

## تعیین زمان برداشت میوه سیب با استفاده از تصاویر رنگی و یادگیری عمیق

سید ایمان ساعدی<sup>\*۱</sup>

### چکیده

شناسایی مراحل رشد میوه پیش از برداشت، عامل مهمی در بهبود کمیت و کیفیت میوه است. داشتن چنین اطلاعاتی به باغدار کمک می‌کند که تیمار مناسب هر مرحله از رشد را اعمال نماید و با توجه به شرایط متغیر آب‌وهوایی، به درک مناسبی از زمان برداشت میوه دست پیدا کند. با این هدف، در پژوهش حاضر از تصاویر رنگی برای شناسایی هفته‌های منتهی به زمان برداشت میوه سیب گلدن پاییزه استفاده شد. با استفاده از فناوری یادگیری عمیق و شبکه‌های عصبی پیچشی، مدل EfficientNetB1 برای طبقه‌بندی عکس‌های گرفته شده در هفته‌های مختلف رشد میوه سیب استفاده شد. داده‌ها به صورت تصادفی به سه دسته آموزش (۶۰٪)، اعتبارسنجی (۲۰٪) و آزمون (۲۰٪) تقسیم شدند. همچنین، دو فرایند پیش‌پردازش یعنی نرمال‌سازی داده‌ها و نیز داده‌افزایی برای حصول نتایج بهتر منظور گردید و در مرحله توسعه مدل از بهینه‌ساز Nadam و تابع هزینه categorical\_crossentropy استفاده شد. نتایج نشان داد که مدل توسعه داده شده قابلیت خوبی در طبقه‌بندی تصاویر ورودی داشت. مقدار ضریب همبستگی (R) برای داده‌های آموزش، اعتبارسنجی و آزمون به ترتیب ۰/۸۶، ۰/۸۸ و ۰/۸۷ به دست آمد. همچنین، توانایی مدل در طبقه‌بندی با استفاده از عوامل precision، recall و f1-score برای هر طبقه ارائه گردید که برطبق آن برخی از طبقه‌ها با دقت ۱۰۰٪ از سایر طبقه‌ها متمایز شدند. با توجه به قابلیت‌های یادگیری عمیق در طبقه‌بندی عکس‌ها در شرایط کاملاً طبیعی، این قبیل مدل‌ها می‌توانند در توسعه ربات‌های برداشت و یا سامانه‌های عکس‌برداری هوایی و غیره استفاده شوند و اهداف مختلفی در کشاورزی دقیق، و به طور خاص، باغبانی دقیق را برآورده سازند.

**واژه‌های کلیدی:** باغبانی دقیق، یادگیری عمیق، طبقه‌بندی، زمان برداشت، تصاویر رنگی، سیب.

ارجاع: ساعدی س. ا. ۱۴۰۲. تعیین زمان برداشت میوه سیب با استفاده از تصاویر رنگی و یادگیری عمیق نشریه پژوهش‌های مکانیک ماشین‌های کشاورزی. ۲۸: ۴۵-۵۳. <https://dx.doi.org/10.22034/JRMAM.2023.14078.619>

۱- استادیار گروه آب و خاک، دانشکده کشاورزی، دانشگاه صنعتی شاهرود.

\* نویسنده مسئول: [isaedi@shahroodut.ac.ir](mailto:isaedi@shahroodut.ac.ir)

تاریخ دریافت: ۱۴۰۱/۰۷/۱۹ تاریخ پذیرش: ۱۴۰۱/۱۰/۲۰

## مقدمه

نیاز روزافزون جهان به محصولات باغی ضرورت استفاده از رویکردهای نوآورانه برای تولید میوه و سبزیجات را نمایان می‌کند. در این راستا، اتخاذ راهبردهایی که استفاده حداقل نهاده‌ها و تولید حداکثر عملکرد را به دنبال داشته باشد امری حیاتی است (Gebbers & Adamchuk, 2010; Saedi *et al.*, 2019). با به‌کارگیری فناوری‌های نوین در تولید محصولات باغی می‌توان مدیریت خاص مکانی را در باغ به اجرا در آورد. راهبردی که منجر به توسعه روش‌های مفید در اجرای فرایندهای باغبانی مکانیزه و هوشمند می‌گردد (Williams *et al.*, 2019). یک سامانه مکانیزه باغبانی که ممکن است از ربات‌ها یا هواپیماهای بدون سرنشین تشکیل شده باشد، عمدتاً به تصاویری وابسته است که باید به‌طور مؤثر با یک سامانه خیره پردازش شوند. در زمینه باغبانی دقیق، تشخیص میوه روی شاخه کاربردهای متعددی مانند پیش‌بینی عملکرد باغات، برداشت مکانیزه/رباتیک میوه، تیمار مناسب درختان میوه و سمپاشی دقیق را دارا است. این فرآیندها عموماً در حالت سنتی دشوار، زمان‌بر، کم‌بازده و پرهزینه هستند (Sa *et al.*, 2016; Wu *et al.*, 2019; Amatya *et al.*, 2016; Gené-Mola *et al.*, 2019; Pourreza *et al.*, 2015). برای مثال، نقشه عملکرد باغ به پراکندگی محصول در یک باغ توجه دارد، در حالی که یک ربات برداشت میوه به یک سکوی تشخیص میوه مناسب برای فعال کردن بازوی چیدن نیاز دارد. از سوی دیگر، یک سامانه تیمار درختان میوه، به میوه شناسایی شده هدف وابسته است و یک سمپاش دقیق به دنبال منطقه مورد نظر در درخت میوه برای انجام کارآمد فرایند سمپاشی است.

رویکردهای مختلفی برای تشخیص یا شناسایی میوه معرفی شده‌است. این رویکردها بیشتر به ویژگی‌های بصری میوه‌ها بستگی دارند که با استفاده از روش‌های پردازش تصویر، مسئول تشخیص میوه‌ها از اشیاء دیگر هستند. این روش‌ها اساساً چالش برانگیزند، زیرا اثرات محیطی مانند پس‌زمینه پیچیده، نور متغیر (Feng *et al.*, 2019)، همپوشانی‌ها و انسدادها با سایر بخش‌های گیاه (Wang *et al.*, 2017) تشخیص دقیق میوه‌ها را دشوارتر می‌کند. چالش‌های دیگر در مورد ویژگی تعمیم و همچنین زمان اجرای یک روش است، به این معنی که

الگوریتم پیشنهادی باید بتواند انواع مختلف میوه‌ها را در زمان واقعی برای کاربردهای غیر ایستا (مثل ربات برداشت میوه) شناسایی نماید. همچنین، به منظور برداشت مناسب میوه، می‌توان به راهکارهایی برای تشخیص زمان مناسب چیدن میوه بر اساس رسیدگی آن توجه نمود. محققان موفق به ارائه الگوریتم‌های مناسب تشخیص میوه و نیز تشخیص مرحله رشدی میوه روی درخت برای انواع کاربردهای باغبانی شدند که هرکدام دارای دقت متفاوتی است. تصاویر RGB یا رنگی، که اطلاعات دوبعدی را ارائه می‌کنند، در این زمینه بیشتر مورد استفاده قرار گرفته‌اند (Gené-Mola *et al.*, 2019). استفاده از یادگیری عمیق برای نیل به اهداف فوق می‌تواند نتایج امیدبخشی به همراه داشته باشد. یادگیری عمیق یک زمینه یادگیری ماشین خاص بر اساس نمایش پی‌درپی لایه‌های داده‌است. در سال‌های اخیر کاربرد این رویکردها در زمینه‌های مختلف کشاورزی شتاب گرفته است (Kamilaris & Prenafeta-Boldú 2018). این رویکردها که معمولاً مبتنی بر شبکه‌های عصبی پیچشی هستند دارای خاصیت تعمیم قوی و همچنین قابلیت بالا برای استخراج غیرخطی ویژگی‌های تصویر برای طبقه‌بندی هستند (Nasiri *et al.*, 2019; Peng *et al.*, 2018).

شبکه‌های عصبی پیچشی<sup>۱</sup> زیرمجموعه‌ای از یادگیری عمیق هستند که در زمره شبکه‌های عصبی با نظارت طبقه‌بندی می‌شوند (Chollet, 2017). به طور کلی، یک شبکه عصبی پیچشی ابتدا عکس را که در اندازه‌های مختلف ممکن است باشد دریافت می‌کند. این عکس با انجام پیش‌پردازش‌هایی وارد مرحله بعدی شبکه یعنی بخش استخراج ویژگی یا یادگیری ویژگی می‌شود. در این قسمت با استفاده از لایه‌های مختلف عمل استخراج ویژگی‌ها صورت می‌گیرد. با افزایش لایه‌ها ویژگی‌های استخراج شده به تدریج پیچیده‌تر می‌شوند. در بخش استخراج ویژگی‌ها، لایه‌های مختلفی معرفی و استفاده می‌شوند که مهم‌ترین آن‌ها لایه‌های پیچش و Pooling هستند. در کنار آن‌ها لایه‌هایی از قبیل Global Average Pooling، Batch Normalization و غیره نیز ممکن است استفاده شود. بعد از انجام فرایند استخراج ویژگی فرایند طبقه‌بندی صورت می‌گیرد که در این حالت از همان

1- Convolutional Neural Network

یکی از کاربردهای مهم در طبقه‌بندی عکس‌ها در کشاورزی دقیق تشخیص مرحله رسیدگی محصول است که به کشاورز این توانایی را می‌دهد که با توجه به شرایط محصول هدف تیمار مدنظر را برای رشد بهتر اعمال نماید. این امر در بسیاری از تحقیقات مورد توجه پژوهش‌گران قرار گرفته است ( Yue *et al.*, 2020; Adhanhabi *et al.*, 2022; Moraes *et al.*, 2022; Tan *et al.*, 2018). در یک مطالعه، طبقه‌بندی مراحل رسیدگی میوه قهوه با استفاده از راهبردهای یادگیری ماشین و اندازه‌گیری امپدانس الکترومکانیکی صورت پذیرفت (Pineda *et al.*, 2022). در پژوهشی مشابه، یک رویکرد شبکه عصبی پیچشی عمیق توسط محققین برای طبقه‌بندی مراحل رشدی زیتون از روی عکس‌های رنگی استفاده گردید. مدل طراحی شده توانست با دقت مناسبی هر یک از این مراحل را تشخیص دهد (Khosravi *et al.*, 2021).

تخمین زمان مناسب برداشت میوه اطلاعاتی از روند رشدی میوه در اختیار می‌گذارد. این قابلیت، به باغ‌دار کمک می‌کند تا تیمار مناسب را در هر مرحله رشدی اعمال نماید. به عنوان مثال، اگر در یک زمان، میزان رشد میوه، مناسب تشخیص داده نشود می‌توان از کوددهی، یا محلول پاشی برای تسریع روند رشد استفاده نمود. لذا، در این پژوهش در نظر است از یک مدل یادگیری عمیق استفاده شود که بتواند هفته‌های باقیمانده تا زمان برداشت سیب را با پردازش تصاویر رنگی گرفته شده در شرایط کاملاً طبیعی برآورد کند.

### مواد و روش‌ها

در این پژوهش به منظور توسعه مدل شبکه عصبی عمیق، در ابتدا عکس‌هایی از میوه سیب روی درخت در طول دوره رشد در فواصل زمانی یکسان (۷ تا ۱۰ روز) از باغات اطراف شهرستان شاهرود گرفته شد. سیب‌ها از رقم لبنانی گلدن پاییزه بودند. در شکل ۱ نمونه‌ای از این عکس‌ها نمایش داده شده است. عکس‌ها در ۱۵ هفته متوالی منتهی به زمان برداشت با استفاده از دوربین تلفن همراه (Redmi Note 8 (48MP Quad Camera) گرفته شد.

لایه‌های سنتی شبکه‌های عصبی یعنی تمام متصل<sup>۱</sup> استفاده خواهد شد (Chollet, 2017).

در زمینه کاربرد شبکه‌های عصبی عمیق و یا پیچشی در شناسایی میوه می‌توان به پژوهش‌های مرتبطی اشاره نمود. در یک مطالعه، یک رویکرد شبکه عصبی عمیق پیشرفته به نام R-CNN Fast توسط محققان برای توسعه یک سامانه کارآمد تشخیص میوه استفاده شد (Ren *et al.*, 2015). همچنین، با استفاده از یادگیری انتقالی<sup>۲</sup>، محققین یک الگوریتم تشخیص میوه را توسعه دادند که در آن دو نوع تصویر RGB و NIR با روش همجوشی اولیه و سریع ترکیب شدند (Sa *et al.*, 2016). در پژوهش دیگری گروهی از پژوهش‌گران از سه روش شبکه عصبی پیچشی به نام‌های YOLOv3، ResNet50 و ResNet152 برای تشخیص مرکبات استفاده کردند تا در یک ربات برداشت میوه آزمایش شوند. برگ‌ها، شاخه‌ها و میوه‌ها نیز با سامانه بینایی پیشنهادی متمایز شدند و بالاترین دقت تشخیص توسط ResNet152 به دست آمد (Liu *et al.*, 2019). در مطالعه‌ای دیگر، یک الگوریتم یادگیری عمیق SSD با استفاده از مدل ResNet101 برای تشخیص سیب و چند نوع میوه دیگر توسعه داده شد. در این تحقیق، یک الگوریتم بهینه‌سازی SGD و یک روش افزایش داده نیز برای بهبود دقت تشخیص میوه و تعمیم مدل استفاده شد (Peng *et al.*, 2018). یکی دیگر از رویکردهای یادگیری عمیق پیرامون ترکیب اطلاعات RGB-D و رادیومتریک برای تشخیص سیب فوجی بود. در این پژوهش، شدت سیگنال تصحیح دامنه و ثبت تصویر در کنار مدل R-CNN Faster به عنوان فرآیند تشخیص استفاده شد (Gené-Mola *et al.*, 2019). علاوه بر این، برای تشخیص خودکار میوه سرخالو خوشه‌ای برای یک ماشین برداشت رباتیک، گروهی از محققین از ترکیبی از تقسیم‌بندی، آستانه پیکسل و روش تطبیق مبتنی بر مرکز هندسی استفاده کردند (Liu *et al.*, 2018). در نهایت، پژوهش‌گران از یک حسگر RGB-D برای تشخیص میوه گواوا استفاده کردند. در این مطالعه، تصویر RGB با استفاده از یک شبکه کاملاً پیچشی برای ایجاد یک نقشه دودویی از میوه و شاخه تقسیم شد. سپس یک رویکرد خوشه‌بندی اقلیدسی برای ایجاد مجموعه‌ای از میوه‌ها به کار گرفته شد (Lin *et al.*, 2019).

1- Fully Connected

2- Transfer learning



شکل ۱- تصاویری از میوه سیب گلدن پاییزه در هفته‌های مختلف منتهی به زمان برداشت؛ هر هفته با یک شماره مشخص شده‌است که بیان‌گر تعداد هفته‌های باقی‌مانده تا زمان برداشت است.

طبقه‌ای را نشان می‌دهد که میوه‌های آن بایستی حدوداً ۱۲ هفته دیگر برداشت شود و میوه با شماره ۱۰ باید حدوداً ۱۰ هفته دیگر برداشت شود. در نهایت، میوه با شماره صفر آماده چیده شدن از روی درخت است. تعداد عکس‌های گرفته شده در هر هفته رشدی در جدول ۱ نمایش داده شده‌اند. با توجه به این جدول در مجموع ۱۴۳۴ عکس از هفته‌های مختلف رشدی گرفته شد که از آن‌ها برای توسعه مدل و انجام فرایند آموزش شبکه عصبی عمیق استفاده شد.

روند تهیه عکس‌ها از میوه سیب روی درخت به این صورت بود که عکس‌برداری هفتگی از مراحل اولیه رشد در هفته‌های متوالی (با ثبت تاریخ هر مرحله) آغاز شد. این روند تا زمانی ادامه یافت که بنا به نظر فرد خبره (باغدار)، زمان برداشت میوه فرا رسیده است. با توجه به تاریخ‌های ثبت شده، مشخص شد که اولین مرحله عکس‌برداری، ۱۵ هفته پیش از برداشت بوده‌است. به این ترتیب، به عکس‌های هر هفته شماره‌هایی از ۰ تا ۱۴ نسبت داده شد که نشان دهنده تعداد هفته‌های باقی‌مانده تا زمان برداشت میوه است. به عنوان مثال، میوه با شماره ۱۲

جدول ۱- تعداد عکس‌های گرفته شده میوه سیب در هر هفته رشدی باقی‌مانده تا زمان برداشت

شماره هفته تا برداشت	۰	۱	۲	۳	۴	۵	۶	۷	۸	۹	۱۰	۱۱	۱۲	۱۳	۱۴
تعداد عکس	۸۷	۹۵	۱۰۸	۱۰۳	۱۰۳	۹۴	۱۰۳	۹۹	۱۰۰	۹۷	۸۴	۱۲۲	۶۷	۷۱	۱۰۱

آموزش تمام شبکه‌های عصبی معمولی است. یعنی ورودی وارد شبکه می‌شود و از لایه‌های مختلف عبور می‌کند و نتیجه حاصل می‌شود. این نتیجه با نتیجه مطلوب مقایسه می‌شود و اختلاف این دو خطا را برمی‌گرداند. با استفاده از این خطا با حرکت رو به عقب عوامل شبکه اصلاح می‌گردد

به منظور توسعه مدل شبکه عصبی عمیق داده‌های تصویری موجود به سه بخش آموزش، ارزیابی و آزمون تقسیم شدند. به این منظور ۶۰ درصد از کل داده‌ها به صورت تصادفی عنوان آموزش، ۲۰ درصد به عنوان ارزیابی و ۲۰ درصد به عنوان آزمون در نظر گرفته شدند. فرایند آموزش همانند

وزن‌های از پیش آموزش دیده شده ImageNet بارگذاری شده‌است. این شبکه بسیار عمیق و پیچیده است. توضیحات مربوط به لایه‌های مختلف به جهت اختصار از طریق راهنمای تصویری ارائه شده در شکل ۲ بیان شده است. لایه‌های مختلف با آرایش قرارگیری متفاوتی در این الگوریتم استفاده شده‌اند که معروف‌ترین آن‌ها شامل پیچش دو بعدی (Conv2D)، Global Average Pooling، Dropout، Batch Normalization و غیره است.

یکی از نکاتی که در توسعه هر مدل شبکه عصبی و از جمله شبکه عصبی عمیق بایستی مدنظر قرار داد این است که اساساً تئوری ریاضی مشخصی در توسعه مدل وجود ندارد و بیشتر فرایند ایجاد مدل بهینه با سعی و خطا صورت می‌گیرد. بدیهی است در مدل پیچیده‌ای مثل EfficientNetB1 تغییرات بسیار زیادی را در جهت بهبود دقت می‌توان انجام داد. تغییر اندازه عکس‌های ورودی، تغییر عامل‌های مورد استفاده در داده‌افزایی و تغییر در تعداد، نوع و عوامل مورد استفاده در شبکه EfficientNet مورد استفاده از جمله این موارد به شمار می‌آیند.

به منظور بهبود عملکرد مدل این قابلیت وجود دارد که اصلاحات دقیق<sup>۳</sup> در مدل فوق صورت داد. این اصلاحات شامل تغییر در ضریب حذف نرون‌ها در Dropout و جابجایی لایه‌هایی مثل Batch Normalization و Global Average Pooling است. به منظور انتخاب بهینه‌ساز با بررسی دقت حاصل از چند بهینه‌ساز مختلف از جمله SGD، RMSprop، Adam و Nadam، در نهایت Nadam مورد استفاده قرار گرفت. تابع categorical\_crossentropy نیز به عنوان تابع هزینه انتخاب شد. در اجرای فرایند آموزش اولیه تعداد batch برابر با ۸ و تعداد تکرار<sup>۴</sup> برابر ۲۰۰ لحاظ گردید. در ادامه فرایند آموزش ۱۰۰ لایه آخر مدل به شرط آنکه از نوع Batch Normalization نباشند دوباره آموزش داده شدند. در این حالت تعداد batch برابر با ۸ و تعداد تکرار برابر ۱۰۰ انتخاب شد و با لحاظ کردن تابع هزینه فوق‌الذکر فرایند آموزش صورت پذیرفت. در مرحله آموزش، عامل دقت به عنوان معیار بررسی مدل انتخاب شد.

برای توسعه مدل از محیط ابری گوگل تحت عنوان Google Colaboratory، زبان برنامه‌نویسی Python و کتابخانه‌های tensorflow و keras استفاده شد.

و مجدداً داده به شبکه وارد می‌شود و نتایج و خطای جدید محاسبه شده و سپس عوامل دوباره اصلاح می‌شوند. این چرخه به دفعات تکرار می‌شود. برای محاسبه خطای شبکه روابط و توابع مختلفی وجود دارد. پس از آنکه خطا محاسبه شد بایستی توسط این خطا عوامل اصلاح شوند. به این فرایند بهینه‌سازی گفته می‌شود. این فرایند حرکت قدم به قدم به سمت کمترین خطا است، یعنی اصلاح و به‌روزرسانی وزن‌ها برای رسیدن به حداقل خطا.

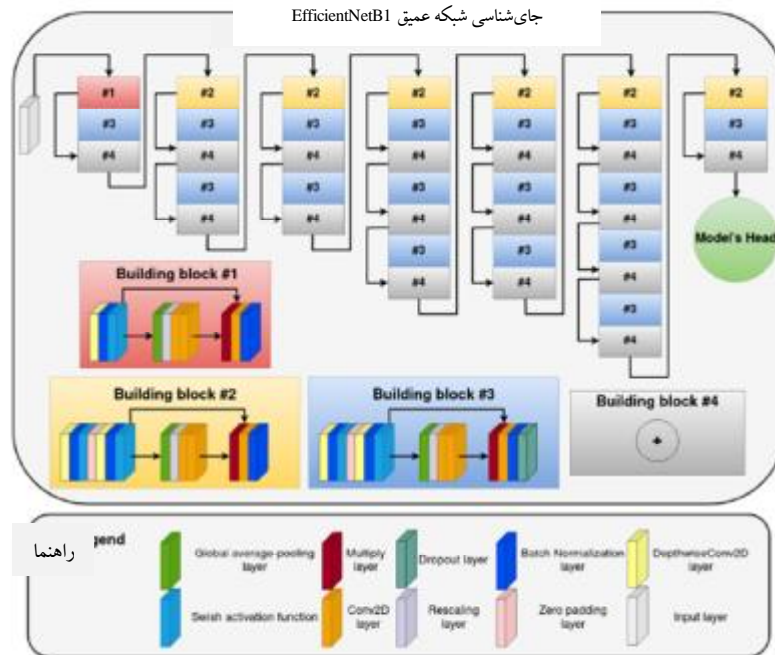
به عنوان یک عملیات مهم، بایستی تصاویر ورودی پیش‌پردازش شوند. اجرای درست این فرایند به بهبود دقت مدل کمک قابل توجهی خواهد کرد، از بیش‌برازش<sup>۱</sup> کرده و قابلیت تعمیم بالاتری نیز به مدل خواهد داد. بدین منظور، ابتدا تمامی عکس‌ها به ۲۰۰ پیکسل در ۲۰۰ پیکسل تغییر اندازه داده شدند تا به عنوان ورودی مناسب شبکه انتخابی استفاده شوند. سپس نرمال‌سازی داده‌های ماتریس مربوط به عکس‌ها صورت گرفت. به این ترتیب که اندازه هر عکس به بیشینه مقدار پیکسل عکس‌های گرفته شده تقسیم شد. در مرحله بعدی از داده‌افزایی<sup>۲</sup> استفاده شد تا تعداد عکس‌های استفاده شده در توسعه مدل به صورت مجازی افزایش یابد. در این فرایند از چرخش عکس، جابجایی عکس، آیینه کردن عکس و تغییر وضوح استفاده شد.

الگوریتم استفاده شده در این پژوهش یک شبکه عصبی عمیق پیچشی با نام EfficientNetB1 بود که ساختار آن در شکل ۲ نمایش داده شده است. الگوریتم‌های خانواده EfficientNet یک معماری شبکه عصبی پیچشی همراه با مقیاس‌بندی را ارائه می‌دهند. روش مقیاس‌بندی EfficientNet به طور یکنواخت عرض، عمق و وضوح شبکه را با مجموعه‌ای از ضرایب مقیاس‌بندی ثابت ارائه می‌دهد. برای مثال، اگر بخواهیم از منابع محاسباتی بیشتری استفاده کنیم، می‌توانیم به سادگی عمق شبکه، عرض و اندازه تصویر را با هم افزایش دهیم، به طوری که ضرایب ثابت با جستجوی شبکه کوچک در مدل کوچک اصلی تعیین می‌شوند. EfficientNet از یک ضریب ترکیبی برای مقیاس یکنواخت عرض، عمق و وضوح شبکه به روشی اصولی استفاده می‌کند. این الگوریتم در حالات EfficientNetB0 تا EfficientNetB7 ارائه شده‌است.

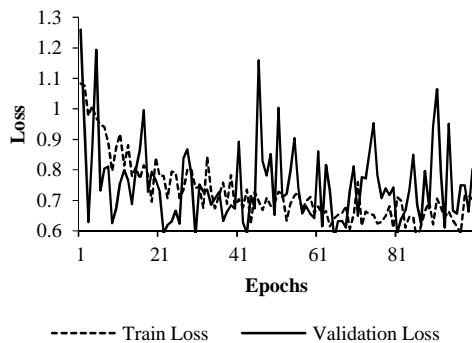
الگوریتم EfficientNetB1 یک مدل طبقه‌بندی تصویر با استفاده از کتابخانه Keras را بر می‌گرداند که معمولاً با

3- Fine tuning  
4- Epoch


1- Overfitting  
2- Data augmentation



شکل ۲- جای‌شناسی شبکه عمیق EfficientNetB1 که دارای یک معماری پیچیده است.



شکل ۳- نمودار تغییرات خطا در روند آموزش برای داده‌های آموزش و اعتبارسنجی



شکل ۴- نمودار تغییرات دقت در روند آموزش برای داده‌های آموزش و اعتبارسنجی

## نتایج و بحث

در این بخش نتایج توسعه مدل یادگیری عمیق EfficientNetB1 برای شناسایی هفته‌های منتهی به زمان برداشت میوه سیب گلدن پاییزه با استفاده از تصاویر رنگی ارائه می‌شود.

در شکل ۳ نمودار تغییرات خطا در برابر تکرار (Epoch) برای داده‌های آموزش و اعتبارسنجی ارائه شده است. همان‌گونه که در این شکل مشاهده می‌شود در هر دو بخش داده‌های آموزش و اعتبارسنجی روند کاهش خطا تقریباً به طور پیوسته و البته با نوساناتی مشاهده می‌شود. همچنین با توجه به این نمودار کمترین خطا در داده‌های آموزش در تکرار ۸۳ و به میزان  $0.7492$  و در داده‌های اعتبارسنجی در تکرار ۴۷ و با مقدار  $0.7332$  به دست آمد. در شکل ۴ نمودار تغییرات دقت در برابر تکرار برای داده‌های آموزش و اعتبارسنجی آورده شده است. با توجه به این شکل، در مورد داده‌های آموزش بالاترین دقت در تکرار ۹۱ و به مقدار  $0.7348$  و در داده‌های اعتبارسنجی در تکرار ۳۷ و به مقدار  $0.7739$  حاصل گردید.

طبق این جدول، مقدار خطا در داده‌های آزمون برابر با ۰/۶۵ و ضریب تبیین برابر با ۰/۸۸ به دست آمد.

در جدول ۲ خلاصه‌ای از نتایج حاصل از توسعه مدل ارائه شده‌است. در این جدول بهترین حالات حاصل شده برای داده‌های آموزش، اعتبارسنجی و آزمون ارائه شده‌است. بر

جدول ۲- نتایج توسعه مدل EfficientNetB1 بر روی داده‌های آموزش، اعتبارسنجی و آزمون

داده‌های آموزش	داده‌های اعتبارسنجی	داده‌های آزمون	
۰/۷۳	۰/۷۷	۰/۷۵	دقت
۰/۷۵	۰/۷۳	۰/۶۵	خطا
۰/۸۶	۰/۸۸	۰/۸۷	ضریب همبستگی

در آن صورت نگرفته است و می‌توان در این هفته نیز کار برداشت را انجام داد.

پژوهش‌های مشابه که بر روی مطالعه روند رشدی میوه با استفاده از یادگیری عمیق متمرکز بوده‌اند کارایی این روش را تأیید می‌کنند. به عنوان مثال، Khosravi et al., 2021 با استفاده از یادگیری عمیق مراحل رشدی مهم میوه زیتون را از روی تصاویر پیش‌بینی نمودند. در این مطالعه، چهار طبقه مختلف، یعنی چهار مرحله رشدی مطالعه شد. در مطالعه حاضر پانزده مرحله رشدی میوه سیب بررسی شد که کارایی یادگیری عمیق در برآورد آن‌ها به تأیید رسید.

### نتیجه‌گیری

در پژوهش حاضر یک مدل شبکه عصبی عمیق مبتنی بر شبکه استاندارد EfficientNet به منظور پیش‌بینی هفته‌های باقی‌مانده تا زمان برداشت میوه سیب گلدن پاییزه از طریق تصاویر رنگی توسعه داده‌شد. نتایج حاصل از آزمون مدل با استفاده از داده‌های دیده نشده (داده‌های آزمون) نشان داد که این مدل می‌تواند با دقت مناسبی زمان برداشت میوه سیب را با استفاده از عکس‌برداری به کاربر ارائه دهد. راهبرد مورد استفاده در این پژوهش می‌تواند به عنوان بستری در توسعه ربات‌های برداشت و یا سامانه‌های عکس‌برداری هوایی با استفاده از پهپاد استفاده شود و اهداف مختلفی در کشاورزی دقیق، و به طور خاص، باغبانی دقیق را برآورده سازد.

به منظور نمایش بهتر نتایج طبقه‌بندی، گزارش طبقه‌بندی<sup>۱</sup> برای هر کدام از طبقه‌های مدنظر (۱۴ هفته تا زمان برداشت تا خودموعود برداشت) در جدول ۳ ارائه شده است. عملهای نمایش داده شده در این جدول شامل precision، recall و f1-score هستند که حداقل آن‌ها صفر و حداکثر آن‌ها یک می‌تواند باشد. به طور خلاصه، بالا بودن عامل precision نشان دهنده این است که نسبت تعداد مواردی که مدل اشتباه پیش‌بینی کرده است به تعداد پیش‌بینی‌های درست کمتر است و بالعکس. عامل recall هرچقدر بالاتر باشد به معنی این است که نسبت تعداد مواردی که انتظار می‌رفت مدل پیش‌بینی کند ولی پیش‌بینی نشده‌است، به تعداد پیش‌بینی‌های درست کمتر بوده‌است، و بالعکس. در نهایت، عامل f1-score برابر میانگین هندسی دو عامل قبل است. بر طبق این جدول، مقدار precision برای طبقه ۸ هفته تا برداشت و طبقه زمان برداشت (صفر) برابر ۱ به دست آمد که به معنای آن است که مدل با دقت ۱۰۰٪ توانسته است این دو طبقه را متمایز کند. همچنین عامل recall برای طبقه‌های ۷ و ۸ هفته تا برداشت به بیشینه خود (یک) رسیده‌است که دقت مدل در تمایز ۱۰۰٪ این دو طبقه را نشان می‌دهد. از طرفی بیشترین مقدار f1-score برابر ۰/۹۳ به دست آمد که مربوط به طبقه ۷ هفته تا زمان برداشت است. کمترین مقادیر این عامل مربوط به هفته‌های ۱۲ و ۱ تا زمان برداشت است. به عبارت دیگر مدل در شناسایی زمان دقیق برداشت از روی عکس‌های این دو طبقه چندان دقیق عمل نکرده است. این نکته را می‌توان به تشابه زیاد میوه در هفته‌های قبل و بعد آن نسبت داد. مثلاً در مورد طبقه ۱ هفته تا زمان برداشت می‌توان این نتیجه را گرفت که میوه در فاصله یک هفته تا زمان برداشت تغییر چندانی

جدول ۳- گزارش طبقه‌بندی شناسایی هفته‌های باقی‌مانده تا زمان برداشت میوه سیب از روی تصاویر رنگی

نام کلاس‌ها	precision	recall	f1-score	support
۱۴ هفته تا برداشت	۰/۸۹	۰/۸۴	۰/۸۶	۱۹
۱۳ هفته تا برداشت	۰/۵۵	۰/۹۲	۰/۶۹	۱۳
۱۲ هفته تا برداشت	۰/۷۵	۰/۳۵	۰/۴۸	۱۷
۱۱ هفته تا برداشت	۰/۶۰	۰/۴۷	۰/۵۳	۱۹
۱۰ هفته تا برداشت	۰/۷۶	۰/۵۷	۰/۶۵	۲۸
۹ هفته تا برداشت	۰/۸۰	۰/۹۵	۰/۸۷	۲۱
۸ هفته تا برداشت	۱/۰۰	۰/۶۴	۰/۷۸	۱۴
۷ هفته تا برداشت	۰/۸۶	۱/۰۰	۰/۹۳	۱۹
۶ هفته تا برداشت	۰/۵۷	۱/۰۰	۰/۷۲	۱۳
۵ هفته تا برداشت	۰/۹۰	۰/۸۳	۰/۸۶	۲۳
۴ هفته تا برداشت	۰/۸۸	۰/۶۸	۰/۷۷	۲۲
۳ هفته تا برداشت	۰/۹۰	۰/۸۳	۰/۸۶	۲۳
۲ هفته تا برداشت	۰/۹۵	۰/۹۰	۰/۹۲	۲۰
۱ هفته تا برداشت	۰/۸۳	۰/۲۹	۰/۴۳	۱۷
زمان برداشت	۱/۰۰	۰/۵۸	۰/۷۳	۱۹
micro avg.	۰/۸۰	۰/۷۲	۰/۷۶	۲۸۷
macro avg.	۰/۸۲	۰/۷۲	۰/۷۴	۲۸۷
weighted avg.	۰/۸۳	۰/۷۲	۰/۷۵	۲۸۷
samples avg.	۰/۷۲	۰/۷۲	۰/۷۲	۲۸۷

Lin, Guichao, Yunchao Tang, Xiangjun Zou, Juntao Xiong, & Jinhui Li. (2019). Guava Detection and Pose Estimation Using a Low-Cost RGB-D Sensor in the Field, *Sensors*, 19: 428.

Liu, Jizhan, Yan Yuan, Yao Zhou, Xinxin Zhu, & Tabinda Naz Syed. (2018). Experiments and Analysis of Close-Shot Identification of On-Branch Citrus Fruit with RealSense, *Sensors*, 18: 1510.

Liu, Y.-P., C.-H. Yang, H. Ling, S. Mabu, & T. Kuremoto. (2019). A Visual System of Citrus Picking Robot Using Convolutional Neural Networks. In *Int. Conf. Syst. Informatics, ICSAI*, 344-349.

Moraes, I. A. de, Cruz-Tirado, L. J. P., & Barbin, D. F. (2022). Online measurement of carambola (*Averrhoa carambola* L.) physicochemical properties and estimation of maturity stages using a portable NIR spectrometer. *Scientia Horticulturae*, 304: 111263.

Nasiri, Amin, Amin Taheri-Garavand, & Yu-Dong Zhang. (2019). Image-based deep learning automated sorting of date fruit, *Postharvest Biology and Technology*, 153: 133-41.

Peng, H., B. Huang, Y. Shao, Z. Li, C. Zhang, Y. Chen, & J. Xiong. (2018). General improved SSD model for picking object recognition of multiple fruits in natural environment. In *Nongye Gongcheng Xuebao/Transactions of the Chinese*

## منابع

Amatya, S., Karkee, M., Gongal, A., Zhang, Q., & Whiting D. M. (2016). Detection of cherry tree branches with full foliage in planar architecture for automated sweet-cherry harvesting, *Biosystems Engineering*, 146: 3-15.

Chollet, F. (2017). Deep Learning with Python, *Manning Publications Co.*

Feng, Juan, Lihua Zeng, & Long He. (2019). Apple Fruit Recognition Algorithm Based on Multi-Spectral Dynamic Image Analysis, *Sensors*, 19: 949.

Gebbers, Robin, & Viacheslav I. Adamchuk. (2010). *Precision Agriculture and Food Security*, *Science*, 327: 828.

Gené-Mola, Jordi, Verónica Vilaplana, Joan R. Rosell-Polo, Josep-Ramon Morros, Javier Ruiz-Hidalgo, & Eduard Gregorio. (2019). Multi-modal deep learning for Fuji apple detection using RGB-D cameras and their radiometric capabilities, *Computers and Electronics in Agriculture*, 162: 689-98.

Kamilaris, Andreas, & Francesc X. Prenafeta-Boldú. (2018). Deep learning in agriculture: A survey, *Computers and Electronics in Agriculture*, 147: 70-90.

Khosravi, H., Saedi, S. I., Rezaei, M., (2021). Real-time recognition of on-branch olive ripening stages by a deep convolutional neural network. *Scientia Horticulturae (Amsterdam)*, 287: 110252.



- Strategy for Harvesting Robots, *Sensors*, 19: 612.
- Yue, Y., Li, J.-H., Fan, L. F., Zhang, L. L., Zhao, P. F., Zhou, Q., Wang, N., Wang, Z. Y., Huang, L., & Dong, X. H. (2020). Prediction of maize growth stages based on deep learning. *Computers and Electronics in Agriculture*, 172: 105351.
- Society of Agricultural Engineering*, 155-62.
- Pineda, M. F., Tinoco, H. A., Lopez-Guzman, J., Perdomo-Hurtado, L., Cardona, C. I., Rincon-Jimenez, A., & Betancur-Herrera, N. (2022). Ripening stage classification of *Coffea arabica* L. var. Castillo using a Machine learning approach with the electromechanical impedance measurements of a contact device. *Materials Today: Proceedings*, 62: 6671-6678.
- Pourreza, Alireza, Won Suk Lee, Reza Ehsani, John K. Schueller, & Eran Raveh. (2015). An optimum method for real-time in-field detection of Huanglongbing disease using a vision sensor, *Computers and Electronics in Agriculture*, 110: 221-32.
- Ren, S., He, K., Girshick, R., & Sun, J. (2015). Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks, *Eprint arXiv:1506.01497*: arXiv: 1506.01497.
- Sa, I., Ge, Z., Dayoub, F., Upcroft, B., Perez, T., & McCool, C. (2016). *DeepFruits: A Fruit Detection System Using Deep Neural Networks*.
- Saedi, S. I., Alimardani, R., Mousazadeh H., & Salehi, R. (2019). Development and evaluation of an energy and water efficient intensive cropping system , *INMATEH - Agricultural Engineering*, 58: 93-104.
- Tan, K., Lee, W. S., Gan, H., & Wang, S. (2018). Recognizing blueberry fruit of different maturity using histogram oriented gradients & colour features in outdoor scenes. *Biosystems Engineering*, 176: 59-72.
- Wang, C., Yunchao, T., Xiangjun, Z., Lufeng L., & Xiong C. (2017). Recognition and Matching of Clustered Mature Litchi Fruits Using Binocular Charge-Coupled Device (CCD) Color Cameras, *Sensors*, 17.
- Williams Henry, A. M., Jones Mark, H., Nejati, M., Seabright Matthew, J., Bell, J., Penhall Nicky, D., Barnett Josh, J., Duke Mike, D., Scarfe Alistair, J., Ahn Ho, S., Lim, J., & MacDonald Bruce, A. (2019). Robotic kiwifruit harvesting using machine vision, convolutional neural networks, and robotic arms, *Biosystems Engineering*, 181: 140-156.
- Wu, J., Baohua, Z., Jun Z., Yingjun, X., Baoxing, G., & Xiaolong, Y. (2019). Automatic Recognition of Ripening Tomatoes by Combining Multi-Feature Fusion with a Bi-Layer Classification

