

ارزیابی مدل شبکه عصبی مصنوعی GMDH در تخمین پراکنش مکانی کفشدوزک
هفت نقطه‌ای *Coccinella septempunctata* (Col.: Coccinellidae) در مزارع
یونجه منطقه باجگاه شیراز

روناک محمدی^{۱*}، علیرضا شعبانی نژاد^۱، محمود عالیچی^۲ و محمدرضا شعبانی نژاد^۳

۱- دانشکده کشاورزی، دانشگاه رازی، کرمانشاه، ایران، ۲- بخش گیاهپزشکی، دانشکده کشاورزی، دانشگاه شیراز
و ۳- دانشکده شیمی، دانشگاه صنعتی جندی شاپور، دزفول، ایران
* مسئول مکاتبات: پست الکترونیک: ronak.m1363@gmail.com

چکیده

این مطالعه به منظور پیش‌بینی تغییرات تراکم جمعیت تراکم کفشدوزک هفت نقطه‌ای در مزرعه یونجه، با استفاده از شبکه عصبی مصنوعی انجام شد. داده‌های مربوط به تراکم جمعیت این حشره در مزرعه‌ای به مساحت ۴ هکتار در منطقه باجگاه شیراز در سال ۱۳۹۲-۱۳۹۳ ثبت شد. در این مدل‌ها از متغیرهای طول و عرض جغرافیایی به عنوان متغیرهای ورودی و تغییرات جمعیت حشره کامل کفشدوزک هفت نقطه‌ای به عنوان متغیر خروجی استفاده شد. شبکه مورد استفاده از نوع Group method of data handling (GMDH) بهینه شده با الگوریتم ژنتیک بود. برای ارزیابی قابلیت شبکه‌های عصبی مورد استفاده در پیش‌بینی پراکنش مکانی کفشدوزک، از مقایسه آماری پارامترهایی مانند واریانس، توزیع آماری و میانگین بین مقادیر پیش‌بینی شده مکانی توسط شبکه عصبی و مقادیر واقعی آن‌ها استفاده شد. نتایج نشان داد که در فازهای آموزش و آزمایش بین مقادیر و ویژگی‌های آماری واریانس، توزیع آماری و میانگین مجموعه داده‌های واقعی و پیش‌بینی شده مکانی دشمن طبیعی توسط شبکه عصبی GMDH، تفاوت معنی‌داری وجود نداشت و همچنین وجود ضریب تبیین ۰٫۹۸ نشان از دقت بالایی شبکه عصبی در پیش‌بینی تراکم این گونه داشت. نقشه‌های ترسیم شده توسط شبکه نشان داد، توزیع این دشمن طبیعی تجمعی است.

واژگان کلیدی: توزیع مکانی، شبکه عصبی مصنوعی GMDH، کفشدوزک هفت نقطه‌ای

Evaluation of GMDH artificial neural network model to predict the spatial distribution of *Coccinella septempunctata* (Col.: Coccinellidae) in the alfalfa farm of Bajgah, Shiraz

Ronak Mohamadi^{1*}, Ali Reza Shabani Nejad¹, Mahmood Alichchi² & Mohammad Reza Shabani Nejad³

1. Department of Plant Protection, Faculty of Agriculture, Razi University, Kermansha, Iran, 2. Plant Protection Department, Faculty of Agriculture, Shiraz University, Shiraz, Iran. & 3. Department of Chemistry Engineering, Faculty of Chemistry, Jundi-Shapur University of Technology, Dezful, Iran.

*Corresponding author, E-mail: ronak.m1363@gmail.com

Abstract

This study aimed to predict population of *Coccinella septempunctata* in the field using artificial neural network. The data was collected from a four-hectare field in years of 2013-2014 in the area of Badjga Shiraz. In this model, the input variables were, longitude and latitude and population changes of *Coccinella septempunctata* was used as the outcome variable. The neural network type used, was Group Method of Data Handling (GMDH) that optimized by genetic algorithm. To evaluate the ability of

دریافت: ۱۳۹۶/۰۸/۱۵، پذیرش: ۱۳۹۷/۰۵/۰۲

دبیر تخصصی: یعقوب فتیحی پور

GMDH neural networks to predict the spatial distribution of the species, statistical comparison of the parameters such as mean, variance, statistical distribution and coefficient determination of linear regression between predicted values and actual values was used. Results showed that in training and test phases of GMDH, there was no significant effect between variance, mean and statistical distribution of actual and predicted values, and the coefficient of determination of 0.98 indicates the high accuracy of this neural network in predicting the density of this species. The drawn maps showed that the distribution of this natural enemy is patchy.

Keyword: *Coccinella septempunctata* L., GMDH artificial neural network, Spatial distribution

Received: 6 November 2017, Accepted: 24 July 2018

مقدمه

یونجه گیاهی بومی نواحی گرمسیری بوده که در هر نوع آب و هوایی رشد می‌کند و نسبت به خشکی مقاوم می‌باشد. این گیاه یک جزء مهم از سیستم‌های تولید محصولات کشاورزی محسوب می‌گردد. برخلاف محصولات یک ساله که رشد رویشی و زایشی‌شان یک سال به طول می‌انجامد، یونجه گیاهی علوفه‌ای چند ساله و تا حدودی پایدار می‌باشد که به‌طور معمول حداقل سه سال دوام دارد (Elliott & Kieckhefe, 1990). مهم‌ترین آفات موجود در مزارع یونجه، سرخرطومی برگ، *Hypera postica* Gyllenhal و سرخرطومی‌های ریشه یونجه، *Sitona* spp. زنجبرک سیب‌زمینی، *Empoasca decipiens* Paoli، شته خالدار یونجه، *Therioaphis maculate*، *Buckton*، شته سیاه باقلا، *Aphis fabae* Scopoli و شته نخود فرنگی، *Acyrtosipgon pisum* Harris هستند. یکی از مهم‌ترین دشمنان طبیعی آفات گروه جوربالان در این مزارع کفشدوزک‌ها هستند که در بسیاری از زیستگاه‌ها شامل زمین‌های زراعی، باغ‌ها، جنگل‌ها، سواحل دریا، کوه‌ها و یا مکان‌های دیگر یافت می‌شوند (Ali & Rizvi, 2010). اغلب افراد این خانواده شکارگر بوده و جزء عوامل کلیدی در کنترل تعدادی از آفات متعلق به Hemiptera (شته‌ها، شپشک‌های نباتی، سفیدبالک‌ها و پسیل‌ها)، تریپس‌ها، لارو بعضی از سوسک‌ها، پروانه‌ها و بندپایان دیگر از قبیل کنه‌های نباتی می‌باشند. کفشدوزک هفت‌نقطه‌ای، *Coccinella septempunctata* L. یکی از گونه‌های مهم است که مبدا اولیه این گونه آسیا و اروپا بوده ولی در حال حاضر در سراسر خاورمیانه، هند و آمریکای شمالی گسترش دارد (Hodek, 1973). این گونه اغلب دشمنان طبیعی غالب شته‌ها در مزارع یونجه می‌باشند که این اهمیت آن‌ها را در کنترل بیولوژیک شته‌های مزارع یونجه نشان می‌دهد. با این حال جمعیت کفشدوزک‌ها در مزارع یونجه به صورت غیرقابل پیش‌بینی در طی زمان و مکان تغییر یافته، به همین دلیل، کنترل بیولوژیک به‌وسیله این شکارگرها غیرقابل پیش‌بینی است. بنابراین تاثیر روش‌های مختلف نمونه‌برداری برای برآورد جمعیت کفشدوزک‌ها، در تصمیم‌گیری و اجرای صحیح مدیریت تلفیقی آفات مزارع یونجه حائز اهمیت می‌باشد (Elliott & Micheis, 1997). کفشدوزک هفت‌نقطه‌ای، *C. septempunctata* یک گونه متداول مورد استفاده برای کنترل بیولوژیک در سامانه‌های کشاورزی است که بسیاری از گونه‌های بومی آفات به‌وسیله آن‌ها کنترل می‌شوند (Honek & Martinkova, 2005). استفاده بهینه و افزایش کارایی از این حشرات مفید، مستلزم در نظر گرفتن عواملی از قبیل زمان، مکان، و گیاهان میزبان می‌باشد (Hagen, 1962). شناخت این عوامل به عنوان اولین قدم در بهره‌گیری از این دشمنان طبیعی و همچنین حفاظت و تکثیر آن‌ها در قالب یک مبارزه بیولوژیک موفق، نقش به‌سزایی دارد. لازمه تکوین برنامه مدیریت تلفیقی هر آفتی، داشتن آگاهی کامل از بیولوژی، اکولوژی و دینامیسم جمعیت آفت و دشمنان طبیعی آن می‌باشد. به‌منظور توسعه استراتژی کنترل بیولوژیک پایدار درک چگونگی ساختار زیستگاه، اندازه و تغییرات جمعیت آن‌ها و همچنین تحت تاثیر قرار گرفتن دشمن طبیعی برای از بین بردن طعمه لازم و ضروری است (Kianpour et al., 2010). اما آنچه رسیدن به این اهداف را محقق می‌سازد

افزایش صحت و دقت روش‌های درون‌یابی و تهیه نقشه‌های کاربردی از جمعیت حشرات است. درون‌یابی مکانی شامل تخمین متغیرهایی مانند تراکم حشره مورد نظر، در نقاط نمونه‌برداری نشده با استفاده از داده‌های به دست آمده از نقاط نمونه‌برداری شده می‌باشد. به عبارتی یک روش درون‌یابی ایده‌آل قادر است تا با استفاده از اطلاعات مربوط به تراکم حشره در تعداد نقاط محدود نمونه‌برداری شده، تراکم حشره را در نقاط نمونه‌برداری نشده به درستی تخمین بزند (Shabani nejad & Tafaghodiniya, 2017). از روش‌های درون‌یابی مورد استفاده در مطالعات حشره‌شناسی روش‌های کریجینگ و شبکه عصبی مصنوعی را می‌توان نام برد.

مدل‌های شبکه عصبی مصنوعی در مقایسه با مدل‌های ریاضی دارای توانایی آموزش روابط بین متغیرهای مستقل و وابسته هستند (Mittal & Zhang, 2010). شبکه‌های عصبی مصنوعی با دقت و صحت بیشتری می‌توانند رابطه بین متغیرها را شبیه‌سازی کنند (Cravener & Roush, 2013). مطالعات متعددی نشان داده است که شبکه‌های عصبی توانایی بالایی در تشخیص الگوهای توزیع مکانی جمعیت‌های اکولوژیکی دارند (Goel et al., 2003; Irmak et al., 2006). در پژوهشی مدل شبکه عصبی بردار چندی ساز یادگیر، Learning Vector Quantization Neural Network (LVQ) 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 پیش‌بینی الگوی پراکنش کنه تارتن دو لکه‌ای در مزرعه خیار استفاده شد که نتایج کارایی بسیار بالای این شبکه را نشان داد (Shabani nejad et al., 2017). از طرفی از شبکه عصبی LVQ4 در تخمین توزیع پراکنندگی شب‌پره مینوز گوجه‌فرنگی استفاده شد، و کارایی بسیار بالایی از خود نشان داد (Shabani nejad & Tafaghodiniya, 2016a). در پژوهشی داده‌های حاصل از نمونه‌برداری مزرعه خیار توسط روش خوشه‌بندی اتوماتیک تقسیم‌بندی شدند و توسط شبکه نو-فازی پراکنندگی سفید بالک پنبه ترسیم شد (Shabani nejad & Tafaghodiniya, 2017) و در نهایت مقایسه‌ای بین روش‌های زمین‌آمار و شبکه عصبی مصنوعی در تعیین پراکنش مکانی کنه تارتن دولکه‌ای *Tetranychus urticae* Koch در مزرعه خیار شهرستان رامهرمز انجام شد که نتایج برتری روش شبکه عصبی مصنوعی نشان داد (Shabani nejad & Tafaghodiniya, 2016b). بنا به بررسی‌های انجام شده، تاکنون پژوهشی به منظور ارزیابی روش شبکه عصبی مصنوعی GMDH در راستای تحقق برنامه مدیریت توزیع کفشدوزک هفت‌نقطه‌ای، در مزرعه یونجه صورت نگرفته است. به همین دلیل تحقیق حاضر با هدف شناخت وضعیت پراکنش این آفت در مزرعه یونجه منطقه باجگاه انجام شد.

مواد و روش‌ها

موقعیت جغرافیایی و تهیه نقشه نمونه‌برداری

به منظور انجام این پژوهش یک مزرعه یونجه به مساحت ۴ هکتار در منطقه باجگاه در استان شیراز در محدوده جغرافیایی بین ۴۸ درجه و ۴۴ دقیقه تا ۵۲ درجه و ۲۷ دقیقه طول شرقی از نصف‌النهار گرینویچ و ۳۱ درجه و ۶۰ دقیقه تا ۴۳ درجه و ۶ دقیقه عرض شمالی از خط استوا، انتخاب شد.

روش نمونه‌برداری

مزرعه یونجه انتخاب شده به وسعت ۴/۲ هکتار واقع در منطقه باجگاه، به دو قطر تقسیم شد. سپس بر روی قطرها، با حرکت زیگزاکی و با استفاده از تور حشره‌گیری با دهانه‌ای به قطر سی سانتی‌متر و طول دسته ۷۵ سانتی‌متر به ازای هر ۱۰ متر، ۱۰ تور (نمونه) به‌طور تصادفی به عرض یک متر زده شد (در مجموع ۲۰۰ نمونه

برروی دو قطر). نمونه برداری‌ها به منظور بررسی روند تغییرات جمعیت کفشدوزک به صورت هفتگی از اواسط فروردین ۱۳۹۲ شروع شد و تا اواخر فروردین ۱۳۹۳ ادامه داشت.

تجزیه و تحلیل آماری

نرمال بودن داده‌های مربوط به نمونه‌برداری به کمک نرم‌افزار SPSS 19 و آزمون کولموگروف-اسمیرنوف، بررسی شد و به دلیل عدم نرمال بودن آنها، داده‌ها توسط روش کاکس-کاکس نرمال شدند. کد رایانه‌ای شبکه عصبی GMDH در محیط نرم‌افزار Matlab نسخه ۸/۱ تهیه شد.

پیش‌پردازش داده‌ها

در ابتدا داده‌ها به طور تصادفی به دو دسته مجموعه آموزش با ۱۴۰ عضو (۷۰ درصد کل داده‌ها) و مجموع آزمایش با ۶۰ عضو (۳۰ درصد کل داده‌ها) تقسیم بندی گردید. البته اگر این تقسیم‌بندی منجر به نتایج مطلوب نشود، می‌توان این مرحله را به طور مجدد تکرار کرد (Zhang et al, 1998).

قبل از بکارگیری داده‌های خام اولیه در آموزش شبکه، باید داده‌ها در دامنه مناسبی نرمالیزه شوند زیرا الگوریتم یادگیری همراه با داده‌های خام نمی‌تواند عملکرد مناسبی داشته باشد و همچنین به دلیل دامنه تغییرات خروجی تابع فعالیت سیگموئیدی بکار 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 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-Baghmishah & Pavešicmm, 2003). برای تبدیل داده‌ها از روش نرمالیزاسیون 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_{min} و x_{max} به ترتیب مقادیر بیشینه و کمینه داده‌های اولیه، r_{min} و r_{max} هم به ترتیب حد بالایی و پایین دامنه تغییرات داده‌های تبدیل شده است.

از شبکه عصبی GMDH با هدف طبقه‌بندی سطح مزرعه به دو کلاس برای سه حالت مختلف استفاده شد. حالت اول برای زمانی است که مزرعه را به دو منطقه عدم وجود و کوچکتر یا مساوی ۶ حشره و به ترتیب حالت دوم و سوم برای زمانی است که تراکم حشره برای نقاطی از مزرعه کوچکتر یا مساوی و یا بزرگتر ۱۲ و ۱۸ حشره می‌باشد. کلاس اول برای حالت اول، دوم و سوم به ترتیب شامل ۱۴۳، ۱۷۲ و ۱۸۳ نقطه نمونه‌برداری شده می‌باشد و کلاس دوم برای حالت اول، دوم و سوم به ترتیب شامل ۵۷، ۲۸ و ۱۷ نقطه نمونه‌برداری شده می‌باشد. به صورت کاملاً تصادفی، ۷۰ درصد از کل داده‌ها برای آموزش شبکه و ۳۰ درصد باقی‌مانده برای آزمایش شبکه به منظور طبقه‌بندی انتخاب شد.

شبکه عصبی مصنوعی GMDH

شبکه عصبی GMDH دربرگیرنده مجموعه‌ای از نرون‌ها است که از پیوند جفت‌های مختلف از طریق یک چند جمله‌ای درجه دوم به وجود می‌آیند. شبکه با ترکیب چند جمله‌ای‌های درجه دوم حاصل از تمامی نرون‌ها، تابع تقریبی \hat{f} را با خروجی \hat{y} ، برای یک مجموعه از ورودی‌های $X = (x_1, x_2, x_{31}, \dots, x_{n1})$ با کمترین خطا در مقایسه با خروجی واقعی y ، توصیف می‌کند. بنابراین برای M داده آزمایشگاهی شامل n ورودی و یک خروجی، نتایج واقعی به شکل رابطه ۲ نمایش داده می‌شوند (Nariman-Zadeh et al. 2013).

$$y_i = f(x_{i1}, x_{i2}, x_{i3}, \dots, x_{in}) \quad (i = 1, 2, \dots, M) \quad (2)$$

در اینجا به دنبال شبکه‌ای هستیم که بتواند مقدار خروجی \hat{y} را برای هر بردار ورودی X بر اساس رابطه ۳ پیش‌بینی کند.

$$\hat{y}_i = \hat{f}(x_{i1}, x_{i2}, x_{i3}, \dots, x_{in}), \quad (i = 1, 2, \dots, M) \quad (3)$$

بطوری که میانگین مربعات خطا (MSE) بین مقادیر حقیقی و پیش‌بینی کمینه شود، به بیان دیگر:

$$MSE = \frac{\sum_{i=1}^M (\hat{y}_i - y_i)^2}{M} \rightarrow \min \quad (4)$$

شکل عمومی اتصال بین متغیرهای ورودی و خروجی را می‌توان با استفاده از تابع چند جمله‌ای به شکل رابطه ۵، بیان کرد.

$$y = a_0 + \sum_{i=1}^n a_i x_i + \sum_{i=1}^n \sum_{j=1}^n a_{ij} x_i x_j + \sum_{i=1}^n \sum_{j=1}^n \sum_{k=1}^n a_{ijk} x_i x_j x_k + \dots \quad (5)$$

که چند جمله‌ای ایواخنکو نامیده می‌شود. در بسیاری از موارد کاربردی از شکل درجه دوم و دو متغیره این چند جمله‌ای به صورت رابطه ۶ استفاده می‌شود.

$$\hat{y} = G(x_i, x_j) = a_0 + a_1 x_i + a_2 x_j + a_3 x_i^2 + a_4 x_j^2 + a_5 x_i x_j \quad (6)$$

ضرایب مجهول a_i در رابطه ۶ با تکنیک‌های رگرسیونی چنان به دست می‌آیند که اختلاف بین خروجی واقعی y و مقادیر محاسبه شده \hat{y} برای هر جفت متغیر ورودی x_i و x_j کمینه شود. مجموعه‌ای از چندجمله‌ای‌ها با استفاده از رابطه ۶ ساخته می‌شوند که ضرایب مجهول تمام آنها، با استفاده از روش حداقل مربعات به دست می‌آیند. برای هر تابع G_i (هر نرون ساخته شده)، ضرایب معادلات هر نرون برای حداقل کردن خطای کل E به منظور انطباق بهینه ورودی‌ها برای تمام جفت مجموعه‌های ورودی-خروجی، به دست می‌آیند.

$$E = \frac{\sum_{i=1}^M (y_i - G_i)^2}{M} \rightarrow \min \quad (7)$$

در روش‌های پایه‌ای الگوریتم GMDH، تمامی ترکیبات دوتایی (نرون‌ها) از n متغیر ورودی ساخته شده و ضرایب نامعلوم تمام نرون‌ها با استفاده از روش حداقل مربعات به دست می‌آیند. بنابراین: $\binom{n}{2} = \frac{n(n-1)}{2}$ نرون در لایه دوم ساخته می‌شوند که آن را می‌توان به شکل مجموعه ۸ نمایش داد.

$$\{(y_i, y_{ip}, y_{iq}) : (i = 1, 2, \dots, M) \& p, q \in (1, 2, \dots, m)\} \quad (8)$$

از شکل درجه دوم تابع بیان شده در رابطه ۵ برای هر M ردیف سه‌تایی استفاده می‌کنیم، این معادلات را می‌توان به شکل ماتریس رابطه ۹ بیان کرد.

$$Aa = Y \quad (9)$$

که در آن، A بردار ضرایب مجهول درجه دو نشان داده شده در رابطه ۵ است، یعنی:

$$a = \{a_0, a_1, \dots, a_5\} \quad (10)$$

و

$$Y = \{y_1, y_2, y_3, \dots, y_m\}^2 \quad (11)$$

از مقادیر بردارهای ورودی و شکل تابع به راحتی قابل مشاهده است که:

$$A = \begin{bmatrix} 1 & x_{1p} & x_{1q} & x_{1q}^2 & x_{1p}^2 & x_{1p}x_{1q} \\ 1 & x_{2p} & x_{2q} & x_{2q}^2 & x_{2p}^2 & x_{2p}x_{2q} \\ 1 & x_{3p} & x_{3q} & x_{3q}^2 & x_{3p}^2 & x_{3p}x_{3q} \\ 1 & x_{Mp} & x_{Mq} & x_{Mq}^2 & x_{Mp}^2 & x_{Mp}x_{Mq} \end{bmatrix} \quad (12)$$

روش حداقل مربعات از آنالیز Multiple - regression حل معادلات را به شکل ۱۳ به دست می‌دهد:

$$a = (A^T A)^{-1} A^T Y \quad (13)$$

این رابطه بردار رابطه ۶ را برای تمام M مجموعه سه تایی ایجاد می کند. ضرایب نرون ها در لایه های پنهان و خروجی در مرحله آموزش، توسط الگوریتم ژنتیک صورت می گیرد. بنابراین محاسبات در حجم بالا در عمل قابل حل بوده و کمک می کند تا سیستم معادلات نرمال، در شرایط مناسب و قابل حل قرار گیرد (Atashkari Jamali et al., 2010).

یکی از مسایل مهمی که در شبکه های عصبی مصنوعی چند لایه مطرح است، طراحی ساختار شبکه است. در این طراحی باید تعداد لایه ها و نیز ساختار درونی از قبیل تعداد وزن ها و مقادیر اولیه آنها و همچنین تابع تحریک هر نرون به صورت مناسب انتخاب گردد تا یک نگاهت مناسب و ایده آل میان داده های ورودی و خروجی برقرار شود. مساله طراحی شبکه عصبی GMDH با مسایل عنوان شده در بالا متمایز است. در این نوع از طراحی، هدف جلوگیری از رشد واگرایی شبکه و نیز مرتبط کردن شکل و ساختار شبکه به یک یا چند پارامتر عددی است، به گونه ای که با تغییر این پارامتر، ساختار شبکه ساختار شبکه ها نیز تغییر کند. روش های تکاملی مانند الگوریتم ژنتیک کاربرد وسیعی در مراحل مختلف طراحی شبکه های عصبی به دلیل قابلیت های منحصر به فرد خود در پیدا کردن مقادیر بهینه و امکان جست و جو در فضاهای غیر قابل پیش بینی دارند (Amanifard et al., 2007). در این پژوهش، برای طراحی شکل شبکه عصبی و تعیین ضرایب آن، از الگوریتم ژنتیک استفاده شد.

کاربرد الگوریتم ژنتیک در طراحی ساختار شبکه های عصبی نوع GMDH

برای عمومیت بخشیدن به شبکه عصبی GMDH لازم است که قید استفاده از لایه مجاور در ساختن لایه بعد حذف شود. در این نوع شبکه های عصبی برای ساخت لایه جدید می توان از تمام لایه های قبلی استفاده کرد. به این ساختار شبکه (GS) گویند.

نمایش ژنوم شبکه عصبی GS-GMDH

ژنوم یا کروموزومی که برای نمایش ساختار شبکه عصبی در نظر گرفته شد، شامل یک رشته نمایشی ساده، حاصل از ترکیب حروف الفبا است که در آن هر حرف نشان از یکی از ورودی های شبکه عصبی است. در این نوع کدگذاری، هر ورودی با یک حرف جایگزین می شود و هر کروموزوم به صورت رشته ای ساخته شده از این حروف الفبا است. برای یک شبکه با N ورودی $X = (x_1, x_2, x_3, \dots, x_n)$ یک کروموزوم به صورت تک رشته و ترکیبی از $\{a, b, c, d, \dots\}$ به شکل $a_1 a_2 \dots a_i \dots a_n$ شکل می گیرد، که در آن a, b, c به ترتیب جایگزین ورودی های x_1, x_2, x_3, \dots می شوند. در این پژوهش شبکه با دو ورودی، دو حرف می تواند برای ساختن ژنوم ها استفاده شود. بدیهی است که هر کروموزوم با طول برابر 2k که $k \in \{1, 2, 3, \dots, (n_1 + 1)\}$ که n_1 تعداد لایه مخفی است، می تواند نشان دهنده یک ساختار شبکه عصبی باشد. ابتدا فرض می کنیم که هر نرون از ترکیب دو نرون در لایه مجاور ساخته شده است. به طور کلی، رابطه $2^{HL+1} = \text{Lenght of noron}$ که HL نشان از لایه مخفی است، ارتباط بین طول نرون و تعداد لایه های مخفی را در این کدگذاری نشان می دهد. بنابراین این شبکه دارای دو لایه مخفی است.

بدیهی است که هر نرون به طول 2n متعلق به لایه n ام است. در شبکه عصبی نوع GS نرون ها با طول های مختلف با یکدیگر ترکیب می شوند، در واقع، نرون با طول کوچکتر باید از چند لایه مخفی جهش کرده و با نرون با طول بزرگتر ترکیب شود. برای حل این مشکل نام نرون هایی را که از لایه ها جهش می کنند، تکرار می کنیم (Atashkari Jamali et al., 2010).

شرط توقف

تعداد کل تکرار الگوریتم‌های ژنتیک برابر با ۱۰۰ در نظر گرفته شده است و اگر بعد از ۵۰ تکرار بهبودی در مقدار برازندگی به وجود نیاید، الگوریتم متوقف می‌شود.

تنظیم پارامترهای ورودی الگوریتم

مقدار پارامترهای ورودی الگوریتم شامل اندازه جمعیت، نرخ کراسینگ آور، نرخ جهش، که مقدار این پارامترها در جدول یک ارائه شده است.


جدول ۱- مقادیر پارامترهای ورودی الگوریتم ژنتیک برای آموزش شبکه عصبی GMDH

Table 1. The values input parameters of Genetic Algorithm for Training GMDH neural networks

Parameters	Values
Maximum number of generations (Max- gen)	100
Crossover rate (Pc)	0.6
Mutation rate (Pm)	0.03
Population size	50

نتایج و بحث


بررسی تغییرات جمعیت کفشدوزک هفت‌نقطه‌ای در مزارع یونجه منطقه باجگاه طی سال ۱۳۹۲ نشان داد که حشرات کامل زمستان‌گذران از اواسط فروردین ظاهر شده و در دارای سه نسل در شرایط آب و هوایی این منطقه است. روند تغییرات جمعیت کفشدوزک به خوبی در شکل ۱ قابل مشاهده است.



شکل ۱- تغییرات جمعیت کفشدوزک *Coccinella septempunctata* طی دوره‌های نمونه‌برداری در منطقه باجگاه سال ۱۳۹۲

Fig1. Population changes of *Coccinella septempunctata* during sampling periods in Badjgah area, 2013

با توجه به شکل شماره ۲ که در محور افق تعداد تکرار و عمود میزان خطا را نشان می‌دهد پس از تکرار ۴۰ الگوریتم ژنتیک روند کاهش شاخص خطا آموزش ثابت ماند و مقدار آن (۰/۰۰۶) به دست آمد.



شکل ۲- روند همگرایی الگوریتم ژنتیک پس از صد تکرار در کاهش خطا آموزش شبکه عصبی GMDH

Fig. 2. Convergence of Genetic Algorithm after hundred iteration in error reduction of Training GMDH neural networks

برای اطمینان از یادگیری شبکه عصبی آموزش دیده برای پیش‌بینی الگوی پراکنش کفشدوزک هفت نقطه‌ای، 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 فرضیه در سطح احتمال ۵ درصد به کمک پارامتر p آزمون شد. به ترتیب برای مقایسه میانگین، واریانس و توزیع آماری از آزمون F ، T و کولموگروف - اسمیرنوف استفاده شد. مقادیر P محاسبه شده برای هر مورد در جدول ۲ نشان داده شده است. نتایج نشان می‌دهد که میانگین، تجزیه واریانس برای شبکه GMDH اختلاف معنی دار نشان داد ($p > 0.60$) و بین توزیع آماری مقادیر واقعی و پیش‌بینی شده توسط شبکه GMDH اختلاف معنی داری در سطح ۹۵ درصد وجود ندارد ($p > 0.84$). وجود $p=1$ در مورد توزیع آماری بین مقادیر پیش‌بینی شده و مقادیر واقعی تراکم کفشدوزک هفت نقطه‌ای در فاز آموزش و همچنین وجود $p=1.00$ در فاز آزمایش در سطح مزرعه، نشان از دقت بالا و نیز قابلیت تطابق با مقادیر بحرانی را دارد.

جدول ۲- مقایسات آماری مقادیر واقعی و پیش‌بینی تراکم کفشدوزک هفت نقطه‌ای توسط شبکه عصبی GMDH

Table 2. Statistical comparisons between the observed and estimated *Coccinella septempunctata* density by GMDH neural networks

Classification	Utilization phase	Comparisons of means	Comparisons of variance	Comparisons of distribution
CD=0, CD \leq	Training Phase	0.620	0.909	0.82
	Test Phase	0.988	0.994	0.91
CD>6, CD \leq 12	Training Phase	0.753	0.972	1.00
	Test Phase	0.966	1.00	1.00
CD>12, CD \leq 18	Training Phase	0.802	0.983	1.00
	Test Phase	0.993	1.00	1.00

ضرایب تبیین و رابطه خطی رگرسیونی بین مقادیر واقعی هر کلاس در مقابل مقادیر پیش‌بینی شده توسط شبکه GMDH در جدول شماره ۳ نشان داده شده است. بهترین نتایج بر اساس این دو معیار وقتی به دست می‌آید که معادله خطی مابین تراکم کفشدوزک هفت نقطه‌ای واقعی و تراکم کفشدوزک هفت نقطه‌ای پیش‌بینی شده توسط شبکه GMDH علاوه بر داشتن ضرایب تبیین بالا دارای عرض از مبدا کم و شیب نزدیک به یک باشد. کاملاً واضح است که ضرایب تبیین بین داده‌های واقعی و پیش‌بینی شده بسیار رضایت‌بخش می‌باشند (۰/۸).

نتایج جدول ۳ نشان می‌دهد که قابلیت تعمیم‌پذیری شبکه عصبی آموزش دیده بسیار بالا می‌باشد، زیرا فاز آزمایش در مقایسه با فاز آموزش دارای ضریب تبیین بالاتر و نیز معادله خطی رگرسیونی مابین مقادیر واقعی و پیش‌بینی شده از شیب نزدیک‌تر به واحد و عرض از مبدا نزدیک به صفر برخوردار است.

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	R^2
CD=0, CD≤6	Training Phase	$pv= 0.9498 av +0.0089$	0.9412
	Test Phase	$pv= 0.8645 av +0.0100$	0.8910
CD>6, CD≤12	Training Phase	$pv= 0.9785 av +0.0105$	0.9699
	Test Phase	$pv= 0.9154 av +0.0154$	0.9231
CD>12, CD≤18	Training Phase	$pv= 0.9899 av +0.0021$	0.9800
	Test Phase	$pv= 0.9019 av +0.0004$	0.9457

نقشه‌های توزیع مکانی کفشدوزک هفت نقطه‌ای

نقشه پراکندگی مکانی کفشدوزک هفت نقطه‌ای توسط شبکه GMDH تفکیک و ترسیم شده و در شکل ۲ نشان داده شده است. در این شکل ابتدا تراکم این دشمن طبیعی به دو کلاس فاقد و دارای ۶ دشمن طبیعی، ترسیم و نقشه‌های آن رسم شد (شکل ۱ a و b). در شکل ۱ c و d و نیز در شکل ۱ e و f به ترتیب، جمعیت این دشمن طبیعی بر اساس دو کلاس ۱۲ و ۱۸ عدد ترسیم شده است. این حدود انتخابی یک حد آستانه محاسبه است تا به وسیله آنها قابلیت شبکه GMDH نشان داده شود. 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 GMDH است. ولی در مورد صحت کارایی یک مدل نمی‌توان تنها با مقایسه یک یا چند نقطه قضاوت کرد (Zhang & Fuh, 1998).

در مقایسه نقشه‌های تفکیک شده توسط مدل شبکه عصبی و نقشه‌های واقعی بخش‌های مرکزی زمین دارای این دشمن طبیعی بودند 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. آنها رفتار اکولوژیک حشرات در کارایی مدل‌های شبکه عصبی موثر دانستند (Zhang et al., 2008). لذا برای بالابردن کارایی یک شبکه عصبی برای تشخیص پراکندگی تعداد لایه‌های مخفی، توابع تحریک و حتی مرحله زیستی حشره موثر است (Filippi and Jensen, 2006; Zhang et al., 2008). در پژوهش دیگری که با استفاده از شبکه عصبی LVQ4 انجام شد، محققین پراکندگی شب‌پره مینوز گوجه‌فرنگی را در سه سطح بررسی کردند و نتایج نشان از قدرت تفکیک و کارایی بسیار بالای شبکه عصبی LVQ4 و توزیع تجمعی این آفت داشت (Shabani nejad et al., 2016). همچنین در پژوهش کارایی بالای شبکه عصبی مصنوعی MLP در پیش‌بینی پویایی جمعیت مگس گالزا (Diptera: Cecidomyiida) در جنگل‌های سوزنی‌برگ آمریکا بود بررسی شد (Young et al., 2000). نتایج به دست آمده از این دو پژوهش‌ها با نتایج حاصل از این پژوهش هماهنگی داشت.



شکل ۳- نقشه توزیع کفشدوزک هفت نقطه‌ای *Coccinella septempunctata* در دو حالت واقعی (شکل‌های b, d و f) و تفکیک شده توسط مدل شبکه عصبی (شکل‌های a, c, e). نقشه‌های (a, b) بر اساس حد آستانه ۶ حشره، نقشه‌های (c, d) بر اساس حد آستانه ۱۲ حشره و نقشه‌های (e, f) بر اساس حد آستانه ۱۸ حشره.

Fig. 3. *Coccinella septempunctata* distribution maps in actual (b, d and f) and classified conditions by GMDH neural networks (c, e and a). The maps of a, c, e and b, d, f have been drawn according to economic threshold of 6, 12 and 18 respectively.

نتیجه‌گیری

زندگی کفشدوزک هفت‌نقطه‌ای به رغم مطالعات گسترده در جهان به دلیل چرخه زیستی متفاوت در مکان‌های مختلف، بسیار پیچیده است. تغییرات شرایط آب و هوایی در هر منطقه علاوه بر رشد جمعیت، می‌تواند بر زمان شروع و پایان دوره استراحت کفشدوزک هفت‌نقطه‌ای نیز تاثیر گذار باشد. همچنین مطالعه حاضر نشان داد که کفشدوزک هفت‌نقطه‌ای در شرایط اقلیمی منطقه باجگاه دارای سه نسل در سال است. اجرای هر برنامه مدیریتی که شامل شکارگرانی مانند کفشدوزک یاد شده است باید همراه با مطالعات محلی در مورد پراکنش، دیابوز، نوسانات جمعیت در فصول مختلف آن‌ها باشد. کفشدوزک هفت‌نقطه‌ای یکی از مهم‌ترین دشمنان طبیعی آفات گروه جوربالان در مزارع یونجه محسوب می‌شود که بخصوص در کنترل شته‌ها نقش به‌سزایی را ایفا می‌کند. اگرچه ممکن است نقش این حشرات مفید در طبیعت زیاد مهم به نظر نرسد ولی بدون آن‌ها کنترل آفات از جمله شته‌ها در مزارع و باغات مشکل خواهد بود. حفاظت از این دشمنان طبیعی مستلزم ایجاد شرایطی مناسب بوده که دارای حداقل استرس باشد. یکی از عواملی که می‌تواند به این مسئله کمک کند تغییر در عملیات زراعی شامل (حفظ پناهگاه‌های آن‌ها با کاشت و یا برداشت ردیفی یا حفظ پوشش گیاهی، رعایت تناوب و تقویت جمعیت‌های محلی می‌باشد (Obrycki & Kring, 1998). مدیریت مکان - ویژه‌ی دشمنان طبیعی، راهکاری برای حفاظت و حمایت از این دشمنان طبیعی می‌باشد. نتایج حاصل از این پژوهش می‌تواند در مدیریت مکان - ویژه این گونه نیز مورد استفاده قرار گیرند به این صورت که با استفاده از نقشه‌های پراکنش، می‌توان از این عوامل کنترل طبیعی در نقاط پراکنش آنها، متمرکز ساخت 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 (نقشه پراکنش) را پیش‌بینی کرد. در این پژوهش شبکه عصبی توانست با دقت مناسبی علاوه بر پیش‌بینی، نقشه پراکنش کفشدوزک هفت‌نقطه‌ای را ترسیم نماید. نقشه حاصله بیان‌کننده پراکنش تجمعی این دشمن طبیعی است. بنابراین در محل‌هایی با تراکم بالا کفشدوزک می‌توان با کاهش مصرف سموم جهت حفاظت و حمایت از این شکارگر پرداخت.

References

- Ali, A. & Rizvi, P. Q. (2010). Age and stage specific life table of *Coccinella septempunctata* L. (Coleoptera: Coccinellidae) at varying temperatures. *World Journal of Agricultural Sciences* 6, 268-273.
- Atashkari, K., Nariman-Zadeh, N., Gölcü M, Khalkhali A., Jamali, A. (2010). Modeling and multi-objective optimization of a variable valve-timing spark-ignition engine using polynomial neural networks and evolutionary algorithms. *Energy Conversion and Management* 48, 29-41.
- Amanifard. N., Nariman-Zadeh, M., Borji, A., Khalkhali & Habibdoust, A. (2007). Modeling and Pareto Optimization of Heat Transfer and Flow Coefficients in Micro channels using GMDH Type neural Networks and Genetic Algorithms. *Energy Conversion and Management* 15, 32-40.
- Cravener, T. L., & Roush, W. B. (2013). Improving neural network prediction of amino acid levels in feed ingredients. *Journal of applied poultry research* 78, 983- 991 .
- Elliott, N.C., & Kieckhefe, R.W. (1990). A thirteen-year survey of the aphidophagous insects of alfalfa. *Prairie Naturalist* 22, 87-96.

- Elliott, N.C. & Micheis, G.J.** (1997). Estimating aphidophagous Coccinellid population in alfalfa. *Biological control* 8, 43-51.
- 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.
- Hagen, J.S.** (1962). Biology and ecology of predaceous *Coccinllidae*. *Annual Review of Entomology* 7, 289-326.
- Hodek, I.** (1973). Biology of Coccinellidae. *Aeademia* publishing house of theczechoslovak Academy of Sciences Pragus 260pp.
- Honek, A. & Martinkova, Z.** (2005). Long term changes in abundance of *Coccinella septempunctata* L. (Coleoptera: Coccinellidae) in the Czech Republic. *European Journal of Entomology* 102, 443-448.
- Irmak, A., Jones, J. W., Batchelor, W. D., Irmak, S., Boote, k. J. & 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.
- Kianpour, R., Fathipour, Y., Kamali, K. & Naseri, B.** (2010). Bionomics of *Aphis gossypii* (Homoptera: Aphididae) and its predators *Coccinella septempunctata* and *Hippodamia variegata* (Coleoptera: Coccinellidae) in natural conditions. *Journal of Agricultural Science and Technology* 12, 1-11.
- Mittal, G., S, & Zhang, J.** (2010). Prediction of temperature and moisture content of frankfurters during thermal processing using neural network. *Journal of applied poultry research* 70, 13-24.
- Nariman-Zadeh, N., Darvizeh, A., Ahmad-Zadeh, G.R.** (2013). Hybrid genetic design of GMDH-type neural networks using singular value decomposition for modeling and prediction of the explosive cutting process. *Energy Conversion and Management* 217, 79-90.
- Shabani nejad, A. R. & tafaghodinia, B.** (2016a) 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.
- Shabani nejad, A. R. & tafaghodinia, B.** (2016b) Evaluation of Geostatistical Methods and Artificial Neural Network for Estimating the Spatial Distribution of *Tetranychus urticae* (Acari: Tetranychidae) in Cucumber field Ramhormoz. *Journal of Applied Entomology and Phytopathology* 85, 22-30.
- Shabani nejad, A. R., tafaghodinia, B., Zandi- sohani, N.** (2016). Hybrid neural network with genetic algorithms for predicting distribution pattern of *Tetranychus urticae* T. in cucumbers field of Rāmhormoz. *Persian journal of Acarology* 8, 240-252.
- Shabani nejad, A. & Tafaghodiniya, B.** (2017). Automatic clustering of data from sampling and evaluation of neuro-fuzzy network to estimating the distribution of *Bemisia. tabaci* (Hem.: Aleyrodidae). *Journal of Iranian Entomological Society* 37, 91-105.
- Shabani nejad, A. R., tafaghodinia, B., zandi- sohani, N.** (2017). Evaluation of Geostatistical Method and hybrid Artificial Neural Network with Imperialist Competitive Algorithm for predicting distribution pattern of *Tetranychus urticae* (Acari: Tetranychidae) in cucumber field of Behbahan, Iran. *Persian journal of Acarology* 8, 333-345.

- Vakil-Baghmisheh, MT & N, Pavešic.** (2003). Premature clustering phenomenon and new training algorithms for LVQ. *Pattern recognition* 36(5), 1901-1921.
- Young-S.P., Ja-Myung, K., Buom-Young, L., Yeong-Jin, L. & 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.
- Yuxin, M., D. J, Mulla & C. R, Pierre.** (2006) Identifying important factors influencing corn yield and grain quality variability using artificial neural networks. *Precision Agriculture* 7(2), 117-135.
- 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.