

مقایسه عملکرد الگوریتم‌های مختلف یادگیری شبکه عصبی در پیش‌بینی الگوی توزیع سفید بالک پنبه *Bemisia tabaci* در خیارکاری‌های بهبهان

علیرضا شعبانی نژاد^۱ و بهرام تفاق‌دینی‌نیا^{۲*}

۱. دانشجوی سابق کارشناسی ارشد حشره‌شناسی، دانشکده کشاورزی، دانشگاه شاهرود، شاهرود

۲. استادیار، گروه گیاه‌پزشکی سازمان پژوهش‌های علمی و صنعتی ایران، تهران

(تاریخ دریافت: ۱۳۹۵/۷/۲۴ - تاریخ پذیرش: ۱۳۹۶/۵/۱۰)

چکیده

امروزه تشریح الگوهای پراکندگی حشرات با استفاده از روش‌های درون‌یابی و برآورد تراکم به‌منظور بررسی امکان مدیریت و کنترل متناسب با مکان آن‌ها مورد توجه بسیاری از محققان قرار گرفته است. این پژوهش به‌منظور ارزیابی قابلیت الگوریتم‌های مختلف شبکه عصبی پرسپترون چندلایه‌ای (MLP) در درون‌یابی و برآورد جمعیت سفید بالک پنبه در نقاط نمونه‌برداری نشده و نیز ترسیم نقشه پراکنش آن انجام شد. برای ارزیابی قابلیت الگوریتم‌های مختلف شبکه عصبی MLP از میانگین مربعات خطا و ضریب تبیین استفاده شد و برای ارزیابی شبکه با الگوریتم مطلوب از مقایسه فراسنجه (پارامتر)هایی مانند میانگین، واریانس، توزیع آماری و نیز ضریب تبیین رابطه خطی رگرسیونی بین مقادیر پیش‌بینی‌شده توسط شبکه عصبی با الگوریتم یادگیری مطلوب و مقادیر واقعی آن‌ها استفاده شد. نتایج نشان از عملکرد مطلوب شبکه عصبی با الگوریتم لونیگ-مارکوات و نرخ یادگیری ۰/۲۶، عامل مومنتوم ۰/۷۵ و شمار یازده نرون در لایه میانی و همچنین نبود تفاوت معنی‌داری بین مقادیر ویژگی‌های آماری (میانگین، واریانس) و توزیع آماری مجموعه داده‌های پیش‌بینی‌شده تراکم آفت و میزان واقعی آن بود. به عبارتی شبکه عصبی مصنوعی با الگوریتم لونیگ-مارکوات به‌خوبی توانست مدل داده‌های تراکم سفید بالک پنبه را بیاموزد. نقشه به‌دست‌آمده از درون‌یابی نشان داد، این آفت توزیع تجمعی داشته و لذا امکان کنترل مناسب با مکان آن در مزرعه مورد بررسی وجود دارد.

واژه‌های کلیدی: توزیع مکانی، درون‌یابی، سفید بالک پنبه، شبکه عصبی.

Comparing the performance of different learning neural network algorithms to predict distribution pattern of *Bemisia tabaci* in cucumber fields of Behbahan

Alireza Shabaninejad¹ and Bahram Tafaghodiniya^{2*}

1. Former M. Sc. Student of Entomology, Faculty of Agriculture, Shahrood University, Shahrood, Iran

2. Assistant Professor of Entomology, Iranian Research Organization for Science and Technology, Iran

(Received: Oct. 15, 2016 - Accepted: Aug. 1, 2017)

ABSTRACT

Today, describing the distribution patterns of insects using interpolation and estimation methods in order to explore the possibility of proportional control where they has gained the attention of many researchers. This study was performed to evaluate the MLP neural network algorithms and interpolation of population estimates of *B. tabaci* in areas not sampled and mapped its distribution. Information density of this pest was obtained by sampling in cucumber field of Behbahan. For evaluating ability of different neural network algorithms we used, mean square error and coefficient of determination and to evaluat the network with optimal algorithm we utilized a comparisson of parameters such as mean, variance, statistical distribution and the determination coefficients of linear regression between predicted values by the neural network and actual values. Results showed optimum performance of neural network white Levenberg-Marquardt algorithms was in Learning rate 0.26, Momentum Factor 0.75 and 11 neuron in hidden layer and no significant difference between the values of statistical characteristics (mean, variance) and differences in the statistical distribution of predict and the actual pest density. In other words, an artificial neural network with Levenberg-Marquardt could well learn whitefly density data model. Map of interpolation showed that the pest had cumulative distribution and proved possibility of site-specific pest control on this field.

Keywords: *B. tabaci*, interpolation, neural network, spatial distribution.

* Corresponding author E-mail: tafaghodinia@gmail.com

مقدمه

خیار (*Cucumis sativus* L.) با ۱۴ کروموزوم، گیاه یک‌ساله دوجنسی و متعلق به تیره کدوسانان (Cucurbitaceae) است. این گیاه بومی کشور هندوستان است و به‌عنوان اقتصادی‌ترین گیاه تیره کدوسانان، یکی از محصولات ارزشمند سبزی و جالیز در خاورمیانه به‌شمار می‌رود (Nario *et al.*, 2010). سطح زیر کشت و میزان تولید این محصول در ایران، به ترتیب ۸۰۰۰۰ هکتار و ۱۴۰۰۰۰ تن است که اغلب در نظام‌های کشت صحرایی و گلخانه‌ای تولید می‌شود (Anonymous, 2011). خیار آفات و بیماری‌های پرشماری دارد که یکی از آفات مهم آن، سفید بالک پنبه (*Bemisia tabaci* Gennadius) (Hem.:Aleyrodidae) است که افزون بر خیار به حدود ۲۰۰ گیاه زراعی و صیفی در بیشتر مناطق جهان به‌ویژه در نواحی گرم، معتدل و خشک آسیب و زیان وارد می‌کند. حشرات بالغ و پوره‌های این آفت با تغذیه از شیرۀ گیاهی سبب کاهش عملکرد محصول می‌شوند (Shishehbor, 2001). این آفت به‌صورت غیرمستقیم نیز با تولید عسلک، سبب چسبندگی ذرات گردوغبار به سطح برگ‌ها شده و میزان نورساخت (فتوسنتز) را کاهش می‌دهد. عسلک ناشی از این آفت موجب جلب قارچ‌های پوده‌رست (ساپروفیت) موسوم به کپک سیاه یا دوده (مانند *Capnodium* spp) می‌شود که منجر به تضعیف گیاه و ایجاد لکه‌های رنگ‌پریده روی اندام‌های مختلف گیاه می‌شود (Gerling, 1990). سفیدبالک پنبه ناقل بیماری‌های ویروسی چندی مانند موزاییک خیار است که آسیب و زیان جبران‌ناپذیری به گیاه وارد می‌کند (Yang *et al.*, 2010).

برای تدوین برنامه‌های مدیریت تلفیقی این آفت مهم، آگاهی از تغییرپذیری جمعیت آن در مزرعه در طی زمان ضروری است (Garzia *et al.*, 2011). به همین خاطر امروزه تحقیقات زیادی در مورد تهیه و استفاده از نقشه‌های توزیع آفات با استفاده از مدل‌سازی پویایی جمعیت آفات به‌منظور به‌کارگیری در مدیریت متناسب با مکان در حال انجام است (Dille *et al.*, 2003). اما آنچه رسیدن به این هدف‌ها را محقق می‌سازد افزایش درستی و دقت روش‌های

درون‌یابی و تهیه نقشه‌های کاربردی از جمعیت آفات است. درون‌یابی مکانی شامل برآورد متغیرهایی مانند تراکم آفت مورد نظر، در نقاط نمونه‌برداری نشده با استفاده از داده‌های به‌دست‌آمده از نقاط نمونه‌برداری شده است. به عبارتی یک روش درون‌یابی مطلوب می‌تواند با استفاده از داده‌های مربوط به تراکم آفات در شمار نقاط محدود نمونه‌برداری شده (دارای مشاهده)، تراکم آفت را در نقاط نمونه‌برداری نشده به‌درستی برآورد کند (Makarjian, 2008). بررسی‌های چندی نشان داده است، شبکه‌های عصبی توانایی بالایی در تشخیص الگوهای توزیع مکانی و تراکم جمعیت‌های بوم‌شناختی (اکولوژیکی) دارند (Goel *et al.*, 2006; Irmak *et al.*, 2003). در پژوهشی مدل شبکه عصبی بردار چندی ساز یادگیر^۱ برای بررسی توزیع مکانی حشرات در اراضی مرتعی استفاده شد و کارایی مطلوبی نشان داد (Zhang *et al.*, 2008). در پژوهشی از شبکه عصبی مصنوعی ترکیب‌شده با الگوریتم ژنتیک برای پیش‌بینی الگوی پراکنش کنه تارتن دو لکه‌ای در مزرعه خیار استفاده شد که نتایج کارایی بسیار بالای این شبکه را نشان داد (Shabani *et al.*, 2017) و از (nejad *et al.*, 2017) نیز به ارزیابی مدل شبکه عصبی بردار چند ساز یادگیر LVQ4 در تشخیص پراکندگی شب‌پره مینوز گوجه‌فرنگی پرداختند که نتایج کارایی بالای این روش را در مزرعه گوجه‌فرنگی نشان داد. بنا به بررسی‌های انجام شده، تاکنون پژوهشی به‌منظور ارزیابی الگوریتم‌های یادگیری مختلف شبکه عصبی مصنوعی در راستای تحقق برنامه مدیریت این آفت، در مزرعه خیار صورت نگرفته است. به همین دلیل، این تحقیق با هدف شناخت وضعیت پراکنش این آفت در مزرعه خیار شهرستان بهبهان انجام شد. به نظر می‌رسد که با تعیین مسیرهای ورود و خروج این حشره به مزرعه بهتر بتوان از عامل‌های کنترل‌کننده طبیعی و یا سموم در کنترل آفت در کانون‌های آلودگی بهره گرفت.

مواد و روش‌ها

به منظور انجام این پژوهش یک مزرعه خیار به مساحت یک هکتار در اطراف شهرستان بهبهان در محدوده جغرافیایی بین ۴۷ درجه و ۴۱ دقیقه تا ۵۰ درجه و ۳۹ دقیقه طول شرقی از نصف‌النهار گرینویچ و ۲۹ درجه و ۵۸ دقیقه تا ۳۳ درجه و ۴ دقیقه عرض شمالی از خط استوا، انتخاب شد. برای نشانه‌گذاری موقعیت مکانی نقاط نمونه برداری پس از مشخص کردن برای شمال زمین، نقطه‌ای در حاشیه جنوبی زمین به عنوان مبدأ مختصات مشخص شد. مزرعه به شبکه‌های ۱۰ متری تقسیم و در مجموع صد نقطه برای زمین مشخص شد در همه نقاط نمونه برداری یک بلوک ۲×۲ مترمربع انتخاب و درون آن شمار چهار بوته به صورت تصادفی به عنوان واحد نمونه برداری انتخاب، و شمار آفت‌های موجود در قسمت‌های پشت برگ گیاه شمارش و ثبت شد.

پیش‌پردازش داده‌ها

در آغاز داده‌ها به طور تصادفی به دودسته مجموعه آموزش با ۷۰ عضو و مجموع آزمایش با ۳۰ عضو تقسیم‌بندی شد. البته اگر این تقسیم‌بندی منجر به نتایج مطلوب نشود، می‌توان این مرحله را دوباره تکرار کرد (Zhang et al., 1998). پیش از به‌کارگیری داده‌های خام اولیه در آموزش شبکه، باید داده‌ها در دامنه مناسبی عادی‌سازی (نرمالیزه) شوند زیرا الگوریتم یادگیری همراه با داده‌های خام نمی‌تواند عملکرد مناسبی داشته باشند بنابراین برای تبدیل داده‌ها از روش عادی‌سازی خطی (رابطه ۱) استفاده شد (Makarjian et al., 2007):

$$x_n = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \times (\Gamma_{\max} - \Gamma_{\min}) + \Gamma_{\min} \quad (1)$$

در اینجا x داده خام اولیه، x_n داده عادی‌سازی شده، x_{\min} و x_{\max} به ترتیب مقادیر بیشینه و کمینه داده‌های اولیه، Γ_{\min} و Γ_{\max} هم به ترتیب حد بالایی و پایینی دامنه تغییرپذیری داده‌های تبدیل شده است.

از شبکه عصبی MLP با هدف طبقه‌بندی سطح مزرعه به دو کلاس استفاده شد که به ترتیب به کلاس اول و دوم ۹۱ و ۹ عضو تعلق گرفت و به صورت کامل

تصادفی، ۷۰ درصد از کل داده‌ها برای آموزش شبکه و ۳۰ درصد باقی‌مانده برای آزمایش شبکه به منظور طبقه‌بندی انتخاب شد.

شبکه عصبی پرسپترون چندلایه

بر پایه قضیه تقریب عمومی، شبکه عصبی با یک لایه مخفی و با شمار کافی نورون در آن لایه قادر به تقریب هر تابع پیوسته دلخواه است (Gutierrez et al., 2008). بنابراین یک لایه مخفی برای شبکه عصبی انتخاب شد. ساختار شبکه MLP با یک لایه مخفی در شکل ۱ نشان داده شده است. شبکه MLP با دریافت بردار ورودی X_q بردار خروجی Z_q برای هر q ($q=1, \dots, Q$) تولید خواهد کرد. هدف اتخاذ فرانسجه (پارامتر)های درست شبکه، به منظور دستیابی به خروجی واقعی Z_q که تا حد ممکن نزدیک به خروجی مطلوب d_q متناظر با خود باشد (Makarjian et al., 2007). برای آموزش شبکه از الگوریتم‌های گرادیان نزولی با مومنتم^۱، لونیبرگ-مارکواریت^۲ و گرادیان نزولی^۳ استفاده شد.

تنظیم فرانسجه‌های شبکه


لایه ورودی شامل ۳ نورون است زیرا ورودی‌های شبکه شامل عامل بایاس و مختصات مکانی سفید بالک پنبه است. تعیین الگوی انشعاب‌های (توپولوژی) بهینه، شمار نورون‌ها در لایه مخفی شبکه از روش آزمون سعی و خطا به دست آمد. اگر شمار نورون‌ها در لایه مخفی کافی نباشد، شبکه قادر به یادگیری خوب نخواهد شد. ولی در شمار بسیار زیاد آن هم مسئله بیش برآزشی^۴ پیش خواهد آمد که این حالت منجر به تضعیف تعمیم‌پذیری شبکه می‌شود (Wang & Elhag, 2007).

ماتریس اغتشاش ابزاری سودمند برای تحلیل چگونگی عملکرد روش دسته‌بندی در تشخیص داده‌ها یا مشاهده‌های دسته‌های مختلف است. اگر داده‌ها در m دسته قرار گرفته باشند. یک ماتریس دسته‌بندی، جدولی با کمترین اندازه $M \times M$ است. عنصر C_{ij} در i

1. Gradient Descent with Momentum
2. Levenberg - Marquardt
3. Conjugate Gradient
4. Over-fitting

مشاهده‌ها روی قطر اصلی ماتریس قرار گرفته باشند و دیگر مقادیر ماتریس صفر یا نزدیک به صفر باشند. ماتریس ممکن است سطر یا ستون اضافه داشته باشد که نشان‌دهنده مجموعه عناصرها یا درصد شناخت است (Hudaib & Cooke, 2005).

امین سطر و z امین ستون، نشان‌دهنده شمار مشاهده‌هایی از دسته i است که توسط روش دسته‌بندی به‌عنوان دسته z تشخیص داده شده است. برای اینکه یک روش دسته‌بندی، درجه درستی بالایی داشته باشد، حالت مطلوب آن است که بیشتر داده‌های مرتبط به



شکل ۱. ساختار شبکه MLP با یک لایه مخفی (Vakil-Baghmisheh & Pavešicmm, 2003)

Figure 1. Configuration of the MLP with one hidden layer (Vakil-Baghmisheh & Pavešicmm, 2003)

نتایج و بحث

مقایسه ارزیابی الگوریتم‌های مختلف

برای ارزیابی قابلیت الگوریتم‌های مختلف شبکه عصبی MLP از میانگین مربعات خطا و ضریب تبیین استفاده شد. بنابر نتایج جدول ۱ از میان الگوریتم‌های به‌کاررفته برای آموزش شبکه عصبی، الگوریتم لونیبرگ-مارکوات با کمترین میزان میانگین مربعات خطا و بیشترین ضریب تبیین به‌عنوان الگوریتم مناسب انتخاب شد. نتایج به‌دست‌آمده از پژوهش Zhang *et al.* (2008) بیان‌کننده قابلیت شبکه عصبی مصنوعی MLP با الگوریتم لونیبرگ-مارکوات در تشخیص پراکندگی حشرات مرتعی بود و همچنین Shafie *et al.* (2011) از شبکه عصبی مصنوعی برای پیش‌بینی بارش اسکندریه مصر استفاده کردند که نتایج نشان از کارایی شبکه عصبی مصنوعی با الگوریتم لونیبرگ-مارکوات در مقایسه با مدل رگرسیون چند متغیره داشت.

در این تحقیق داده‌های به‌دست‌آمده از نمونه‌برداری به دو گروه تقسیم شدند که گروه اول با ۹۱ عضو و گروه دوم با ۹ عضو است. از آنجایی که در این تحقیق دودسته وجود دارد، ماتریس 2×2 تعریف می‌شود. در این تحقیق از مفاهیمی استفاده شده که به توضیح آن‌ها می‌پردازیم. عنصر (مثبت درست (TP)) به مشاهده‌هایی از دسته اول دلالت دارد که توسط روش دسته‌بندی به‌درستی تشخیص داده شده است. عنصر (منفی درست (TN)) به مشاهده‌هایی از دسته دوم اطلاق می‌شود که توسط روش دسته‌بندی تشخیص داده شده است. به‌طور همسان (منفی نادرست (FN)) مشاهده‌هایی از دسته اول است که توسط روش دسته‌بندی به نادرستی در دسته دوم قرار گرفته و (مثبت نادرست (FP)) مشاهده‌هایی از دسته دوم است که به نادرستی در دسته اول قرار گرفته‌اند. به‌منظور ارزیابی کیفیت سه روش دسته‌بندی از شاخص دقت (نرخ تشخیص) رابطه (۲) استفاده می‌کنیم.

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

جدول ۱. مقایسه عملکردی الگوریتم‌های مختلف یادگیری شبکه عصبی MLP

Algorithm	Number of neurons	Learning rate	Momentum Factor	Epoch	Coefficient determination	Mean Square Error
Momentum	19	0.37	0.89	14000	0.71	0.070
Levenberg - Marquardt	11	0.26	0.75	12000	0.80	0.086
Conjugate Gradient	14	0.29	0.83	13000	0.78	0.079

شبکه از نظر آماری با هم مقایسه شدند. در اینجا فرض صفر بر تساوی میانگین، واریانس و توزیع آماری دلالت دارد. هر فرضیه در سطح احتمال ۹۵ درصد به کمک فراسنجه p آزمون شد. اگر میزان P محاسبه شده بیشتر از 0.05 باشد فرض صفر را نمی توان رد کرد. به ترتیب برای مقایسه میانگین، واریانس و توزیع آماری از آزمون F ، t و کولموگروف-اسمیرنو استفاده شد. مقادیر P محاسبه شده برای هر مورد در جدول ۳ نشان داده شده است. نتایج نشان می دهد، بین میانگین، واریانس و توزیع آماری برای شبکه عصبی مصنوعی اختلاف معنی داری را نشان نمی دهد. وجود $P > 0.05$ در مورد توزیع آماری بین مقادیر پیش بینی شده و مقادیر واقعی تراکم سفید بالک پنبه در سطح مزرعه، نشان از دقت بالا و نیز قابلیت شبکه عصبی مصنوعی MLP به منظور طبقه بندی سطح مزرعه از نظر تراکم این آفت با هر میزان تراکم بحرانی است.

خطای تشخیص شبکه عصبی با الگوریتم لوبنرگ-مارکوات

خطای تشخیص شبکه عصبی مصنوعی در دو مرحله یادگیری و آزمایش در جدول ۲ نشان داده شده است، خطای شبکه در تراکم های مختلف متفاوت است. در بررسی الگوی پراکنش حشرات در پژوهش Zhang *et al.* (2008) خطای تشخیص برای تراکم های خاص حشرات برابر با صفر بود. زیرا حشرات مرتعی تحرکات بیشتری به جهت به دست آوردن غذای کافی داشته و تا حدودی یک پراکنش یکنواختی دارند. ماده های بالغ سفیدبالک پنبه با تغذیه از شیرۀ گیاه و نداشتن تحرک زیاد در زمین زراعی باعث افزایش خطای تشخیص شبکه عصبی شده است.

برای اطمینان از یادگیری شبکه عصبی آموزش دیده برای پیش بینی الگوی پراکنش سفید بالک پنبه، داده های واقعی و پیش بینی شده توسط

جدول ۲. خطای تشخیص شبکه عصبی MLP در دو مرحله آموزش و آزمایش

Table 2. Recognition error of MLP neural network in training and test phases

Members of class 1	Recognition error in training phase (%)	Recognition error in test phase (%)	Member of class 2	Recognition error in training phase (%)	Recognition error in test phase (%)	Total recognition error in training phase (%)	Total recognition error in test phase (%)
91	3.5	9.3	9	13.6	15.03	11.2	15

جدول ۳. مقایسه آماری مقادیر واقعی و پیش بینی تراکم سفیدبالک پنبه توسط شبکه عصبی MLP

Table 3. Statistical comparisons between the observed and estimated cotton whitefly density by MLP neural networks

Utilization phase	Comparisons of means	Comparisons of variance	Comparisons of distribution
Training Phase	0.866	0.815	0.87
Test Phase	0.898	0.625	0.63

در پژوهشی که منظور تعیین الگوهای پراکنش حشرات در یک مرتع با شبکه عصبی انجام شد، نتیجه این بود که شبکه عصبی MLP، LVQ و خطی می توانند به خوبی الگوهای توزیع حشرات را تشخیص دهند. اما در بین شبکه های یاد شده شبکه های MLP قوی ترین الگوریتم در تشخیص الگوها را داشت (Zhang *et al.*, 2008) و همچنین نتایج پژوهش Yeong *et al.* (2000) بیانگر کارایی بالای شبکه عصبی مصنوعی MLP در پیش بینی پویایی جمعیت مگس گالزا (Diptera: Cecidomyiida) در جنگل های سوزنی برگ آمریکا بود. نتایج به دست آمده از دو

همان گونه که در جدول ۴ نشان داده شده است ماتریس اغتشاش دقت طبقه بندی را نمایش می دهد و خلاصه عملکرد طبقه بندی با شبکه عصبی مصنوعی ارائه می شود (Hagan *et al.*, 1996). در این جدول طیف طبقه بندی بر ازای دو گروه نشان داده شده است.

جدول ۴. ماتریس اغتشاش

Table 4. Confusion Matrix

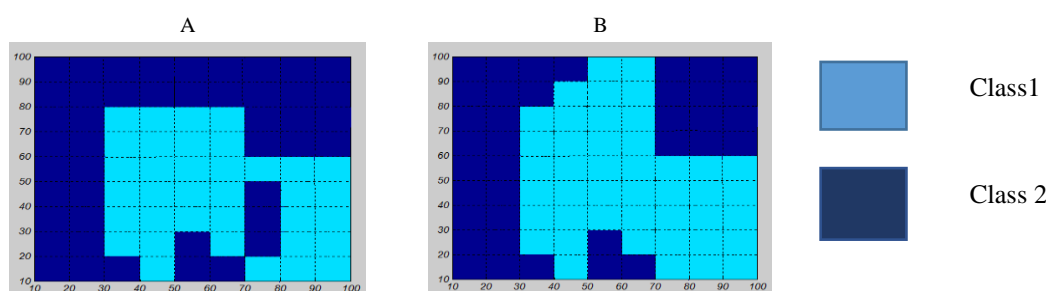
Class 1	85	6	95.3
Class 2	6	3	96.8
	91.3	91.6	90.71
Class 1	Class 1		

پژوهش یادشده با نتایج به دست آمده از این پژوهش هماهنگی داشت.

نقشه‌های توزیع مکانی سفیدبالک پنبه

نقشه پراکندگی مکانی سفیدبالک پنبه توسط شبکه عصبی جداسازی و ترسیم شده و در شکل ۲ نشان داده شده است. در مقایسه نقشه‌های جداسازی شده توسط مدل شبکه عصبی و نقشه‌های واقعی بخش‌های شمالی و جنوبی زمین آفت داشتند که توسط شبکه عصبی قابل پیش‌بینی نبود. در مقایسه سه مدل شبکه عصبی برای تعیین الگوهای پراکندگی حشرات در سطح یک چمنزار، بیان کردند که شبکه عصبی MLP الگوریتم قوی‌تری در تشخیص الگوی پراکندگی حشرات بود. آنان رفتار بوم‌شناختی (اکولوژیک) حشرات را در کارایی مدل‌های شبکه عصبی مؤثر دانستند (Zhang *et al.*, 1998). لذا برای بالا بردن کارایی یک شبکه عصبی برای تشخیص پراکندگی شمار لایه‌های مخفی، توابع تحریک و حتی مرحله زیستی حشره مؤثر است (Filippi & Jensen, 2006; Zhang *et al.*, 2008). در پژوهش دیگری که با استفاده از شبکه عصبی LVQ انجام شد، محققان میزان آلودگی خوشه باز (پانیکول) برنج به بیماری بلایت را به چند سطح سالم، با آلودگی کم، متوسط و شدید طبقه‌بندی کرده و آنگاه بر پایه

آستانه آلودگی مورد نظر اقدام به کنترل بیماری کردند (Liu *et al.*, 2010). نتایج به دست آمده از پژوهش‌های یادشده با نتایج به دست آمده از این پژوهش هماهنگی داشت. آستانه اقتصادی به صورت تراکمی از آفت تعریف می‌شود که در آن هزینه کنترل آفت معادل سود به دست آمده از کنترل است (Seraj, 2011). روشن است که نقاط دارای تراکم بیشتر از حد آستانه در مدیریت متناسب با مکان، سم‌پاشی می‌شوند و دیگر نقاط که زیر حد آستانه قرار دارند نیاز به کاربرد سم ندارند. نقشه‌های تهیه شده با شبکه عصبی چنانچه دقت بالایی داشته باشند می‌توانند به مدیر مزرعه در جهت اعمال کنترل محدوده‌ای آفتکش کمک کنند. افزون بر این چنانچه نقشه‌ها منطبق بر مختصات جغرافیایی هر مکان تهیه شوند، راهنمای خوبی برای فعال شدن نازل‌ها در نقاط بالای حد آستانه آفت در عملگرهای نرخ متغیر^۱ خواهند بود. نقشه‌های ترسیم شده نشان‌دهنده توزیع به صورت تجمعی است. با توجه به مناسب بودن فراسنجه‌های آماری می‌توان با اطمینان به نقشه‌های شبکه عصبی محل‌های مناسب سم‌پاشی را انتخاب و به صورت موضعی نقاط آلوده را سم‌پاشی کرد و از سم‌پاشی سراسری مزرعه و آلودگی بیشتر محیط زیست جلوگیری کرد.



شکل ۲. نقشه توزیع سفیدبالک پنبه در دو حالت واقعی (شکل A) و جداسازی شده توسط مدل شبکه عصبی (شکل‌های B)
Figure 2. Cotton whitefly distribution maps in actual (A) and classified conditions by MLPNN (B)

نتیجه‌گیری

در این پژوهش شبکه عصبی با الگوریتم لونیبرگ-مارکوات توانست با دقت مناسبی افزون بر پیش‌بینی، نقشه پراکنش سفیدبالک پنبه را ترسیم کند. نقشه به دست آمده بیان‌کننده پراکنش تجمعی این آفت است.

بنابراین تنها با سم‌پاشی محل‌هایی با تراکم بالا می‌توان به مدیریت مناسب مزرعه و کاهش کاربرد سموم که در نتیجه باعث افزایش سطح سلامت جامعه و کاهش خروج منابع ارزی شود، دست یافت.

REFERENCES

1. Baniameri, V. & Cheraghian, A. (2011). The current status of *Tuta absoluta* in Iran and initial control strategies. In: Proceedings of 1st International Symposium on management of *Tuta absoluta* in collaboration with the IRAC and IBMA, 5-7 May., Agadir University, Egypt, pp. 19-20.
2. Dille, J. A., Milner, M., Groeteke, J. J., Mortensen, D. A. & Williams, I. M. (2003). How good is your weed map? A comparison of spatial interpolators. *Weed Science*, 51(9), 44-55.
3. Filippi, A. M. & Jensen, J. R. (2006). Fuzzy learning vector quantization for hyper spectral coastal vegetation classification. *Remote Sensing Environment*, 100(26), 512-530.
4. Goel, P. K., Prasher, S. O., Patel, R. M., Landry, J. A., Bonnell, R. B. & Viau, A. A. (2003). Classification of hyper spectral data by decision trees and artificial neural networks to identify weed stress and nitrogen status of corn. *Computers and Electronics in Agriculture*, 39(12), 67-93.
5. Gonzalez- Cabrera, J., Molla, O., Monton, H. & Urbaneja A. (2011). Efficacy of *Bacillus thuringiensis* in controlling the *Tuta absoluta* (Lepidoptera: Gelechiidae). *International Organization of Biological Control*, 56(9), 71-80.
6. Garzia, T. G., Siscaro, G., Biondi, A. & Zappala, L. (2011). Distribution and damage of *Tuta absoluta*, an exotic invasive pest from South America. In: Proceedings of 1st International symposium on management of *Tuta absoluta*. 5-7 Nov, Agadir University, Egypt, pp. 12-13.
7. Gutierrez, P. A., Lopez-Granados, F., Pena-Barragan, J. M., Jurado-Exposito, M., Gomez- Casero, M. T. & Hervas-Martinez, C. (2008). Mapping sunflower yield as affected by *Ridolfia segetum* patches and elevation by applying evolutionary product unit neural networks to remote sensed data. *Computers and Electronics in Agriculture*, 60(13), 122-132.
8. Gerling, D. (1990). *Whiteflies: their bionomics, pest status and management*. (1st ed.). Oxford University Press.
9. Heykin, S. (1999). *Neural Networks A Comprehensive Foundation*. (1st ed.). Cambridge University Press.
10. Hagan, M. T., Demuth, H. B. & Beale, H. (1996). *Neural network design*. (2nd ed.). Boston University Press.
11. Hudaib, M. & Cooke, T. E. (2005). The Impact of Managing Director Changes and Financial Distress on Audit Qualification and Auditor Switching. *Journal of Business Finance & Accounting*, 32(9), 1703-1739.
12. Lee, D. S., Joen, C. O., Park, J. M. & Chang, K. S. (2002). Hybrid neural network modeling of a full-scale industrial wastewater treatment plant. *Biotechnology and Bioengineering*, 78(12), 670-682.
13. Liu, Z. Y., Wu, H. F. & Huang, J. F. (2010). Application of neural networks to discriminate fungal infection levels in rice panicles using hyper spectral reflectance and principal components analysis. *Computers and Electronics in Agriculture*, 72(14), 99-106.
14. Makarian, H. (2008). *Investigation of spatial and temporal dynamic of weed seed bank and seedling populations and its effect on saffron (Crocus sativus L.) leaf dry weight under different weed management conditions*. Ph.D. Thesis. Faculty of Agriculture Ferdowsi University of Mashhad, Iran.
15. Makarian, H., Rashed Mohassel, M. H., Bannayan, M. & Nassiri, M. (2007). Soil seed bank and seedling populations of *Hordeum murinum* and *Cardaria draba* in saffron fields. *Agriculture Ecosystems and Environment*, 120(7), 307-312.
16. Aninymous. (2011). *Agricultural statistics, Department of Planning and Economy*. The office of Statistics and Information Technology, Tehran.
17. Seraj, A. A. (2011). *Principle of Plant pest control*. (1th ed.). Shahid chamran University Publication.
18. Shishehbor, P. (2001). *White fly*. (1th ed.). Shahid Chamran University Publication.
19. Shafie, A., Mazoghi, H., Shehata, A. & Taha, M. (2011). Artificial neural network technique for rainfall forecasting applied to Alexandria, Egypt. *International Journal of the Physical Sciences*, 6(2), 1306-1316.
20. Shabni nejad, A. R. & Tafaghodinia, B. (2017). Evaluation of the ability of LVQ4 Artificial neural network model to predict the spatial distribution pattern of *Tuta absoluta* in the tomato field in Ramhormoz. *Journal of Entomological Society of Iran*, 36(13), 195-204.
21. Shabni nejad, A. R., Tafaghodinia, B. & Zandi Sohani, N. (2017). Hybrid neural network With genetic algorithms for predicting distribution pattern of *Tetranychus urticae* (Acari.: Tetranychidae) in cucumbers field of Ramhormoz. *Persian Journal of Acarology*, 6(5), 53-62.
22. Vakil-Baghmisheh, M. T. & Pavešić, N. (2003). Premature clustering phenomenon and new training algorithms for LVQ. *Pattern Recognition*, 36(5), 1901-1921.
23. Wang, Y. M. & Elhag, T. M. S. (2007). A comparison of neural network, evidential reasoning and multiple regression analysis in modeling bridge risks. *Expert Systems with Applications*, 32(5), 336-348.
24. Williams, M. M., Gerhards, R. & Mortensen, D. A. (1999). Spatiotemporal outcomes of site-specific weed management in maize. *Computers and Electronics in Agriculture*, 53(14), 105-116.

25. Young, S. P., JaMyung, K., Buom Young, L., Yeong, J. & YooShin, K. (2000). Use of an Artificial neural network to predict population dynamics of the forest-pest pine needle gall midge (Diptera: Cecidomyiida). *Environmental Entomology*, 29(6), 1208-1215.
26. Yang, N. W., Li AL Wan, F. H., Liu, W. X. & Johnson, D. (2010). Effects of on essential oils on immature and adult sweet potato whitefly, *Bemisia tabaci* biotype B. *Crop Protection*, 29(3), 1200-1207.
27. Zhang, Y. F. & Fuh, J. Y. H. (1998). A neural network approach for early cost estimation of packaging Products. *Computers and Industrial Engineering*, 34(3), 433-50.
28. Zhang, W. J., Zhong, X. Q. & Liu, G. H. (2008). Recognizing spatial distribution patterns of grassland insects: neural network approaches. *Stochastic Environmental. Research and Risk Assessment*, 22(6), 207-216.
29. Zhang, Y. F. & Fuh, J. Y. H. (1998). A neural network approach for early cost estimation of packaging products. *Computers and Industrial Engineering*, 34(7), 433-50.