

ارزیابی مدل شبکه عصبی مصنوعی LVQ4 در پیش‌بینی الگوی پراکندگی شبپره مینوز گوجه

در شهرستان رامهرمز *Tuta absolutea* (Lep.: Gelechiidae)

علیرضا شعبانی نژاد^۱ و بهرام تقدی نیا^{۲*}

۱- گروه گیاه‌پردازی، دانشکده کشاورزی، دانشگاه شاهرود، شاهرود، ایران، ۲- گروه گیاه‌پردازی، دانشکده کشاورزی، سازمان پژوهش‌های علمی و صنعتی، تهران، ایران.

*مسئول مکاتبات، پست الکترونیکی: tafaghodinia@gmail.com

Evaluation of LVQ4 artificial neural network model for Predicting spatial distribution pattern of *Tuta absoluta* in Ramhormoz, Iran

A. Shabannejad¹, B. Tafaghodiniya² and N. Zandi-Sohani³

1- Faculty of Agriculture, Shahrood University, Shahrood, 2- Iranian Research Organization for Science and Technology.

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

Journal of Entomological Society of Iran, 2016, 36 (3): 195–204.

چکیده

این پژوهش به منظور پیش‌بینی الگوی پراکندگی جمعیت شبپره مینوز گوجه فرنگی با استفاده از شبکه عصبی LVQ4 در سطح مزرعه در شهرستان رامهرمز انجام شد. داده‌های مربوط به تراکم جمعیت شبپره مینوز گوجه فرنگی از طریق نمونه‌برداری بر روی یک شبکه علامت‌گذاری شده مربعی با ابعاد 10×10 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 پارامترهای 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 معنی داری در سطح اطمینان ۹۵ درصد بین میانگین، واریانس و توزیع آماری مجموعه داده‌های پیش‌بینی شده مکانی آفت و مقادیر واقعی آنها مشاهده نشد. بنابراین شبکه عصبی مصنوعی به خوبی توانست مدل داده‌های مکانی شبپره مینوز گوجه فرنگی را بیاموزد. نتایج به دست آمده نشان داد، که شبکه عصبی آموزش دیده دارای قابلیت بالایی در پیش‌بینی مکانی این آفت در نقاط نمونه‌برداری شده با دقت تشخیص حدود ۸۸ درصد بود. شبکه عصبی توانست، نقشه توزیع مکانی شبپره مینوز گوجه فرنگی را در تمام نقاط سطح مزرعه ترسیم نماید. نقشه حاصل نشان داد، که این آفت دارای توزیع تجمعی است و لذا امکان کنترل مناسب با مکان آن در سطح مزرعه مورد مطالعه وجود دارد.

واژه‌های کلیدی: توزیع مکانی، شبپره مینوز گوجه فرنگی، شبکه عصبی مصنوعی

Abstract

In this research, a Learning Vector Quantization (LVQ) neural network model was developed to predict the spatial distribution of *Tuta absoluta* in tomato fields of the city of Ramhormoz, Iran. Pest density was assessed through $10 \text{ m} \times 10 \text{ m}$ grid pattern on the field with a total of 100 sampling units. Some statistical tests, such as means comparison, variance and statistical distribution were performed between the sampling point data and the estimated pest values in order to evaluate the performance of prediction of pest distribution. In training and test phase, there was no significant difference in average, variance, statistical distribution and coefficient of determination at 95% confidence level. The results suggest that LVQ neural network can learn pest density model precisely and trained LVQ neural network high capability (88%) of predicting pest density for non-sampled points. The LVQNN successfully predicted and mapped the spatial distribution of *Tuta absoluta* whose aggregation distribution implied the possibility of using site-specific pest control in the field.

Keywords: Artificial Neural network, spatial distribution, Tomato leaf miner moth

زیست محیطی دنبال می‌شود. مهمترین محور کشاورزی

مقدمه

دقیق شناخت دقیق مزرعه و شناخت تمام نقاط زمین

کشاورزی دقیق جدیدترین فناوری در عرصه

زراعی است، به طوری که بتوان زمین زراعی را

کشاورزی می‌باشد که بر اساس سه اصل افزایش

آسیب‌شناسی کرد و در جهت مدیریت مناسب با

عملکرد، افزایش بهره اقتصادی و کاهش اثرات زیان‌آور

است (Dille *et al.*, 2003). اما آنچه رسیدن به این اهداف را محقق می سازد افزایش صحت و دقت روش های درون یابی و تهیه نقشه های کاربردی از جمعیت آفات است (Makarian, 2008). از روش های درون یابی مورد استفاده در مطالعات حشره شناسی روش کریجینگ (Kriging) را می توان نام برد. کریجینگ نیز با استفاده از سمی واریوگرامها (Semivariogram) با ترکیب وزن های داده شده به داده های نقاط مجاور، خطای مربوط به مقادیر پیش بینی شده را محاسبه می کند (Gotway *et al.*, 1996). مطالعات متعددی نشان داده است که شبکه های عصبی توانایی بالایی در تشخیص الگوهای توزیع مکانی جمعیت های اکولوژیکی دارند (Drummond *et al.*, Goel *et al.*, 2003; Irmak *et al.*, 2006) (Zhang *et al.*, 2008).

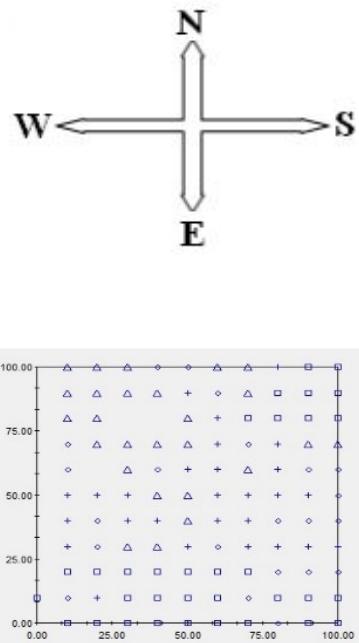
شبکه عصبی مصنوعی دارای ساختاری شبیه سیستم عصبی بیولوژی مغز انسان است (Torrecilla *et al.*, 2004). امروز شبکه های عصبی در بسیاری از زمینه ها از جمله طبقه بندي، تشخیص الگو، پیش بینی و مدلسازی فرآیند ها در علوم مختلف بکار گرفته می شوند. مزیت روش شبکه عصبی یادگیری مستقیم از روی داده ها، بدون نیاز به برآورد مشخصات آماری آنها است (Vakil-Baghmisheh & Pavešic, 2003).

شبکه عصبی بدون در نظر گرفتن فرضیه اولیه و همچنین دانش قبلی از روابط بین پارامترهای مورد مطالعه، قادر به پیدا کردن رابطه بین مجموعه ای از ورودی ها و خروجی ها برای پیش بینی هر خروجی متناظر با ورودی دلخواه می باشد (Torrecilla *et al.*, 2004 ; Kaul *et al.*, 2005).

ویرایش نقاط مختلف زمین گام برداشت (Searcy, 2008) در این رهیافت با به خدمت گرفتن فناوری اطلاعات، مزرعه به چندین واحد مشابه تفکیک شده و پس از تشخیص خصوصیات هر یک از این واحدها، مدیران مزرعه نهاده ها را برای هر واحد و بر اساس مقدار مورد نیاز جهت دستیابی به حداقل بازده اقتصادی به کار می بند (Cardina & Doohan, 2008). کاربرد متناسب نهاده ها (کودها و آفت کش ها و) بر اساس نقشه های صحیح و دقیق، عامل کلیدی در کاربرد موفق کشاورزی دقیق است. شناخت الگوهای پراکنش آفات و کنترل متناسب با مکان آنها می تواند سبب کاهش هزینه ها و نیز کاهش ورود مواد شیمیایی به محیط زیست شده و از طرفی سبب کنترل بهتر آفات در مزرعه شده است (Williams *et al.*, 1999).

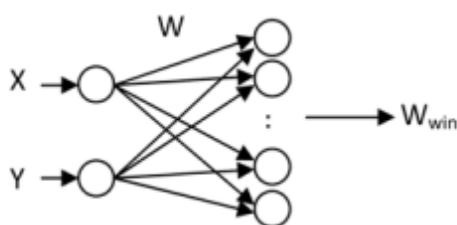
یکی از آفات مهم گوجه فرنگی، مینوز گوجه فرنگی (*Tuta absoluta* Meyrick. (Lep.: Gelechiidae) است (Baniameri & Cheraghian, 2011). لارو این حشره به تمام قسمت های گیاه گوجه فرنگی حمله می کند و به تمام مراحل رشدی گیاه گوجه فرنگی خسارت می زند. لاروها، جوانه های انتهایی، برگچه های نازک، گل ها و میوه های سبز را برای تغذیه ترجیح می دهند. همچنین لاروها از بافت مزووفیل برگ ها تغذیه می کنند و مسیر تغذیه آنها به صورت لکه های نامنظم در می آید و فضولات سیاه لاروها درون دالان ها قابل مشاهده است. این لکه ها ممکن است بعداً نکروزه شوند (Gonzalez *et al.*, 2011). برای تدوین برنامه های مدیریت تلفیقی این آفت، آگاهی از تغییرات 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 نقشه های توزیع آفات با استفاده از مدل سازی پویایی جمعیت آفات به منظور بکارگیری در مدیریت متناسب با مکان در حال انجام

واحد نمونه‌برداری انتخاب، و تعداد لاروهای موجود در قسمت‌های مختلف گیاه شمارش و ثبت شد.



شکل ۱- نقاط نمونه‌برداری در مزرعه

Fig.1. Sampling points in the field



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.

دیگر شبکه عصبی، تحمل‌پذیری در مقابل خطا می‌باشد (Azadeh et al., 2006). این مزایا دلایل بکارگیری شبکه عصبی در پیش‌بینی تراکم آفت را برای ما روشن می‌سازد. در حال حاضر، مطالعات متعددی به منظور پیش‌بینی و تهیه نقشه‌های دقیق پوشش‌های گیاهی، تغییرات جمعیت آفات و غیره با روش‌های مختلف درون‌یابی در حال انجام است و هدف اصلی در همه آنها تهیه نقشه‌های قابل اطمینان جهت مدیریت دقیق مزارع می‌باشد (Makarian, 2008). بنابراین هدف ما نیز در این مطالعه، ارزیابی قابلیت شبکه عصبی چندی‌ساز بردار یادگیر (LVQ4NN) به عنوان یک روش نوین جایگزین در پیش‌بینی و طبقه‌بندی توزیع شبپره مینوز گوجه فرنگی در نقاط نمونه‌برداری نشده بر اساس مدادهای حاصل از نقاط نمونه‌برداری شده در یک مزرعه گوجه فرنگی بود.

مواد و روش‌ها

به منظور انجام این پژوهش یک مزرعه خیار به ابعاد یک هکتار در اطراف شهرستان رامهرمز با مختصات ۴۹ درجه و ۳۶ دقیقه پهنهای طولی و ۳۰ درجه و ۳۳ دقیقه پهنهای عرضی و بلندی ۱۵۰ متر از سطح دریا، انتخاب شد. در درون هر مزرعه موقعیت مکانی هر نقطه نمونه‌برداری بر اساس موقعیت جغرافیایی آنها در تمام طول نمونه‌برداری ثابت در نظر گرفته شد. جهت علامت‌گذاری موقعیت مکانی نقاط نمونه‌برداری پس از مشخص کردن جهت شمال زمین، نقطه‌ای در حاشیه جنوبی زمین به عنوان مبدا مختصات مشخص شد. مزرعه به شبکه‌های ۱۰ متری تقسیم، و در مجموع ۱۰۰ نقطه مشخص شد (شکل ۱). در تمامی نقاط نمونه‌برداری یک بلوک 2×2 متر مریع انتخاب و درون آن تعداد ۴ بوته به صورت تصادفی به عنوان

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, 1999).

الگوریتم آموزش LVQ4

فرض شود X^q بردار ورودی از مجموعه آموزش باشد:

$$\mathbf{x} \in \mathbb{R}^n, \quad q = 1, \dots, Q$$

بردار کد باشد.

$$\mathbf{w}_m \in \mathbb{R}^n, \quad m = 1, \dots, M$$

بیدا کردن نزدیکترین بردار کد به X^q :

$$\epsilon = \operatorname{argmin}_{\mathbf{u}_m} (\|\mathbf{x}^q - \mathbf{w}_m\|)$$

تنظیم \mathbf{w}_c :

$$\mathbf{w}_0(t+1) = \mathbf{w}_q(t) + \mathbf{a}(n)s(n)[\mathbf{x}^q - \mathbf{w}_q(t)]$$

آنگاه یادگیری در طول زمان آموزش از رابطه زیر بدست آمد.

$$\begin{aligned} \mathbf{a}(n) = & \\ & \text{K}_1 \quad \text{if } q \leq q_0 \\ & \{k_2 \exp(-\frac{q - q_m}{r}) \text{ if } q > q_0, o < \\ & a(n) < 1 \end{aligned}$$

اگر طبقه‌بندی صحیح باشد ($d_c(n) = s(n)$ می‌باشد) و در صورتی که طبقه‌بندی صحیح نباشد ($s(n) = 1 - d_c(n)$) عامل متعدد کننده است و از رابطه زیر بدست می‌آید:

$$d_c(n) = \frac{E_c(n)}{P_c(n)}$$

در این رابطه به ترتیب $E_c(n)$ و $P_c(n)$ تعداد بردارهایی است به درستی و اشتباه توسط بردار کد طبقه‌بندی می‌شود. تا پایان تکرار اول مقدار $d_c(n)$ مشخص نخواهد شد. بنابراین از روش زیر برای محاسبه آن استفاده شد:

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

پیش‌پردازش داده‌ها

قبل از بکارگیری داده‌های خام اولیه در آموزش شبکه، باید داده‌ها در دامنه مناسبی نرمال‌سازی شوند زیرا الگوریتم یادگیری همراه با داده‌های خام نمی‌تواند عملکرد مناسبی داشته باشد و همچنین به دلیل دامنه تغییرات خروجی تابع فعالیت سیگموئیدی (Sigmoid transfer function) بکار گرفته شده در لایه میانی، این امر ضروری به نظر می‌رسد. در غیر این صورت شبکه در طول فاز آموزش همگرا نخواهد شد. نتیجتاً نتایج مطلوبی هم به دست نمی‌آید (Yuxin et al., 2006). زمانی که از تابع فعالیت سیگموئیدی استفاده می‌شود، بهترین دامنه تبدیل داده‌ها بین (۰/۹ و ۰/۱) می‌باشد (Vakil-Baghmisheh & Pavešićmm, 2003). داده‌ها از روش نرمال‌سازی خطی معادله استفاده شد:

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

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} و r_{min} 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 \mathbb{R}^n به تعدادی منطقه‌های متمایز از هم با نام 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 نخواهد شد. الگوریتم تا وقتی که ناحیه‌های تصمیم‌گیری و مرکزهای آنها ثابت نشود، ادامه خواهد یافت. شبکه

پارامتر P آزمون شد. به ترتیب برای مقایسه میانگین، واریانس و توزیع آماری از آزمون F و کولموگرف - اسمیرنوف (Kolmogorov - smirnov) استفاده شد. مقادیر P محاسبه شده برای هر مورد در جدول ۲ نشان داده شده است. نتایج نشان می‌دهد که میانگین، واریانس برای شبکه عصبی مصنوعی اختلاف معنی داری را نشان نمی‌دهد ($p > 0.001$) با این وجود بین توزیع آماری مقادیر واقعی و پیش‌بینی شده توسط شبکه عصبی اختلاف معنی داری در سطح ۹۵ درصد وجود ندارد ($p > 0.8$). وجود $p > 0.82$ در مورد توزیع آماری بین مقادیر پیش‌بینی شده و مقادیر واقعی تراکم شبپره مینوز گوجه فرنگی در سطح مزرعه، نشان از دقت بالا و نیز قابلیت شبکه عصبی مصنوعی LVQ4 در تخمین این آفت می‌باشد.

ضرایب تبیین و رابطه خطی رگرسیونی بین مقادیر واقعی هر کلاس 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 شبیه نزدیک به یک باشد. نتایج جدول ۳ بیانگر قدرت تعمیم پذیر بودن شبکه عصبی در تخمین تراکم شبپره مینوز گوجه فرنگی در مزرعه است.

در پژوهشی که منظور تعیین الگوهای پراکنش حشرات در یک مرتع به وسیله شبکه عصبی انجام شد، بیان شد که شبکه عصبی MLP و LVQ و خطی می‌توانند به خوبی الگوهای توزیع حشرات را تشخیص دهند. اما در بین شبکه‌های مذکور شبکه‌های LVQ دارای قوی‌ترین الگوریتم در تشخیص الگوها بود (Zhang et al., 2008) و همچنین پژوهش Yeong et al. (2000) بیانگر کارایی بالای شبکه عصبی

که در آن $0 < \epsilon < 1$ و $\gamma \geq 1$ می‌باشد. مقادیر توصیه شده $\epsilon = 0.2$ و $\gamma = 10$ است.

(Vakil-Baghmisheh & Pavešić, 2003)

ساختار شبکه عصبی LVQ4 استفاده شده به منظور طبقه‌بندی سطح مزرعه بر مبنای تراکم‌های مختلف، در شکل ۲ نشان داده شده است. ورودی‌های شبکه مختصات مکانی شبپره مینوز گوجه فرنگی می‌باشند و خروجی شبکه بردار کدی است نزدیکترین فاصله اقلیدسی را با ورودی دارد. برچسب بردار کد تعیین کننده کلاس بردار ورودی است. برنامه نویسی مدل شبکه عصبی در نرم‌افزار Matlab نسخه ۱/۸ و محاسبات آماری در نرم‌افزار SPSS نسخه ۱۹ انجام گرفت.

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 شبپره مینوز گوجه فرنگی در مرحله لاروی از میوه‌ی سیز گوجه فرنگی استفاده می‌کند و 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 شبپره مینوز گوجه فرنگی، داده‌های واقعی و پیش‌بینی شده توسط شبکه از نظر آماری با هم مقایسه شدند. در اینجا فرض صفر برتساوی میانگین، واریانس و توزیع آماری دلالت دارد. هر فرضیه در سطح احتمال ۹۵ درصد به کمک

آفت تعریف می‌شود که در آن هزینه کنترل آفت معادل سود حاصل از کنترل است (Seraj, 2011). واضح است که نقاط دارای تراکم بیشتر از حد آستانه در مدیریت مناسب با مکان، مورد سمپاشی قرار می‌گیرند و سایر نقاط که زیر حد آستانه قرار دارند نیاز به مصرف سم ندارند. نقشه‌های تهیه شده به وسیله شبکه عصبی چنانچه از دقت بالایی برخوردار باشند می‌توانند به مدیر مزرعه در جهت اعمال کنترل محدوده‌ای آفت‌کش کمک کنند. علاوه بر این چنانچه نقشه‌ها منطبق بر مختصات جغرافیایی هر مکان تهیه شوند، راهنمای خوبی برای فعال شدن نازل‌ها است.

با توجه به مناسب بودن پارامترهای آماری می‌توان با اطمینان به نقشه‌های شبکه عصبی محل‌های مناسب سمپاشی را انتخاب نمود و به صورت موضوعی نقاط آلوده را سمپاشی کرد و از سمپاشی سراسری مزرعه و آلودگی بیشتر محیط زیست جلوگیری کرد. از طرف دیگر، با توجه به هزینه بر بودن تهیه فرومون جنسی و نصب تله‌های فرومونی، با استفاده از نقشه‌های شبکه عصبی، می‌توان تله‌های فرومونی را در کانون‌های آفت نصب نمود و یا استفاده از عوامل کنترل طبیعی مانند زنبورهای پارازیتوئید لارو و کفشدوزک‌های شکارگر تخم مینوز گوجه فرنگی مانند *Chilocorus bipustulatus* L. را در نقاط آلوده، متتمرکز ساخت.

نتیجه‌گیری

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

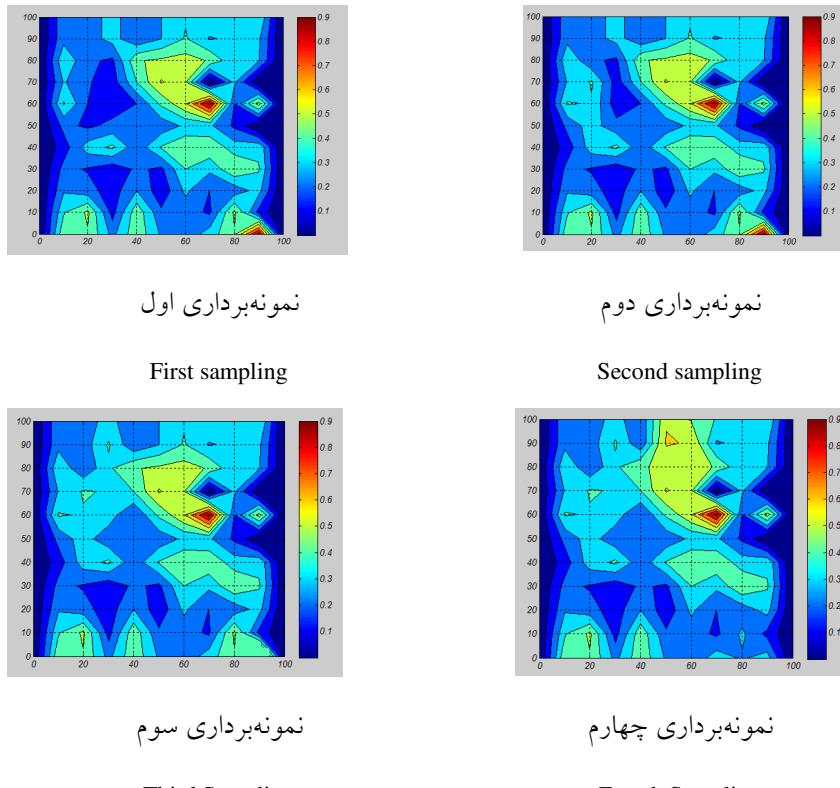
مصنوعی LVQ در پیش‌بینی پویایی جمعیت مگس گالزا (Diptera: Cecidomyiida) در جنگل‌های سوزنی‌برگ آمریکا بود. نتایج به دست آمده از این دو پژوهش با نتایج حاصل از این پژوهش هماهنگی داشت.

نقشه‌های توزیع مکانی شبپره مینوز گوجه فرنگی بر اساس شکل ۳ این آفت در مراحل اولیه نمونه‌برداری در قسمت جنوب شرقی زمین وجود داشت که به تدریج از تراکم آن کاسته شد. به صورت کلی تراکم این آفت در قسمت مرکزی و شمال شرقی زمین بیشتر بود و به آرامی در سطح مزرعه در دو جهت گسترش پیدا کرد، همانگونه که در نقشه نمونه‌برداری سوم قابل مشاهده است این آفت به سمت غرب حرکت کرد و در نمونه‌برداری چهارم عمدۀ قسمت‌های شمالی زمین را اشغال و حتی به مزرعه مجاور هم منتقل شد.

Zhang et al. (1998) در مقایسه سه مدل شبکه عصبی برای تعیین الگوهای پراکنده‌گی حشرات در سطح یک چمنزار، بیان کردند که شبکه عصبی LVQ الگوریتم قوی‌تری در تشخیص الگوی پراکنده‌گی حشرات بود. آنها رفتار اکولوژیک حشرات در کارایی مدل‌های شبکه عصبی موثر دانستند. لذا برای بالابردن کارایی یک شبکه عصبی برای تشخیص پراکنده‌گی تعداد لایه‌های مخفی، توابع تحریک و حتی مرحله زیستی حشره موثر است (Filippi & Jensen, 2006; Zhang et al., 2008). در LVQ پژوهش دیگری که با استفاده از شبکه عصبی پیاماری شد، محققین میزان آلودگی پانیکول برنج به انجام شد، محققین میزان آلودگی پانیکول برنج به بیماری بلایت را به چند سطح سالم، با آلودگی کم، متوسط و شدید طبقه‌بندی کرده و سپس بر اساس آستانه آلودگی مورد نظر اقدام به کنترل بیماری کردند (Liu et al., 2010). آستانه اقتصادی به صورت تراکمی از

سمپاشی محلهایی با تراکم بالا می‌توان به مدیریت مناسب مزرعه و کاهش مصرف سوم دست یافت.

دقت مناسبی علاوه بر پیش‌بینی، نقشه پرآکنش شب‌پره مینوز گوجه فرنگی را ترسیم نماید. نقشه حاصله بیان کننده پرآکنش تجمعی این آفت است. بنابراین تنها با



شکل ۳- پرآکندگی شب‌پره مینوز گوجه فرنگی در مراحل مختلف نمونه‌برداری

Fig. 3. Distribution of *T. absoluta* in different stages of sampling

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 (%)
16/03/2016	24	28
23/03/2016	12	16
30/03/2016	10.07	11
06/04/2016	9	10.20

جدول ۲- مقایسات آماری مقادیر واقعی و پیش‌بینی تراکم شبپره مینوز گوجه فرنگی توسط شبکه عصبی LVQ

Table 2. Statistical comparisons between the observed and estimated to *T. absoluta* density by LVQ neural networks

Sampling date	Utilization phase	Comparisons of means	Comparisons of variance	Comparisons of distributuin
16/03/2016	Training	0.571	0.672	0.66
	Test	0.662	0.767	0.51
23/03/2016	Training	0.712	0.443	0/76
	Test	0.686	0.553	0.69
30/03/2016	Training	0.796	0.875	0.79
	Test	0.699	0.668	0.71
06/04/2016	Training	0.823	0.785	0.87
	Test	0.734	0.578	0.75

جدول ۳- مقایسات آماری مقادیر واقعی و پیش‌بینی تراکم شبپره مینوز گوجه فرنگی شبکه عصبی LVQ

Table 3. Statistical comparisions between the observed and estimated *T. absoluta* density by LVQ neural networks.

Sampling date	Utilization phase	Comparisons of means	Comparisons of variance	Comparisons of distributuin
16/03/2016	Training Phase	0.733	0.733	0.61
	Test Phase	0.005	0.621	0.58
23/03/2016	Training Phase	0.642	0.384	0.77
	Test Phase	0.009	0.006	0.71
30/03/2016	Training Phase	0.799	0.544	0.85
	Test Phase	0.701	0.008	0.73
06/04/2016	Training Phase	0.776	0.787	0.89
	Test Phase	0.633	0.006	0.76

منابع

- Azadeh, A., Ghaderi, S. F. & Sohrabkhani, S.** (2006) Forecasting electrical consumption by integration of Neural Network, time series and ANOVA. *Applied Mathematics and Computation* 186, 1753-1761.
- Baniameri, V. & Cheraghian, A.** (2011) The current status of *Tuta absoluta* in Iran and initial control strategies. EPPO/IOBC/FAO/NEPPO Joint International Symposium on management of *Tuta absoluta* (tomato borer, Lepidoptera:Gelechiidae) in collaboration with the IRAC and IBMA. Agadir, Morocco, p. 20.
- Cardina, J., & Doohan, D. J.** (2008) Weed biologyand precision farming. Site-specific management guideline. www.ppi-far.org/ssmg.
- Dille, J. A., Milner, M., Groeteke, J. J., Mortensen, D. A. & Williams, M. M.** (2003) How good is your weed map? A comparison of spatial interpolators. *Weed Science* 51: 44 – 55.
- Drummond, S. T., Sudduth, K. A., Joshi, A., Birrell, S. J. & Kitchen, N. R.** (2003) Statistical and neural methods for site-specific yield prediction. *Transactions of the American Society of Agricultural and Biological Engineers* 46, 5–14.
- Filippi, A. M. & Jensen, J. R.** (2006) Fuzzy learning vector quantization for hyper spectral coastal vegetation classification. *Remote Sensing Environment* 100, 512–530
- 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, 67–93.
- Gonzalez-Cabrera, J., Molla, O., Monton, H., & Urbaneja, A.** (2011) Efficacy of *Bacillus thuringiensis* (Berliner) in controlling the tomato borer, *Tuta absoluta* (Meyrick) (Lepidoptera:Gelechiidae). *International Organization of Biological Control (IOBC)* 56, 71- 80.
- Garzia, T. G., Siscaro, G., Biondi, A. & Zappala, L.** (2011) Distribution and damage of *Tuta absoluta*, an exotic invasive pest from South America. International symposium on management of *Tuta absoluta* (Tomato borer) Proceeding. Agadir, Morocco, 16-18
- Gotway, C. A., Ferguson, R. B., Hergert, G. W. & Peterson, T. A.** (1996) Comparison of kriging and inverse distance methods for mapping soil parameters. *Soil Science Society America Journal* 60, 1237-1247.
- Heykin, S.** (1999) *Neural Networks A Comprehensive Foundation*. 2thed. 125pp. Oxford University press.
- Kaul, M., Hill, R. L. & Walther, C.** (2005) Artificial neural networks for corn and soybean yield prediction. *Agriculture system* 85, 1-18.
- 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, 99-106.
- 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 in weed science. Ferdowsi University of Mashhad. 193pp.
- 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, 307- 312.
- Seraj A. A.** (2011) *Principle of Plant pest control*. 7745pp. Shahid Chamran Press.

- Searcy, S. W.** (2008) Precision farming: a new approach to crop management. Texas agricultural extension service. Txprecag.tamu.edu/content/pub/pf-ncm.pdf.
- Torrecilla, J. S., Otero, L. & Sanz, P. D.** (2004) A neural network approach for thermal/pressure food processing. *Food Engineer* 62,89-95.
- Vakil-Baghmisheh, M. T. & Pavešić, N.** (2003) Premature clustering phenomenon and new training algorithms for LVQ. *Pattern recognition* 36, 1901-1921.
- Vakil-Baghmisheh, M. T. & Pavešić, N.** (2003) A Fast simplified fuzzy ARTMAP network. *Neural Processing Letters* 17, 273-301.
- 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, 336-348.
- Williams, M. M., Gerhards, R. & Mortensen, D. A.** (1999) Spatio temporal outcomes of site-specific weed management in maize. pp. 897-906 in J. V. Stafford (Eds) *Precision Agriculture*. 99 pp. Sheffield, Great Britain: Society of Chemical Industry.
- Yuxin, M., Mulla, D. J. & Pierre, C. R.** (2006) Identifying important factors influencing corn yield and grain quality variability using artificial neural networks. *Precision Agriculture* 7, 117–135.
- Young-S. P., Ja-Myung, 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* 29,1208-1215.
- 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, 207–216.
- Zhang, Y. F. & Fu, J. Y.H.** (1998) A neural network approach for early cost estimation of packaging products. *Computers & Industrial Engineering* 34, 433-50.