



### تشخیص آفت حلزون در باغ مرکبات تحت شرایط نورپردازی متفاوت با استفاده از

#### شبکه‌های عصبی عمیق

رمضان هادی پور رکنی<sup>۱</sup>، عزت‌اله عسکری اصلی ارده<sup>۲\*</sup>، سجاد سبزی<sup>۳</sup>، ایمان اسمعیلی پایین افراکتی<sup>۴</sup>

۱- دانشجوی دکتری، گروه مهندسی مکانیک بیوسیستم، دانشگاه محقق اردبیلی، اردبیل، ایران.

۲- دانشیار، گروه مهندسی مکانیک بیوسیستم، دانشگاه محقق اردبیلی، اردبیل، ایران.

۳- پژوهشگر پسادکتری، گروه مهندسی مکانیک بیوسیستم، دانشگاه محقق اردبیلی، اردبیل، ایران.

استادیار، گروه مهندسی برق، دانشگاه مازندران، بابل، ایران.

چکیده	اطلاعات مقاله
<p>دفع آفات و امراض جزء مهمترین عملیات در مرحله داشت مرکبات محسوب می‌شود. امروزه تحقیقات زیادی در زمینه تشخیص آفات و بیماری‌های گیاهی با به‌کارگیری روش‌های ماشین بینایی انجام شده است. یکی از مشکلاتی که باعث کاهش دقت ماشین برای تشخیص آفات در شرایط مزرعه‌ای می‌شود، وجود عوامل نامساعد از قبیل سایه و تغییرات شدت نور در ساعات مختلف روز می‌باشد. در این پژوهش به منظور یافتن شدت نور مناسب در ساعات مختلف روز از نورپردازی به وسیله یک لامپ در محل تصویربرداری استفاده شده است. برای تشخیص درختان آلوده به آفت حلزون از روش یادگیری عمیق با سه نوع الگوریتم بهینه‌ساز نسبتاً قوی یعنی <b>Adam.RMSProp</b> و <b>SGDm</b> استفاده شد. برای بررسی و آزمون الگوریتم‌های مورد استفاده، تعداد ۸۰۰۰ تصویر در ۹ شرایط مزرعه‌ای و یک حالت آزمایشگاهی مورد بررسی قرار گرفت. در شرایط مزرعه‌ای، کمترین مقدار دقت تشخیص الگوریتم‌ها با ۶۴/۳۲ درصد مربوط به تصویربرداری در روز ابری با شدت نور ۳۵۰ الی ۷۰۰ لوکس و با استفاده از الگوریتم <b>RMSProp</b> حاصل شد، ولی با ایجاد شدت نور کنترل شده به وسیله لامپ (تقریباً ۹۰۰۰ لوکس)، دقت تشخیص با استفاده از الگوریتم <b>SGDm</b> تا ۹۵/۲۵ درصد بهبود یافت. در شرایط آزمایشگاهی که تصاویر در محیطی کنترل شده با شدت نور ثابت تهیه شده بود، استفاده از الگوریتم <b>SGDm</b>، دقت تشخیص را تا مقدار ۹۸/۷۳ درصد ارتقاء داد.</p>	<p>تاریخ های مقاله :</p> <p>تاریخ دریافت: ۹۹ / ۰۹ / ۲۵</p> <p>تاریخ پذیرش: ۱۴۰۰ / ۰۱ / ۲۵</p> <p>کلمات کلیدی:</p> <p>مرکبات، آفت حلزون، تشخیص هوشمند، پردازش تصویر، یادگیری عمیق.</p> <p>DOI: 10.29252/fsct.18.06.12</p> <p>* مسئول مکاتبات: ezzataaskari@uma.ac.ir</p>

## ۱- مقدمه

مرکبات حاوی منابع غنی از ویتامین‌ها (به‌ویژه ویتامین C)، کربوهیدرات‌ها، فیبرها و دارای طعم مطبوع هستند، به‌طوری که این مزایا سبب شده تا این محصول باغی مورد توجه اکثر مردم دنیا قرار گیرد. تولید مرکبات در دنیا حدود ۱۲۴ میلیون تن است در حالی که کشور ایران با تولید حدود ۴ میلیون تن در مقام هفتم دنیا قرار دارد [۱]. امروزه کنترل آفات و بیماری‌های گیاهی یک چالش بزرگ برای اطمینان از امنیت جهانی غذا و کشاورزی پایدار است [۲]. بنابراین کنترل آفات و بیماری‌ها، یکی از مهمترین عملیات حفاظت از باغ مرکبات محسوب می‌شود که تعلل و تاخیر در انجام آن سبب کاهش عملکرد محصول و از بین رفتن زحمات باغدار می‌شود. از آنجایی که اقدامات باغداران برای کنترل آفات و بیماری‌ها کافی نیست، بنابراین نظارت دقیق برای تشخیص درست و زود هنگام آفات و بیماری‌ها، ضروری به نظر می‌رسد [۳ و ۴]. اگر درخت آلوده به آفات با دقت بالا شناسایی گردد و مبارزه مناسب شیمیایی (شیوه مرسوم) موضعی انجام شود، علاوه بر کاهش مصرف سموم و بهبود شرایط محیط زیست، برای باغداران صرفه اقتصادی خواهد داشت [۵].

حلزون‌ها یکی از آفات مهم کشاورزی در سرتاسر جهان به ویژه در مناطق مرطوب به‌شمار می‌آیند [۶]. در استان مازندران به علت شرایط مناسب اقلیمی (آب و هوای معتدل و رطوبت نسبی بالا) فعالیت حلزون بسیار زیاد است و از آفات اصلی مرکبات به شمار می‌آید. این آفت در باغات مرکبات با تغذیه از برگ و میوه درختان، موجب کاهش رشد درختان و کیفیت محصول می‌شود [۷]. برای تشخیص این آفات و جلوگیری از شیوع آنها، استفاده از تکنیک‌های یادگیری ماشین می‌تواند بسیار کارآمد و مناسب باشد. یادگیری عمیق یک روش جدید در حوزه یادگیری ماشین است. مهمترین مزیت استفاده از این روش، استخراج ویژگی خودکار است که در طی آن، مرحله پیش‌پردازش به حداقل می‌رسد و یا حتی در بعضی موارد حذف می‌شود. بنابراین نیازی به انجام یک پیش‌مطالعه به‌منظور یافتن ویژگی‌های موجود در تصویر نیست [۵]. امروزه روش یادگیری عمیق به صورت گسترده در بینایی ماشین مانند تشخیص اشیاء [۸-۱۱]، تشخیص چهره [۱۲ و ۱۳]، دسته‌بندی تصاویر [۹، ۱۴ و ۱۵] مورد استفاده قرار گرفته است. یکی از مهمترین

روش‌های یادگیری عمیق، شبکه عصبی کانولوشن (CNN<sup>۱</sup>) است این شبکه‌ها نوعی از شبکه عصبی چند لایه بوده که برای داده‌های دو بُعدی از قبیل تصویر و ویدئو طراحی شده است. بخش‌های مختلف تصویر به عنوان ورودی به لایه‌های شبکه عصبی که به صورت سلسله مراتبی می‌باشد، اعمال می‌شود و در هر لایه با اعمال فیلترهای دیجیتال، ویژگی‌های مناسبی از تصویر استخراج شده و به یک لایه طبقه‌بند ارسال می‌شود. در این قسمت، ویژگی‌ها با هم ترکیب شده و پیش‌بینی مناسب انجام می‌شود [۴ و ۱۶]. تحقیقات زیادی در زمینه مختلف کشاورزی از جمله تشخیص آفات و بیماری‌های گیاهی [۱۷، ۱۸، ۱۹، ۲۰ و ۲۱]، جداسازی محصولات کشاورزی [۲۲]، شناسایی درختان [۲۳] و شناسایی علف‌های هرز [۲۴] با به‌کارگیری الگوریتم‌های هوشمند انجام شده است.

در مطالعات اخیر، الگوریتم‌های بهینه‌ساز<sup>۲</sup> مختلفی برای دستیابی به نتایج بهتر در روش یادگیری عمیق استفاده شده است. در تحقیقی برای تشخیص و طبقه‌بندی تصاویر چند نوع میوه به روش یادگیری عمیق، از الگوریتم‌های بهینه‌ساز SGDm<sup>۳</sup>، Adam<sup>۴</sup> و RMSProp<sup>۵</sup> استفاده شد دقت تشخیص الگوریتم‌های مذکور به ترتیب ۹۸/۸۳، ۹۸/۰۸ و ۹۹/۰۲ درصد گزارش شد [۲۵]. الروویلی و همکاران (۲۰۱۹) برای تشخیص بیماری‌های زیتون با استفاده از روش یادگیری عمیق و به کمک الگوریتم بهینه‌ساز SGDm موفق به دقت تشخیص بیماری ۹۹/۱۱ درصد شدند [۲۶]. همچنین استفاده از الگوریتم‌های بهینه‌ساز مختلف در تشخیص بیماری‌های مرکبات [۲۷ و ۲۸]، تشخیص آفات سویا [۲۹] و تشخیص بیماری‌های انگور [۳۰] گزارش شده است.

از جمله مشکلات بینایی ماشین در شرایط طبیعی (مزرعه‌ای) وجود عوامل نامساعد از قبیل سایه و تغییرات شدت نور در ساعات مختلف روز است. در تحقیقی برای بررسی تاثیر شدت نور بر میزان دقت تشخیص، ۳۸۰۰ تصویر در سه شرایط طبیعی مربوط به زمان صبح، ظهر و عصر مورد استفاده قرار گرفت. دقت

1. convolutional neural networks  
2. optimization algorithms  
3. Stochastic Gradient Descent with Momentum  
4. Root Mean Square Propagation  
5. Adaptive Moment Estimation


مازندران که درختان آن دچار آفت حلزون بودند، تهیه شد. برای ارزیابی میزان تاثیر عوامل محیطی بر دقت تشخیص، تعداد ۸۰۰۰ تصویر (در ۱۰ مرحله) با رزولوشن  $4128 \times 2322$  پیکسل در دو شرایط مزرعه‌ای و آزمایشگاهی مورد بررسی قرار گرفت (جدول ۱).

**Table 1** Different imaging conditions

Row	Imaging conditions	Ambient light intensity	Number Of images
1	Laboratory (by boxes equipped with camera and LED lamps)	Uniform light intensity (1300 LUX)	800
2	Farm (in the citrus orchard)	Natural light on a sunny day	800
		Natural light on a cloudy day	800
		Natural light at sunset	800
		Artificial light with different lights intensity in six status	4800

#### ۲-۱-۱-۲ شرایط آزمایشگاهی

در شرایط آزمایشگاهی از سامانه تصویربرداری شرکت ابزارکاران فن‌پویای شمال که شامل جعبه‌ای به ابعاد  $50 \times 40 \times 40$  سانتی‌متر، دو عدد لامپ LED 10W با نور سفید و دوربین LifeCam Studio شرکت میکروسافت با کیفیت ۸ مگاپیکسل بود، استفاده شد. فاصله بین دوربین و نمونه ۳۰ سانتی‌متر تنظیم شد، سپس تصاویر از طریق کابل USB و نرم‌افزار LifeCam به رایانه انتقال یافت. (شکل ۱).



**Fig 1** Laboratory imaging device; (1) Box isolated from ambient light (2) Camera (3) Lamp (4) Leaf (5) Monitor (6) Computer system

الگوریتم طبقه‌بند در روزهای آفتابی و ابری به ترتیب  $84/58$  و  $68/11$  درصد گزارش شد [۳۱]. در پژوهش هرناندز و همکاران (۲۰۱۶)، تصاویر در چهار حالت مختلف تحت نور مستقیم خورشید، ابری و دو حالت با نور سفید متعادل شده به وسیله دوربین دیجیتال گرفته شد. نتایج نشان داد که روش پیشنهادی در شرایط تعیین شده کارایی خوبی دارد [۳۲]. در تحقیقی برای درجه‌بندی میوه از یک نوار نقاله، محفظه تصویربرداری با نورپردازی لامپ و دوربین استفاده شد. نتایج نشان داد که وجود سایه در بعضی از قسمت‌های میوه ممکن است دقت تشخیص الگوریتم را تا ۲۰ درصد کاهش دهد [۳۳]. در تحقیق دیگر برای طبقه‌بندی کیفیت روغن نخل با در نظر گرفتن میزان رسیدگی، از سیستم روشنایی ترکیبی لامپ فلورسنت و نور لیزر در محیط آزمایشگاهی استفاده شد. به کمک این روش دقت تشخیص تا ۸۵ درصد بهبود یافت [۳۴]. برای تشخیص گل‌های آفت‌دار در یک مزرعه پرورش گل از سیستم ماشین بینایی مجهز به یک پلتفرم، دوربین و لامپهای فلورسنت استفاده شد، دقت تشخیص ۹۰ درصد به دست آمد [۳۵]. برای ارزیابی میزان مواد مغذی محصولات زراعی در محیط گلخانه، یک دوربین فراتطیفی<sup>۱</sup> و سیستم روشنایی با لامپهای هالوژن ۹۰، ۱۲۰ و ۲۵۰ وات برای تصویربرداری مورد استفاده قرار گرفت. برای حذف سایه‌ها و جلوگیری از پراکندگی طیفی، تصویربرداری در شب انجام شد. دقت تشخیص ۸۰ درصد به دست آمد [۳۶]. در تحقیق دیگر، نتایج دقت تشخیص بیماری بوته برنج در دو شرایط مزرعه‌ای و آزمایشگاهی به ترتیب ۹۴ و ۹۸ درصد گزارش شد [۳۷].

هدف از این تحقیق، تشخیص دقیق آفت حلزون در درون باغ مرکبات با استفاده از روش یادگیری عمیق تحت شرایط نورپردازی متفاوت و تعیین شدت نور بهینه است.

## ۲- مواد و روش‌ها

### ۲-۱- نمونه برداری (ایجاد دیتابیس)

در این پژوهش، تصاویر از باغ مرکبات (پرتهال و نارنگی) به مساحت ۳۰۰۰ متر مربع واقع در شهرستان قائمشهر- استان

1. hyperspectral

۲-۱-۲- شرایط مزرعه‌ای

برای تهیه تصاویر در شرایط مزرعه‌ای از دوربین دیجیتالی مدل EOS-550D با کیفیت ۱۲ مگاپیکسل از شرکت کانون- ژاپن استفاده شد. تصاویر با فاصله حدود ۳۰ سانتی‌متر از درخت ثبت شد (شکل ۲). با توجه به اینکه شدت نور طبیعی در روزها، ساعات مختلف و در زیر سایه‌ی درختان متفاوت بود و معمولاً حلزون‌ها در قسمت سایه‌ی درختان (تنه و میان شاخ‌برگها) قرار داشتند، از طرفی دیگر، تغییرات شدت نور باعث کاهش دقت تشخیص می‌شد [۳۱ و ۳۲]، از این‌رو برای ارزیابی صحیح و

تعیین شدت نور مناسب محیط از دستگاه لوکس‌متر مدل TEM-8820 شرکت لوترون برای اندازه‌گیری و ثبت شدت نور محیط استفاده شد (شکل ۳). در این شرایط، تصویربرداری در ۳ حالت طبیعی و ۶ حالت با نورپردازی لامپ LED 200w انجام شد. حالت‌های نورپردازی مختلف به منظور افزایش روشنایی در قسمت سایه‌ی درختان و با هدف دستیابی به شدت نور بهینه در زمان تصویربرداری مورد استفاده قرار گرفت. برای تعیین رنگ مناسب نورپردازی، از لامپهایی با نور سفید و زرد در تصویربرداری استفاده شد (شکل ۴).



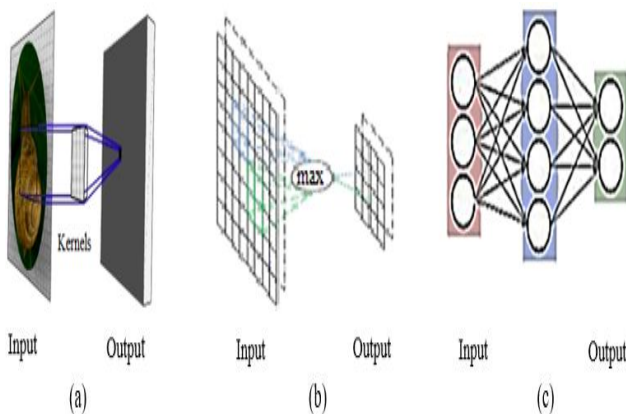
Fig 2 Examples of images in citrus orchard (Ghaemshahr- 2020)




Fig 3 Measurement of light intensity with a lux meter device (Ghaemshahr- 2020)



Fig 4 (a) Imaging with Natural light and (b) Imaging with using lamp light (Ghaemshahr- 2020)



**Fig 5** Performance (a) convolution layer, (b) pooling layer and (c) fully connected layer



**Fig 6** Proposed model based on CNN

### ۲-۳- الگوریتم‌های بهینه‌ساز<sup>۵</sup>

شبکه‌های عمیق شامل پارامترهای زیادی هستند که بر عملکرد مدل‌های CNN تاثیر می‌گذارند [۵]، بنابراین استفاده از الگوریتم‌های بهینه‌ساز مناسب برای پیدا کردن سطح بهینه در فرآیند یادگیری ضروری به نظر می‌رسد. در برنامه‌های یادگیری عمیق، الگوریتم‌های بهینه‌ساز SGD، RMSProp و Adam کاربرد زیادی دارند [۳۸]. در این تحقیق برای دستیابی به نتیجه مطلوب از الگوریتم‌های بهینه‌ساز مختلف SGD، RMSProp و Adam در فرآیند یادگیری شبکه استفاده شد. که به شرح آنها می‌پردازیم:

SGD: یکی از الگوریتم‌های بهینه‌ساز پرکاربرد برای

شبکه‌های عصبی عمیق می‌باشد که از نسبت یادگیری عددی

### ۲-۲- یادگیری عمیق

در این تحقیق برای مقایسه صحیح بین حالت‌های مختلف تصویربرداری از پیش‌پردازش تصاویر استفاده نشده است. با توجه به اینکه تعداد تصاویر زیادی در شبکه CNN مورد پردازش قرار می‌گیرد، کاهش اندازه تصاویر می‌تواند سبب افزایش سرعت محاسبات شود [۲۶]. بنابراین برای افزایش سرعت محاسبات شبکه، اندازه تصاویر از  $4128 \times 2322$  به ابعاد  $100 \times 100$  کاهش داده شد. برای طراحی معماری شبکه CNN، لایه‌های مختلف مورد بررسی قرار گرفت تا مناسب‌ترین معماری با پنج لایه انتخاب شد. اولین لایه، لایه کانولوشن<sup>۱</sup> می‌باشد که هسته اولیه برای ساخت شبکه CNN است و وظیفه اصلی آن استخراج ویژگی‌ها از تصاویر می‌باشد. این لایه شامل فیلترهای کانولوشنال دو بعدی لغزنده است که به صورت عمودی و افقی روی تصویر می‌لغزد تا وزن و بایاس شبکه تولید شود (شکل a-۵). اندازه فیلترها می‌تواند  $3 \times 3$ ،  $5 \times 5$ ،  $7 \times 7$ ،  $9 \times 9$  و یا  $11 \times 11$  باشد [۵]. در این پژوهش، با استفاده از روش سعی و خطا، اندازه مناسب فیلتر با ابعاد  $5 \times 5$  انتخاب و تعداد ۲۰ فیلتر در نظر گرفته شده است. لایه دوم لایه واحد خطی اصلاح شده<sup>۲</sup> بود به طوری که روی هر کمیت ورودی شبکه یک آستانه گیری انجام می‌داد تا سرعت یادگیری را افزایش دهد. لایه سوم لایه ادغام<sup>۳</sup> بود که با انجام عملیات ماکزیمم‌گیری در ماتریسها به منظور کاهش پارامترها و در نتیجه افزایش سرعت محاسباتی استفاده شده است. در این لایه هر نرون به خروجی تعداد محدودی از نرون‌ها در لایه قبل متصل است (شکل b-۵). لایه چهارم لایه کاملاً متصل<sup>۴</sup> می‌باشد. وظیفه این لایه ضرب و اضافه کردن وزن و بایاس به ورودی می‌باشد. در این لایه از دو خروجی شبکه (آفت یا سالم) که بیانگر تصاویر حلزون‌دار و تصاویر بدون حلزون می‌باشد، استفاده شد (شکل c-۵). لایه پنجم Softmax layer می‌باشد که با بهره‌گیری از احتمالات برای رفع پیچیدگی مربوط به طبقه‌بندی تصاویر استفاده شده است. در شکل ۶، مدل کار بر پایه شبکه CNN ارائه شده است.

1. Convolutional layer
2. Relu layer
3. pooling layer
4. Fully connected layer

5. optimization algorithms

که در آن:

TN، تعداد تصاویر سالمی که سیستم آنها را درست تشخیص داده است. TP، تعداد تصاویر آفت که سیستم آنها را درست تشخیص داده است. FN، تعداد تصاویر سالمی که سیستم آنها را آفت تشخیص داده است. FP، تعداد تصاویر آفت که سیستم آنها را سالم تشخیص داده است. در شکل (۷) مراحل کار این پژوهش برای تشخیص آفت نشان داده است.




Fig 7 Framework used for snail pest Detection

### ۳- نتایج و بحث

در این بخش به ارائه تجزیه و تحلیل مقایسه‌ای بین حالت‌های مختلف تصویربرداری تحت شرایط نور محیطی متفاوت با الگوریتم‌های بهینه‌ساز SGDm، RMSProp و Adam پرداخته شده است به طوری که نتایج بدست آمده از آن منجر به انتخاب شدت نور بهینه و بهترین الگوریتم شده است. در این پژوهش از ۸۰۰۰ تصویر (۱۰ حالت) در دو شرایط آزمایشگاهی و مزرعه‌ای استفاده شد. مدل پیشنهادی با دراختیار داشتن تصاویر در سه حالت نور طبیعی (حالت‌های ۱ تا ۳)، پنج حالت با نورپردازی بوسیله لامپ سفید (حالت‌های ۴ تا ۸)، یک حالت با نورپردازی بوسیله لامپ زرد (حالت ۹) و یک حالت آزمایشگاهی (حالت ۱۰) مورد ارزیابی قرار گرفت (جدول ۲).

یکسان برای پارامترهایی که در پیشرفت آموزش موثر هستند، استفاده می‌کند و عملکرد خوبی در برنامه‌های آزمایشی ارائه می‌دهد [۵] و [۳۹].

RMSProp: این الگوریتم مبتنی بر یادگیری تطبیقی است که برای هر بُعد پارامتر، سرعت یادگیری جداگانه‌ای را در نظر می‌گیرد [۴۰]. به عبارت دیگر، سرعت یادگیری را بر میانگین نمایی میراشونده‌ی مربعات گرادینت‌ها تقسیم می‌کند [۴۱].

Adam: این الگوریتم با استفاده از محاسبه گشتاور اول و دوم شیب‌ها برای هر یک از پارامترها در یادگیری استفاده می‌کند. به عبارت دیگر این الگوریتم از ترکیب خواص اکتشافی الگوریتم‌های SGDm و RMSProp استفاده می‌کند [۳۸] و [۴۲].

### ۲-۴- آموزش و آزمون شبکه

رایج‌ترین نسبت تقسیم مجموعه داده‌ها در برنامه‌های شبکه عصبی برای آموزش<sup>۱</sup>، اعتبارسنجی<sup>۲</sup> و آزمون<sup>۳</sup> به ترتیب ۷۰، ۲۰ و ۱۰ درصد است [۲۹] و [۴۳]. بنابراین در هر مرحله ۷۰ درصد از تصاویر برای آموزش شبکه و ۲۰ درصد تصاویر برای اعتبارسنجی و ۱۰ درصد تصاویر برای آزمون در نظر گرفته شد.

### ۲-۵- معیارهای ارزیابی

معیارهای آماری استاندارد مانند دقت تشخیص<sup>۴</sup>، صحت<sup>۵</sup>، فراخوانی<sup>۶</sup> و F1 score (میانگین هارمونیک از دقت و یادآوری) برای ارزیابی میزان تشخیص و طبقه‌بندی الگوریتم‌ها استفاده می‌شود [۲۶]، ۳۰، ۴۰ و [۴۴]. بنابراین مقادیر آن با استفاده از روابط (۱) تا (۴) محاسبه شد.

$$\text{Accuracy} = \frac{\text{TN} + \text{TP}}{\text{TN} + \text{FN} + \text{TP} + \text{FP}} \quad (1)$$

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (2)$$

$$\text{Recall} = \frac{\text{TP}}{\text{FN} + \text{TP}} \quad (3)$$

$$\text{F1 score} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (4)$$

1. Training
2. Validation
3. Testing
4. Accuracy
5. Precision
6. Recall

**Table 2** Different shooting modes under different ambient light conditions

state	Imaging conditions	Average intensity of natural light in the shade of trees (LUX)	Light intensity created using light lamp ( LUX )
1	sunny day	4000	-
2	Cloudy day	1000	-
3	Sunset	530	-
4	Sunny day with <u>white</u> lamp lighting	3500	12000- 13000
5		3000	15000- 16000
6		3175	11000- 12000
7		3500	8500- 9500
8		2700	7000- 8000
9	Sunny day with <u>yellow</u> lamp lighting	3300	8500- 9500
10	Inside the box isolated from disturbing lights with light intensity	-	1300

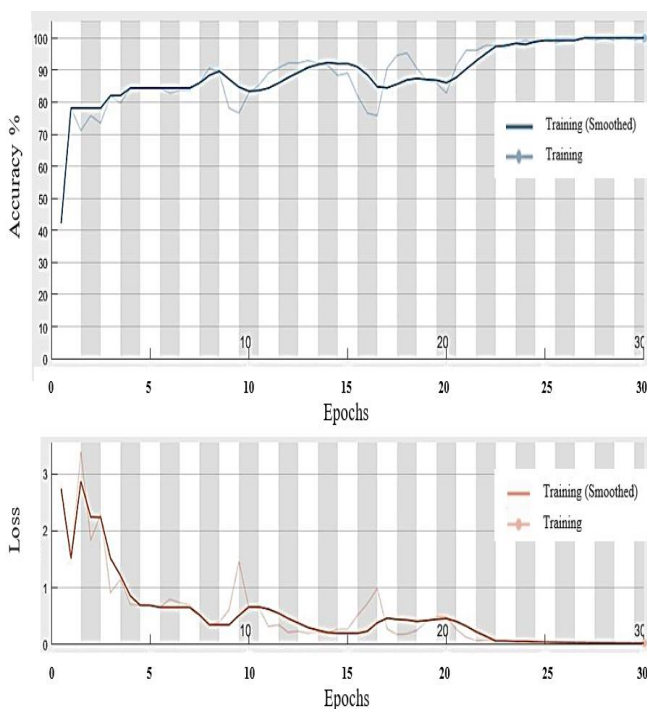
**Table 3** Results of accuracy of algorithm detection by imaging in different conditions of ambient light intensity

state	optimization algorithms	Accuracy	Precision	Recall	F1 score
1	SGDm	0.9250	0.9259	0.9250	0.9254
	Adam	0.9200	0.9207	0.9200	0.9235
	RMSProp	0.9200	0.9213	0.9196	0.9204
2	SGDm	0.8850	0.8852	0.8850	0.8851
	Adam	0.8875	0.8879	0.8876	0.8877
	RMSProp	0.7275	0.7278	0.7267	0.7273
3	SGDm	0.7320	0.7328	0.7320	0.7324
	Adam	0.7340	0.7342	0.7340	0.7341
	RMSProp	<b>0.6432</b>	<b>0.6439</b>	<b>0.6432</b>	<b>0.6435</b>
4	SGDm	0.9275	0.9276	0.9275	0.9275
	Adam	0.9325	0.9329	0.9326	0.9327
	RMSProp	0.8525	0.8526	0.8525	0.8525
5	SGDm	0.8829	0.8839	0.8827	0.8833
	Adam	0.9057	0.9064	0.9057	0.9060
	RMSProp	0.8000	0.8012	0.7995	0.8003
6	SGDm	0.9400	0.9411	0.9398	0.9404
	Adam	0.9340	0.9348	0.9336	0.9342
	RMSProp	0.9280	0.9283	0.9277	0.9280
7	<b>SGDm</b>	<b>0.9525</b>	<b>0.9533</b>	<b>0.9525</b>	<b>0.9529</b>
	Adam	0.9425	0.9428	0.9425	0.9426
	RMSProp	0.9500	0.9502	0.9500	0.9501
8	SGDm	0.9350	0.9360	0.9350	0.9355
	Adam	0.9250	0.9258	0.9250	0.9254
	RMSProp	0.9250	0.9260	0.9250	0.9255
9	SGDm	0.9420	0.9433	0.9420	0.9341
	Adam	0.9400	0.9408	0.9400	0.9404
	RMSProp	0.9340	0.9355	0.9336	0.9354
10	<b>SGDm</b>	<b>0.9873</b>	<b>0.9885</b>	<b>0.9873</b>	<b>0.9879</b>
	Adam	0.9773	0.9782	0.9773	0.9777
	RMSProp	0.9793	0.9800	0.9793	0.9796

به ۶۴/۳۲ درصد کاهش یافته است. دلیل این امر، کاهش وضوح تصاویر بواسطه کاهش شدت نور محیطی است. به طور مشابه، گزارش‌های میاو و همکاران [۳۱] و لیو و همکاران [۳۳] نشان داد که دقت تشخیص الگوریتم ممکن است به دلیل کاهش شدت نور

نتایج معیارهای ارزیابی الگوریتم‌ها در حالت‌های مختلف قرائت شده است (جدول ۳). نتایج ارزیابی در سه شرایط طبیعی (حالت‌های ۱، ۲ و ۳) نشان داد که با کاهش شدت نور محیطی از حالت ۱ تا حالت ۳، مقدار دقت تشخیص الگوریتم‌ها از ۹۲/۵۰

الگوریتم دیگر بهتر است، هر چند که الگوریتم Adam در تعدادی از حالت‌ها، کارایی بهتری نسبت به دیگر الگوریتم‌ها دارد، همچنین الگوریتم RMSProp به ترتیب با مقادیر ۶۴/۳۲، ۶۴/۳۹، ۶۴/۳۲ و ۶۴/۳۵ درصد دارای کمترین کارایی بوده است. در شکل‌های زیر، نمودارهای دقت تشخیص<sup>۱</sup> و کاهش تابع زیان<sup>۲</sup> در فرآیند آموزش شبکه CNN ارائه شده است. نمودار دقت تشخیص و زیان مربوط حالت ۳ (غروب) در شکل ۸ نشان می‌دهد که کاهش وضوح تصاویر سبب شد تا تعداد تکرارهای آموزش برای دستیابی به دقت پیش‌بینی مطلوب در دوره‌های ۱<sup>۳</sup> تا ۲۲ دارای میزان خطای بالایی باشد که با ادامه فرآیند آموزش به حداقل میزان خطا رسیده است، درحالی که با افزایش وضوح تصاویر (حالت‌های ۷ و ۱۰) تعداد تکرارهای آموزش برای رسیدن به دقت پیش‌بینی مطلوب پس از سپری نمودن ۹ دوره به حداقل میزان خطا (نزدیک به صفر) رسیده است (شکل‌های ۹ و ۱۰).



**Fig 8** The progress of validation accuracy and loss function through the training phase with algorithm RMSProp (state 3)


1. Accuracy
2. Loss
3. Epochs

محیطی تا حدود ۲۰ درصد کاهش یابد. اما هاشیم و همکاران [۳۴] و نگوین و همکاران [۳۶] با استفاده از روش نورپردازی بوسیله لامپهای مختلف در محیط آزمایشگاهی و محیط گلخانه به دقت تشخیص مطلوب دست یافتند. بنابراین به منظور افزایش دقت الگوریتم‌ها از روش نورپردازی در زمان تصویربرداری (حالت‌های ۴ تا ۹) استفاده شد. در ابتدا فاصله لامپ با مکان آفت به نحوی تنظیم شد تا شدت نور محیطی در محدوده ۱۳۰۰۰-۱۲۰۰۰ لوکس ایجاد شود (حالت ۴). میزان دقت تشخیص الگوریتم‌ها در این حالت نسبت به حالت‌های قبل کمی افزایش یافت. برای تعیین محدوده نورپردازی بهینه، شدت نور محیطی در محدوده ۱۶۰۰۰-۱۵۰۰۰ لوکس افزایش داده شد (حالت ۵). نتایج نشان داد که با افزایش شدت نور محیطی، دقت تشخیص الگوریتم‌ها کاهش یافت. دلیل این امر بازتابش زیاد نور از سطوح آفت به سوی دوربین و در نتیجه کاهش وضوح تصاویر است که با نتایج کاهش دقت تشخیص بیماری‌های بوته برنج در شرایط مزرعه‌ای مطابقت دارد [۳۷]. در ادامه آزمایش‌ها، شدت نور لامپ با تنظیم فاصله در سطوح پایین‌تر کاهش داده شد. با کاهش شدت نور محیطی تا محدوده ۹۵۰۰-۸۵۰۰ لوکس، دقت تشخیص الگوریتم‌ها تا ۹۵/۲۵ درصد افزایش یافت. سپس با کاهش بیشتر شدت نور، سیر نزولی پیدا کرد. با توجه به نتایج به دست آمده و نتایج تحقیق بوسال و همکاران [۴۵] و عبدالمهی و همکاران [۴۶] می‌توان دریافت که کاهش و یا افزایش بیش از حد شدت نور محیطی باعث کاهش کیفیت و وضوح تصاویر و در نتیجه کاهش دقت الگوریتم‌ها می‌شود. حتی رنگ نورپردازی می‌تواند بر دقت تشخیص الگوریتم‌ها تاثیر بگذارد (حالت ۹). در حالت ۱۰ که تصاویر در محیطی کنترل شده با شدت نور نسبتاً کم (۱۳۰۰ لوکس) تهیه شده بود، دقت تشخیص تا ۹۸/۷۳ درصد ارتقا یافت. بنابراین نتیجه‌گیری می‌شود که حذف عوامل محیطی نظیر سایه و نورهای مزاحم می‌تواند سبب افزایش دقت تشخیص الگوریتم‌ها شود.

نتایج حاصل از معیارهای دقت، صحت، فراخوانی و معیار F1 score در حالت‌های مختلف نشان داد که کارایی الگوریتم SGDm در شرایط مزرعه‌ای به ترتیب با مقادیر ۹۵/۲۵، ۹۵/۳۳، ۹۵/۲۵ و ۹۸/۷۸ درصد و در شرایط آزمایشگاهی با مقادیر ۹۸/۷۳، ۹۸/۸۵، ۹۸/۷۳ و ۹۵/۲۹ درصد نسبت به دو



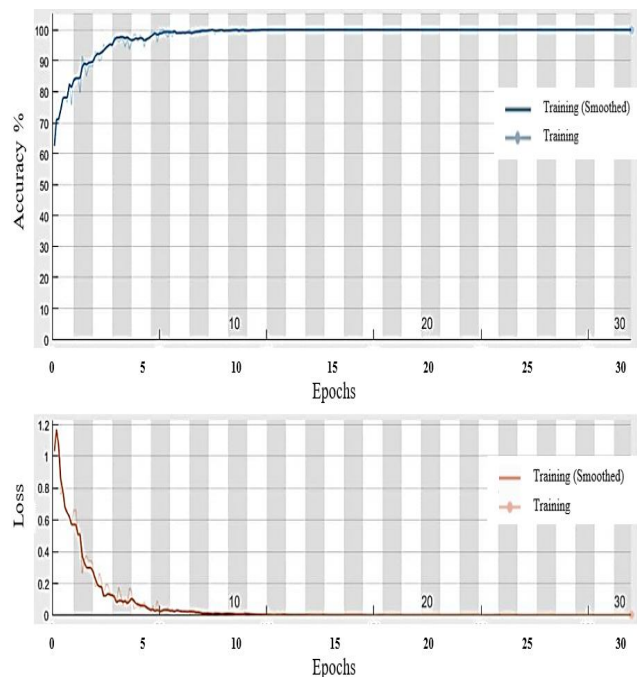
نمودار معیار دقت تشخیص الگوریتم‌ها با حالت‌های مختلف در شکل ۱۱ نشان داده شده است.



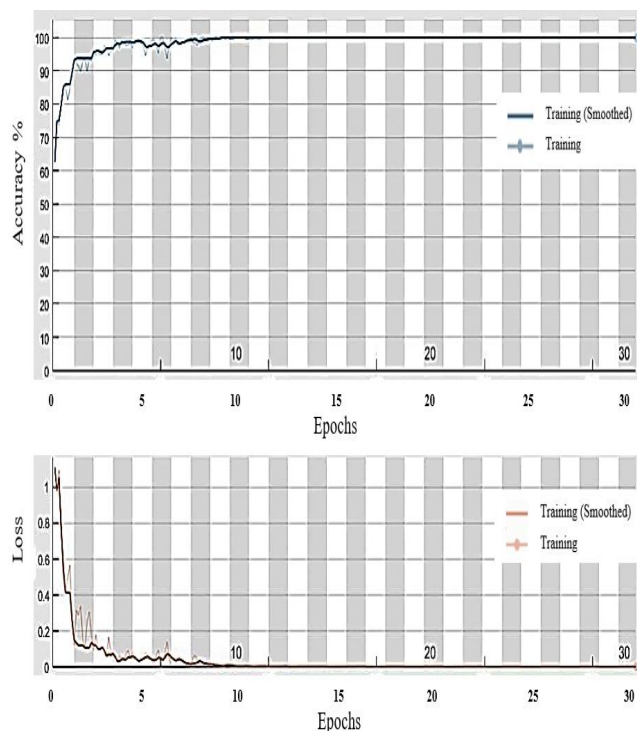
**Fig 11** Comparison between detection accuracy of algorithms in different imaging conditions in field conditions and laboratory conditions

نتایج نشان می‌دهد که میزان دقت تشخیص الگوریتم RMSProp به‌ازای کاهش شدت نور محیط، اختلاف زیادی با دو الگوریتم دیگر دارد، ولی با افزایش شدت نور در حالت‌های ۶ تا ۱۰، این اختلاف به حداقل رسیده است. بنابراین استفاده از الگوریتم RMSProp در شرایط نور محیطی کم توصیه نمی‌شود. نتایج دقت تشخیص در شرایط آزمایشگاهی (حالت ۱۰) نشان داد که حذف عوامل محیطی از قبیل سایه و نورهای مزاحم می‌تواند کارایی شبکه را بهبود بخشد. با وجود اینکه کیفیت دوربین در این شرایط نسبتاً پایین و شدت نور داخل جعبه (۱۳۰۰ لوکس) نسبت به حالت‌های مزرعه‌ای کمتر بود، دقت تشخیص مطلوبی به‌دست آمد. بطور مشابه، نتایج دقت تشخیص بیماری بوته برنج در شرایط آزمایشگاهی ۴ درصد بیشتر از شرایط مزرعه‌ای گزارش شد [۳۷].

بیشترین دقت تشخیص با مدل پیشنهادی در شرایط مزرعه‌ای (حالت ۷) ۹۵/۲۵ درصد به‌دست آمد، هر چند که زینگ و همکاران (۲۰۲۰) با استفاده از مدل‌های از پیش آموزش دیده CNN برای تشخیص آفات مرکبات از جمله حلزون به دقت تشخیص ۹۵/۴۷ درصد دست یافتند [۲۱]، اما این نتیجه در مقایسه با نتیجه تحقیق حاضر اختلاف ناچیزی دارد. همچنین بیشترین میزان دقت تشخیص در شرایط آزمایشگاهی ۹۸/۷۳ درصد به‌دست آمد که در مقایسه با نتایج مشابه در گزارش‌های



**Fig 9** The progress of validation accuracy and loss function through the training phase with algorithm SGDm (state 7)



**Fig 10** The progress of validation accuracy and loss function through the training phase with algorithm SGDm (state 10)

## ۵- منابع

- [1] Officer, P. (2016). Food and agriculture organization of the United Nations. *FAO, Italy*.
- [2] Lee, S. H., Goëau, H., Bonnet, P., & Joly, A. (2020). New perspectives on plant disease characterization based on deep learning. *Computers and Electronics in Agriculture*, 170, 105220
- [3] Lee, H. Y., Kim, D. H., & Park, K. R. (2019). Pest diagnosis system based on deep learning using collective intelligence. *The International Journal of Electrical Engineering & Education*, 0020720919833052.1-15.
- [4] Arel, I., Rose, D. C., & Karnowski, T. P. (2010). Deep machine learning-a new frontier in artificial intelligence research [research frontier]. *IEEE computational intelligence magazine*, 5(4), 13-18.
- [5] Turkoglu, M., Hanbay, D., & Sengur, A. (2019). Multi-model LSTM-based convolutional neural networks for detection of apple diseases and pests. *Journal of Ambient Intelligence and Humanized Computing*, 1-11.
- [6] Sepasi, M., Damavandian, M. R., & Amiri Besheli, B. (2019). Mineral oil barrier is an effective alternative for suppression of damage by white snails. *Acta Agriculturae Scandinavica, Section B—Soil & Plant Science*, 69(2), 114-120.
- [7] Kheirodin, A., Damav, M. R., & Sarailoo, M. H. (2012). Mineral oil as a repellent in comparison with other control methods for citrus brown snail, *Caucasotachea leucoranea*. *African Journal of Agricultural Research*, 7(42), 5701-5707.
- [8] Abu-Saqer, M. M., Abu-Naser, S. S., & Al-Shawwa, M. O. (2020). Type of Grapefruit Classification Using Deep Learning.
- [9] Zheng, Y. Y., Kong, J. L., Jin, X. B., Wang, X. Y., Su, T. L., & Zuo, M. (2019). CropDeep: The crop vision dataset for deep-learning-based classification and detection in precision agriculture. *Sensors*, 19(5), 1058.
- [10] Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 779-788).

نگوین و همکاران [۳۶]، علی و همکاران [۳۴]، پولدر و همکاران [۳۵] و عسکری اصلی ارده و همکاران [۳۷] که به ترتیب به دقت تشخیص ۸۰، ۸۵، ۹۰ و ۹۸ درصد دست یافتند، نتیجه مطلوبی است. بنابراین نتیجه‌گیری می‌شود که استفاده از نورپردازی مناسب به منظور افزایش روشنایی درقسمتهای سایه‌ی درختان و ایجاد نور محیطی کنترل شده در زمان تصویربرداری می‌تواند سبب افزایش دقت تشخیص الگوریتم‌ها شود.

## ۴- نتیجه گیری

در این پژوهش برای تشخیص دقیق آفت حلزون از یک مدل پیشنهادی CNN با الگوریتم‌های بهینه‌ساز RMSProp، Adam و SGDm استفاده شد. تعداد ۸۰۰۰ تصویر در ۹ حالت مزرعه‌ای و یک حالت آزمایشگاهی بکار گرفته شد. در شرایط مزرعه‌ای، تصویربرداری در ۳ حالت طبیعی و ۶ حالت با نورپردازی لامپ انجام شد. نتایج به دست آمده در ۳ حالت طبیعی نشان داد که با کاهش شدت نور محیط، دقت تشخیص الگوریتم‌ها کاهش می‌یابد. به منظور یافتن میزان شدت نور بهینه، تصویربرداری در ۶ حالت مزرعه‌ای با استفاده از نورپردازی لامپهای سفید و زرد انجام شد. نتایج نشان داد که با افزایش شدت نور محیط تا محدوده ۹۰۰۰ لوکس، میزان دقت تشخیص الگوریتم‌ها روند صعودی داشته و در محدوده بیشتر از آن کاهش یافته است. همچنین تصویربرداری با نورپردازی لامپ زرد در شرایط شدت نور یکسان با لامپ سفید، باعث کاهش دقت تشخیص الگوریتم‌ها گردید. مناسب‌ترین محدوده شدت نور محیط با نورپردازی لامپ سفید، حدود ۹۰۰۰ لوکس بود، به طوری که میزان دقت تشخیص با الگوریتم SGDm تا ۹۵/۲۵ درصد بهبود یافت. کمترین میزان دقت تشخیص ۶۴/۳۲ درصد بود که با استفاده از الگوریتم RMSProp در محدوده شدت نور ۷۰۰ لوکس (بدون نورپردازی) به دست آمد. بیشترین میزان دقت تشخیص در شرایط آزمایشگاهی رخ داد به طوری که با الگوریتم SGDm تا ۹۸/۷۳ درصد ارتقا یافت. بطور کلی می‌توان گفت که استفاده از نور مصنوعی کنترل شده با شدت نور بهینه می‌تواند باعث افزایش دقت تشخیص الگوریتم‌ها در شرایط مزرعه‌ای شود.

- Fracarolli, J. A. (2020). Computer vision based detection of external defects on tomatoes using deep learning. *Biosystems Engineering*, 190, 131-144.
- [23] Csillik, O., Cherbini, J., Johnson, R., Lyons, A., & Kelly, M. (2018). Identification of citrus trees from unmanned aerial vehicle imagery using convolutional neural networks. *Drones*, 2(4), 39.
- [24] Sowmya, G., & Srikanth, J. (2017). Automatic weed detection and smart herbicide spray robot for corn fields. *Int J Sci Eng Technol Res*, 6(1), 131-137.
- [25] Postalcioglu, S. (2020). Performance Analysis of Different Optimizers for Deep Learning-Based Image Recognition. *International Journal of Pattern Recognition and Artificial Intelligence*, 34(02), 2051003.
- [26] Alruwaili, M., Alanazi, S., Abd El-Ghany, S., & Shehab, A. (2019). An Efficient Deep Learning Model for Olive Diseases Detection.
- [27] Luaibi, A. R., Salman, T. M., & Miry, A. H. (2020). Detection of citrus leaf diseases using a deep learning technique. *International Journal of Electrical and Computer Engineering (IJECE)*. Vol. 11, No. 2, pp. 1719~1727
- [28] Barman, U., Choudhury, R. D., Sahu, D., & Barman, G. G. (2020). Comparison of convolution neural networks for smartphone image based real time classification of citrus leaf disease. *Computers and Electronics in Agriculture*, 177, 105661.
- [29] Tetila, E. C., Machado, B. B., Astolfi, G., de Souza Belete, N. A., Amorim, W. P., Roel, A. R., & Pistori, H. (2020). Detection and classification of soybean pests using deep learning with UAV images. *Computers and Electronics in Agriculture*, 179, 105836.
- [30] Liu, B., Ding, Z., Tian, L., He, D., Li, S., & Wang, H. (2020). Grape leaf disease identification using improved deep convolutional neural networks. *Frontiers in Plant Science*, 11, 1082.
- [31] Miao, R. H., Tang, J. L., & Chen, X. Q. (2015). Classification of farmland images based on color features. *Journal of Visual Communication and Image Representation*, 29, 138-146.
- [32] Hernández-Hernández, J. L., García-Mateos, G., González-Esquiva, J. M., [11] Karabag, C., Verhoeven, J., Miller, N., & Reyes-Aldasoro, C. C. (2019). Texture Segmentation: An Objective Comparison between Traditional and Deep-Learning Methodologies. *Preprints*.
- [12] Sun, X., Wu, P., & Hoi, S. C. (2018). Face detection using deep learning: An improved faster RCNN approach. *Neurocomputing*, 299, 42-50.
- [13] Majumder, A., Behera, L., & Subramanian, V. K. (2016). Automatic facial expression recognition system using deep network-based data fusion. *IEEE transactions on cybernetics*, 48(1), 103-114.
- [14] Ashqar, B. A., Abu-Nasser, B. S., & Abu-Naser, S. S. (2019). Plant Seedlings Classification Using Deep Learning.
- [15] Marani, R., Milella, A., Petitti, A., & Reina, G. (2019). Deep learning-based image segmentation for grape bunch detection. In *Precision agriculture'19* (pp. 3320-3328). Wageningen Academic Publishers.
- [16] Fooladi, S., Farsi, H., & Mohamadzadeh, S. (2019). Detection and classification of skin cancer using deep learning. *J Birjand Univ Med Sci*, 26(1), 44-53.
- [17] Rangarajan, A. K., Purushothaman, R., & Ramesh, A. (2018). Tomato crop disease classification using pre-trained deep learning algorithm. *Procedia computer science*, 133, 1040- 1047.
- [18] Too, E. C., Yujian, L., Njuki, S., & Yingchun, L. (2019). A comparative study of fine-tuning deep learning models for plant disease identification. *Computers and Electronics in Agriculture*, 161, 272-279.
- [19] Barbedo, J. G. A. (2019). Plant disease identification from individual lesions and spots using deep learning. *Biosystems Engineering*, 180, 96-107.
- [20] Tavakoli, N., Hemmat, A., & Nazari, B. (2013). Preventing spread of downy mildew in greenhouse cucumber with machine vision system. In *Proceeding of National Conference of Passive Defense in Agriculture*.
- [21] Xing, S., & Lee, M. (2020). Classification Accuracy Improvement for Small-Size Citrus Pests and Diseases Using Bridge Connections in Deep Neural Networks. *Sensors*, 20(17), 4992.
- [22] da Costa, A. Z., Figueroa, H. E., &

- arXiv:1712.07628*.
- [40] Fooladi, S., Farsi, H., & Mohamadzadeh, S. (2019). Detection and classification of skin cancer using deep learning. *J Birjand Univ Med Sci*, 26(1), 44- 53.
- [41] Karabayir, I., Akbilgic, O., & Tas, N. (2020). A Novel Learning Algorithm to Optimize Deep Neural Networks: Evolved Gradient Direction Optimizer (EVGO). *IEEE Transactions on Neural Networks and Learning Systems*.
- [42] Çarkacı, N. (2018). Derin Öğrenme Uygulamalarında En Sık kullanılan Hiper-parametreler.
- [43] Saleem, M. H., Potgieter, J., & Arif, K. M. (2020). Plant Disease Classification: A Comparative Evaluation of Convolutional Neural Networks and Deep Learning Optimizers. *Plants*, 9(10), 1319.
- [44] Jahanbakhshi, A., Momeny, M., Mahmoudi, M., & Zhang, Y. D. (2020). Classification of sour lemons based on apparent defects using stochastic pooling mechanism in deep convolutional neural networks. *Scientia Horticulturae*, 263, 109133
- [45] Bhusal, S., Bhattarai, U., & Karkee, M. (2019). Improving Pest Bird Detection in a Vineyard Environment using Super-Resolution and Deep Learning. *IFAC-PapersOnLine*, 52(30), 18-23.
- [46] Abdullahi, H. S., Sheriff, R., & Mahieddine, F. (2017). Convolution neural network in precision agriculture for plant image recognition and classification. In International Conference Seventh on Innovative Computing Technology (INTECH) (Vol. 10).
- Escarabajal-Henarejos, D., Ruiz-Canales, A., & Molina-Martínez, J. M. (2016). Optimal color space selection method for plant/soil segmentation in agriculture. *Computers and Electronics in Agriculture*, 122, 124-132.
- [33] Liu, X., Zhao, D., Jia, W., Ruan, C., Tang, S., & Shen, T. (2016). A method of segmenting apples at night based on color and position information. *Computers and Electronics in Agriculture*, 122, 118-123.
- [34] Ali, M. M., Hashim, N., & Hamid, A. S. A. (2020). Combination of laser-light backscattering imaging and computer vision for rapid determination of oil palm fresh fruit bunches maturity. *Computers and Electronics in Agriculture*, 169, 105235.
- [35] Polder, G., van der Heijden, G. W., van Doorn, J., & Baltissen, T. A. (2014). Automatic detection of tulip breaking virus (TBV) in tulip fields using machine vision. *Biosystems Engineering*, 117, 35-42.
- [36] Nguyen, H. D. D., Pan, V., Pham, C., Valdez, R., Doan, K., & Nansen, C. (2020). Night-based hyperspectral imaging to study association of horticultural crop leaf reflectance and nutrient status. *Computers and Electronics in Agriculture*, 173, 105458.
- [37] Askari Asli-Ardeh, E., Larijani, M. R., Loni, R. (2020). Diagnosis of Rice Blast Disease in Different Environmental Conditions using Image Processing Technique. *Journal of Food Science & Technology*. JFST No 100, Vol 17. 17- 28.
- [38] Kathuria, A. (2018). Intro to optimization in deep learning: Momentum, rmsprop and adam.
- [39] Keskar, N. S., & Socher, R. (2017). Improving generalization performance by switching from adam to sgd. *arXiv preprint*



## Detection of snail pest in citrus orchard under different lighting conditions using deep neural networks

Hadipour Rokni, R. <sup>1</sup>, Askari Asli-Ardeh, E. <sup>2\*</sup>, Sabzi, S. <sup>3</sup>, Esmaili paeen- Afrakoti, I. <sup>4</sup>

1. Ph.D. student, Department of Biosystems Engineering, University of Mohaghegh Ardabili, Ardabil, Iran
2. Associate professor, Department of Biosystems Engineering, University of Mohaghegh Ardabili, Ardabil, Iran.
3. Postdoc Researcher, Department of Biosystems Engineering, University of Mohaghegh Ardabili, Ardabil, Iran.
4. Assistant Professor, Faculty of Engineering & Technology, University of Mazandaran, Babolsar, Iran.

ARTICLE INFO	ABSTRACT
<p><b>Article History:</b></p> <p>Received 2020/12/15 Accepted 2021/04/14</p> <hr/> <p><b>Keywords:</b></p> <p>Citrus, Snail pest, Intelligent detection, Image processing, Deep learning.</p> <hr/> <p><b>DOI:</b> 10.29252/fsc.t.18.06.12</p> <hr/> <p>*Corresponding Author E-Mail: ezzataaskari@uma.ac.ir</p>	<p>The control pests and diseases is considered one of the most important operations of Citrus in the protection stage. Today, a lot of research has been done in various fields of agriculture, including the diagnosis of plant pests and diseases by using machine vision methods. One of the problems that reduce the accuracy of the machine for detecting pests in farm conditions is the presence of adverse factors such as shade and changes in light intensity at different times of the day. In this study, in order to find the appropriate light intensity at different times of the day and increase the brightness of the shady parts of the trees, lighting by a lamp at the imaging site has been used. For detect pest-infected trees (in this snail study) has been used to Deep learning method which has been studied and evaluated by various optimization algorithms such as RMSProp, Adam and SGDm. To evaluate and test the algorithm used, 8000 images were examined in 9 farm conditions and one laboratory state In farm conditions, the lowest detection accuracy of algorithms with 64.32% related to imaging in cloudy days with light intensity of 350 to 700 lux was obtained using RMSProp algorithm, which Detection accuracy was improved up to 95.25% using SGDm algorithm by creating a light intensity controlled by a lamp (approximately 9000 lux). In laboratory conditions where the images were prepared in a controlled environment with constant light intensity, the detection accuracy was Obtained 98.73% with SGDm algorithm.</p>