



Identification of *Idiocerus stali* (Hem.: Cicadellidae) Using Image Processing and Artificial Neural Networks

Z. Azizpour¹, H. Vahedi², A. N. Lorestani^{3*}

1- MSc Student, Plant Protection Department, Agricultural Faculty, Razi University, Kermanshah, Iran

2- Associate Professor, Plant Protection Department, Agricultural Faculty, Razi University, Kermanshah, Iran

3- Associate Professor, Mechanical Engineering of Biosystems Department, Agricultural Faculty, Razi University, Kermanshah, Iran

(*- Corresponding Author Email: lorestani@razi.ac.ir)

Received: 28-05-2019

How to cite this article:

Revised: 16-11-2019

Azizpour, Z., H. Vahedi, and A. N. Lorestani. 2022. Identification of *Idiocerus stali* (Hem.: Cicadellidae) Using Image Processing and Artificial Neural Networks. Journal of Agricultural Machinery 12 (2): 107-118. (In Persian). DOI: [10.22067/jam.v12i2.81004](https://doi.org/10.22067/jam.v12i2.81004).

Accepted: 02-12-2019

Introduction

Pistachio or Green Gold is one of the most important agricultural crops and is especially important for Iranian exports. A group of pistachio's pests mainly feed on pistachio, among which *Idiocerus stali* is very important. Conventional methods for identifying insects using identification keys are time-consuming and costly. Due to the rapid development of the Pistachio industry, the use of artificial intelligence techniques such as image processing, for identification and population monitoring is highly recommended. On the other hand, little research was carried out on *I. stali*. Therefore, in this research, *I. stali* was selected as a target insect for the identification and counting on sticky yellow cards using image processing techniques and artificial neural networks. The purpose of this study was to determine the feasibility of *I. stali* identification algorithm by image processing, to determine the possibility of separation and counting of *I. stali* from other non-target insects by artificial neural network and to determine its accuracy in identification of *I. Stali*.

Materials and Methods

Idiocerus stali was selected as the target insect for identification. Sticky yellow cards were used for collecting samples. Taking the photos with the help of a SONY Handycam Camera, which had a 12-megapixel resolution and G lens, was carried out (SONY, HDR-XR500, CMOS, SONY Lens G, Made in Japan). Then insects were counted on each card manually and the data was recorded. The data, which were digital images of yellow sticky cards, were imported into the MatLab R2017b software environment. A total of 357 color properties and 20 shape's features for the identification of *I. stali* were extracted by an image processing algorithm. Color properties were divided into two categories of mean and standard deviation and characteristics related to vegetation indices. An ANN-PSO (Artificial Neural Network hybrid method-Particle Swarm Optimization) algorithm was used to select the effective features. The selected effective characteristics for insect classification were: Color index for extra collective vegetation related to HSL color space, normalized difference index for LCH color space, gray channel for color space YCbCr, second component index minus third component for color space YCbCr, area and mean of the first, second and third components of color space Luv.

Results and Discussion

Comparing the results with the results of Qiao *et al.* (2008), we found that in his study, which divided the data into three categories, for medium and high-density groups, the detection rate was 95.2% and 94.6%, respectively. On the other hand, in low densities (less than 10 trapped insects); its detection rate was 72.9%, while the detection rate of the classifier system designed in this study for different densities of trapped insects, was identical and equal to 99.59%. Also, comparing the results of this study with Espinoza *et al.* (2016), we found that their algorithm in whiteflies detection had a high accuracy of about 0.96 on a sticky yellow card, while the Thrips identification algorithm accuracy was 0.92 on a sticky blue card. As stated above, the correct detection rate of *I. stali* by the algorithm designed in this study was 99.72%.

Conclusion

The results showed the feasibility of the new method for identifying the pest insects without destroying them on the farm and in natural light conditions and in a short time and with very high accuracy. This suggests that this algorithm can be applied to the machine vision system and can be used in future in the construction of agricultural robots.

Keywords: Artificial Neural Network, Classification, Identification, Image processing



مقاله پژوهشی

جلد ۱۲، شماره ۲، تابستان ۱۴۰۱، ص ۱۱۸-۱۰۷

شناسایی زنجرک پسته (*Idiocerus stali* (Hem.: Cicadellidae) با استفاده از پردازش تصویر و شبکه‌های عصبی مصنوعیزنیب عزیزپور^۱، حسنعلی واحدی^۲، علی نجات لرستانی^{۳*}

تاریخ دریافت: ۱۳۹۸/۰۳/۰۷

تاریخ پذیرش: ۱۳۹۸/۰۹/۱۱

چکیده

استراتژی مدیریت تلفیقی آفات (IPM)، به پایش پیوسته جمیعت آفات وابسته است، این کار نه تنها زمان بر است، بلکه وابستگی زیادی به داوری انسان دارد و پر هزینه نیز می‌باشد. استفاده از روش‌های هوش مصنوعی به جای تصمیم‌گیری‌های دستی و انسانی، علاوه بر این که سبب افزایش بهره‌وری می‌گردد، از دقت بالایی نیز برخوردار است. پسته، یک محصول تجاری است و هر ساله خسارت زیادی توسط حشرات به تولیدکنندگان این محصول وارد می‌شود. گروهی از آفات پسته عمده‌اً از میوه پسته تغذیه می‌کنند، که از این گروه زنجرک پسته، دارای اهمیت زیادی می‌باشد. در این تحقیق زنجرک پسته به عنوان حشره هدف جهت شناسایی انتخاب شد. برای جمع‌آوری نمونه‌ها از کارت‌های زرد چسبنده استفاده شد. ۳۵۷ خصوصیت رنگی و ۲۰ خصوصیت شکلی برای شناسایی زنجرک پسته به وسیله الگوریتم پردازش تصویر استخراج شد. خصوصیات رنگی به دو دسته‌ی خصوصیات مربوط به میانگین و انحراف‌معیار و خصوصیات مربوط به شاخص‌های سبزی تقسیم شدند. از ۱۷ فضای رنگی مختلف مثل RGB، HSV و غیره برای استخراج خصوصیات و از روش هیبرید شبکه عصبی مصنوعی-الگوریتم بهینه‌سازی ازدحام ذرات (ANN-PSO) برای انتخاب خصوصیات مؤثر استفاده گردید. خصوصیات مؤثر انتخابی جهت طبقه‌بندی حشرات عبارتند از: شاخص رنگی برای پوشش گیاهی استخراجی مربوط به فضای رنگی HSL، شاخص تفاضل نرم‌مال شده مربوط به فضای رنگی LCh، کanal خاکستری مربوط به فضای رنگی YCbCr، شاخص مؤلفه دوم منهای مؤلفه سوم مربوط به فضای رنگی YCbCr، مساحت و میانگین مؤلفه‌های اول، دوم و سوم فضای رنگی Luv. نرخ شناسایی الگوریتم پردازش تصویر طراحی شده، ۷۷/۹۹ درصد کل اشیا (زنجرک پسته، سوسک چوب‌خوار قرمز پسته و سایر حشره‌های غیر هدف و متفرقه) می‌باشد. شبکه‌های عصبی مصنوعی، توانایی طبقه‌بندی حشرات به سه کلاس (زنجرک پسته، سوسک چوب‌خوار قرمز پسته و سایر حشره‌های غیر هدف و متفرقه) و دو کلاس (زنجرک پسته و سوسک چوب‌خوار قرمز پسته) به ترتیب با دقت ۵۳/۱۰ و ۵۹/۹۶ درصد را دارند.

واژه‌های کلیدی: پردازش تصویر، زنجرک پسته، شبکه عصبی مصنوعی، شناسایی

مقدمه

پسته یا طلای سبز یکی از محصولات مهم کشاورزی است و در میان محصولات صادراتی ایران، از اهمیت ویژه و اعتبار بالایی برخوردار می‌باشد. ایران بزرگ‌ترین تولیدکننده و صادرکننده پسته در سطح جهانی می‌باشد (Karbasi and Taohidi, 2015). سطح زیر

کشت پسته در ایران در سال ۲۰۱۷ میلادی برابر ۴۲۹۵۳۵ هکتار بوده که با برداشت ۵۷۴۸۷ تن محصول در آن سال، عملکرد ۱۳۳۸/۶ کیلوگرم بر هکتار به دست آمد (FAO, 2017). در باغات پسته آفات متنوعی دیده شود که از قسمت‌های مختلف درخت پسته تغذیه نموده و خسارت می‌زنند. گروهی از آن‌ها عمده‌اً از میوه پسته تغذیه نموده و سایر حشره‌های غیر هدف و متفرقه می‌باشد. شبکه‌های عصبی زیادی می‌باشد (Jalilvand and Kashani-Zadeh, 2013) به طوری که در باغ‌های آلووه اگر با آن مبارزه نشود، خسارت سنگینی به بار می‌آورد و کاهش معنی‌داری در عملکرد رخ خواهد داد (Mehrnejad, 2001). شناسایی عبارت است از آگاهی از جنس و گونه‌ی هر نمونه از جاندار با بهره‌گیری از مجموعه‌ها و منابع علمی

- دانشجوی کارشناسی ارشد، گروه گیاه‌پزشکی، دانشکده کشاورزی، دانشگاه رازی، کرمانشاه، ایران
 - دانشیار گروه گیاه‌پزشکی، دانشکده کشاورزی، دانشگاه رازی، کرمانشاه، ایران
 - دانشیار گروه مهندسی مکانیک بیوپسیستم، دانشکده کشاورزی، دانشگاه رازی، کرمانشاه، ایران
- (Email: lorestani@razi.ac.ir) - نویسنده مسئول: (DOI: [10.22067/jam.v12i2.81004](https://doi.org/10.22067/jam.v12i2.81004))

عرض به طول، نسبت مساحت به طول، خروج از مرکزیت، تمایل، سطح محدب^۲، سطح یکپارچه، قطر معادل، عدد اویلر، یکپارچگی، محدوده^۳، کشیدگی، فشردگی، نسبت تصویر و نسبت طول به محیط استخراج می‌شوند. انتخاب خصوصیات مؤثر در میان خصوصیات استخراج شده به منظور طبقه‌بندی بسیار پراهمیت می‌باشد. روش‌های مختلفی برای انتخاب خصوصیات مؤثر مثل هیرید شبکه عصبی مصنوعی - الگوریتم بهینه‌سازی ازدحام ذرات^۴، وجود دارد (Gonzalez et al., 2004). شبکه‌های عصبی مصنوعی از عناصر عملیاتی ساده‌ای به صورت موازی ساخته می‌شوند. این عناصر از سیستم‌های عصبی زیستی الهام گرفته‌اند. در طبیعت، ساختار شبکه‌های عصبی از طریق نحوه اتصال بین اجزا تعیین می‌شود. بنابراین می‌توان یک ساختار مصنوعی به تعیین از شبکه‌های طبیعی ساخت و با تنظیم مقادیر هر اتصال تحت عنوان وزن اتصال نحوه ارتباط بین اجزای آن را تعیین نمود. پس از تنظیم یا همان آموژش شبکه عصبی، اعمال یک ورودی خاص به آن منجر به دریافت پاسخ خاص می‌شود. شبکه بر مبنای تطابق و همسنجی بین ورودی و هدف سازگار می‌شود تا این که خروجی شبکه و هدف بر هم منطبق گردد. عموماً تعداد زیادی از این زوچ‌های ورودی و خروجی به کار گرفته می‌شوند تا در این روند، که از آن تحت عنوان یادگیری نظارت شده یاد می‌شود، شبکه آموژش داده شود. جهت آموژش مدل به شبکه از روش آموژش لوبنبرگ-مارکوارت^۵ استفاده می‌شود، زیرا این روش آموژش دارای سرعت و دقت بالاتری از الگوریتم پس‌انتشار^۶ استاندارد می‌باشد و داده‌های ورودی کمتری برای آموژش نیاز دارد. پس از تکمیل آموژش، شبکه طراحی شده باستی توانایی تعمیم به کل مجموعه و آن‌هایی که در آموژش شرکت نداشته‌اند، را داشته باشد (Kia, 2009).

تحقیقات زیادی در خصوص شناسایی حشرات با پردازش تصویر انجام شده که چند مورد آن به شرح زیر آمده است. چو و همکاران (Cho et al., 2007) به شناسایی خودکار سفیدبالک‌ها، شته‌ها و ترپیس‌ها با استفاده از پردازش تصاویر پرداختند. شناسایی خودکار حشرات انتخابی آفت در گلخانه‌ها، روی نمونه‌های جمع‌آوری شده بر روی تله‌های چسبنده زرد انجام شد. اندازه (مساحت) و مؤلفه‌های رنگی اشیاء (میانگین مؤلفه‌های R, G و B) به عنوان خصوصیات شناسایی خودکار انتخاب شدند. شته‌ها به آسانی شناسایی شدند زیرا اختلاف کمی در اطلاعات مربوط به رنگ آن‌ها مشاهده شد و اندازه بدن آن‌ها تفاوت قابل ملاحظه‌ای با حشره‌های دیگر داشت. پس از شناسایی شته‌ها، خطای شناسایی برای داده‌های مربوط به ترپیس و

موجود. واژه‌ی شناسایی به صورت تعیین هویت و تشخیص نیز بیان می‌شود. برای شناسایی مهم‌ترین وسیله‌ی مورد نیاز تاکسونومیست، کلید شناسایی است. تهییه‌ی کلید شناسایی مستلزم صرف زمان زیادی می‌باشد. معمولاً مشخصات ریخت‌شناسی مثل رنگ بدن، طول بدن، اندازه بدن و غیره بیش از دیگر خصوصیات در طبقه‌بندی مورد استفاده قرار می‌گیرند (Modarres Awal, 2009). تصویر دیجیتالی ماتریسی دو در دو است که هر زوج از اندیس‌های سط्रی و ستونی آن، یک نقطه از تصویر را مشخص می‌کند. عناصر این ماتریس پیکسل نامیده می‌شوند. برای شناساندن رنگ یک پیکسل به نرم‌افزار، مدل‌های مختلفی وجود دارد که مدل رنگ RGB به دلیل سادگی کار با آن، بهترین مدل بوده و بیشتر از آن استفاده می‌شود. هر پیکسل از یک تصویر رنگی RGB، دارای سه مؤلفه به نام‌های مؤلفه قرمز^۷، سبز^۸ و آبی^۹ می‌باشد. این اجزا متناسب با نوع کلاس داده، مقادیر RGB محدودی خواهند داشت. به عنوان مثال در صورتی که تصویر در کلاس داده double unit8 باشد به ترتیب دارای مقادیری بین صفر و یک، صفر و ۲۵۵ یا صفر و ۶۵۵۳۵ می‌باشند. سایر فضاهای رنگی با استفاده از این فضای رنگی درست شده‌اند. به طور کلی به عملیاتی که قبل از پردازش اصلی تصویر دیجیتال صورت می‌گیرد، پیش‌پردازش گویند. به عنوان مثال تغییر مقیاس تصویر، چرخش تصویر، استخراج نواحی موردنظر در یک تصویر وغیره. از طرفی دیگر، به مجموعه عملیاتی که بعد از اجرای بخشی از پردازش تصویر صورت می‌گیرد، عملیات پس‌پردازش گویند. به عنوان مثال، به منظور استخراج خصوصیات شکلی نیاز به تبدیل تصویر دودویی می‌باشد (Gonzalez and Woods, 2018). فرآیند پردازش تصویر در چهار مرحله پیش‌پردازش، استخراج خاصیت^{۱۰}، انتخاب خاصیت و طبقه‌بندی هوشمند انجام می‌گیرد. ابتدا از یک یا چند نمونه مورد مطالعه، با استفاده از دوربین دیجیتال، تصویر تهیه می‌شود. گام بعدی پردازش تصویر است، که تصاویر رنگی را به تصاویر سیاه و سفید تبدیل می‌کنند، سپس به تصویر باینری تبدیل می‌شوند که تنها شامل دو بخش سیاه و سفید است که طی آن، ناحیه موردنظر از پس زمینه تصویر جدا می‌شود (Solomon and Breckon, 2011). سپس استخراج خاصیت صورت می‌گیرد و خاصیت‌های استخراج شده طبقه‌بندی می‌شوند. طبقه‌بندهای مختلفی هم‌چون شبکه‌های عصبی Ghaiwat and Arora, (2014) یکی از مهم‌ترین خصوصیات به منظور قطعه‌بندی و همچنین طبقه‌بندی، خصوصیات رنگی است. بیست خصوصیت شکلی مختلف از جمله طول، عرض، مساحت، محیط، لگاریتم نسبت طول به عرض، نسبت محیط شکل به محیط مستطیل در برگیرنده شکل، نسبت

6- Convex Area

7- Extent

8- Artificial Neural Network- Particle Swarm Optimization algorithm (ANN-PSO)

9-Levenberg- Marquardt (LM)

10- Backpropagation (BP)

1- Red (R)

2- Green (G)

3- Blue (B)

4- Feature Extraction

5- Artificial Neural Networks (ANN)

واقعی و تخمین زده شده ۰/۹۹۹ بود ($P<0.0001$) (Qiao *et al.*, 2008). باربودو (Barbedo, 2014) از تکنیک پردازش تصویر برای شمارش سفیدبالک روی برگ‌های سویا استفاده کرد. وی از ۷۴۸ تصویر از برگ‌های سویا برای این کار استفاده نمود. میزان آلودگی این برگ‌ها از کاملاً سالم و بدون آفت تا کاملاً آلوده، متغیر بود. تصاویر با استفاده از یک دوربین ۱۰ مگاپیکسل گرفته شدند. تصاویر گرفته شده ۳۶۴۸ پیکسل عرض و ۲۷۳۶ پیکسل ارتفاع داشتند که به فرمت JPEG و در فضای رنگی RGB بودند. نشان داده شد که شمارش اکثر هدف‌ها می‌تواند کاملاً به طور خودکار انجام شود و سیستم پیشنهادی هنوز سریع‌تر از شمارش دستی است. الگوریتم پیشنهاد شده قادر بود نه تنها سفیدبالک‌های بالغ را تشخیص داده و شمارش نماید، بلکه نمونه‌ها در مرحله پورگی را نیز با دقت ۹۸/۳ درصد تشخیص دهد. اگرچه این الگوریتم به طور کامل با استفاده از برگ‌های سویا توسعه یافته، اما می‌تواند به آسانی برای انواع محصولات دیگر نیز با کمی تغییر توسعه داده شود. این سیستم چون عملیات پردازش تصویر را به خدمت می‌گیرد، لذا می‌تواند در هر بسته نرم‌افزاری پردازش تصویری اعمال شود (Barbedo, 2014). اسپینوزا و همکاران (Espinoza *et al.*, 2016) از ترکیب پردازش تصویر و شبکه‌های عصبی مصنوعی به عنوان یک دستاوردهای جدید، برای شبکه‌ای سفیدبالک^۱ (*Bemisia tabaci*) و تریپس^۲ (Frankliniella occidentalis) چسبنده زرد رنگ و آبی یکپارچه (بدون شبکه‌بندی) برای اجتناب از ایجاد نویز در عکس‌برداری دیجیتال، در گلخانه‌های کشاورزی استفاده نمودند. آن‌ها ۹۰۳ کارت زرد چسبناک و ۶۹۰ کارت آبی چسبناک داشتند. بعد از شمارش دستی سفیدبالک‌ها و تریپس‌های روی کارت‌های رنگی، از آن‌ها عکس گرفته شد. الگوریتم شناسایی سفیدبالک دقت بالایی در حدود ۹۶/۰ را کارت زرد چسبناک داشت، در حالی که الگوریتم شناسایی تریپس دقیقی در حدود ۹۲/۰ داشت، در حالی که الگوریتم شناسایی تریپس دقیقی در حدود ۹۶/۰ را کارت آبی چسبناک داشت (Espinoza *et al.*, 2016). حیدری و امیری پریان (Heidari and Amiri Parian, 2019) در مطالعه‌ای شناسایی و شمارش خودکار آفات مهم گلخانه (سفید بالک و تریپس) از طریق کارت‌های چسبناک زرد رنگ به کمک پردازش تصویر را انجام دادند. از کارت‌های زرد رنگ در طول روز به کمک دوربین دیجیتال عکس گرفته شد. الگوریتم پیشنهاد شده قادر به تشخیص آفات سفید بالک و تریپس و نیز شمارش تعداد آن‌ها بود. برخی مؤلفه‌های رنگی و اندازه اشیاء برای شناسایی خودکار انتخاب شدند. به کمک روش ماتریس اختشاش، دقت الگوریتم پیشنهاد شده برابر با ۹۴/۵ و ۸۷/۲ درصد به ترتیب برای شناسایی حشرات سفید بالک و تریپس محاسبه شد (Heidari and Amiri Parian, 2019).

روش‌های مرسوم برای شناسایی حشرات با استفاده از کلید

سفیدبالک کاهش یافت. مقادیر مرجع اندازه و مؤلفه‌های رنگی نمونه‌برداری شده از ۵۰ حشره، برای هر حشره جهت شناسایی و شمارش استفاده شد. دقت شناسایی الگوریتم برای سفیدبالک‌ها، شته‌ها و تریپس‌ها به ترتیب ۹۳/۹۶، ۹۲/۷۳ و ۸۸/۹ درصد به دست آمد. ایشان اظهار داشتند که اگر از کارت‌های زرد چسبنده یکپارچه (بدون شبکه‌بندی) استفاده شود، دقت کار بیشتر خواهد شد (Cho *et al.*, 2007). بویسارد و همکاران (Boissard *et al.*, 2008) برای شناسایی سریع و شمارش خودکار آفت گلخانه‌ای سفیدبالک از سیستم پردازش تصویر به صورت عکس‌برداری در محل و در شرایط نور طبیعی، استفاده نمودند. آن‌ها از سفیدبالک‌های بالغ چسبیده به زیر برگ‌های گل رز (به تعداد ۲۰ برگ) عکس تهیه نمودند. آن‌ها در این تحقیق از مشخصه‌های رنگ (فضای رنگی HSI که مشابه HSI می‌باشد)، شکل (گرد بودن، خروج از مرکزیت، چهار گوش بودن، کشیده بودن، محدب بودن و فشرده‌گی تصویر حشره) و اندازه (مساحت، طول و محیط) حشره که از تصویرها به کمک پردازش تصویر استخراج گردید، برای شناسایی و شمارش سفیدبالک‌ها استفاده نمودند. لازم به ذکر است که ایشان از ۱۲ خاصیت و ۲۰ نمونه برای استخراج خصوصیات تصویر جهت شناسایی و شمارش در الگوریتم پردازش تصویر استفاده نمودند. ایشان اظهار داشتند که شمارش دستی به وسیله انسان به آزمایشگاه و شرایط نورپردازی مناسب و وسایلی مثل ذره‌بین و غیره نیاز دارد، از طرفی چون شمارش حشرات کاری تکراری است، بعد از مدتی شخص خسته شده و از دقت کار کاسته می‌شود ولی سیستم شمارش خودکار که با الگوریتم پردازش تصویر تدارک دیده شده است، ضمن داشتن دقت و سرعت بالا همچنین دقت الگوریتم پردازش تصویر پیشنهاد شده برای شناسایی و شمارش سفیدبالک‌ها، در مقایسه با شمارش چشمی، ۸۳٪ گزارش Qiao *et al.*, 2008) گردید (Boissard *et al.*, 2008). کیاون و همکاران (Qiao *et al.*, 2008) اظهار داشتند که پیش‌بینی دقیق تراکم آفت برای مدیریت مؤثر آفت ضروری است. آن‌ها آزمایش‌ها را در آزمایشگاه و گلخانه انجام دادند. کارت زرد چسبناک (۱۸ cm در ۱۳ cm) با خطوط سبز رنگ شبکه‌بندی شده در ۹ ردیف به فاصله ۲ متر از هم‌دیگر در روی بوته‌های گوجه‌فرنگی در گلخانه به کار بردند. نمونه‌ها به وسیله کارت‌های زرد چسبناک از گلخانه‌ای جمع‌آوری شدند، که بعد از سبز رنگ شبکه‌بندی شده در ۹ ردیف به فاصله ۲ متر از هم‌دیگر در روی بوته‌های گوجه‌فرنگی در گلخانه به کار بردند. نمونه‌ها به وسیله کارت‌های زرد چسبناک از گلخانه‌ای جمع‌آوری شدند، که بعد از گلخانه گوجه‌فرنگی در آن جا پیاده سازی نمودند. سپس تصویر دیجیتال (200 dpi) را با استفاده از اسکنر از کارت‌های زرد رنگ چسبناک تهیه نمودند. با استفاده از سیستم پردازش تصویر به طور خودکار تراکم سفیدبالک‌ها بر روی کارت‌های زرد چسبناک را تخمین زدند. تراکم‌های تخمین زده شده نمونه‌ها در آزمایشگاه و گلخانه با مقادیر واقعی هم‌خوانی داشتند. نرخ تشخیص در کارت‌های زرد چسبناک با تعداد حشره ۳۹ تا ۱۴۹ عدد در روی هر کارت و در آزمایشگاه، تقریباً ۹۷/۵ درصد بود. ضریب همبستگی بین داده‌های

خصوصیت رنگی و شکلی استخراج شد. آماره‌های مینیمم، میانگین، ماکریمم، انحراف معیار و واریانس برای خصوصیات استخراجی اعمال شد. این خصوصیات در فضاهای مختلف رنگی مورد بررسی قرار گرفتند و از بین آن‌ها خصوصیاتی که بیشترین تأثیر را در شناسایی و طبقه‌بندی داشتند، به عنوان خصوصیات مؤثر انتخاب شدند، که این خصوصیات مؤثر ورودی‌های شبکه عصبی مصنوعی برای طبقه‌بندی بودند. خصوصیات مؤثر توسط الگوریتم هیبرید شبکه عصبی مصنوعی- بهینه‌سازی ازدحام ذرات انتخاب شدند و روش کار چنین است که ابتدا کل خصوصیات استخراجی به عنوان یک بردار در نظر گرفته می‌شود. در مرحله بعد با استفاده از الگوریتم بهینه‌سازی ازدحام ذرات از میان این بردار، بردارهای دیگر با اندازه‌های مختلف انتخاب و به شبکه عصبی مصنوعی ارسال می‌گردند. این بردارها به عنوان ورودی‌ها به شبکه عصبی مصنوعی پرسپترون چند لایه ارسال می‌شوند. خروجی شبکه عصبی مصنوعی پرسپترون چند لایه شامل کلاس‌ها می‌باشد. در نهایت میانگین مربعات خطای مربوط به هر برداری که توسط الگوریتم بهینه‌سازی ازدحام ذرات به شبکه عصبی مصنوعی پرسپترون چند لایه ارسال می‌گردد، ثبت می‌شود. هر بردار انتخابی توسط الگوریتم بهینه‌سازی ازدحام ذرات که دارای کمترین مقدار میانگین مربعات خطای باشد، به عنوان خصوصیت مؤثر انتخاب می‌گردد. الگوریتم بهینه‌سازی ازدحام ذرات از الگوی حرکات دسته جمعی پرنده‌گان برای حل مسائل، تقليید می‌کند. دسته پرنده‌گان در حال پرواز را در نظر بگیرید که هر کدام ضمن حفظ فاصله خود با همسایگان، سرعت را نیز حفظ می‌کنند. زمانی که منبع غذایی یا موقعیتی برای استراحت پیدا می‌کنند، به طور ناگهانی تعییر جهت داده و در مکان مورد نظر فرود می‌آیند. پس در این الگوریتم، اجتماع پرنده‌گان به صورت ازدحام ذرات در نظر گرفته شده است و هر پاسخ مسئله را یک ذره فرض نموده که هر ذره نیز مدام در حال جستجو و جابه‌جایی با حفظ سرعت می‌باشد. حرکت ذره به موقعیت کنونی ذره، بهترین موقعیتی که ذره تاکنون داشته و بهترین موقعیتی که کل مجموعه ذرات تاکنون داشته‌اند، بستگی دارد (Kennedy and Eberhart, 1995). یکی از مهم‌ترین مراحل پردازش تصویر قطعه‌بندی^۱ می‌باشد. در صورتی که عملیات قطعه‌بندی دارای دقت بالایی نباشد، ممکن است که بخش‌هایی از پس‌زمینه به عنوان حشره تشخیص داده شود و بر عکس، که در نهایت منجر به کاهش دقت، آفزایش زمان انجام عملیات محاسبات و کاهش کارآیی سیستم ماشین بینایی می‌شود. ابتدا تصویر یک کارت را انتخاب نموده که در فضای رنگی RGB تهیه شده است (شکل ۱). تصویر مورد نظر از فضای رنگی RGB به فضای رنگی CMY تبدیل می‌شود (شکل ۱). سپس آستانه ۲۰۰^(i,j) اعمال می‌شود. این آستانه بیان می‌کند هر پیکسل در فضای رنگی CMY با مقدار موافقه سوم (Y) کمتر از ۲۰۰، عضو کارت می‌باشد و باید باقی بماند. مقدار آستانه از طریق سعی و خطای در هنگام برنامه‌نویسی جهت پردازش تصویر تعیین شد. این

شناسایی زمان بر و پر هزینه هستند. استفاده از روش‌های هوش مصنوعی به جای تصمیم‌گیری‌های دستی و انسانی، علاوه بر این که سبب افزایش بهره‌وری می‌گردد، از دقت بالایی نیز برخوردار است، از طرفی در خصوص زنجرک پسته تحقیقات انگشت‌شماری یافت شد، لذا در این تحقیق زنجرک پسته، به عنوان حشره هدف برای شناسایی، طبقه‌بندی و شمارش آن روی کارت زرد، انتخاب شد و از تکنیک‌های پردازش تصویر و شبکه عصبی مصنوعی، که دارای سرعت و دقت بالایی می‌باشند، جهت شناسایی و طبقه‌بندی استفاده می‌شود. هدف از این تحقیق امکان سنجی تدوین الگوریتم شناسایی زنجرک پسته به کمک پردازش تصویر، بررسی امکان طبقه‌بندی و شمارش آفت زنجرک پسته شناسایی شده از سایر حشرات غیر هدف به کمک شبکه عصبی مصنوعی و تعیین دقت آن می‌باشد.

مواد و روش‌ها

این تحقیق در زمینی به مساحت ۱۰۰۰ مترمربع در باغ پسته ۴۵ ساله با تراکم ۹۰۰ درخت بر هکتار پردهیس کشاورزی و منابع طبیعی دانشگاه رازی انجام گرفت. این باغ پسته آلوده به آفاتی چون زنجرک پسته بود و سمپاشی نشده بود. برای جمع‌آوری نمونه‌ها از ۱۰۵ کارت زرد چسبناک (Daegil Co Ltd., Made in Korea) یکپارچه (بدون شبکه‌بندی) به ابعاد ۱۰۰ mm*۲۵۰ mm استفاده شد. حشره مورد *Idiocerus stali* (Hem.:Cicadellidae) پسته (*Mozaffarian and Wilson, 2016*) Fieber, 1868 نمونه‌برداری در تیر و مردادماه ۱۳۹۶ انجام گردید. هر روز صبح زود کارت‌های زرد رنگ روی درختان پسته آلوده به آفت زنجرک پسته نصب می‌شوند. بعد از حدود ۶ ساعت کارت‌ها از سطح باغ پسته جمع‌آوری شده با یک شماره، هر کارت را از بقیه متمایز نموده و تحت شرایط نور آفتاب از آن‌ها عکس گرفته شد. عکس‌برداری به کمک دوربین هندی کم SONY مدل HDR-XR500 ساخت کشور ژاپن، دارای لنز G سونی با رزولوشن ۱۲ مگاپیکسل (Sony HDR-X500, CMOS, SONY Lens G, Made in Japan) انجام شد. ابتدا حشرات روی کارت‌های چسبنده زرد رنگ توسط متخصصین حشره‌شناسی شناسایی و بعد به طور چشمی نیز حشرات روی هر کارت شمارش شده و داده‌ها ثبت گردید. لازم به ذکر است که علاوه بر *I. stali* که حشره مورد مطالعه بود، حشره دیگری نیز با *Anthaxia* Sp. Eschscholtz, 1829 (Coleoptera: Buprestidae) (Baiocchi, 2013)، روی کارت زرد به دام افتاده بود، که مورد بررسی قرار گرفت. داده‌ها که تصاویر دیجیتال از MatLab کارت‌های زرد چسبناک بودند، به محیط نرم‌افزار متلب R2017b فراخوانده شدند. در این نرم‌افزار با توجه به برنامه‌نویسی انجام شده، تصاویر ابتدا پیش‌پردازش شده، نویزها (قسمت‌هایی از پس‌زمینه) که به صورت اشتباهی حشره تشخیص داده شدند، پس‌زنمینه که حذف شدند، سپس به فضاهای رنگی مختلف تبدیل شدند. بعد با توجه به تعداد کانال‌ها، از هر تصویر تعداد ۳۷۷

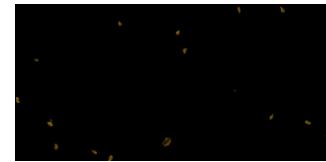
بزرگ‌تر از ۱۱۰ و مؤلفه دوم پیکسلی بزرگ‌تر از ۱۱۰ و مؤلفه سوم پیکسلی بزرگ‌تر از ۱۰۵ و قدر مطلق تفاضل مؤلفه اول و دوم پیکسلی کمتر از ۱۰ یا مؤلفه اول بزرگ‌تر از ۱۵۰ باشد، آن پیکسل جزو پس زمینه می‌باشد و باید حذف گردد.

$$(TBW1(i,j) > 110 \& TBW2(i,j) > 110 \& TBW3(i,j) > 105 \& \text{abs}(TBW1(i,j) - TBW2(i,j)) < 10) | TBW1(i,j) > 150 \quad (1)$$



شکل ۱- تصویر یک کارت زرد چسبناک در فضای رنگی RGB (سمت راست) و تبدیل تصویر RGB به فضای رنگی CMY (سمت چپ)

Fig.1. Images of a sticky yellow card in RGB color space (Right) and the converted RGB image to CMY color space (Left)



شکل ۲- اعمال آستانه برای حذف پس زمینه (سمت راست) و کارت زرد پردازش شده که اشیاء با شماره مشخص شده‌اند (سمت چپ)

Fig.2. Applied thresholds to remove the background (Right) and processed yellow card with objects marked with the number (Left)

پس انتشار برگشتی، `trainlm` و تابع یادگیری وزن/بایاس پس انتشار برگشتی، `learnsom` مطابق جدول ۱ استفاده شد. ۶۰ درصد از داده‌ها به صورت تصادفی برای آموزش، ۲۰ درصد برای آزمون و ۲۰ درصد نیز برای اعتبارسنجی استفاده گردید.

در این تحقیق هدف شناسایی زنجیرک پسته بود، پس در نهایت داده‌ها به دو کلاس طبقه‌بندی شدند که برای این کار در جعبه‌ابزار شبکه‌های عصبی مصنوعی نرم‌افزار متلب، از شبکه عصبی پرسپترون چندلایه، با ۳۸ نورون، ۳ تابع انتقال `tansig`, `satlins` و `tansig` به ترتیب در لایه‌های اول، دوم و سوم با تابع آموزش شبکه

جدول ۱- مقادیر پارامترهای شبکه عصبی پرسپترون چندلایه برای لایه‌های پنهان جهت طبقه‌بندی به دو کلاس

Table 1- Parameters' values of the multilayer perceptron neural network for hidden layers for classification into two classes

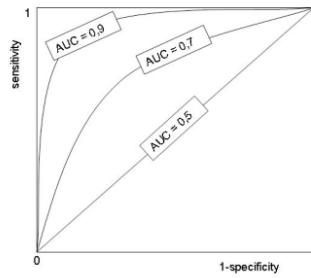
Neurons نرون‌ها	First Layer: 18, Second Layer: 13, Third Layer: 7 لایه اول: ۱۸، لایه دوم: ۱۳، لایه سوم: ۷
Number of Layers تعداد لایه‌ها	3
Transfer Functions تابع انتقال	First Layer: <code>satlins</code> , Second Layer: <code>tansig</code> , Third Layer: <code>tansig</code> لایه اول: <code>satlins</code> , لایه دوم: <code>tansig</code> , لایه سوم: <code>tansig</code>
Backward back propagation network training function تابع آموزش شبکه پس انتشار برگشتی	<code>Trainlm</code>
Backward back propagation Weight / Bias learning function تابع یادگیری وزن/بایاس پس انتشار برگشتی	<code>Learnsom</code>

داده‌های جدول ۲ است (Šimundić, 2009).

جدول ۲ - رابطه بین سطح زیر منحنی ROC و دقت تشخیص

Table 2- The relationship between the area under the ROC curve and the accuracy of detection

Area	Diagnostic accuracy
سطح	دقت تشخیص
0.9-1.0	Excellent عالی
0.8-0.9	Very good خیلی خوب
0.7-0.8	Good خوب
0.6-0.7	Sufficient کافی
0.5-0.6	Bad بد
< 0.5	Test not useful آزمون مفید نیست



شکل ۳ - منحنی خصوصیت عملیاتی دریافت‌کننده (ROC)

Fig.3. Receiver Operating Characteristic (ROC) Curve

نتایج و بحث

تعداد زنجرک‌های پسته چسبیده به کارت‌های زرد بین ۸ تا ۴۰۲ عدد در روی هر کارت متغیر بود، که به طور متوسط ۴۶ عدد *I. Stali* در روی هر کارت زرد وجود داشت. با استفاده از الگوریتم پردازش تصویر طراحی شده به طور خودکار تراکم زنجرک‌های پسته بر روی کارت‌های زرد چسبناک تخمین زده شد. تراکم‌های تخمین زده شده نمونه‌ها به وسیله سیستم پردازش تصویر با مقادیر واقعی هم‌خوانی خوبی داشتند. ضریب تعیین^۷ بین تعداد *I. Stali* چسبیده به کارت زرد و تعداد *I. Stali* تخمین زده شده به وسیله پردازش تصویر ۰/۹۹۷۲ بود (شکل ۴). بنابراین نرخ تشخیص الگوریتم پردازش تصویر طراحی شده ۹۹/۷۲ درصد می‌باشد. در مقایسه با کار کیاوش و همکاران (Qiao

7- Coefficient of determination (R^2)

جهت بررسی عملکرد و کارآیی سیستم طبقه‌بند به کار رفته در این الگوریتم از ماتریس اغتشاش^۱، دقت طبقه‌بندی و نمودار خصوصیت عملیاتی دریافت‌کننده (ROC)^۲ استفاده می‌شود. ماتریس اغتشاش، ماتریسی است مربعی که به تعداد کلاس‌ها، سطر و ستون دارد. دقت طبقه‌بندی بر مبنای کل داده‌هایی که درست طبقه‌بندی شده‌اند، ارائه شده است. عملکرد الگوریتم‌های طبقه‌بندی، معمولاً توسط ارزیابی حساسیت^۳، خاصیت^۴ و دقت^۵ بررسی می‌گردد. سه معیار حساسیت، خاصیت و دقت به ترتیب با استفاده از روابط (۲) تا (۴) تعریف می‌شوند (Kazmi et al., 2015):

$$\text{Sensitivity} = \frac{TP}{TP + FN} \quad (2)$$

$$\text{Specificity} = \frac{TN}{TN + FP} \quad (3)$$

$$\text{Accuracy} = \frac{TP + TN}{N} \quad (4)$$

در این روابط:

Sensitivity، حساسیت (بر حسب درصد)، Specificity، خاصیت (بر حسب درصد)، Accuracy (بر حسب درصد) و درصد، N برابر تعداد کل نمونه‌ها، TP برابر است با تعداد نمونه‌های هر کلاس، که درست طبقه‌بندی شده‌اند. TN برابر است با تعداد نمونه‌های کلاس‌های دیگر غیر از کلاس مورد نظر، که به درستی طبقه‌بندی شده‌اند. FN برابر است با مجموع نمونه‌های کلاس مورد نظر، که به درستی در کلاس مورد نظر طبقه‌بندی نشده‌اند یا به طور نادرست در کلاس‌های دیگر طبقه‌بندی شده‌اند. FP برابر است با مجموع نمونه‌های کلاس‌های دیگر، که به طور نادرست در کلاس مورد نظر طبقه‌بندی شده‌اند (Kazmi et al., 2015).

شکل منحنی ROC و سطح زیر منحنی^۶ به ما در تخمین این که توان تشخیص یک سیستم طبقه‌بند چه قدر است، کمک می‌کند. هر قدر منحنی به گوشه بالا سمت چپ نزدیک‌تر باشد و سطح زیر منحنی بزرگ‌تر باشد، سیستم طبقه‌بند عملکرد بهتری دارد (شکل ۳). سطح زیر منحنی می‌تواند مقداری بین صفر و یک داشته باشد و این یک شخص خوب برای ارزیابی سیستم طبقه‌بند است. یک سیستم طبقه‌بند عالی سطح زیر منحنی برابر یک را دارد (AUC=1.0). در صورتی که یک سیستم طبقه‌بند ضعیف سطحی برابر نیم دارد (AUC=0.5). به طور کلی رابطه بین AUC و دقت تشخیص طبق

1- Cconfusion matrix

2- Receiver Operating Characteristic (ROC)

3- Sensitivity

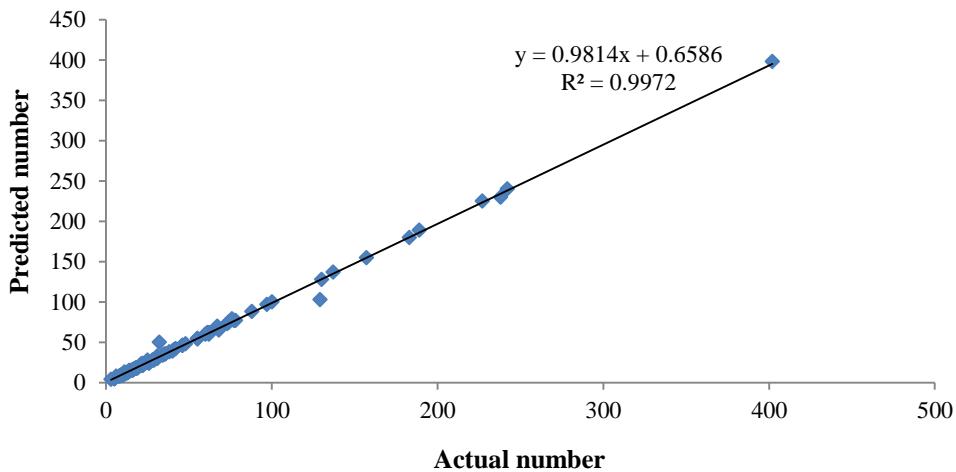
4- Specificity

5- Accuracy

6- Area under the curve (AUC)

بود. ضریب تعیین کیاٹو برای کل سفیدبالک‌ها 0.865 بود. همان‌طور که مشاهده می‌شود ضریب تعیین تحقیق حاضر ($R^2 = 0.9972$)، که روی کل کارت‌ها با تراکم‌های مختلف زنجرک پسته انجام گرفته است، بسیار بالاتر از ضریب تعیین کیاٹو می‌باشد.

(et al., 2008) که گروه‌ها براساس تعداد سفیدبالک‌های در دام افتاده: کمتر از 10 (تراکم کم)، 10 تا 50 (تراکم متوسط) و بیش از 50 (تراکم زیاد) تقسیم‌بندی شده بودند، ضریب تعیین (R^2) بین داده‌های برآورد شده و واقعی به ترتیب 0.98 و 0.96 برای گروه‌های با تراکم متوسط و زیاد بود. با این حال، در تراکم کم، ضریب تعیین (R^2) تنها 0.656 بود.



شکل ۴- نمودار رگرسیونی بین تعداد زنجرک‌های به دام افتاده مشاهده شده (محور افقی) و تعداد زنجرک‌های تشخیص داده شده به وسیله الگوریتم پردازش تصویر (محور عمودی)

Fig.4. Regression graph between number of *I. Stali* observed (horizontal axis) and number of *I. Stali* identified by image processing algorithm (vertical axis)

جدول ۳ مشاهده می‌گردد، حشره هدف که زنجرک پسته می‌باشد، دارای کمترین درصد تشخیص اشتباه ($2/60$ درصد) بوده و دقت طبقه‌بندی این الگوریتم، در صورتی که بخواهیم حشرات جذب شده روی کارت زرد را به سه دسته طبقه‌بندی نماییم، $91/53$ درصد می‌باشد، که دقت قابل قبولی است.

ماتریس اغتشاش و دقت طبقه‌بندی مربوط به داده‌های آزمون جهت بررسی عملکرد و کارآیی سیستم طبقه‌بند به ترتیب در شکل ۵ و جدول ۳ ارائه شده است. در جدول ۳ سه دسته زنجرک پسته، *Anthaxia Sp.* و اشیاء متفرقه وجود دارد که اشیاء متفرقه ممکن است حشرات متفرقه دیگر یا گرد و خاک باشند. همان‌طور که از

Confusion Matrix				
		Output Class	Target Class	
	1	1614 74.72%	40 1.85%	
		91 4.21%	330 15.28%	
	2	3 0.14%	15 0.69%	
		15 0.69%	75.69% 24.31%	
	3	6 0.28%	28 1.30%	
		33 1.53%	49.25% 50.75%	
		94.33% 5.67%	82.91% 17.09%	
		64.71% 35.29%	91.53% 8.47%	

شکل ۵- ماتریس اغتشاش بر روی مجموعه آزمون برای سه کلاس مختلف

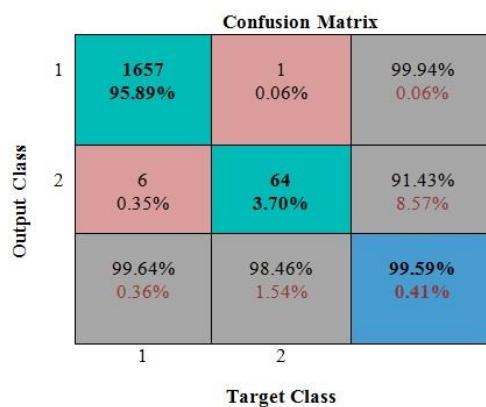
Fig.5. The confusion matrix on the test set for three different classes

جدول ۳- ماتریس اغتشاش و میزان دقت سیستم طبقه‌بندی بر روی مجموعه آزمون برای سه کلاس مختلف**Table 3-** The confusion matrix and accuracy level of the classification system on the test set for three different classes

Classes کلاس‌ها	<i>Idiocerus stali</i> زنجرک پسته	Miscellaneous objects اشیاء متفرقه	<i>Anthaxia Sp.</i> سوسک چوبخوار قرمز پسته	Total کل	Percentage of misdiagnosis درصد تشخیص اشتباه	Total percentage of correct diagnosis درصد کل تشخیص درست
<i>Idiocerus stali</i> زنجرک پسته	1614	40	3	1657	2.60	91.53
Miscellaneous objects اشیاء متفرقه	91	330	15	436	24.31	
<i>Anthaxia Sp.</i> سوسک چوبخوار قرمز پسته	6	28	33	67	50.75	

این تعداد حشره یعنی ۱۷۲۸ حشره به صورت تصادفی برای آزمون و اعتبارسنجی استفاده نمود. همان‌گونه که در شکل ۶ و جدول ۴ مشاهده می‌شود، درصد تشخیص اشتباه زنجرک پسته ۰/۰۶ درصد می‌باشد و دقت الگوریتم برای شناسایی زنجرک پسته در طبقه‌بندی داده‌ها به دو دسته، ۹۹/۵۹ درصد می‌باشد.

اما با توجه به این که هدف از این تحقیق شناسایی زنجرک پسته بود، لذا با استفاده از این الگوریتم داده‌ها به دو دسته حشره هدف یعنی زنجرک پسته و *Anthaxia Sp.*، طبقه‌بندی شدند. تعداد حشره زنجرک پسته روی کارت زرد ۴۱۴۹ عدد و حشره *Anthaxia Sp.* روی کارت زرد ۴۳۲۰ عدد بود که در مجموع ۴۳۶۹ حشره بودند و سیستم از ۴۰ درصد ۱۷۱



شکل ۶- ماتریس اغتشاش بر روی مجموعه آزمون برای دو کلاس مختلف
Fig.6. The confusion matrix on the test set for two different classes

جدول ۴- ماتریس اغتشاش و میزان دقت سیستم طبقه‌بندی بر روی مجموعه آزمون برای دو کلاس مختلف**Table 4-** The confusion matrix and accuracy level of the classification system on the test set for two different classes

Classes کلاس‌ها	<i>I. stali</i> زنجرک پسته	<i>Anthaxia Sp.</i> سوسک چوبخوار قرمز پسته	Total کل	Percentage of misdiagnosis درصد تشخیص اشتباه	Total percentage of correct diagnosis درصد کل تشخیص درست
<i>I. stali</i> زنجرک پسته	1657	1	1658	0.06	99.59
<i>Anthaxia Sp.</i> سوسک چوبخوار قرمز پسته	6	64	70	8.57	

در مقایسه این نتایج با نتایج تحقیق حیدری و امیری پریان (Heidari and Amiri Parian, 2019)، که ایشان در تحقیق خود سفیدبالک و تریپس را بهتریب با دقت $94/5$ و $87/4$ درصد شناسایی نمودند و این در حالی است که دقت تحقیق حاضر برای شناسایی زنجرک پسته، $99/59$ درصد می‌باشد.

جدول ۵ مقادیر حساسیت، خاصیت و دقت مربوط به سیستم طبقه‌بندی برای حالت دو کلاس را نشان می‌دهد. نحوه محاسبه مقادیر موجود در جدول ۵ با استفاده از روابط (۲) تا (۴) بوده که در آن‌ها، به عنوان مثال برای زنجرک پسته مقادیر TP برابر 1657 ، TN برابر 564 FN برابر 1 و FP برابر 6 از جدول ۴ به دست آمدند. همانطور که در جدول ۵ مشاهده می‌شود، نتایج نشان می‌دهد که روش هیبرید عصبی-ازدحام ذرات در شناسایی زنجرک پسته دارای حساسیت $99/94$ می‌باشد و این بدان معنی است که سیستم طراحی شده درصد $99/94$ حشره زنجرک پسته را درست تشخیص داده است. به طور کلی حساسیت بالا بین معنی است که نمونه‌های بیشتری به طور صحیح طبقه‌بندی شده‌اند. از طرفی خاصیت سیستم برای همین حشره برابر با $91/43$ به دست آمد و این بدان معنی است که سیستم طبقه‌بند فقط $8/57$ درصد حشره *Anthaxia Sp.* و نقاط سیاه رنگ ناشی از گرد و خاک روی کارت‌های زرد رنگ را به صورت اشتباه زنجرک پسته تشخیص داده است. در نهایت مشاهده می‌گردد که حشره زنجرک پسته با دقت $99/59$ درصد طبقه‌بندی شده است.

در مقایسه این نتایج با نتایج تحقیق چو و همکاران (Cho et al., 2007) مشاهده می‌شود که در کار ایشان که سه حشره مختلف سفیدبالک، شته و تریپس را مورد شناسایی قرار دادند و نرخ تشخیص الگوریتم بهتریب برابر با $93/83$ درصد، $92/73$ درصد و $88/9$ درصد بود و این در حالی است که نرخ تشخیص سیستم طبقه‌بند طراحی شده در تحقیق حاضر برای هر دو نوع حشره به دام افتاده یکسان و برابر $99/59$ درصد بود.

در مقایسه نتایج با تحقیق بویسارد و همکاران (Boissard et al., 2008) که ایشان از سیستم پردازش تصویر به صورت عکس‌برداری در محل و در شرایط نور طبیعی، برای شناسایی سفیدبالک استفاده نمودند، مشاهده می‌شود که دقت تشخیص الگوریتم شناسایی آن‌ها در مقایسه با شمارش چشمی، 83 درصد بود، در حالی که دقت تشخیص الگوریتم شناسایی تحقیق حاضر $99/59$ درصد می‌باشد.

در مقایسه این نتایج با نتایج تحقیق کیائو و همکاران (Qiao et al., 2008)، مشاهده می‌شود که در کار ایشان که داده‌ها را به سه زیردسته تقسیم کرده بود، برای دسته تراکم متوسط و زیاد نرخ تشخیص بهتریب برابر با $95/2$ و $94/6$ درصد بود. از طرفی در تراکم کم (کمتر از 10 حشره به دام افتاده)، نرخ تشخیص آن نیز $72/9$ درصد بود و این در حالی است که نرخ تشخیص سیستم طبقه‌بند طراحی شده در تحقیق حاضر برای تراکم‌های مختلف حشرات به دام افتاده یکسان و برابر $99/59$ درصد بود.

جدول ۵ - مقادیر حساسیت، خاصیت و دقت مربوط به سیستم طبقه‌بندی برای حالت دو کلاس

Table 5- The sensitivity, specificity and accuracy values of the classification system for the two classes

Classes کلاس‌ها	The hybrid method of ANN-PSO		
	Sensitivity حساسیت	Accuracy دقت	Specificity خاصیت
<i>I. stali</i> زنجرک پسته	99.94	99.59	91.43
<i>Anthaxia Sp.</i> سوسک چوب‌خوار قرمز پسته	91.43	99.59	99.94

جدول ۶ - مقادیر مربوط به معیارهای مختلف خطای درصد طبقه‌بندی صحیح و سطوح زیر منحنی ROC برای حالت ۲ کلاس

Table 6- The values for the different error criteria, the percentage of the correct classification and the Area under the ROC curve for the 2 classes

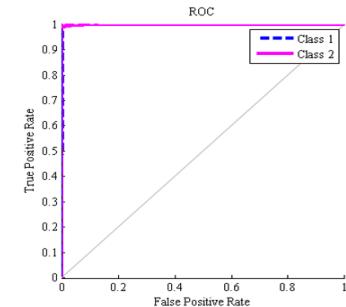
AUC(2)	AUC(1)	OCA	MAE	RMSE	MSE
۰.۹۹۹۶۲	۰.۹۹۹۶۹	۹۹.۵۹	۰.۰۱۳	۰.۰۵۹۸	۰.۰۰۳۶
۲	۱	کلی	مطلق	خطا	خطا

همانطور که در شکل ۷ مشاهده می‌شود هر دو کلاس با فاصله خیلی زیادی از نیمساز واقع شده‌اند، این بدان معنی است که سیستم طبقه‌بندی شبکه عصبی مصنوعی، هر دو کلاس را به خوبی طبقه‌بندی نموده است. معیارهای مختلف خطای درصد طبقه‌بندی صحیح و سطوح زیر منحنی ROC برای حالت ۲ کلاس مختلف نیز در جدول ۶ نشان داده شده است. همچنین در شکل ۷ و جدول ۶ سطح زیر منحنی در هر دو کلاس بسیار بیشتر از سطح بالای منحنی‌ها بوده و طبق جدول ۲ در ناحیه دقت تشخیص عالی می‌باشد و این یعنی طبقه‌بند شبکه عصبی مصنوعی با دقت بالا نمونه‌های هر دو کلاس را طبقه‌بندی کرده است. نتایج نشان می‌دهد که دقت طبقه‌بندی کلی^۵ برای دو کلاس مختلف ۹۹/۵۹ درصد می‌باشد. سایر معیارهای میانگین مربعات خطای (MSE)، ریشه میانگین مربعات خطای (RMSE) و میانگین خطای مطلق (MAE) نسبت به حالت سه کلاس بسیار پایین‌تر می‌باشد، که هر قدر این پارامترها کوچک‌تر باشند، نشان دهنده طراحی بهتر الگوریتم طبقه‌بندی می‌باشد.

نتیجه‌گیری

برای توسعه الگوریتم پردازش تصویر، جهت شناسایی زنجرک پسته، از خصوصیات رنگی و شکلی اشیاء (حشره زنجرک پسته و سایر حشره‌های غیر هدف و متفرقه) موجود در تصاویر مربوط به کارت زرد چسبناک، استفاده شد. از ۱۷ فضای رنگی، ۳۵۷ خصوصیت رنگی و ۲۰ خصوصیت شکلی برای شناسایی زنجرک پسته به وسیله الگوریتم پردازش تصویر، استخراج شد. از روش هیبرید شبکه عصبی مصنوعی - الگوریتم بهینه‌سازی ازدحام ذرات برای انتخاب خصوصیات مؤثر مثل شاخص رنگی برای پوشش گیاهی استخراجی مربوط به فضای رنگی HSL، شاخص تفاضل نرمال شده مربوط به فضای رنگی YCbCr، رنگی LCH، کanal خاکستری مربوط به فضای رنگی YCbCr، شاخص مؤلفه دوم منهای مؤلفه سوم مربوط به فضای رنگی YCbCr، مساحت و میانگین مؤلفه‌های اول، دوم و سوم فضای رنگی Luv. تحلیل منحنی ROC جهت مشخص کردن حساسیت و خاصیت سیستم طبقه‌بند به کار برده می‌شود. محور افقی این منحنی نرخ مثبت کاذب^۱ یا همان یک منهای خاصیت^۲ است و محور عمودی آن نرخ مثبت واقعی^۳ TPR یا همان حساسیت می‌باشد عبارت است از عنصر روی قطر فرعی^۴ تقسیم بر مجموع عناصر روی ردیف مربوطه در ماتریس اغتشاش. نرخ TPR برابر است با عنصر روی قطر اصلی برای هر کلاس که درست طبقه‌بندی شده، تقسیم بر مجموع عناصر روی ردیف مربوطه که برابر حساسیت است (Wisaeng, 2013). به تعداد کلاس‌ها منحنی وجود دارد. نمودار ROC مربوط به طبقه‌بندی شبکه عصبی مصنوعی برای دو کلاس در شکل ۷ نشان داده شده است.

همان‌گونه که در بخش مواد و روش‌ها ذکر گردید، از مجموع ۳۷۷ خصوصیت استخراجی از هر شیء، با استفاده از روش هیبرید شبکه عصبی مصنوعی - الگوریتم بهینه‌سازی ازدحام ذرات (PSO)، ۶ خصوصیت که میانگین مربعات خطای کمتری داشتند، به عنوان خصوصیات مؤثر انتخاب گردید و به عنوان ورودی شبکه عصبی مصنوعی برای طبقه‌بندی اعمال شدند. خصوصیات مؤثر عبارتند از: شاخص رنگی برای پوشش گیاهی استخراجی مربوط به فضای رنگی HSL، شاخص تفاضل نرمال شده مربوط به فضای رنگی LCH، کanal خاکستری مربوط به فضای رنگی YCbCr، شاخص مؤلفه دوم منهای مؤلفه سوم مربوط به فضای رنگی YCbCr، مساحت و میانگین مؤلفه‌های اول، دوم و سوم فضای رنگی Luv. تحلیل منحنی ROC جهت مشخص کردن حساسیت و خاصیت سیستم طبقه‌بند به کار برده می‌شود. محور افقی این منحنی نرخ مثبت کاذب^۱ یا همان یک منهای خاصیت^۲ است و محور عمودی آن نرخ مثبت واقعی^۳ TPR یا همان حساسیت می‌باشد عبارت است از (Panduranga Vitala et al., 2015).



شکل ۷- نمودار ROC مربوط به طبقه‌بندی شبکه عصبی مصنوعی برای ۲ کلاس مختلف، (کلاس ۱ Anthaxia Sp.، کلاس ۲ زنجرک پسته)

Fig.7. The ROC curve for Artificial Neural Network classification for two different classes, (Class 1 Anthaxia Sp., Class 2 *Idiocerus stali*)

1- False Positive Rate (FPR)
2- 1-specificity

3- True Positive Rate (TPR)
4- Non-diagonal elements

می‌تواند روی سیستم ماشین بینایی پیاده شود و در آینده در ساختمان ربات‌های کشاورزی از آن بهره گرفت.

چوب‌خوار قرمز پسته و سایر حشره‌های غیر هدف و مفترقه) و دو کلاس زنجرک پسته و *Anthaxia* Sp. بهترتب با دقیق ۹۱/۵۳ و ۹۹/۵۹ درصد را دارند. این امر بیانگر آن است که این الگوریتم

References

1. Baiocchi, D. 2013. The *Anthaxia* (*Anthaxia*) manca (Linnaeus, 1767) species-group in Iran, with description of a new species and a new synonymy (Coleoptera: Buprestidae). Zootaxa 3616: 455-481.
2. Barbedo, J. G. A. 2014. Using digital image processing for counting whiteflies on soybean leaves. Journal of Asia-Pacific Entomology 17: 685-694.
3. Boissard, P., V. Martin, and S. Moisan. 2008. A cognitive vision approach to early pest detection in greenhouse crops. Computers and Electronics in Agriculture 62: 81-93.
4. Cho, J., J. Choi, M. Qiao, C.-W. Ji, H.-Y. Kim, K.-B. Uhm, and T.-S. Chon. 2007. Automatic identification of whiteflies, aphids and thrips in greenhouse based on image analysis. International Journal of Mathematics and Computers in Simulation 7 (1): 46-53.
5. Espinoza, K., D. L. Valera, J. A. Torres, A. López, and F. D. Molina-Aiz. 2016. Combination of image processing and artificial neural networks as a novel approach for the identification of *Bemisia tabaci* and *Frankliniella occidentalis* on sticky traps in greenhouse agriculture. Computers and Electronics in Agriculture 127: 495-505.
6. FAO. 2017. Food and agriculture organization of the United Nations. Retrieved May 16, 2019; Available at: <http://fao.org/faostat/en/#data>.
7. Ghaiwat, S. N. and P. Arora. 2014. Detection and classification of plant leaf diseases using image processing techniques: A review. International Journal of Recent Advances in Engineering and Technology 2 (3): 1-7.
8. Gonzalez, R. C., and R. E. Woods. 2018. Digital Image Processing, 4th ed. Pearson, 1306 pp., New York, USA.
9. Gonzalez, R. C., R. E. Woods, and S. L. Eddins. 2004. Digital Image Processing Using MATLAB, (Second ed.). USA: Pearson Prentice Hall.
10. Heidari, A., and J. Amiri Parian. 2019. Identification and Counting of Two Important Greenhouse Pests by Image Processing, Case Study: Whitefly and Thrips. Journal of Agricultural Machinery 9 (2): 309-320. (In Persian).
11. Jalilvand, N. and S. Kashani-Zadeh. 2013. Study on the Biology of *Idiocerus stali* in Qazvin Climate. Agricultural Research and Natural Resources Journal 3 (15): 22-30. (In Persian).
12. Karbasi, A. R., and A. H. Taohidi. 2015. Factors Affecting Iranian Pistachio Export. Agricultural Economics Research 7 (1): 91-112. (In Persian).
13. Kazmi, W., F. J. Garcia-Ruiz, J. Nielsen, J. Rasmussen, and H. J. Andersen. 2015. Detecting creeping thistle in sugar beet fields using vegetation indices. Computers and Electronics in Agriculture 112: 10-19.
14. Kennedy, J., and R. Eberhart. 1995. Particle Swarm Optimization, 1942-1948 pp., Proceedings of the International Conference on Neural Networks, 27 Nov-1 Dec. 1995, Perth, Australia.
15. Kia, M. 2009. Neural Networks, (Second ed.) Tehran, Iran: Kian Rayaneh Sabz Publisher. 232 pp. (In Persian).
16. Mehrnejad, M. R. 2001. The current status of pistachio pests in Iran. In: Proceedings of the XI GREMPA Seminar on Pistachios and Almonds. (Cahiers Options Méditerranéennes; n. 56). Zaragoza: CIHEAM. pp. 315-322. Retrieved November 21, Available at: <http://om.ciheam.org/option.php?IDOM=769>.
17. Modarres Awal, M. 2009. Classification of insects, (1st ed.). Mashhad, Iran: Ferdowsi University Publisher. (In Persian).
18. Mozaffarian, F., and M. R. Wilson. 2016. A checklist of the leafhoppers of Iran (Hemiptera: Auchenorrhyncha: Cicadellidae). Zootaxa, 4062 (1): 1-63.
19. Panduranga Vitala, T., G. S. V. Prasada Rajub, K. Sreeramamurthy, and V. P. Venkata Charan. 2015. A Probabilistic Neural Network Approach for Classification of Datasets Collected From North Coastal Districts of AP, India Using MatLab 715-721 pp., Proceedings of the International Conference on Computer, Communication and Convergence (ICCC 2015), Odisha, India.
20. Qiao, M., J. Lim, C. W. Ji, B. K. Chung, H. Y. Kim, K. B. Uhm, C. S. Myung, J. Cho, T. S. Chon, D. Herák, A. K., A. Sedláček, and G. Gürdil. 2008. Density estimation of *Bemisia tabaci* (Hemiptera: Aleyrodidae) in a greenhouse using sticky traps in conjunction with an image processing system. Journal of Asia-Pacific Entomology 11: 25-29.
21. Šimundić, A. M. 2009. Measures of Diagnostic Accuracy: Basic Definitions. The Journal of the International Federation of Clinical Chemistry and Laboratory Medicine (EJIFCC) 19: 203-211.
22. Solomon, C., and T. Breckon. 2011. Fundamentals of Digital Image Processing. (First ed.). West Sussex, UK: John Wiley & Sons, Ltd, Publication, 328 pp.
23. Wisaeng, K. 2013. A Comparison of Decision Tree Algorithms for UCI Repository Classification. International Journal of Engineering Trends and Technology (IJETT) 4: 3393-3397.