

## مقاله پژوهشی

## تشخیص آفت سوسک چهار نقطه‌ای حبوبات توسط تکنیک پردازش تصویر و شبکه عصبی مصنوعی

سامان سجادیان<sup>۱</sup>، داود محمدزمانی<sup>۱\*</sup>، سید محمد جاویدان<sup>۲</sup>

۱- گروه مهندسی بیوسیستم، دانشگاه آزاد اسلامی واحد تاکستان، تاکستان، ایران ۲- دانشگاه تربیت مدرس، گروه مکانیک بیوسیستم، تهران، ایران  
(تاریخ دریافت: بهمن ۱۳۹۸؛ تاریخ پذیرش: خرداد ۱۳۹۹)

## چکیده

با توجه به سرعت و دقت بالای تشخیص هوشمند آفات در محصولات انباری، در این پژوهش تشخیص آفت سوسک چهار نقطه‌ای حبوبات توسط تکنیک پردازش تصویر با بهره‌گیری از شبکه‌های عصبی مصنوعی انجام شده است. برای تهیه تصاویر مناسب، جعبه‌های شیشه‌ای تهیه و دانه‌های نخود در مرکز جعبه قرار داده شد. سپس از شش وجه به آن نور تابانده و از تمامی وجوه توسط یک دوربین دیجیتال، از آن عکسبرداری انجام شد. سپس ویژگی تصاویر شامل بافت و لبه‌ها توسط موجک گابور با بکارگیری نرم‌افزار MATLAB استخراج و به‌عنوان داده‌های آموزشی به شبکه عصبی مصنوعی معرفی شدند. برای آموزش شبکه از ۶۹ تصویر نخود آسیب دیده توسط سوسک چهارنقطه‌ای حبوبات و ۵۹ نخود سالم استفاده شد. سپس برای ارزیابی شبکه، یک دسته از داده‌ها که در آموزش شبکه هیچ نقشی نداشته‌اند به عنوان داده‌های آزمون، به شبکه اعمال شد و نتایج آن بررسی شد. در این پژوهش از شبکه‌های عصبی پرسپترون و المن استفاده شد که شبکه پرسپترون نتایج بهتری نسبت به شبکه المن داشت. روش پیشنهادی با ۶/۱۷ درصد خطای عدم تشخیص و ۴/۸۶ درصد خطای تشخیص اشتباه، توانست با نرخ بالایی نخودهای آسیب دیده را آشکارسازی نماید. پس از پردازش تصویر توسط شبکه عصبی و تشخیص نقاط آسیب، میزان آسیب محصول نیز محاسبه شد. بدین منظور، سطح آسیب تشخیص داده شده محاسبه و مقدار آن بر مساحت سطح کل دانه نخود تقسیم و درصد آسیب دانه‌ها برابر با ۲/۳ درصد برآورد شد.

واژه‌های کلیدی: پردازش تصویر، سوسک چهار نقطه‌ای، شبکه عصبی مصنوعی

**Detection of *Callosobruchus maculatus* F. with image processing and artificial neural network**S. SAJADIAN<sup>1</sup>, D. MOHAMMADZAMANI<sup>1\*</sup>, S. M. JAVIDAN<sup>2</sup>

1. Department of Biosystems Engineering, Islamic Azad University, Takestan Branch, Takestan, Iran; 2. Department of Biosystems Engineering, Tarbiat Modares University, Tehran, Iran

**Abstract**

Due to the high speed and accuracy of intelligent pest detection in warehouse products, in this study, the detection of chickpea four-point beetle pest was simulated by image processing technique using artificial neural networks. To prepare the images, a glass box was prepared and the chickpea seeds were placed in the center of the box. The light was then illuminated from all six sides and photographed with a digital camera from all sides. The image properties were then extracted by Wavelet Gabor using MATLAB software and applied to the ANN as training data. To train the network, 69 images of chickpeas damaged and 59 healthy chickpeas were used. Then, to evaluate the network, a set of data that did not play a role in network training as test data was applied to the network and its results were evaluated. In this study, Perceptron and Elman neural networks were used which had better results than Elman network. The proposed method was able to detect the high rate of damaged with 6.17% non-detection error and 4.86% error-detection error. After image processing by the neural network and detection of damage points, the amount of crop damage was also calculated. For this purpose, the level of detected damage was calculated and divided by the area of total area of chickpea seed and percentage of damage. After identifying the injury sites, the damage was estimated 2.3% in the studied images.

**Keywords:** Artificial neural network, bean, *Callosobruchus Maculatus* F., image processing

## مقدمه

تغذیه لارو آفت موجب ایجاد حفره داخل دانه‌ها شده و علاوه بر کاهش وزنی دانه‌ها، موجب می‌شود تا بازار پسندی دانه‌ها به شدت کاهش یابد. در ایران نیز این آفت از مناطق مختلف کشور گزارش شده است (Shahkarami et al., 2004). بیشترین خسارت آفت مربوط به تغذیه لاروهاست که با تغذیه از مواد غذایی درون دانه خسارت قابل توجهی به محصولات وارد می‌سازد. فناوری ماشین بینایی قادر است به‌طور خودکار آفات محصولات را تشخیص، تفکیک و طبقه‌بندی (وجود یا عدم وجود آفت یا آسیب) کند. طراحی و کاربرد این فناوری‌ها بطور عمده به کاهش کاربرد مواد شیمیایی و کاهش هزینه‌های پرسنلی و افزایش حاصلخیزی و کیفیت محصول کمک می‌کند. امروزه بکارگیری فناوری ماشین بینایی و تکنیک‌های پردازش تصویر کاربرد گسترده‌ای در صنعت و کشاورزی پیدا کرده است (Daneshmand Vaziri et al., 2017).

در پژوهشی، نرم‌افزاری برای تشخیص آفات برنج با استفاده از تصاویر آفات ارائه شد. در پژوهش مذکور برای شناسایی نقاط آلوده گیاه از رشد تصاویر و روش‌های تقسیم‌بندی تصویر استفاده شده است. نقشه‌های خود سازمان یافته و شبکه‌های عصبی برای شناسایی آفات برنج مورد استفاده قرار گرفته و در نهایت با استفاده از روش طبقه‌بندی اوتسو محل آسیب به برگ طبقه‌بندی شده است (Pour Hossein, 2011). در پژوهشی به بررسی امکان استفاده از شبکه حسگر بی‌سیم (WSN) و پردازش تصویر در دیده‌بانی و تشخیص به موقع آفت مگس سفید گلخانه پرداخته شده و برای این منظور تعداد ۳۷۵۰ تصویر از ۱۵ تله چسبی نصب شده در گلخانه‌ای با محصول طالبی که به مگس سفید آلوده بوده تهیه و به صورت خودکار با استفاده از WSN و به صورت بی‌سیم به رایانه واقع در فاصله ۹۰۰ متری از گلخانه انتقال یافته و تصاویر رنگی تله‌های چسبی که به کمک ۱۵ دوربین تصویربرداری تهیه شده‌اند با استفاده از نرم‌افزار MATLAB به تصاویر خاکستری تبدیل شده و بعد از بخش‌بندی توسط

یکی از شایع‌ترین مشکلاتی که در زمینه ضرر و زیان به محصولات کشاورزی وجود دارد، گسترش آفات انباری می‌باشد که باعث از بین رفتن برخی از محصولات کشاورزی در مرحله پس از برداشت می‌شود. کارشناسان حوزه کشاورزی با چشم غیر مسلح و گاه با استفاده از استریومیکروسکوپ به شناسایی آفات انباری و مبارزه با آنها اقدام می‌کنند، اما این کار علاوه بر اینکه هزینه و نیروی انسانی زیادی را می‌طلبد بازده کاملاً مطلوبی در شناسایی و از بین بردن آفات کشاورزی ندارد. کم توجهی به اصول نگهداری فرآورده‌های کشاورزی گاهی زیان‌های کیفی مهمی را نیز به همراه دارد. این زیان معمولاً با تغییر ترکیب شیمیایی، رنگ و مزه محصول همراه است که نه تنها باعث کاهش ارزش تجاری و مرغوبیت آن می‌شود، بلکه از ارزش غذایی آن نیز کاسته می‌شود (Arbab, 2011).

حبوبات منبعی از کربوهیدرات، کلسیم، آهن و به‌ویژه پروتئین می‌باشند و حبوبات بعد از غلات دومین منبع غذایی بشر محسوب می‌شوند (Bagheri Zenuz, 1996) سوسک چهارنقطه‌ای حبوبات *Callosobruchus maculatus* F. به‌عنوان یکی از اصلی‌ترین عوامل خسارت‌زا روی این محصولات می‌باشد. این آفت بومی آفریقا بوده ولی امروزه در تمام دنیا به‌خصوص مناطق گرمسیری و نیمه‌گرمسیری خسارت قابل توجهی به محصولات انباری وارد می‌نماید (Bagheri Zenuz, 1996). میزان خسارت ناشی از این آفت روی حبوبات قابل توجه است و هر ساله بیش از ۳۰ درصد نخود ایران در اثر خسارت ناشی از سوسک چهار نقطه‌ای و سایر سوسک‌های خانواده Bruchidae از بین می‌رود (Taheri, 1995). همه‌جازی بودن و پراکنش وسیع این آفت باعث خسارت چشمگیر آن در سرتاسر جهان شده است، در نتیجه کنترل آن ضروری به نظر می‌رسد.

سوسک چهار نقطه‌ای حبوبات کلیدی‌ترین آفت لوبیا چشم بلبلی و ماش در مرحله پس از برداشت نیز می‌باشد.

درصد، در حالی که نرخ مدل برای گونه‌ها به ترتیب ۹۴/۱۷ و ۸۶/۸۸ درصد بوده است (Cao *et al.*, 2014). در پژوهشی دیگر به تکنیک‌های پردازش تصویر برای تشخیص شکل حشرات در محصولات زراعی پرداخته شده، در این مطالعه از تکنیک-های پردازش تصویر دیجیتال برای تصاویر حشرات در محصولات زراعی استفاده و مراحل پردازش، تقسیم‌بندی و استخراج ویژگی‌ها برای تشخیص شکل حشرات موجود در محصولات نیشکر انجام شده است. تشخیص لبه، برای تقسیم تصاویر حشرات در برابر پس زمینه استفاده و در استخراج ویژگی، شکل حشره با نه ویژگی شکل هندسی قابل تشخیص بوده. این روش شناسایی شکل حشرات، به خوبی عمل کرده و برای حشرات فعال در مزرعه نیشکر با شکل‌های گرد (دایر، بیضی، مثلث و مستطیل) با دقت بالایی عمل کرده (Thenmozhi, 2017). در پژوهشی دیگر از طبقه‌بندی کننده با رگرسیون کمینه مربعات جزئی (pls) یا یک شبکه عصبی برای طبقه‌بندی ۱۱ گونه حشرات در آفات اولیه و ثانویه محصولات انباری با دقت ۹۶ درصد استفاده شده، در حالی که در طبقه‌بندی ۱۱ حالت دقت از ۳۰ تا ۱۰۰ درصد متغیر بوده است. این مطالعات نشان داد که بینایی دستگاه و طیف سنجی NIR، همراه با روش تشخیص الگو، ابزاری مناسب برای تشخیص دقیق حشرات هستند (Dowell *et al.* 2019).

هدف از پژوهش حاضر، ارائه یک الگوریتم با دقت بالا به منظور تشخیص آفت سوسک چهار نقطه‌ای حبوبات به کمک پردازش تصویر بود. با بکارگیری نتایج تصاویر پردازش شده در ماشین بینایی برای تشخیص و کنترل آفت با ارائه الگوریتمی که قادر به تجزیه و تحلیل تصاویر جمع‌آوری شده در کوتاه‌ترین زمان ممکن باشد می‌توان به درصد خسارت ناشی از این حشره پی برد.

#### مواد و روش‌ها

در صورت حمله سوسک چهار نقطه‌ای حبوبات، بر سطح دانه‌های نخود حفره‌هایی ظاهر می‌شود. تشخیص وجود یا

الگوریتم ماشین بردار پشتیبان (SVM) و براساس ویژگی‌های تصاویر، به دو دسته تصاویر دارای آفت مگس سفید و فاقد مگس سفید طبقه‌بندی شده‌اند. با ارزیابی سامانه، مشخص شده که دقت الگوریتم SVM برای طبقه‌بندی تصاویر تله‌های چسبی ۹۷/۷۳ درصد و میانگین مقادیر شاخص‌های آماری ماتریس اغتشاش برای ۱۵ تله چسبی شامل حساسیت، صحت، اختصاصی بودن و دقت طبقه‌بندی به ترتیب ۹۸/۴۶، ۸۶/۳۱، ۹۹/۰۸ و ۹۷/۷۲ درصد و میانگین دقت کلی سامانه در تشخیص و شمارش تعداد مگس‌های سفید به دام افتاده در تله‌های چسبی ۹۷/۷۱ درصد بوده است. (Daneshmand Vaziri *et al.*, 2017). در پژوهشی دیگر تشخیص آلودگی ناشی از *Callosobruchus maculatus* در لوبیا با استفاده از تصویربرداری به روش طیف‌سنجی انجام شده و با استفاده از یک سامانه تصویربرداری مادون قرمز (NIR) در ناحیه طول موج ۱۰۰۰-۱۶۰۰ نانومتر در فواصل ۱۰ نانومتر تصویربرداری و طول موج مربوط به بالاترین بارگذاری فاکتورهای اصلی (۱۱۰۰، ۱۲۹۰ و ۱۴۵۰ نانومتر) معنی‌دار در نظر گرفته شده است. میانگین دقت طبقه‌بندی بیش از ۸۲ و ۸۵ درصد با استفاده از طبقه‌بندی کننده‌های آماری برای شناسایی دانه‌های غیر آلوده و آلوده ماش به دست آمده و. نتایج بدست آمده نشان داده که هسته لوبیای مونگ در مرحله سفیره و بزرگسالی، دارای درجه‌بندی بالاتری نسبت به مراحل تخم و مراحل لاروی با استفاده از هر دو طبقه‌بندی بوده‌اند (Kaliramesh *et al.*, 2012). در پژوهش دیگر با هدف تجزیه و تحلیل تصویر چند متغیره به تشخیص حشرات موجود در برنج و ذرت اقدام شده و برای این منظور تصاویر گرفته شده از حشرات پردازش و ۲۲ ویژگی ریخت‌شناسی و بافتی از مناطق مورد علاقه به عنوان ورودی برای یک مدل شناسایی استخراج شده است. مدل شبکه عصبی پس انتشار به عنوان روش برتر برای تمایز بین این گونه‌ها از حشرات ارائه شده و میزان کل شناسایی مدل طبقه‌بندی گونه‌های حشرات برای مجموعه‌های واسنجی و پیش‌بینی به ترتیب ۱۰۰ و ۹۸/۱۳

عدم وجود این حفره‌ها در تصاویر دانه‌ها و نیز درصد آنها معیاری از احتمال حمله این آفت و شدت آسیب ناشی از آن خواهد بود. روش پیشنهادی برای تشخیص شدت خسارت ناشی از آفت سوسک چهار نقطه‌ای حبوبات در تصاویر دیجیتال، شامل دو بخش است. بخش اول شامل یافتن پنجره‌هایی در تصاویر دیجیتال است که احتمال وجود آسیب نخود در آنها بیشتر است که در ادامه چگونگی یافتن این پنجره‌ها شرح داده خواهد شد. در تکنیک پردازش تصویر، هر پنجره با مرکز آن شناخته می‌شود. خروجی بخش اول تعدادی نقطه می‌باشد که تصور می‌شود در آنها آسیب وجود دارد. به این نقاط مراکز نادقیق گفته می‌شود زیرا این پنجره‌ها یا شامل آسیب نمی‌باشند و یا مکان آنها با دانه‌های نخود واقعی در تصویر اندکی تفاوت دارد. در اینجا دومین بخش وارد عمل شده که الگوریتم جستجوی فضای اطراف مرکز نادقیق می‌باشد. در این الگوریتم برای اکتشاف فضا، به سبب یافتن دقیق آسیب دانه‌های نخود به ابزاری نیاز است که پنجره‌ها را به منظور وجود و عدم وجود آسیب نخود آزمایش کند. این ابزار همانند تابعی عمل می‌کند که پنجره را به عنوان ورودی دریافت کرده و هر چه مقدار بازگردانده شده از آن بزرگتر باشد، احتمال وجود یک آسیب در مرکز پنجره بیشتر است. این ابزار یک شبکه عصبی است که به کمک پنجره‌های دارا و یا فاقد آسیب نخود آموزش دیده است.

#### تعیین نادقیق محل آسیب

اهداف از این بخش تعیین نادقیق پنجره‌هایی است که امکان وجود آسیب دانه نخود در آنها وجود دارد. یک تصویر بزرگ شامل هزاران پنجره است. زیرا که اگر پنجره‌ها با مرکز آن که یک پیکسل است، شناخته شود، با تقریب بدون در نظر گرفتن حاشیه‌ها می‌توان به تعداد پیکسل‌های تصویر پنجره دست یافت. مشکل، تعداد زیاد پنجره‌ها است. با حجم عملیاتی که روی هر پنجره صورت می‌گیرد، امکان پردازش همه پنجره‌ها در زمان مطلوب وجود ندارد. با توجه به آنکه نمی‌توان از اطلاعات رنگ نخود بهره برد، لذا ایده اصلی،

بکارگیری ضرایب همبستگی است. همبستگی برابر است با حرکت دادن پنجره بر روی تصویر و ضرب داخلی آنها برای تعیین نقاط نادقیق. ابتدا فرآیند متعادل سازی هیستوگرام روشنایی روی تصویر ورودی انجام شد. این کار به منظور ایجاد بیشترین کنتراست ممکن، انجام شد. سپس نتیجه با پنجره‌ای از تصویر آسیب دانه نخود دلخواه ضرب شده که در نواحی مشکوک به حضور آسیب، ضرایب بزرگتری به وجود می‌آیند. با استخراج این بیشینه‌های محلی، دسته نقاط اولیه به عنوان مراکز نادقیق پنجره‌های محتمل به وجود آسیب دانه نخود به دست می‌آیند.

#### اکتشاف اطراف مراکز نادقیق

مراکز نادقیق به دست آمده در بخش قبل که مرکز پنجره‌های مستطیلی می‌باشند، یا به طور کل شامل دانه نخود نمی‌باشند و یا مرکز پنجره‌ها بر روی نقاط آسیب دانه نخود در تصویر منطبق نمی‌باشند. برای رفع این مشکل، الگوریتمی نیاز است که فضای اطراف این مراکز نادقیق را در صورت لزوم برای یافتن بهترین پاسخ وجود آسیب دیدگی نخود بررسی نمود. در این الگوریتم ابتدا مراکز نادقیق جهت ارجاع به شبکه علامت‌گذاری شدند و تا زمانی که مرکزی برای آزمون یافت نشود، مراکز علامت‌گذاری شده به شبکه عصبی ارجاع داده شد. در صورتیکه شبکه عصبی برای هر مرکز مقداری بزرگتر از آستانه را بازگرداند، پیکسل‌های کناری را در صورتی که علامت‌گذاری نشده اند، علامت بگذارد. با استفاده از این الگوریتم، فقط نواحی لازم مورد بررسی قرار گرفتند و صرفه‌جویی زیادی در زمان آشکارسازی نقاط آسیب دانه‌های نخود صورت گرفت. شکل ۱ مراکز بررسی شده توسط شبکه عصبی را نمایش می‌دهد.

در شکل ۱ نقاط سبز و قرمز به ترتیب نقاطی هستند که مقداری بالاتر و پایینتر از مقدار آستانه (۰/۶) را توسط شبکه برگردانده‌اند. در نواحی بررسی شده (نواحی سبز) تنها یک مرکز به عنوان مرکز پنجره حاوی آسیب نخود انتخاب می‌شود و این مرکز بزرگترین مقدار بازگردانده شده از شبکه عصبی را

$$(\psi_{\mu, \nu}(z) * O_{\mu, \nu}(z)) = I(z) \quad (1)$$

که در آن \* بیانگر عملگر کانولوشن، O نتیجه تبدیل،  $\psi$  موجک به کار رفته در تبدیل با جهت  $\mu$  و بزرگنمایی  $\nu$  است. معادله موجک گابور در حقیقت گویای یک موج ساده صفحه‌ای با فرکانس و جهت مشخص است که در زیر یک تابع گوسی به دام افتاده است. این معادله به شکل‌ها و فرم‌های مختلف بسته به نوع سامانه مختصات اعم از قطبی یا دکارتی می‌تواند تعریف شود و رابطه (۲) مرسوم‌ترین شکل نمایش موجک گابور در مقالات علمی است (Zhu et al., 2010).

$$\psi_{u,v}(z) = \frac{\|k_{u,v}\|^2}{\delta^2} \exp\left(\frac{-\|k_{u,v}\|^2 \|z\|^2}{2\delta^2}\right) \left(e^{ik_{u,v}z} - e^{-\frac{\delta^2}{2}}\right) \quad (2)$$

در رابطه (۲)، K بیانگر طول و جهت موج و  $\delta$  انحراف معیار است و از روابط (۳) محاسبه می‌شود:

$$\phi_v = \mu \frac{\pi}{8}, \quad k_v = \frac{k_{ma}}{f_v}, \quad k_{\mu, \nu} = k_v e^{i\phi_\mu} \quad (3)$$

همانگونه که از رابطه (۳) معلوم است،  $\mu$  در  $\pi/8$  ضرب شده و فاز عدد K را ساخته است، بنابراین مقداری صحیح از ۰ تا ۷ خواهد داشت. مقادیر بزرگتر، موجی با جهات تکراری تولید می‌کنند.  $\nu$  هم می‌تواند مقداری بین ۰ تا ۴ داشته باشد و در مجموع چهل موجک با جهات و اندازه‌های متفاوت از این رابطه ۳ به دست می‌آید. برای درک تحلیلی بهتر از این موجک، یکی از اعضای این خانواده با ابعاد  $128 \times 128$  و پارامترهای  $\nu=7$ ،  $\mu=4$ ،  $\pi=kma$ ،  $\delta=2\pi$  در شکل ۲ نشان داده شده است.




شکل ۲- نمایش یکی از اعضای خانواده موجک گابور بصورت الف:

دوبعدی ب: سه بعدی.

Fig. 2. Representation of a member of the Gabor wavelet family as right: 2D, left: 3D.

دارا بوده و از مقدار آستانه نیز بزرگتر می‌باشد. شبکه عصبی هر نقطه آسیب دانه نخود را با یک نقطه مشخص می‌کند. وقتی صحبت از ارجاع پنجره به شبکه عصبی می‌شود، این عمل به طور مستقیم صورت نمی‌پذیرد. بلکه در این میان یک طبقه برای استخراج ویژگی‌های پنجره وجود دارد و این بردار ویژگی‌ها هستند که برای وجود یا عدم وجود آسیب دانه‌های نخود به شبکه عصبی می‌روند. این ویژگی‌های استخراج شده هستند که تشخیص آسیب را نسبت به تغییرات نور محیط مقاوم می‌گرداند. در مرحله استخراج ویژگی، از تبدیل موجک گابور استفاده شد. تبدیل موجک گابور نیز مانند سایر تبدیل موجک‌های مختلف به علت خواص منحصر به فرد خود در حوزه‌هایی از پردازش تصویر و ماشین بینایی بکار گرفته شده است. فیلتر گابور یکی از ابزارهای شناخته شده‌ای است که می‌تواند برای استخراج ویژگی تصویر بکار گرفته شود. این موجک‌ها زمینه‌ای برای درک فرکانس تصاویر و تحلیل آنها در حوزه مکان فراهم کرده‌اند و بزرگترین مزیت آنها تغییرات آرام در حوزه فرکانس است. توابع دو بعدی و پرکاربرد گابور لبه اشکال، همچنین گودی‌ها و برآمدگی‌های تصویر را تقویت می‌کند. اگر تصویر ورودی با مقادیر شدت نور سطوح خاکستری باشد، تبدیل موجک تصویر طبق رابطه (۱) از کانولوشن یکی از اعضای خانواده موجک با تصویر ورودی I(z) محاسبه می‌شود (Zhu et al., 2010).




شکل ۱- مراکز بررسی شده توسط شبکه عصبی.

Fig. 1. Centers examined by the neural Network.


روش یادگیری پس انتشار خطا با ۴۲۰ نرون در لایه اول، ۲۰۰ نرون در لایه دوم و یک نرون در لایه سوم استفاده شد. تابع انتقال نرون‌ها tan-sig در نظر گرفته شده است که خروجی آن بین اعداد -۱ تا +۱ تغییر می‌کند که این تابع در شکل ۴ نشان داده شده است.

برای تعیین تعداد نرون‌های لایه میانی از کمترین مقدار میانگین مربعات خطا استفاده شده است. شکل ۵ ساختار شبکه پرسپترون به کار رفته شده در این پژوهش را نشان می‌دهد. شبکه‌های عصبی از نظر آموزش به دو بخش با نظارت و بدون نظارت تقسیم می‌شوند. در این پژوهش از شبکه عصبی با نظارت استفاده شده است. تعدادی تصویر شامل دانه‌های



شکل ۳- همه موجک‌های خانواده تبدیل گابور به کار گرفته شده در پژوهش.

Fig. 3. All Gabor transforms family waves used in the research.



$$a = \text{tansig}(n)$$

شکل ۴- تابع tan-sig (Minhaj, 2018).

Fig. 4. Tan-sig function (Minhaj, 2018).

همانگونه که از شکل ۲ بر می‌آید، موجک گابور موجی صفحه‌ای با دامنه کاهشی است. شکل ۳ همه موجک‌های به کار گرفته شده در این پژوهش را نشان می‌دهد که چهار موجک می‌باشند که چهار عدد از این موجک‌ها در آن دو بار تکرار شده‌اند. پس از معرفی موجک‌های گابور، حال به نحوه استخراج ویژگی از دانه نخود آسیب دیده پرداخته می‌شود. پنجره‌ای از تصویر که قرار است در مورد آسیب بودن آن تصمیم‌گیری شود قبل از هر چیز از نظر هیستوگرام سطوح خاکستری متعادل می‌شود. در قدم بعدی تبدیل فوریه آن در تبدیل‌های فوریه موجک‌های گابور ضرب می‌شود.

سپس تبدیل معکوس فوریه از ۴۰ تصویر به دست آمده، در کنار هم قرار گرفته و در حقیقت ماتریس ویژگی‌های پنجره مورد نظر را می‌سازند. در اینجا اگر پنجره ورودی مستطیلی به ابعاد ۱۸×۲۷ باشد، آنگاه ماتریس ویژگی‌ها از رابطه ۴ به دست می‌آید.


$$(4) \quad (18 \times 27) \times 40 = 19440$$

برای طبقه‌بندی ویژگی‌های به دست آمده به دو کلاس دانه نخود سالم و آسیب دیده، از شبکه‌های عصبی مصنوعی استفاده شده است. برای انتخاب و طراحی شبکه عصبی مناسب، عوامل زیادی دخیل هستند. سه نمونه از مهمترین آنها، زمان پاسخگویی، حجم محاسبات و قابلیت تعمیم است. قابلیت تعمیم بدین معنی است که شبکه با تعداد محدود و اندکی از داده‌های آموزشی که در اینجا بردارهای دانه نخود سالم و آسیب دیده است، آموزش داده می‌شود و انتظار می‌رود که شبکه بتواند در مقابل بردارهایی که قبلاً آنها را مشاهده نکرده، پاسخ مطلوبی ارائه دهد. پس از استخراج ویژگی از پنجره‌های ارجاع شده به شبکه، داده‌ها در قالب یک بردار با ۱۹۴۴۰ در خواهند آمد.

برای انتخاب مناسب‌ترین شبکه و نیز تعیین تعداد لایه‌ها و نرون‌ها؛ زمان پاسخگویی، حجم محاسبات و قابلیت تعمیم از مهمترین معیارها می‌باشد. بر این اساس و با بررسی دو شبکه المن و پرسپترون، از شبکه عصبی پرسپترون سه لایه با


## نتایج و بحث

طرح‌واره شبکه عصبی پرسپترون سه لایه شبیه‌سازی شده در نرم افزار MATLAB در شکل ۶ نمایش داده شده است.



شکل ۶- طرح‌واره شبکه عصبی پرسپترون.

Fig. 6. Perceptron Neural Network Schematic.




شکل ۷- نمودار آموزش شبکه پرسپترون.

Fig. 7. Perceptron network training diagram.

این شبکه با استفاده از تصاویر آموزشی و الگوریتم Levenberg-marquardt مورد آموزش قرار گرفت که نمودار آموزش آن در تصویر ۷ ارائه شده است. آنگونه که از این نمودار بر می‌آید، این شبکه به‌خوبی آموزش دیده و پس از گذراندن ۵۷ دوره آموزش به عملکرد معین شده رسیده است. شکل ۸ تعداد دوره آموزش، زمان آموزش و عملکرد شبکه پس از آموزش را نشان می‌دهد.


همانگونه که در شکل ۸ مشخص است، شبکه پرسپترون تحت آموزش پس از گذراندن ۵۷ دوره به عملکرد ۴-۱۰×۱ رسیده است. طرح‌واره شبکه عصبی المن سه لایه شبیه‌سازی شده در نرم افزار MATLAB را در شکل ۹ نمایش داده شده است.

نخود سالم و دانه‌های آسیب دیده و همچنین پاسخ‌های مطلوب آنها نیز به شبکه اعمال می‌شوند، سپس شبکه به کمک الگوریتم پس انتشار خطا وزن‌های خود را با توجه به داده‌های آموزشی تنظیم می‌نماید. بدین ترتیب که تصاویر دانه‌های نخود که از کیفیت ۱۸×۲۷ همانند ابعاد پنجره‌ها، برخوردارند تک به تک به قسمت استخراج ویژگی فرستاده شده و پس از استخراج ویژگی به برداری با ۱۹۴۴۰ عنصر تبدیل شدند. سپس یک ماتریس بزرگ که هر ستون آن بردار ویژگی یکی از تصاویر آموزشی است به همراه جواب مطلوب هر ستون که به ازای بردارهای دانه‌های آسیب دیده معادل ۰/۹ و به ازای بردارهای دانه‌های سالم ۰/۹- است جهت آموزش شبکه به کار گرفته شد. برای تهیه تصاویر مناسب، جعبه‌ای شیشه‌ای تهیه شده و دانه‌های نخودها در مرکز جعبه قرار داده شد. سپس از شش وجه به آن نور تابانده و از تمامی وجوه از آن عکسبرداری انجام شد. برای آموزش شبکه از ۶۹ تصویر دانه نخود آسیب دیده و ۵۹ دانه سالم استفاده شد. در آموزش شبکه‌های عصبی هرچه تعداد داده‌های آموزشی بیشتر باشد، نتایج خروجی برنامه دقیق‌تر است. شبکه عصبی آنچه را که مشاهده می‌کند در قالب پارامترهای درونی خود به‌خاطر می‌سپارد. در واقع، تکرار هر یک از مشاهدات موجب تغییر پارامترهای درونی شبکه در جهت حفظ روابط حاکم بر مشاهدات است که با توجه به تعداد دوره آموزش، زمان و عملکرد شبکه‌های به کار رفته پس از آموزش، صحت و دقت این انتخاب‌ها بررسی شد.



شکل ۵- ساختار شبکه پرسپترون استفاده شده در این پژوهش.

Fig. 5. Perceptron Network Structure Used in This Study.



شکل ۱۱- تعداد دوره آموزش و عملکرد شبکه المن پس از آموزش.


**Fig. 11.** Number of training courses and performance of elman network after training.

همانگونه که در شکل ۱۱ مشخص است، شبکه عصبی المن تحت آموزش پس از گذراندن ۱۰۰ دوره آموزش نتوانسته به عملکرد مورد نظر برسد و عملکرد نهایی این شبکه ۱۶/۴ درصد بوده است.

همانگونه که اشاره شد در این پژوهش، دو شبکه عصبی پرسپترون و المن شبیه‌سازی و آموزش داده شد تا از بین آنها بهترین شبکه برای به کارگیری در روش پیشنهادی انتخاب گردد. نتایج حاصل از آموزش این دو شبکه در جدول ۱ ارائه شده است.


آن‌گونه که در جدول ۱ مشخص است، شبکه پرسپترون به عملکرد تعیین شده ۴-۱۰ رسیده است اما شبکه المن به عملکرد تعیین شده نرسیده است. از آنجایی که رسیدن به نرخ عملکرد تنها عامل تعیین بهترین شبکه نیست، باید این دو شبکه را مورد آزمایش قرار داد تا مشخص گردد کدام شبکه در عمل بهتر است و نقاط ضعف و قوت هر شبکه چیست. لذا برای اینکه بتوان به نتیجه‌گیری بهتری برای انتخاب شبکه رسید، این دو شبکه با به‌کارگیری روش پیشنهادی برای تشخیص آسیب دانه‌های نخود در ۲۰ تصویر مورد آزمایش قرار گرفته اند که نتایج حاصل از آن در جدول ۲ ارائه شده است.

در جدول ۲ خطای عدم تشخیص، نقاط آسیبی است که توسط شبکه تشخیص داده نشده است و خطای تشخیص اشتباه نقاطی هستند که به اشتباه آسیب تشخیص داده شده‌اند. همانگونه که از نتایج پیداست، شبکه پرسپترون عملکرد بهتری نسبت به شبکه المن داشته است. لذا شبکه پرسپترون برای بکارگیری روش پیشنهادی بهتر از شبکه المن است.



شکل ۸- تعداد دوره آموزش، زمان و عملکرد شبکه پرسپترون پس از آموزش.


**Fig. 8.** Number of training courses, time and performance of perceptron network after training.



شکل ۹- طرح‌واره شبکه عصبی المن.

**Fig. 9.** Elman neural network schematic.

این شبکه پس از شبیه‌سازی توسط تصاویر آموزشی و الگوریتم Levenberg-marquardt تحت آموزش قرار گرفت که نمودار آموزش این شبکه در شکل ۱۰ ارائه شده است.



شکل ۱۰- نمودار آموزش شبکه المن.

**Fig. 10.** Elman network training chart.

همانگونه که از نمودار آموزش شبکه بر می‌آید، این شبکه نتوانسته پس از طی ۱۰۰ دوره آموزش به عملکرد تعیین شده ۴-۱۰ برسد. شکل ۱۱ تعداد دوره آموزش گذرانده شده و میزان عملکرد شبکه پس از آموزش را نشان می‌دهد.



در روش پیشنهادی، پس از پردازش تصویر توسط شبکه عصبی و تشخیص نقاط آسیب، میزان آسیب محصول محاسبه شده است. بدین منظور، سطح آسیب تشخیص داده شده محاسبه شد و مقدار آن را بر مساحت سطح کل نخود تقسیم و در نهایت درصد آسیب مشخص شد. پس از تشخیص نقاط آسیب، میزان آسیب در نمونه مورد بررسی، ۲/۳ درصد برآورد گردید.

### نتیجه‌گیری

در این پژوهش، روشی برای تشخیص آسیب سوسک چهارنقطه‌ای به دانه‌های نخود و محاسبه میزان آسیب پیشنهاد و ارائه شد. به‌کارگیری روش‌های غیرمخرب، غیرتماسی و سریع در تشخیص و ردیابی بیماری‌ها و آفات محصولات زراعی دارای مزایای گسترده‌ای همچون هزینه کم، دقت بالا، کاهش آسیب ناشی از اقدام تشخیصی زمان‌بر و در نهایت اقدامات پیشگیرانه مناسب خواهد بود. تکنیک بکار رفته در این پژوهش قادر است بدون نیاز به نمونه‌برداری از محصول انبار شده، بلکه فقط با عکسبرداری در محل، امکان تشخیص سریع و دقیق آفت سوسک چهارنقطه‌ای حبوبات بر محصول نخود فراهم آورد. اگرچه روش‌های غیرمخرب دیگری همچون بکارگیری امواج فراصوت نیز در این زمینه کاربرد دارد اما برتری اصلی روش پیشنهادی عدم نیاز به تجهیزات اندازه‌گیری آکوستیکی است چرا با هر نوع وسیله عکسبرداری می‌توان نمونه عکس‌های مورد نیاز برای نرم‌افزار تشخیصی ارائه شده در این پژوهش مبتنی بر شبکه عصبی پرسپترون چند لایه را تهیه کرد. لذا با توجه به نتایج حاصله از این پژوهش، و نیز با توجه به عدم نیاز روش پیشنهادی به سخت افزارهای خاص و نیز سهولت بکارگیری این روش می‌توان نتیجه گرفت که روش ارائه شده می‌تواند روشی کارآمد برای آشکارسازی آسیب به دانه‌های نخود ناشی از حمله سوسک چهارنقطه‌ای حبوبات و محاسبه میزان آسیب آن باشد.

شبکه پرسپترون خطای کمی (۶/۱۷ درصد خطای عدم تشخیص و ۴/۸۶ درصد خطای تشخیص اشتباه) داشته و توانست با نرخ بالایی نخودهای آسیب دیده را آشکارسازی نماید. این آشکارسازی بطور متوسط برای هر تصویر یک دقیقه و چهل ثانیه زمان لازم داشته است. در شکل ۱۲، یکی از تصاویر پردازش شده توسط شبکه پرسپترون نمایش داده شده است.

جدول ۱- نتایج حاصل از آموزش دو شبکه منتخب.


Table 1- Results of training of two selected networks.

Network type	Number of training courses	Function
Perceptron	57	0.459
Elman	100	16.4

جدول ۲- نتایج آزمایش دو شبکه منتخب بر روی ۲۰ تصویر دانه نخود.

Table 2. Test results of two selected networks on 20 pea seeds images.

Network type	Lack of diagnosis	Misdiagnosis error
Perceptron	2	3
Elman	6	5



شکل ۱۲- تصویر پردازش شده توسط شبکه عصبی پرسپترون.  
Fig. 12. Image Processed By the Perceptron Neural Network.

پس از انتخاب شبکه پرسپترون به‌عنوان بهترین شبکه عصبی و الگوریتم Levenberg-marquardt به‌عنوان الگوریتم یادگیری شبکه برای این مساله خاص، می‌توان بهترین توپولوژی از لحاظ تعداد نرون‌های لایه میانی را تعیین نمود. برای این منظور از روش کمینه مقدار میانگین مربعات خطا استفاده شده است؛ بدین صورت که یک نمودار میله‌ای براساس تعداد نرون‌ها و میانگین مربعات خطای (MSE) نتایج حاصل از شبکه رسم شده است و تعداد نرون‌هایی که دارای کمینه مقدار MSE بوده، به‌عنوان مقدار بهینه تعداد نرون‌ها انتخاب شد.

## References

- ARBAB, A., 2011. Agronomy of Agricultural Crops and their Management, Islamic Azad University Press.
- BAGHERI ZENUZ, E. 1996. Pests of warehouse products and methods of control, Publisher Sepehr. P:328
- CAO, Y., ZHANG, C., CHEN, Q., LI, Y., QI, S., TIAN, L., and REN, Y. 2014. Identification of species and geographical strains of *Sitophilus oryzae* and *Sitophilus zeamais* using the visible/near-infrared hyperspectral imaging technique. Pest Management Science, 71(8), 1113–1121.
- DANESHMAND VAZIRI, M., RAJABIPOUR, A., OMID, M. 2017. Investigate the possibility of using the Wireless Sensor Network (WSN) and image processing in surveillance and timely detection of greenhouse whitefly pests. Iranian Biosystems Engineering. 49. N: 3.
- DOWELL FE., THRONE JE, WANG D. and BAKER JE, 2019. Identifying stored grain insects using near infra red spectroscopy. Journal of Economic Entomology 92: 165–169.
- KALIRAMESH, S., CHELLADURAI, V., JAYAS, D. S., ALAGUSUNDARAM, K., WHITE, N. D. G., and FIELDS, P. G. 2013. Detection of infestation by *Callosobruchus maculatus* in mung bean using near-infrared hyperspectral imaging. Journal of Stored Products Research, 52, 107–111. doi: 10.1016/j.jspr.2012.12.005.
- MINHAJ, M.B. 2018. Fundamentals of neural networks. Amirkabir University publisher. p 716.
- POUR HOSSEIN, A., 2011. Application of image processing in plant pest identification.
- KHADEMI, M. and DAVOOD JAFARI, 1383. Digital Image Processing, Ferdowsi University of Mashhad Publications.
- SHAKARAMI, J. KAMALI, K. MOHARRAMIPOUR, S. and MESHKATASSADT. M. H. 2004. Effects of Three Plant Essential Oils on Biological Activity of *Callosobruchus maculatus* F. (Coleoptera: Bruchidae). Iranian Journal of Agricultural Science Vol. 35, No. 4.
- TAHERI, M. S. 1995. Study of food preference and comparison of life cycle of cowpea weevils on various Iranian peas. Applied Entomology and Phytopathology 63 (1, 2), 1- 8. [In Persian with English Summary.
- THENMOZHI, K., and REDDY, U.S. 2017. Image processing techniques for insect shape detection in field crops. 2017 International Conference on Inventive Computing and Informatics (ICICI), 699-704.
- WEISSY, H., 2009. Neural Networks, Architecture of Algorithms and Applications, Nas Publishing.
- ZHU, Z., ZANG, Y., SHEN, B., XUECHENG ZHOU, and Luo, X. 2010. Detection of cowpea weevil (*Callosobruchus maculatus* (F.)) in soybean with hyperspectral spectrometry and a backpropagation neural network. 2010 Sixth International Conference on Natural Computation. doi:10.1109/icnc.2010.5583638