ac.ir

## Fruit Recognition and Classification Using Deep Learning (Case Study Date Plant).

Maryam Talkhabi<sup>1</sup>, Mahboobeh Shamsi<sup>2\*</sup>, Majid Aghaei<sup>3</sup>.

<sup>1,2,3</sup>computer and electronic, Qom University of Technology, Qom, Iran.

### Abstract

Convolutional neural network with a unique structure for feature extraction and classification is a new technology in the field of machine vision. Today, one of the challenges is to use deep learning in agriculture, harvest and quality-based packaging for domestic use as well as export industry. This study presents a method for discriminating and separating healthy dates, as well as predicting the ripening stage of dates.

The data set of this research was collected using a smart phone camera under uncontrolled conditions from shahani dates, which are specific to Iran. This data set includes images in four classes, three classes related to khalal, rutab, tamar which are the stages of date maturation and one class related to defective dates. This research constructed from convolutional neural network methods, pre-trained networks such as VGG16 and Resnet. The Accuracy was measured by adding images obtained from Histogram of Oriented Gradient (HOG) to the model and using CLR call back technique. The model was able to achieve an overall classification accuracy of 98%.

امروزه طبقه بندی میوه ها چه در زمینه صنعت و چه در زمینه کشاورزی حائز اهمیت می باشد. در کشاورزی برای تولید میوه هایی با کیفیت بالا، زمان برداشت میوه از نظر بلوغ آن بسیار مهم می باشد برای ارزیابی بلوغ میوه ها ویژگی های فیزیکی و تصویری و شیمیایی میوه مورد ارزیابی قرار می گیرد و با استفاده از تصاویر بدست آمده از این ویژگی ها به کمک مکانیزهای طبقه بندی خودکار بهترین زمان برداشت میوه از جهت کیفیت مشخص می شود [۱]. میوه خرما یک محصول کشاورزی اساسی در خاورمیانه و کشورهای شمال آفریقا است که نقش اقتصادی مهمی در خاورمیانه دارد. طبق سازمان غذا و کشاورزی (FAO) ایران جزو ده کشور اول تولید کننده خرما می باشد. با توجه به مواد معدنی و ویتامین بسیار زیادی که در خرما وجود دارد بعنوان یک انتخاب سالم برای همه افراد پیشنهاد می شود. خرما دارای چهار مرحله در فرآیند رسیدن می باشد که به طور سنتی با تغییر بافت، رنگ و طعم آن توصیف می شود. این مراحل به ترتیب کیمیری، خلال یا خارک، رطب و تمار یا تمر می باشد که خرما در سه مرحله از رسیدن خلال، رطب و تمار برداشت و مصرف می شود. انتخاب مراحل رسیدن برای برداشت و بازاریابی وابسته به نوع خرما و شرایط پرورش و اقلیمی و همچنین تقاضای بازار می باشد. متاسفانه در طول فرآیند رشد و مرحله برداشت محصول ممکن است توسط حشرات، کنه ها و تجهیزات مکانیکی آسیب ببینند و این خسارات باعث صدمات اقتصادی قابل توجهی به انبار و صادرات میوه خرما می شوند. به دو دلیل خرماهایی با مراحل بلوغ مختلف نباید کنار هم بسته بندی شوند اول اینکه آنها می توانند اثرات متقابل مخربی برهم داشته باشند دوم به منظور بهبود شرایط بازاریابی سلیقه های مختلف مشتری باید در نظر گرفته شوند. روش های طبقه بندی سنتی خرما وقت گیر، پرهزینه و خسته کننده می باشند بنابراین سیستم های مرتب سازی اتوماتیک باید برای پایین آوردن هزینه و بهبود کیفیت محصول و بسته بندی و افزایش رضایت مشتری توسعه یابند در این راستا نیازمند روش های غیر مخرب برای شناسایی مراحل بلوغ خرما می باشیم.

در این مقاله برخی از تحقیقات انجام گرفته در جهت طبقه بندی اتوماتیک میوه ها بررسی می شوند. استفاده از شبکه عصبی برای طبقه بندی خرماها به سه دسته پیشنهاد شد ویژگی های استخراج شده شامل شکل و سایز خرما استخراج و علاوه بر سیستم بینایی ماشین، برخی محققان از طیف سنجی مادون قرمز به عنوان یک روش غیر مخرب برای تشخیص انواع

و کیفیت خرما در مراحل بلوغ استفاده کردند [۲]. برخلاف شبکه های عصبی مصنوعی، شبکه عصبی کانولوشنی توانایی استخراج ویژگی و کلاس بندی با استفاده از عمق و تقسیم وزن میان گره ها را دارند.

در این تحقیق یک روش بینایی ماشین برای برداشت میوه خرما به وسیله ربات پیشنهاد شد پایگاه داده شامل ۸۰۰۰ تصویر گرفته شده از نخلستان کشور عربستان از چندین خرما با مراحل بلوغ مختلف می باشد. از شبکه های vgg16 و AlexNet برای ساخت مدل استفاده شدند و دقت های ۹۷٪/۲۵ و ۹۸٪/۵۹ حاصل شد [۳].

در این مقاله تعیین سطح بلوغ میوه خرما همچنین جداسازی میوه سالم از ناقص مورد بررسی قرار گرفت و با استفاده از مدل شبکه عصبی کانولوشنی پیاده سازی شد از مدل از روش یادگیری انتقالی برای کلاس بندی استفاده و در نهایت دقت ۹۶٪ بدست آمد [۳].

## ۲ - تهیه پایگاه داده

در این مطالعه خرماهای شاهانی که به عنوان میوه خرما مرطوب در نظر گرفته می شود انتخاب شده است. برای تهیه پایگاه داده خرماهای این پژوهش، سه مرحله بلوغ خرما به نام های رطب و خلال و تمر که از باغهای جهرم جمع آوری شدند. از یک دوربین گوشی هوشمند سامسونگ برای ثبت تصویر استفاده شده پس زمینه تصویر ثابت نگه داشته شده با این حال پارامترهای دیگر مانند فوکوس، زاویه ثبت تصویر شرایط روشنایی و فاصله دوربین از نمونه ها ثابت نیستند مجموعه داده ها شامل ۵۴۲۸ تصویر از خرماهای سالم و معیوب می باشد هر عکس خرما به صورت دستی بر اساس مراحل رشد مختلف و خرماهای ناقص توسط متخصصان طبقه بندی شد بنابراین چهار کلاس مورد نظر در اینجا عبارتند از: خارک شامل ۱۳۰۸، رطب شامل ۱۱۵۲ تصویر، تمر یا خرما شامل ۱۱۳۶ و خرماهای ناقص شامل ۱۸۳۲ مورد است. در این مطالعه، خرماهای ناقص مانند خرماهای آسیب دیده از حشرات، کنه ها و پرندگان، خرماهایی که با وسایل مکانیکی موقع برداشت آسیب دیده اند. خرماهای نارس و خرماهای کپک زده که به وسیله استاندارد ۱۴۳-۱۹۸۵ تعیین شده اند. شکل ۱ برخی از تصاویر بدست آمده از نمونه های میوه خرما را نشان می دهد.

<sup>1</sup> Transfer learning

کافی از این روش استفاده شد. بدین ترتیب تعداد تصاویر آموزش تا ۳۷۰۵۶ تصویر افزایش یافت.

### ۳-۲- معماری شبکه عصبی کانولوشنی: به

منظور آموزش تصاویر RGB شبکه عصبی کانولوشنی می تواند شامل لایه های کانولوشنی به عنوان لایه های اصلی باشد وظیفه این لایه ها استخراج ویژگی های سطح پایین از قبیل لبه ها، لکه ها و رنگها به وسیله فیلترها است عملگر کانولوشن نسبت به انتقال و چرخش تغییر ناپذیر می باشد [۴]. علاوه بر لایه های pooling از دیگر لایه های متداول می باشند که وظیفه کاهش سایز تصاویر را دارند [۵]. در نهایت مانند شبکه عصبی ساختار شبکه عصبی کانولوشن ها شامل لایه های کاملاً متصل می باشند.

آموزش شامل دو مرحله می باشد: تغذیه رو به جلو<sup>۸</sup> و انتشار رو به عقب<sup>۹</sup>

در مرحله تغذیه رو به جلو خطای شبکه به وسیله مقایسه تفاوت بین تصویر داده شده به شبکه و خروجی برچسب گذاری شده بدست می آید. در مرحله انتشار رو به عقب گرادیان وابسته به خطای شبکه بدست می آید سپس هر ماتریس وزن بر اساس گرادیان محاسبه شده به روز رسانی می شود [۶].

برای انجام کارهای کلاسبندی از تکنیک یادگیری انتقالی استفاده می شود که در آن ساختاری مختلف پیش آموزش دیده از شبکه عصبی کانولوشنی وجود دارد که با مجموعه داده از ۱,۴ میلیون تصویر برچسب دار مانند Imagenet با ۱۰۰۰ کلاس متفاوت آموزش دیده اند.

از آنجا که ویژگیهای استخراج شده توسط این شبکه برای میوه های خرما مناسب نمی باشد بنابراین باید از تکنیک fine-tune استفاده کرد به عنوان مثال در شبکه VGG لایه Dens را حذف می کنیم و سپس convolution base را منجمد<sup>۱۰</sup> کرده و جلوی تغییرش را می گیریم سپس روی مجموعه کلاسبندی<sup>۱۱</sup> جدید آموزش را انجام می دهیم.<sup>۱۲</sup> لایه هایی که زودتر می آیند در مدل ویژگی های عمومی تر را مشخص می کنند (مانند لبه ها، رنگ و بافت) در حالی که لایه هایی که بالاتر هستند ویژگی های abstract تری را استخراج می کنند. اگر دیتاست کوچک و متفاوت با دیتاست آموزش دیده باشد باید از لایه های پایین تر استفاده شود در واقع فرآیند آموزش با ماتریس وزن های شبکه مورد نظر به جای شروع با یک ماتریس وزن تصادفی آغاز می شود. دو شبکه عصبی



(شکل ۱- نمونه تصاویر مراحل بلوغ خرمای شاهانی و خرمای معیوب)

### ۳- شیوه انجام تحقیق

#### ۳-۱- پیش پردازش تصاویر: شبکه عصبی

کانولوشنی برای یادگیری نیاز به پارامترهای زیادی دارد بنابراین نیازمند به مجموعه داده زیادی از تصاویر خرما می باشد در غیر اینصورت استفاده از شبکه عصبی کانولوشنی ریسک بیش برآزش شدن را بالا می برد. از آنجائیکه اغلب امکان افزایش تعداد تصاویر ورودی بدون افزایش موازی هزینه و زمان ممکن نیست در روش افزایش داده augmentation مجموعه داده آموزشی با برچسب و کلاس مشابه به وسیله تکنیک های پردازش تصویر مانند چرخش،<sup>۱۳</sup> معکوس کردن عمودی و افقی،<sup>۱۴</sup> جابجایی عرضی،<sup>۱۵</sup> جابجایی طولی،<sup>۱۶</sup> بزرگنمایی،<sup>۱۷</sup> تغییر شدت روشنایی<sup>۱۸</sup> افزایش می یابد تا از بیش برآزش جلوگیری شود. برای این کار از سه روش زیر استفاده می شود DataSet Generation که مثلاً از هر تصویر ۱۰ تا نمونه جدید به وسیله کد ایجاد می شود که این تصویر در حافظه ذخیره می شوند.

روش دوم: ImageDataGenerator یا in-place augmentation که در فرآیند یادگیری مدل از آن استفاده کرده ولی در حافظه ذخیره نمی شود و روش سوم استفاده از ترکیب دو روش بالاست که در این مبحث بدلیل کمبود دیتا

<sup>8</sup> shear intensity

<sup>9</sup> Feed-forward

<sup>۱</sup> Back-propagation

<sup>۱</sup> frozen

<sup>۱</sup> classifier

<sup>۱</sup> train

<sup>2</sup> overfit

<sup>3</sup> Rotation

<sup>40</sup>horizontal-flip

<sup>51</sup>width shift

<sup>62</sup>height shift

<sup>73</sup>zoom

- با استفاده از فرمول های ۱ و ۲ اندازه و جهت شیب محاسبه می شوند.

$$g = \sqrt{g_x^2 + g_y^2} \quad (\text{فرمول ۱-})$$

$$\theta = \tan^{-1} \frac{g_y}{g_x} \quad (\text{فرمول ۲-})$$

تصویر گرادیان بسیاری از اطلاعات غیر ضروری (مثل زمینه ی رنگی و ثابت تصویر) را حذف می کند. اما نمای کلی تصویر را برجسته تر خواهد کرد. در شکل ۲ نمونه ای از تصویر خرما بعد از اعمال هیستوگرام گرادیان جهت گرا آورده شده است



(شکل ۳- نمونه تصویر خرما بعد از اعمال هیستوگرام گرادیان جهت گرا

۴-۲- تعیین نرخ یادگیری بهینه: در روش های معمول پیدا کردن نرخ یادگیری که یکی از هایپرپارامترهای مهم در یادگیری می باشد اغلب از کاهش نرخ یادگیری استفاده می شد در این روش غیر از کم کردن گاهی نرخ یادگیری افزایش می دهند به عبارتی نرخ یادگیری افزایشی و کاهشی باشد تا در صورت افتادن در کمینه محلی بتواند از آن خارج شود در واقع کار اصلی آن پیدا کردن نرخ یادگیری مناسب می باشد. اگر نرخ یادگیری را اشتباه بدهیم مدل واگرا شده و به جواب مورد نظر نمی رسد.

نحوه به روز رسانی وزن های شبکه در فرمول شماره ۳ نشان داده شده که  $\theta_i$  وزن شبکه می باشد در هر مرحله وزن از گرادیان نسبت وزن کم می شود که ضریب  $\alpha$  همان نرخ یادگیری می باشد.

$$\theta_i := \theta_i - \alpha \frac{\delta f(\theta_i)}{\delta \theta_i} \quad (\text{فرمول ۳-})$$

اگر ضریب  $\alpha$  کوچک باشد یادگیری خیلی کند می شود. اگر ضریب  $\alpha$  بزرگ باشد گامها بزرگ شده هیچ وقت به هدف نمی رسد و واگرا می شود.

مراحل پیدا کردن نرخ یادگیری با استفاده از نرخ یادگیری Cyclical:

کانولوشنی که در این تحقیق به کار گرفته شد شامل VGG19 [۷] Resnet150 [۸] می باشد.

عمق شبکه عصبی کانولوشنی نقش مهمی در دقت کلاسبندی ایفا می کند و با افزایش عمق شبکه عصبی کانولوشنی خطای کلاسبندی کاهش می یابد.

#### ۴- روش های پیشنهادی

مدل پیشنهادی برای تشخیص و طبقه بندی میوه ها از جمله این پژوهش مناسب می باشد. مراحل اجرای آن به صورت زیر می باشد.

مرحله اول : ساخت مدل با شبکه عصبی کانولوشنی  
مرحله دوم: هیستوگرام گرادیان جهت گرا<sup>۱۴</sup> برای تصاویر خرما بکار گرفته شد که در ادامه مدل هیستوگرام شرح داده می شود و تصاویر بدست آمده بعد از هیستوگرام به مدل اضافه شدند.  
مرحله سوم: استفاده از callback پیشنهادی Cyclical [۹] برای پیدا کردن نرخ یادگیری<sup>۱۵</sup> بهینه برای بالا بردن دقت و سرعت مدل های استفاده شده در پروژه.

#### ۴-۱- هیستوگرام گرادیان جهت گرا تصاویر

خرما: هیستوگرام گرادیان جهت گرا یک توصیفگر ویژگی می باشد. این روش در بینایی رایانه ای و پردازش تصویر به منظور تشخیص شی مورد نظر مورد استفاده قرار می گیرد. تعداد شیب در بخش محلی یک تصویر را محاسبه می کند. هیستوگرام گرادیان جهت گرا بهتر از هر توصیفگر لبه بر ساختار و شکل یک شی تمرکز دارد و از اندازه و زاویه شیب برای محاسبه ویژگی ها استفاده می کند و برای مناطق تصویر، نمودار هیستوگرام را با استفاده از اندازه و جهت شیب تولید می کند.  
مراحل پیدا کردن هیستوگرام گرادیان جهت گرا به طور خلاصه در زیر آورده شده است.

- پیش پردازش: اندازه تصویر را به  $128 \times 64$  پیکسل تغییر می دهیم. تصحیح گاما نیز یکی از موارد پیش پردازش می باشد.
- محاسبه گرادیان تصاویر: برای محاسبه هیستوگرام گرادیان جهت دار ابتدا باید گرادیان های افقی و عموری را بوسیله فیلتر کردن تصویر توسط کرنل های موجود در شکل ۲ محاسبه کرد.




(شکل ۲- کرنل فیلتر تصاویر

<sup>1</sup> learning rate

<sup>1</sup> Histogram of Oriented Gradient(HOG)

- ابتدا با یک نرخ یادگیری کوچک (مثل  $1e-10$ ) مدل شروع به یادگیری می کند برای جلوگیری از کند شدن فرآیند یادگیری به جای هر epoch با هر batch نرخ یادگیری با یک مقدار مشخص شده با فرمول مربوطه افزایش پیدا می کند.
- شبکه مورد نظر را با پارامتر نرخ یادگیری گفته شده آموزش می دهیم سپس loss آن را ذخیره کرده در هر بار عوض شدن نرخ یادگیری مقدار loss ذخیره می شود. در نهایت نموداری داریم که ابتدا با توجه به کم بودن نرخ یادگیری پیشرفتش محسوس نیست ولی وقتی نرخ یادگیری بیشتر می شود شیب کاهش loss مناسب پیدا می کند تا جایی که بعد از زیاد شدن نرخ یادگیری اوضاع بدتر می شود و loss بالا رفته و اگر شده است تمام این مراحل log می شود.
- در بازه ای از نمودار که بیشترین شیب کاهش loss را داریم همانطور که در شکل ۴ نشان داده شده است بهترین نرخ یادگیری قرار دارد.



(شکل - ۴) بازه نرخ یادگیری بهینه

## ۵- آزمایش ها

### ۵-۱- آزمایش اول: استفاده از مدل از پیش

#### آموزش دیده VGG19

شبکه VGGNet یک شبکه عمیق و دارای ساختار همگن است با وجود اینکه قدرت طبقه بندی VGG کمی پایین تر از GoogleNet می باشد نسبت به آن پیچیدگی کمتری دارد و مشخصه های ایجاد شده توسط معماری VGGNet نسبت به دیگر شبکه های عصبی کانولوشنی بهتر عمل می کند. یکی از انتخاب های محبوب در یادگیری عمیق و کارهای بینایی ماشین می باشد. VGGNet متشکل از ۵ بلوک مختلف است که به طور همگن و زنجیره ای تنظیم می شوند تا خروجی هر بلوک ورودی بلوک بعدی باشد در این معماری ویژگی های قدرتمند

تصاویر مانند بافت، شکل و رنگ استخراج می شود. بنابراین به دلیل کارایی مناسب در وظایف کلاسیک برای مطالعه حاضر انتخاب شده است.

در این آزمایش از تنظیم دقیق شبکه برای تشخیص میوه های خرما استفاده شد بنابراین تا لایه conv1 بلوک ۵ را منجمد کردیم تعداد batch مقدار ۵ در نظر گرفته شد. سپس به ترتیب لایه های مرحله بعد لایه های Dens را به ۲۵۶ و ۱۲۸ و ۶۴ و Dropout را برای جلوگیری از بیش برآزش با نرخ ۰,۳ تغییر دادیم و در پایان با ۴ نورن برای کلاسیک سازی مدل ساخته شد. از تابع بهینه سازی nadam با نرخ یادگیری ۰,۰۰۰۱ استفاده شد که در نهایت دقت ۰,۹۷۳۵ بدست آمد.

در مرحله بعدی از مدل پیشنهادی ارائه شده در مقاله استفاده کردیم موفق شدیم دقت را به ۰,۹۸۸۶ رسانده و همچنین بهترین نرخ یادگیری ۰,۰۰۰۰۱ بدست آمد.

### ۲-۵- آزمایش دوم: استفاده از مدل از پیش

#### آموزش دیده Resnet152

طی سال ها محققان به ایجاد شبکه های عصبی عمیق تر (افزودن لایه های بیشتر) برای حل و بهبود چنین کارهای پیچیده ای تمایل پیدا کرده اند، اما موضوع این است که با افزودن لایه های بیشتری به شبکه های عصبی، آموزش آن ها دشوار می شود و دقت عملکرد شبکه شروع به کاهش می کند. اینجاست که ResNet به کمک ما می آید و به حل این مشکل کمک می کند. قبل از معرفی این شبکه استفاده از شبکه های عصبی با لایه های زیاد دچار مشکل بود. با افزایش تعداد لایه ها شبکه دچار مشکل محوشدگی گرادپان<sup>۱</sup> می شد؛ شبکه های رزنت توانست با ارائه راه حلی این مشکل را تا حد زیادی برطرف کند؛ به همین دلیل، این شبکه قادر است حتی تا ۱۵۲ لایه هم داشته باشد. اتصالات میانبر<sup>۱</sup> یا اتصالات اضافی<sup>۱</sup> راه حلی بود که شبکه ResNet برای حل مشکل شبکه های عمیق ارائه کرد.

در این آزمایش از معماری از پیش آموزش دیده Resnet152 استفاده کردیم تا لایه conv5\_block3\_3\_conv را منجمد کردیم تعداد batch مقدار ۱۶۳ در نظر گرفته شد. سپس به ترتیب لایه های Dens با ۱۲۸ نورن و ۶۴ نورن و لایه Dens با ۴ نورن برای کلاسیک سازی مدل ساخته شد. با در نظر گرفتن تابع بهینه سازی adam در نهایت با تعداد ۳۰ epoch دقت ۰,۸۸۱۵ بدست آمد.

<sup>1</sup> Skip Connections

<sup>1</sup> Residual Connections

<sup>1</sup> Fine-tune

<sup>1</sup> Vanishing Gradient

بندی شامل چندین مرحله مجزا هستند. در این مطالعه از شبکه عصبی عمیق برای غلبه بر سیستم های سنتی برای تشخیص خرماهای ناقص و سالم و مراحل رسیدن خرماهای سالم استفاده شد.

بهترین نتیجه از معماری VGG19 بعد از اصلاح مدل بدست آمد سپس استفاده از تصاویر هیستوگرام دقت مدل را بالاتر ببریم و در نهایت از روش پیشنهادی برای بدست آوردن نرخ یادگیری و جلوگیری از بیش برازش استفاده شد. در این آزمایش نتایج بدست آمده از مدل های VGG19 در مقایسه با نتایج بدست آمده از مدل Resnet152 بسیار بهتر بود

این نتایج عملکرد بالای طبقه بندی مدل های کانولوشنی را برای تشخیص خرماهای سالم از خرماهای ناقص و پیش بینی مراحل بلوغ را نشان داد. بنابراین می توان از این روش برای صنایع غذایی مدرن و کاربردهای مبتنی بر گوشی های همراه بکار برد.


#### ۸- منابع

- [1] M. Khojastehnazhand, V. Mohammadi, and S. Minaei, "Maturity detection and volume estimation of apricot using image processing technique," *Scientia Horticulturae*, vol. 251, pp. 247–251, 2019.
- [2] A. M. Alhamdan and A. Atia, "Non-destructive method to predict Barhi dates quality at different stages of maturity utilising near-infrared (NIR) spectroscopy," *International journal of food properties*, vol. 20, no. sup3, pp. S2950–S2959, 2017.
- [3] H. Altaheri, M. Alsulaiman, and G. Muhammad, "Date fruit classification for robotic harvesting in a natural environment using deep learning," *IEEE Access*, vol. 7, pp. 117115–117133, 2019.
- [4] A. Nasiri, A. Taheri-Garavand, and Y.-D. Zhang, "Image-based deep learning automated sorting of date fruit," *Postharvest biology and technology*, vol. 153, pp. 133–141, 2019.
- [5] M. Dyrmann, H. Karstoft, and H. S. Midtby, "Plant species classification using deep convolutional neural network," *Biosystems engineering*, vol. 151, pp. 72–80, 2016.

در مرحله بعد دقت مدل گفته شده در بالا را با استفاده از طرح پیشنهادی به دقت ۰,۹۴۵۳ برسانیم و نرخ یادگیری بهینه مقدار ۰,۰۰۰۴ تعیین شد.

#### ۶- پارامترهای ارزیابی

نمودار موجود در تصویر شماره ۵ نشان بعد از اجرای روش پیشنهادی برای تعیین نرخ یادگیری مدل VGG19 می باشد که  $10^{-5}$  بهترین نرخ یادگیری می باشد.



(شکل - ۵) بازه نرخ یادگیری بهینه در مدل VGG19

همچنین خلاصه نتایج آزمایش ها در جدول ۱ نشان داده شده است.

(جدول ۱- خلاصه نتایج آزمایش ها)

دقت	نرخ یادگیری	میزان پارامترها	
۰,۹۳۵	۰,۰۰۰۱	۱۰,۰۳۷,۷۰	آزمایش ۱ (vgg19)
۰,۹۳۵	۰,۰۰۰۰	۱۰,۰۳۷,۷۰	آزمایش ۲ (vgg19, HOG)
۰,۹۱۵	۰,۰۰۰۱	۲۶,۲۷۹,۱۰	آزمایش ۳ (Resnet152)
۰,۹۱۵	۰,۰۰۰۴	۲۶,۲۷۹,۱۰	آزمایش ۴ (Resnet152, HOG)

با استفاده از ماتریس آشفتگی مقادیر زیر برای بهترین مدل توانست مرحله رسیدن خرما را با دقت بالایی پیش بینی کند بدست آمد.

Precision= 0.93

Recall=0.91

نزدیک بودن این دو مقدار نشان می دهد که تقریباً توانسته ایم مدل مناسبی بدست آوریم.

#### ۷- نتیجه گیری

کلاسبندی میوه خرما بر اساس مراحل مختلف بلوغ یکی از فرآیندهای مهم در صنعت غذا می باشد روش های طبقه

[6] M. Farooq and E. Sazonov, "Feature extraction using deep learning for food type recognition," in *International conference on bioinformatics and biomedical engineering*, 2017, pp. 464–472.

[7] M. Rahnemoonfar and C. Sheppard, "Deep count: fruit counting based on deep simulated learning," *Sensors*, vol. 17, no. 4, p. 905, 2017.

[8] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," *arXiv preprint arXiv:1409.1556*, 2014.

[9] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 770–778.

[10] L. N. Smith, "Cyclical Learning Rates for Training Neural Networks," in *2017 IEEE Winter Conference on Applications of Computer Vision (WACV)*, Mar. 2017, pp. 464–472. doi: 10.1109/WACV.2017.58.