

ارزیابی قابلیت مدل شبکه عصبی مصنوعی LVQ4 در پیش‌بینی الگوی پراکندگی سرخرطومی *Sitona humeralis* در مزرعه  
یونجه شهرستان مرودشت

حدیث صدیق<sup>۱</sup>، روناک محمدی<sup>۲✉</sup>، محمود عالیچی<sup>۳</sup>، مریم آل عصفور<sup>۳</sup>

۱ و ۳- به ترتیب دانش‌آموخته کارشناسی ارشد حشره شناسی و استادیاران گروه گیاه‌پزشکی، دانشکده کشاورزی، دانشگاه شیراز، شیراز، ایران؛

۲- دانشجوی دکترای حشره شناسی کشاورزی، دانشکده کشاورزی، دانشگاه رازی، کرمانشاه، ایران

(تاریخ دریافت: خرداد ۱۳۹۸؛ تاریخ پذیرش: اسفند ۱۳۹۸)

چکیده

این پژوهش به منظور پیش‌بینی الگوی پراکندگی جمعیت *Sitona humeralis* با استفاده از شبکه عصبی LVQ4 در سطح مزرعه در شهرستان مرودشت انجام شد. داده‌های مربوط به تراکم جمعیت این آفت از طریق نمونه‌برداری روی یک شبکه علامت گذاری شده مربعی با ابعاد ۱۰×۱۰ متر و در مجموع از ۱۰۰ نقطه از سطح مزرعه به دست آمد. برای ارزیابی قابلیت شبکه عصبی LVQ4 در پیش‌بینی پراکندگی این آفت از مقایسه‌های آماری پارامترهایی مانند میانگین، واریانس توزیع آماری و رگرسیون بین مقادیر پیش‌بینی شده مکانی توسط شبکه عصبی و مقادیر واقعی آنها به عنوان معیار استفاده شد. نتایج حاصل نشان داد که در مرحله آموزش و آزمایش تفاوت معنی‌داری در سطح اطمینان ۹۵ درصد بین میانگین، واریانس و توزیع آماری مجموعه داده‌های پیش‌بینی شده مکانی آفت و مقادیر واقعی آنها وجود ندارد. بنابراین شبکه عصبی مصنوعی به خوبی توانست مدل داده‌های مکانی *Sitona humeralis* را بیاموزد. نتایج به دست آمده نشان داد، که شبکه عصبی آموزش دیده دارای قابلیت بالایی در پیش‌بینی مکانی این آفت در نقاط نمونه‌برداری نشده با دقت تشخیص حدود ۹۲ درصد بود. شبکه عصبی توانست، نقشه توزیع مکانی *Sitona humeralis* را در تمام نقاط سطح مزرعه ترسیم نماید. نقشه حاصل نشان داد، که این آفت دارای توزیع تجمعی است و لذا امکان کنترل متناسب با مکان آن در سطح مزرعه مورد مطالعه وجود دارد.

واژه‌های کلیدی: توزیع مکانی، شبکه عصبی مصنوعی، *Sitona humeralis*

**Evaluation of the Ability LVQ<sub>4</sub> Artificial Neural Network Model to Predict the Spatial Distribution Pattern of *Sitona humeralis* in the alfalfa field in Marvdasht**

H. SEDIGH<sup>1</sup>, R. MOHAMMADI<sup>2✉</sup>, M. ALICHI<sup>3</sup>, M. AL OSFOOR<sup>3</sup>

1 and 3. Graduated student and assistant professor in entomology of Plant Protection Department, Faculty of Agriculture,

Shiraz University, Shiraz, Iran; 2. Ph. D. candidate, Department of Plant Protection, College of Agriculture,

Razi Kermanshah University, Kermanshah, Iran

**Abstract**

In this research, a learning vector quantization neural network (LVQ) model was developed to predict the spatial distribution of *Sitona humeralis* in Marvdasht. This method was evaluated on data of pest density from alfalfa field. Pest density assessments were performed following a 10 m × 10 m grid pattern on the field and a total of 100 sampling units on field. Some statistical tests, such as means comparison, variance and statistical distribution were performed between the observed point samples data and the estimated pest values to evaluate the performance of prediction of pest distribution. The results showed that in training and test phase, there were not significant differences, with the confidence level of 95%, between the statistical parameters such as average, variance, statistical distribution and also coefficient of determination in the observed and the estimated pest density. The results suggest that learning vector quantization (LVQ4) neural network can learn pest density model precisely. In addition the results also indicated that trained LVQ4 neural network had a high capability (92%) in predicting pest density for non-sampled points. The technique showed that the LVQNN could predict and map the spatial distribution of *Sitona humeralis*. The map showed that this pest has aggregation distribution so there is possibility potential for using site-specific pest control on this field.

**Keywords:** Artificial neural network, spatial distribution, *Sitona humeralis*

## مقدمه

شبکه را نشان داد (Shabani nejad et al., 2017). از طرفی از شبکه عصبی LVQ4 در تخمین توزیع پراكنندگی شب پره مینوز گوجه فرنگی در خوزستان استفاده شد، و کارایی بسیار بالایی این شبکه از خود نشان داد (Shabani nejad and Tafaghodinia, 2016) همچنین داده های حاصل از نمونه برداری مزرعه خیار توسط روش خوشه بندی اتوماتیک تقسیم بندی شدند و توسط شبکه نرو-فازی پراكنندگی سفید بالک پنبه ترسیم شده است (Shabani nejad and Tafaghodinia, 2017) و در نهایت مقایسه- ای بین روش های زمین آمار و شبکه عصبی مصنوعی در تعیین پراكنش مکانی کنه تارتن دولکهای (Acari: Tetranychidae) *Tetranychus urticae* در مزرعه خیار شهرستان رامهرمز انجام شده که نتایج برتری روش شبکه عصبی مصنوعی را نشان داده است (Shabani nejad and Tafaghodinia, 2016). بر اساس بررسی های انجام شده، تا کنون پژوهشی به منظور بررسی پراكنندگی سرخرطومی های جنس *Sitona humeralis* با استفاده از شبکه عصبی مصنوعی LVQ4، و در راستای تحقق برنامه مدیریت این آفت، صورت نگرفته است. به همین دلیل، تحقیق حاضر با هدف شناخت وضعیت پراكنش این آفت در مزرعه یونجه شهرستان مرودشت انجام شد.

## مواد و روش ها

به منظور انجام این پژوهش یک مزرعه یونجه به ابعاد یک هکتار در اطراف شهرستان مرودشت در ۵۲ درجه و ۴۸ دقیقه شمالی و ۲۹ درجه و ۵۲ دقیقه شرقی و بلندی ۱۶۲۰ متر از سطح دریا، انتخاب شد. در درون هر مزرعه موقعیت مکانی هر نقطه نمونه برداری بر اساس موقعیت جغرافیایی آنها در تمام طول نمونه برداری ثابت در نظر گرفته شد. به منظور علامت گذاری موقعیت مکانی نقاط نمونه برداری پس از مشخص کردن جهت شمال زمین، نقطه ای در حاشیه جنوبی زمین به عنوان مبدا مختصات مشخص شد. مزرعه به شبکه های ۱۰ متری تقسیم، و در مجموع ۱۰۰ نقطه مشخص شد (شکل ۱). در تمامی نقاط نمونه برداری که از اواسط فروردین تا پایان

در بین گیاهان زراعی، یونجه به دلیل گستردگی سطح زیرکشت و همچنین تراکم شاخ و برگ ها و رطوبت نسبتاً بالای مزرعه جایگاه مناسبی برای طیف متنوعی از حشرات اعم از گیاه خواران و دشمنان طبیعی آنها می باشد. از آفات مهمی که گیاه یونجه را مورد حمله قرار می دهند سرخرطومی های جنس *Sitona* معروف به سرخرطومی ریشه یونجه می باشند. اگر چه بعضی از گونه های *Sitona* دارای انتشار جهانی هستند لیکن منشأ اصلی همه آنها احتمالاً اروپا بوده و در نواحی پالئارتیک به ویژه در کانون اصلی خود یعنی منطقه مدیترانه ای به طور وسیعی گسترش دارند (Aeschliman, 1980). از جنس *Sitona* حدود ۱۰۰ گونه در دنیا یافت می شود که جمعاً ۱۴ گونه آن تاکنون از استان فارس گزارش گردیده است که مهمترین آن *Sitona humeralis* است. با توجه به اینکه هر ساله درصد مهمی از عملکرد محصول یونجه در اثر تغذیه مخفیانه و آشکار سرخرطومی های جنس *Sitona* به خطر می افتد لذا برای کنترل این آفت و تدوین برنامه های مدیریت تلفیقی آن، آگاهی از تغییرات جمعیت آن در مزرعه در طی زمان ضروری است. جمعیت های حشرات به صورت طبیعی از نظر تراکم در نقاط مختلف متفاوت می باشند. این عدم یکنواختی تراکم جمعیت در روش های نمونه برداری، درک روابط شکار و شکارچی در برنامه های کنترل زیستی و بهینه سازی مصرف سم بسیار مؤثر است (Garzia et al., 2011). مطالعات متعددی نشان داده است که شبکه های عصبی توانایی بالایی در تشخیص الگوهای توزیع مکانی جمعیت های اکولوژیکی دارند (Goel et al., 2003; Irmak et al., 2006). در پژوهشی مدل شبکه عصبی بردار چندی ساز یادگیر برای مطالعه توزیع مکانی حشرات در اراضی مرتعی استفاده شد و کارایی مطلوبی نشان داد (Zhang et al., 2008). در پژوهشی از شبکه عصبی مصنوعی ترکیب شده با الگوریتم ژنتیک برای پيش بينی الگوی پراكنش کنه تارتن دو لکه ای در مزرعه خیار استفاده شد که نتایج، کارایی بسیار بالای این

ناحیه‌های تصمیم‌گیری و اختصاص یک بردار کد به هر یک از آنها است. طبقه‌بندی بر حسب نزدیکی بردار ورودی  $X$  به بردارهای کد انجام می‌شود. بردار ورودی متعلق به کلاس نزدیکترین بردار کد خواهد شد. الگوریتم تا وقتی که ناحیه‌ای تصمیم‌گیری و مرکزهای آنها ثابت نشود، ادامه خواهد یافت. شبکه عصبی LVQ دارای چهار نوع، LVQ1، LVQ2.1، LVQ3 و LVQ4 است، که در این میان الگوریتم آموزش LVQ4 به جهت بالا بودن کارایی آن استفاده شد (Heykin, S. 1999).

### الگوریتم آموزش LVQ4

فرض شود بردار ورودی از مجموعه آموزش باشد:

$$X \in R^n, \quad q = 1, \dots, Q$$

بردار کد باشد.  $W_m$

$$w_m \in R^n, \quad m = 1, \dots, M$$

پیدا کردن نزدیکترین بردار کد به  $X^q$ :

$$c = \operatorname{argmin}_m (\|x^n - w_m\|)$$

تنظیم  $W_c$ :

$$w_0(t+1) = w_q(t) + a(n)s(n)[x^q - w_q(t)]$$

$a(n)$  آهنگ یادگیری در طول زمان آموزش از رابطه زیر به دست آمد.

$$a(n) = \begin{cases} K_1 & \text{if } q \leq q_0 \\ k_2 \exp\left(-\frac{q - q_m}{r}\right) & \text{if } q > q_0 \end{cases}, \quad 0 < a(n) < 1$$

اگر طبقه‌بندی صحیح باشد،  $d_c(n) = s(n)$  است و

در صورتی که طبقه‌بندی صحیح نباشد  $s(n) = -1$  خواهد شد.

$d_c(n)$  عامل متعادل کننده است و از رابطه زیر به دست می‌آید:

$d_c$  در این رابطه به ترتیب  $E_c(n)$  و  $P_c(n)$  تعداد بردارهایی

است به درستی و اشتباه توسط بردار کد  $c$  طبقه‌بندی می‌شود.

تا پایان تکرار اول مقدار  $d_c(n)$  مشخص نخواهد شد.

بنابراین از روش زیر برای محاسبه آن استفاده شد:

$$d_c(n) = \begin{cases} \epsilon & \text{if } q = 1 \\ \gamma & \text{if } q \geq 2, P_e(n-1) \neq 0 \\ \gamma & \text{if } q \geq 2, P_e(n-1) = 0 \end{cases}$$

که در آن  $0 < \epsilon < 1$  و  $\gamma \geq 1$  می‌باشد. مقادیر توصیه


شده  $\epsilon = 0.2$  و  $\gamma = 10$  است. (Vakil-Baghmishah and

Pavešić, 2003)

ساختار شبکه عصبی LVQ4 استفاده شده به منظور

طبقه‌بندی سطح مزرعه بر مبنای تراکم‌های مختلف، در شکل ۲

شهریور هر دو هفته یکبار از مزرعه انتخابی صورت گرفت یک بلوک  $2 \times 2$  متر مربع انتخاب و درون آن تعداد ۱۰ بوته به صورت تصادفی به عنوان واحد نمونه برداری انتخاب، و تعداد حشرات کامل موجود در قسمت‌های مختلف گیاه شمارش و ثبت شد.



شکل ۱- نقاط نمونه برداری در مزرعه.

Fig.1. Sampling points in the field.

### پیش پردازش داده‌ها

قبل از به کارگیری داده‌های خام اولیه در آموزش شبکه، باید داده‌ها در دامنه مناسبی نرمال شوند زیرا الگوریتم یادگیری همراه با داده‌های خام نمی‌تواند عملکرد مناسبی داشته که به دلیل دامنه تغییرات خروجی تابع فعالیت سیگموئیدی (Sigmoid transfer function) به کار گرفته شده در لایه میانی، این امر ضروری به نظر می‌رسد. در غیر این صورت شبکه در طول فاز آموزش همگرا نخواهد شد. در نتیجه نتایج مطلوبی هم به دست نخواهد آمد (Yuxin et al., 2006). زمانی که از تابع فعالیت سیگموئیدی استفاده می‌شود، بهترین دامنه تبدیل داده‌ها بین  $(0/9)$  و  $(0/1)$  می‌باشد (Vakil-Baghmishah and Pavešić, 2003). برای تبدیل داده‌ها از روش نرمال سازی خطی معادله (۱) استفاده شد:

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

در اینجا  $X$  داده‌ی خام اولیه،  $x_n$  داده‌ی نرمالیزه شده،  $x_{max}$

و  $x_{min}$  به ترتیب مقادیر بیشینه و کمینه داده‌های اولیه،  $r_{max}$

هم به ترتیب حد بالایی و پایین دامنه تغییرات داده‌های

تبدیل شده است.

### شبکه عصبی LVQ

نحوه کار شبکه عصبی LVQ بر اساس تقسیم فضای

ورودی  $R^n$ ، به تعدادی منطقه‌های متمایز از هم با نام

فرضیه در سطح احتمال ۹۵ درصد به کمک پارامتر  $p$  آزمون شد. به ترتیب برای مقایسه میانگین، واریانس و توزیع آماری از آزمون  $t$ ،  $F$  و کولموگروف - اسمیرنوف استفاده شد. مقادیر  $P$  محاسبه شده برای هر مورد در جدول (۲) نشان داده شده است. نتایج نشان می‌دهد که میانگین و واریانس برای شبکه عصبی مصنوعی اختلاف معنی‌داری را نشان نمی‌دهد ( $p < 0.001$ ). وجود  $p=1$  در مورد توزیع آماری بین مقادیر پیش‌بینی شده و مقادیر واقعی تراکم سرخرطومی‌های جنس *Sitona humeralis* در فاز آموزش و همچنین وجود  $p=1.00$  در فاز آزمایش در سطح مزرعه، نشان از دقت بالا و نیز قابلیت شبکه عصبی LVQ4 به منظور ترسیم نقشه پراکندگی این آفت را داشت.


جدول ۱- خطای تشخیص شبکه عصبی LVQ در دو فاز آموزش و آزمایش.

**Table 3.** Recognition error of LVQ neural network in training and test phases

Sampling date	Recognition error in training phase (%)	Recognition error in test phase (%)
4/4/2014	33	29
19/4/2014	33	29
5/5/2014	30	28.4
20/4/2014	30	28.8
5/6/2014	25	22.5
20/6/2014	25	22
6/7/2014	19	16.3
21/7/2014	20	17
6/8/2014	16	14
21/8/2014	14	12.2
6/9/2014	10	8.6
21/9/2014	8.3	6.1

ضرایب تبیین و رابطه خطی رگرسیونی بین مقادیر واقعی در مقابل مقادیر پیش‌بینی شده توسط شبکه عصبی در جدول ۳ نشان داده شده است. بهترین نتایج بر اساس این دو معیار وقتی به دست می‌آید که معادله خطی مابین تراکم آفت و تراکم آفت پیش‌بینی شده توسط شبکه عصبی علاوه بر داشتن ضریب تبیین بالا دارای عرض از مبدا کم و شیب نزدیک به یک باشد. نتایج جدول ۳ بیانگر قدرت تعمیم‌پذیر بودن شبکه عصبی در تخمین تراکم *Sitona humeralis* در مزرعه است. در پژوهشی که به منظور تعیین الگوهای پراکنش حشرات در یک مرتع به وسیله شبکه عصبی انجام شد، بیان

نشان داده شده است. ورودی‌های شبکه مختصات مکانی *Sitona humeralis* می‌باشند و خروجی شبکه بردار کدی است که نزدیکترین فاصله اقلیدسی را با ورودی دارد. برچسب بردار کد تعیین‌کننده کلاس بردار ورودی است. برنامه‌نویسی مدل شبکه عصبی در نرم‌افزار Matlab نسخه ۸/۱ و محاسبات آماری در نرم‌افزار SPSS نسخه ۱۹ انجام گرفت.



**شکل ۲-** ساختار شبکه LVQ استفاده شده برای پیش‌بینی مکانی وجود آفت.  $(X, Y)$ : مختصات نقاط نمونه‌برداری شده،  $W$  ماتریس بردارهای کد،  $W_{win}$  برچسب بردارهای کد برنده شده است.

**Fig. 2.** Configuration of the LVQ for prediction of pest spatial existence.  $(X, Y)$ : coordinate of sampled points,  $W$ : code vectors matrix.  $W_{win}$ : label of winner code vector.

## نتایج و بحث

خطای تشخیص شبکه عصبی مصنوعی LVQ4 در دو مرحله یادگیری و آزمایش در جدول ۱ نشان داده شده است، خطای شبکه در تراکم‌های مختلف متفاوت است. در مطالعه الگوی پراکنش حشرات خطای تشخیص برای تراکم‌های خاص حشرات برابر با صفر بود (Zhang et al., 2008). زیرا حشرات مرتعی تحرکات بیشتری به جهت به دست آوردن غذای کافی داشته و تقریباً پراکنش یکنواختی دارند. اما *Sitona humeralis* در مرحله حشره کامل تحرک زیادی در زمین زراعی ندارد و نتیجه این امر باعث افزایش خطای تشخیص شبکه عصبی شده است.

برای اطمینان از یادگیری شبکه عصبی آموزش دیده برای پیش‌بینی الگوی پراکنش سرخرطومی‌های جنس *Sitona humeralis*، داده‌های واقعی و پیش‌بینی شده توسط شبکه از نظر آماری با هم مقایسه شدند. در اینجا فرض صفر بر تساوی میانگین، واریانس و توزیع آماری دلالت دارد. هر

مصنوعی MLP در پیش‌بینی پویایی جمعیت مگس گالزا (Diptera: Cecidomyiida) در جنگل‌های سوزنی‌برگ آمریکا بود از طرفی شبکه عصبی LVQ4 در تخمین توزیع پراکندگی شب‌پره مینوز گوجه‌فرنگی هم کارایی بسیار بالایی از خود نشان داد (Shabani nejad and Tafaghodinia, 2016).

شد که شبکه‌های عصبی MLP، LVQ و خطی می‌توانند به‌خوبی الگوهای توزیع حشرات را تشخیص دهند. اما در بین شبکه‌های مذکور شبکه‌ی MLP دارای قوی‌ترین الگوریتم در تشخیص الگوها بود (Zhang et al., 2008) و همچنین پژوهش (Young et al., 2010) بیانگر کارایی بالای شبکه عصبی

جدول ۲- مقایسه‌های آماری مقادیر واقعی و پیش‌بینی تراکم *Sitona humeralis* توسط شبکه عصبی LVQ4.

Table 2. Statistical comparisons between the observed and estimated *Sitona humeralis* by LVQ4 neural network.

Classification	Utilization phase	Comparisons of means	Comparisons of variance	Comparisons of distribution
4/4/2014	Training Phase	0.921	0.951	0.80
	Test Phase	1.00	1.00	1.00
19/4/2014	Training Phase	0.973	0.953	1.00
	Test Phase	1.000	1.00	1.00
5/5/2014	Training Phase	0.962	0.981	1.00
	Test Phase	1.00	1.000	1.00
20/4/2014	Training Phase	0.616	0/896	0.70
	Test Phase	0.917	0/963	0.83
5/6/2014	Training Phase	0.758	0.832	0.90
	Test Phase	0.912	0.963	1.00
20/6/2014	Training Phase	0.612	0.923	1.00
	Test Phase	0.901	0.921	1.00
6/7/2014	Training Phase	0.632	0.817	0.832
	Test Phase	0.913	0.964	0.954
21/7/2014	Training Phase	0.753	0.887	1.00
	Test Phase	0.913	0.931	1.00
6/8/2014	Training Phase	0.720	0.921	1.00
	Test Phase	0.954	0.968	0.699
21/8/2014	Training Phase	0.636	0.914	0.893
	Test Phase	0.987	0.936	0.976
6/9/2014	Training Phase	0.721	0.929	1.00
	Test Phase	0.935	1.00	1.00
21/9/2014	Training Phase	0.773	0.921	1.00
	Test Phase	0.944	1.00	1.00

جدول ۳- رابطه خطی رگرسیونی و ضریب تبیین بین av (مقادیر واقعی داده‌ها) و Pv (مقادیر پیش‌بینی شده) توسط مدل.

Table 3. Linear regression relationship and coefficient of determination between dv (actual value) and pv (predicted value by model).

Network goals for classification	Network utilization phase	Linear regression relationship	R2
4/4/2014	Training Phase	pv= 0.9617 av +0.0107	0.9512
	Test Phase	pv= 0.9352 av +0.0141	0.9396
19/4/2014	Training Phase	pv= 0.9863 av +0.0073	0.9902
	Test Phase	pv= 0.9327 av +0.014	0.9312
5/5/2014	Training Phase	pv= 0.9987 av +0.0008	0.9925
	Test Phase	pv= 0.9654 av +0.0025	0.9710
20/4/2014	Training Phase	pv= 0.9152 av +0.0112	0.9214
	Test Phase	pv= 0.8114 av +0.0322	0/8502
5/6/2014	Training Phase	pv= 0.9368 av +0.0132	0/9396
	Test Phase	pv= 0.8444 av +0.027	0/8773
20/6/2014	Training Phase	pv= 0.9646 av +0.0033	0/9796
	Test Phase	pv= 0.8757 av +0.0243	0.9004
6/7/2014	Training Phase	pv= 0.9221av +0.0101	0.9220
	Test Phase	pv= 0.8221 av +0.0303	0.86333
21/7/2014	Training Phase	pv= 0.9321 av +0.0147	0.9487
	Test Phase	pv= 0.8433 av +0.042	0.8910
6/8/2014	Training Phase	pv= 0.9646 av +0.019	0.9801
	Test Phase	pv= 0.8757 av +0.0413	0.9265
21/8/2014	Training Phase	pv= 0.9555 av +0.0136	0.9396
	Test Phase	pv= 0.8606 dv +0.0108	0.899
6/9/2014	Training Phase	pv= 0.9721 av +0.0126	0.9636
	Test Phase	pv= 0.9033 av +0.0164	0.9120
21/9/2014	Training Phase	pv= 0.9836 av +0.0031	0.9898
	Test Phase	pv= 0.9029 av +0.0036	0.9321

real	Predict	Sampling date
		4/4/2014
		19/4/2014
		5/5/2014
		20/4/2014
		5/6/2014
		20/6/2014
		6/7/2014
		21/7/2014
		6/8/2014
		21/8/2014
		6/9/2014
		21/9/2014

شکل ۳- نقشه توزیع سرخرطومی‌های جنس *Sitona humeralis* در دو

حالت واقعی و تخمینی توسط مدل شبکه عصبی LVQ4

Fig. 3. *Sitona humeralis* distribution maps in actual and predicted conditions by learning vector quantization (LVQ4).

### نقشه‌های توزیع مکانی سرخرطومی‌های جنس *Sitona humeralis*

نقشه پراکندگی مکانی سرخرطومی جنس *Sitona humeralis*

توسط شبکه عصبی ترسیم و به دو بخش واقعی و تخمینی در شکل ۳ نشان داده شده است. اگرچه که پیش‌تر براساس مقایسه‌های آماری، مابین مقادیر واقعی و پیش‌بینی شده به عدم وجود تفاوت معنی‌داری در توزیع آماری سرخرطومی دست پیدا کردیم. اما اکنون با مقایسه بین نقشه‌های حاصله از داده‌های واقعی و پیش‌بینی شده توسط شبکه متوجه خواهیم شد بین نقاط متناظر در نقشه در برخی از مکان‌ها تفاوت‌هایی وجود دارد که ناشی از خطای مدل شبکه عصبی است. ولی در مورد صحت کارایی یک مدل نمی‌توان تنها با مقایسه یک یا چند نقطه قضاوت کرد (Zhang and Fuh, 1998).

### نتیجه‌گیری کلی

حشرات کامل و لاروهای این آفت به ترتیب با تغذیه از قسمت‌های هوایی و ریشه‌ی این گیاه، خسارت قابل توجهی به آن وارد می‌کنند. منابع متعددی در مورد خسارت گونه‌های این جنس وجود دارد که اگر با آن مبارزه قاطع نشود چین اول یونجه را به‌کلی نابود می‌کند. بنابراین کنترل موثر این آفت، لازم و ضروری می‌باشد. این پژوهش نشان داد که یکی دیگر از روش‌های مدل‌سازی رفتار حشرات، شبکه‌های عصبی مصنوعی است. در این گونه مدل‌ها بدون در نظر گرفتن معادلات پیچیده غیر خطی، می‌توان پویایی حاکم بر سیستم را استخراج کرد و از این طریق، خروجی‌های مدل را پیش‌بینی کرد. در این پژوهش شبکه عصبی توانست با دقت مناسبی علاوه بر پیش‌بینی، نقشه پراکنش سرخرطومی *Sitona humeralis* را ترسیم نماید. نقشه حاصله بیان‌کننده پراکنش تجمعی این آفت است. بنابراین تنها با سم‌پاشی محل‌هایی با تراکم بالا می‌توان به مدیریت مناسب مزرعه و کاهش مصرف سموم دست یافت.

## References

- AESCHLIMANN, J. P. 1980. The *Sitona* species occurring on medicago and their natural enemies in Mediterranean region. *Entomophaga*, 25(4): 139-153.
- GARZIA, T. G., SISCARO, G., BIONDI, A. and ZAPPALA, L. 2011. Distribution and damage of *Tuta absoluta*, an exotic invasive pest from South America. Proceeding of 1th In: International symposium on management of *Tuta absoluta* (Tomato borer). 13 -15 November, Morocco.PP16.
- GOEL, P. K., PRASHER, S. O., PATEL, R. M., LANDRY, J. A., BBONNELL, R. B. and viau, A. A. 2003. Classification of hyperspectral data by decision trees and artificial neural networks to identify weed stress and nitrogen status of corn. *Computers and Electronics in Agriculture*, 39: 67-93.
- HEYKIN, S. 1999. *Neural Networks A Comprehensive Foundation*. 2thed. 125pp. Oxford University press.
- IRMAK, A., JONES, J. W., BATCHELOR, W. D., IRMAK, S., BOOTE, k. J. and PAZ, J. 2006. Artificial neural network model as a data analysis tool in precision farming. *Transactions of the American Society of Agricultural and Biological Engineers*, 49: 2027-2037.
- SHABANI NEJAD, A. R. and TAFAGHODINIA, B. 2016. 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*, 36,195-204. [In Persian with English summary]
- SHABANI NEJAD, A. R. and TAFAGHODINIA, B. 2017. Automatic clustering of data from sampling and evaluationg of neuro-fuzzy network for estimating the distribution of *Bemisia tabaci* (Hem.: Aleyrodidae). *Entomological Society of Iran* 37, 91-105. [In Persian with English summary]
- SHABANI NEJAD, A. R. and TAFAGHODINIA, B. (2016). Evaluation of Geostatistical Methods and Artificial Neural Network for Estimating the Spatial Distribution of *Tetranychus urticae* (Acari: Tetranychidae) in Cucumber field Ramhormoz.2018 *Journal of Applied Entomology and Phytopathology* 85, 22-30. [In Persian with English summary].
- SHABANI NEJAD, A. R. and TAFAGHODINIA, B., ZANDI- SIHANI N. 2016. Hybrid neural network with genetic algorithms for predicting distribution pattern of *Tetranychus urticae*. in cucumbers field of Rāmhormoz. *Persian Journal of Acarology* 8, 240-252.
- VAKIL-BAGHMISHEH, M. T. and PAVESIC, N. 2003. Premature clustering phenomenon and new training algorithms for LVQ. *Pattern recognition*, 36: 1901-1921.
- VAKIL-BAGHMISHEH, M. T. and PAVESIC, N. 2003. A fast simplified fuzzy ARTMAP network. *Neural Processing Letters*, 17: 273-301.
- YUXIN, M., MULLA, D. J. and PIERRE, C. R. 2006. Identifying important factors influencing corn yield and grain quality variability using artificial neural networks. *Precision Agriculture*, 7: 117-135.
- YOUNG, P., JA-MYUNG, K., BUOM-YOUNG, L., YEONG-JIN. and YOOSHIN, K. 2010. Use of an Artificial Neural Network to Predict Population Dynamics of the Forest-Pest Pine Needle Gall Midge (Diptera: Cecidomyiida). *Environmental Entomology*, 29:1208-1215.
- ZHANG, W. J., ZHONG, X. Q. and LIU, G. H. 2008. Recognizing spatial distribution patterns of grassland insects: neural network approaches. *Stochastic Environmental. Research and Risk Assessment*, 22:207-216.
- ZHANG, Y. F. and FUH, J. Y. H. 1998. A neural network approach for early cost estimation of packaging products. *Computers & Industrial Engineering*, 34: 433-50.