

## ارزیابی مدل شبکه عصبی مصنوعی GMDH در برآورد پراکنش مکانی کنه‌های خانواده Laelapidae (Acari, Mesostigmata) در منطقه شاهرود استان سمنان

مسعود حکیمی تبار<sup>۱\*</sup>، سید رضا حجازی<sup>۲</sup>، علیرضا شعبانی نژاد<sup>۳</sup>، پریسا قرآنی دامداباجا<sup>۴</sup> و الناز فدائی<sup>۴</sup>

۱ و ۴. استادیار و دانشجوی سابق کارشناسی ارشد، گروه گیاهپزشکی، دانشکده کشاورزی، دانشگاه صنعتی شاهرود، شاهرود، ایران

۲. استادیار، گروه ریاضی محض، دانشکده ریاضی، دانشگاه صنعتی شاهرود، شاهرود، ایران

۳. دانشجوی دکتری، گروه گیاهپزشکی، دانشکده کشاورزی، دانشگاه رازی، کرمانشاه، ایران

(تاریخ دریافت: ۱۳۹۶/۱۰/۱۹ - تاریخ پذیرش: ۱۳۹۷/۱۰/۹)

### چکیده

این پژوهش به منظور برآورد پراکنش مکانی کنه‌های خانواده Laelapidae در منطقه شاهرود با به کارگیری شبکه عصبی مصنوعی انجام شد. داده‌های مربوط به تراکم جمعیت این کنه از زیستگاه‌های گوناگون منطقه شاهرود در سال ۱۳۹۴ به دست آمدند. در این پژوهش از متغیرهای طول و عرض جغرافیایی به عنوان متغیرهای ورودی و از دگرگونی‌های جمعیت کنه‌های خانواده Laelapidae به عنوان متغیر خروجی استفاده شد. شبکه مورد استفاده از نوع GMDH بهینه شده با الگوریتم ژنتیک بود. برای ارزیابی توانایی شبکه‌های عصبی مورد استفاده در پیش‌بینی توزیع از سنجش آماری مؤلفه‌هایی مانند واریانس، توزیع آماری و میانگین میان اندازه‌های پیش‌بینی شده مکانی به وسیله شبکه عصبی و اندازه‌های واقعی آن‌ها استفاده شد. نتیجه‌ها نشان دادند که در فازهای آموزش و آزمایش میان اندازه‌های ویژگی‌های آماری واریانس، توزیع آماری و میانگین مجموعه داده‌های واقعی و پیش‌بینی شده مکانی این خانواده به وسیله شبکه عصبی GMDH تفاوت معنی‌داری وجود نداشت. نقشه‌های ترسیم شده نشان داد که توزیع کنه‌های این خانواده تجمعی است. نقشه‌های به دست آمده از شبکه‌های عصبی مصنوعی می‌توانند به برنامه‌ریزان جهت به کارگیری برنامه‌های مهار آفت‌ها یاری کنند به ویژه اگر نقشه‌ها با مختصات جغرافیایی هر مکان همانندی داشته باشند. به طوری که تمرکز بیشتر مهار به منطقه‌هایی معطوف شود که تراکم این کنه‌های شکارگر کمتر است.

**واژه‌های کلیدی:** توزیع مکانی، شبکه عصبی مصنوعی GMDH، پراکنش تجمعی.

## Evaluation of GMDH artificial neural network model for predicting the spatial distribution of the family Laelapidae (Acari, Mesostigmata) in Shahrood region, Semnan province

Masoud Hakimitabar<sup>1\*</sup>, Seyed Reza Hejazi<sup>2</sup>, Alireza Shabaninejad<sup>3</sup>, Parisa Ghorani Damdabaja<sup>4</sup> and Elnaz Fadaei<sup>4</sup>

1, 4. Assistant Professor and Former M. Sc. Student, Department of Plant Protection, Faculty of Agriculture, Shahrood University of Technology, Shahrood, Iran

2. Assistant Professor, Faculty of Mathematics, Shahrood University of Technology, Shahrood, Iran

3. Ph. D. Candidate, Department of Plant Protection, College of Agriculture, Razi Kermanshah University, Kermanshah, Iran

(Received: Jan. 9, 2018 - Accepted: Dec. 30, 2018)

### ABSTRACT

This study aimed to predict the population of Laelapid mites in Shahrood region using an artificial neural network. The data of this family were obtained in the year 2015. In this model, the variables sampling date, longitude and latitude as the input variables, and the population of Laelapid mites were used as the output variable. The network type used was GMDH neural network that was optimized by genetic algorithms. To evaluate the ability of GMDH neural networks to predict the distribution, statistical comparison parameters such as mean, variance, statistical distribution, and coefficient determination of linear regression between predicted values and actual values were used. Results showed that in training and test phases of GMDH neural network, there was no significant effect between variance, mean, and statistical distribution of actual values and predicted values. Our map showed the patchy distribution of these predatory mites. Maps obtained from artificial neural networks help program planners to use the pest control programs, particularly if maps coordinate with geographical conformity of each location. Therefore, control was focused on areas with decreased densities of these predatory mites.

**Keywords:** Cumulative dispersion, GMDH artificial neural network, spatial distribution.

\* Corresponding author E-mail: hakimitabar@yahoo.com

### مقدمه

کنه‌ها بخش مهمی از زیست‌بوم را تشکیل می‌دهند که کم‌وبیش در همگی زیستگاه‌های شناخته‌شده به‌وسیله انسان وجود دارند. شمار فراوانی از بندپایان از جمله کنه‌ها در بقایای مواد آلی و هوموسی درون خاک، به‌صورت همزیست با حشرات و بندپایان دیگر و روی گیاهان و بدن مهره‌داران زندگی می‌کنند. کنه‌ها از اجزاء بسیار باارزش زنجیره‌ها و شبکه‌های غذایی در خاک هستند که گوناگونی فراوانی در رژیم غذایی آن‌ها مشاهده می‌شود. شماری از این کنه‌ها پوسیده خوار بوده و از بقایای مواد موجود در خاک تغذیه می‌کنند. برخی از آن‌ها، بندپایان دیگر از جمله کنه‌ها، حشرات، نماتدها و غیره را درون خاک مورد حمله قرار می‌دهند. عده‌ای نیز از بافت زنده بخش‌های زیرزمینی گیاهان و قارچ‌ها تغذیه می‌کنند. شمار فراوانی از کنه‌های خاکزی رژیم غذایی شکارگری دارند و این کنه‌های شکارگر بیشتر به راسته میان استیگمایان تعلق دارند (Krantz & Walter, 2009). شمار فراوانی از این کنه‌ها با دیگر بندپایان و به‌ویژه حشرات در پیوند هستند و این وابستگی به دلیل‌های گوناگونی در این کنه‌ها رخ می‌دهد که وابستگی انگلی و رایج‌تر از آن، به‌کارگیری میزبان برای جابجایی به زیستگاه‌های تازه و دسترسی به منبع‌های غذایی با شرایط بهتر از این موارد هستند (Walter & Proctor, 1999; Joharchi, 2011).

خانواده Laelapidae گروهی بسیار گوناگون از لحاظ ریخت‌شناسی و بوم‌شناختی در بالاخانواده Dermanyssoidea است. این کنه‌ها یکی از مهم‌ترین گروه‌های کنه‌های شکارگر را تشکیل می‌دهند که از بندپایان دیگر و نماتدها تغذیه می‌کنند و نقش مهمی در کاهش جمعیت برخی از میزبان‌های خود دارند. شمار فراوانی از گونه‌های جنس‌های گوناگون این خانواده رفتار شکارگری را در خاک و مواد انباری از خود نشان می‌دهند، به‌طوری‌که امروزه در شماری از نقطه‌های دنیا برخی از گونه‌های شکارگر این خانواده را در مبارزه زیستی در برابر آفت‌ها مورد استفاده قرار می‌دهند (Krantz & Walter, 2009). کنه *Stratiolaelaps miles* (Berlese) در کنترل آفت‌های

گلخانه‌ای مانند لارو مگس‌های Sciaridae مورد استفاده قرار می‌گیرد و گونه *Gaeolaelaps aculeifer* Canestrini شکارگر خاکزی است که به‌عنوان دشمن طبیعی نماتدها، تریپس‌ها و کنه‌های Acaridae هستند. شمار فراوانی از این کنه‌ها با حشره‌های گوناگون و در زیستگاه‌های گوناگون پیوستگی دارند، بنابراین امروزه از آن‌ها به‌عنوان عامل‌های دارای توانایی مهار زیستی در کنترل بسیاری از آفت‌ها یاد می‌شود (Joharchi, 2011).

درون‌یابی مکانی دربرگیرنده برآورد متغیرهایی مانند انبوهی حشره موردنظر، در بخش‌های نمونه‌برداری نشده با به‌کارگیری داده‌های به‌دست‌آمده از بخش‌های نمونه‌برداری شده است. به گفته‌ای یک روش درون‌یابی ایده آل قادر است با به‌کارگیری داده‌ها مربوط به انبوهی حشره در بخش‌های اندک نمونه‌برداری شده، انبوهی حشره را در بخش‌های نمونه‌برداری نشده به‌درستی برآورد کند (Makarjian, 2008). از روش‌های درون‌یابی مورد استفاده در پژوهش‌های حشره‌شناسی روش‌های کریجینگ<sup>۱</sup> و شبکه عصبی مصنوعی<sup>۲</sup> را می‌توان نام برد.

مدل‌های شبکه عصبی مصنوعی در سنجش با مدل‌های ریاضی دارای توانایی آموزش رابطه‌های میان متغیرهای مستقل و وابسته هستند (Mittal & Zhang, 2010). شبکه‌های عصبی مصنوعی با دقت و درستی بیشتری می‌توانند همبستگی میان متغیرها را شبیه‌سازی کنند (Cravermer & Roush, 2013). پژوهش‌های بی‌شماری نشان داده‌اند که شبکه‌های عصبی توانایی بالایی در شناسایی الگوهای توزیع مکانی جمعیت‌های بوم‌شناختی‌ای دارند (Goel et al., 2003; Irmak et al., 2006). در پژوهشی، مدل شبکه عصبی بردار چندی ساز یادگیر<sup>۳</sup> برای بررسی توزیع مکانی حشره‌ها در زمین‌های چراگاهی استفاده شد و کارایی پسندیده‌ای نشان داد (Zhang et al., 2008). در پژوهشی دیگر، داده‌های برآمده از نمونه‌برداری مزرعه خیار به‌وسیله روش خوشه‌بندی خودکار تقسیم‌بندی شدند و به‌وسیله شبکه

1. Kriging

2. Artificial Neural Network

3. Learning Vector Quantization Neural Network

آب و هوایی آن است. بخش جنوبی که در همسایگی کویر واقع شده است آب و هوای کم‌وبیش گرم و خشک دارد. بخش مرکزی و بخش‌های شرقی شاهرود دارای آب و هوای معتدل و بخش‌های شمالی آن کوهستانی با آب و هوایی کم‌وبیش سرد و خشک هستند. میانگی دمای سالانه در این شهرستان ۱۴ درجه سلسیوس و میانگین بارندگی سالانه ۱۸۰ میلی‌متر است. این شهر در حاشیه شمالی دشت کویر و در دامنه‌های جنوبی رشته‌کوه البرز با موقعیت جغرافیایی ۳۶ درجه و ۲۵ دقیقه عرضی و ۵۴ درجه و ۵۸ دقیقه طولی در شمال خاوری استان سمنان قرار گرفته است.

#### روش نمونه‌برداری

به‌منظور جمع‌آوری کنه‌های خانواده Laelapidae در منطقه شاهرود، از خاک بر پایه برنامه زمان‌بندی شده نمونه‌برداری انجام شد. این نمونه‌برداری به‌صورت تصادفی تا ژرفای ۲۰ سانتی‌متر انجام شد. نمونه‌ها درون کیسه‌های پلاستیکی ریخته شدند و پس از کار گذاشتن برچسب که دربرگیرنده داده‌های مربوط به محل جمع‌آوری، تاریخ جمع‌آوری و میزبان است به آزمایشگاه منتقل شدند. برای جداسازی کنه‌ها از نمونه‌های خاک از قیف برلیز استفاده شد. نمونه خاک روی الک درون قیف برلیز ریخته شده و کنه‌های درون آن در یک ظرف دربردارنده الکل ۷۵ درصد که زیر قیف قرار داشت جمع‌آوری شدند. با بررسی درون‌مایه‌های ظرف در زیر استریومیکروسکوپ نمونه‌ها با به‌کارگیری پنس ظریف به درون ظرفی که دربرگیرنده مایع شفاف کننده نسبی است انتقال یافت. پس از شفاف شدن نمونه‌ها، برای آماده کردن اسلاید از آن‌ها از مایع فاوور استفاده شد. اسلایدها برای زمانی برابر دو هفته تا ۲۰ روز درون آون با دمای ۴۵ درجه سلسیوس قرار داده شدند تا خشک شوند و برای جلوگیری از راه‌یابی رطوبت به مایع فاوور، کناره‌های لامل با رنگ‌های روغنی درزگیری شد و در پایان برچسب ویژگی‌ها کار گذاشته شد.

#### تجزیه و تحلیل آماری

آزمون نرمال‌سازی داده‌های مربوط به نمونه‌برداری به

نروفازی پراکندگی سفید بالک پنبه ترسیم شد (Shabani nejad & Tafaghodiniya, 2017a)، همچنین، در پژوهشی در مزرعه خیار شهرستان بهمان، روش‌های زمین‌آمار و شبکه عصبی مصنوعی بهینه‌شده در آشکار ساختن پراکندگی مکانی کنه تارتن دولک‌های مورد ارزیابی قرار گرفت و توانا به پیش‌بینی انبوهی آفت با دقت پسندیده بود (Shabaninejad et al., 2017a)، در پژوهشی دیگر، از شبکه عصبی مصنوعی و الگوریتم ژنتیک در پیش‌بینی الگوی توزیع کنه تارتن دو لکه‌ای در مزرعه خیار شهرستان رامهرمز استفاده شد که برآیندها کارایی بسیار بالای این شبکه را نشان داد و نقشه‌های ترسیم‌شده نشان داد که توزیع آفت جمعی است (Shabani nejad et al., 2017b). در پژوهشی دیگر، شعبانی نژاد و تفقدی نیا (Shabaninejad and Tafaghodiniya, 2017b) با روش‌های زمین‌آمار و شبکه عصبی مصنوعی پراکندگی مکانی کنه تارتن دو لکه‌ای در مزرعه خیار شهرستان رامهرمز را تعیین کردند. افزون بر این، در پژوهشی از شبکه عصبی LVQ4 در برآورد توزیع پراکندگی شب‌پره مینوز گوجه‌فرنگی استفاده شد و کارایی بسیار بالایی از خود نشان داد (Shabani nejad & Tafaghodiniya, 2016)، در نهایت حکیمی تبار و همکاران (Hakimitabar et al., 2017) مدل شبکه عصبی مصنوعی MLP را در تعیین پراکندگی مکانی کنه‌های خانواده Ascidae در سطح شهرستان دامغان ارزیابی کردند.

بنا به بررسی‌های انجام‌شده، تاکنون پژوهشی به‌منظور ارزیابی روش شبکه عصبی مصنوعی GMDH در راستای انجام شدن برنامه مدیریت تلفیقی آفت‌ها و پراکندگی شکارگرها، در منطقه شاهرود انجام نشده است. به همین دلیل، پژوهش حاضر با هدف شناخت چگونگی پراکندگی این کنه‌های شکارگر در منطقه شاهرود انجام شد.

#### مواد و روش‌ها

##### موقعیت جغرافیایی

شاهرود یکی از شهرستان‌های استان سمنان است که در فاصله ۴۰۰ کیلومتری تهران و در حاشیه کویر واقع شده است. یکی از برتری‌های برجسته این شهرستان گوناگونی

نمونه‌ها، برای تقسیم‌بندی سطح زمین به منطقه‌های گوناگون انبوهی‌ای سه کلاس تشکیل شد و از طرفی این سه کلاس به این خاطر به وجود آمد که توانایی جداسازی شبکه در برابر سطوح گوناگون انبوهی‌ای سنجیده شود.

شبکه عصبی GMDH دربرگیرنده مجموعه‌ای از نورون‌ها است که از پیوند جفت‌های گوناگون از راه یک چندجمله‌ای پایه دوم به وجود می‌آیند (Nariman-Zadeh *et al.*, 2013).

یکی از پرسش‌های مهمی که در شبکه‌های عصبی مصنوعی چندلایه پیش کشیده شده است، طراحی ساختار شبکه است. در این طراحی باید شمار لایه‌ها و نیز ساختار درونی مانند شمار وزن‌ها و اندازه‌های نخستین آن‌ها و همچنین، تابع برانگیختن هر نورون به صورت پسندیده گزینش شده تا یک نگاشت بایسته و دلخواه میان داده‌های ورودی و خروجی برپا شود. چالش طراحی شبکه عصبی GMDH با پرسش‌های عنوان‌شده در بالا جدا است. در این گونه از طراحی، هدف جلوگیری از رشد واگرایی شبکه و نیز پیوسته کردن شکل و ساختار شبکه به یک یا چند مؤلفه عددی بوده، به گونه‌ای که با دگرگونی این مؤلفه ساختار شبکه ساختار شبکه‌ها نیز دگرگونی شود. روش‌های تکاملی مانند الگوریتم ژنتیک کاربرد گسترده‌ای در مراحل گوناگون طراحی شبکه‌های عصبی به دلیل توانایی‌های منحصر به فرد خود در پیدا کردن اندازه‌های بهینه و امکان جست‌وجو در فضاهای غیرقابل پیش‌بینی دارند. در این پژوهش، برای طراحی شکل شبکه عصبی و تعیین ضریب‌های آن، از الگوریتم ژنتیک استفاده شده است (Amanifard *et al.*, 2007). به منظور کاربرد الگوریتم ژنتیک در طراحی ساختار شبکه‌های عصبی نوع GMDH برای عمومیت بخشیدن به شبکه عصبی GMDH نیاز است که قید به‌کارگیری لایه مجاور در ساختن لایه بعد را حذف کنیم. در این نوع شبکه‌های عصبی برای ساخت لایه تازه می‌توان از همه لایه‌های پیشین استفاده کرد. به این ساختار شبکه (GS)<sup>۳</sup> گویند.

یاری نرم‌افزار SPSS 19 و آزمون کولموگروف-اسمیرنوف<sup>۱</sup>، بررسی شد و به دلیل عدم نرمال بودن آن‌ها، داده‌ها به وسیله روش کاکس باکس نرمال شدند. کد رایانه‌ای شبکه عصبی GMDH در محیط نرم‌افزار Matlab نسخه ۸/۱ تهیه شد.

### پیش‌پردازش داده‌ها

در آغاز داده‌ها به طور تصادفی به دو دسته مجموعه آموزش با ۹۹ عضو (۷۰ درصد همه داده‌ها) و مجموع آزمایش با ۴۲ عضو (۳۰ درصد همه داده‌ها) تقسیم‌بندی شدند. البته اگر این تقسیم‌بندی منجر به برآیندهای دلخواه نشود، می‌توان این مرحله را دوباره تکرار کرد (Zhang & Fu, 1998). پیش از به‌کارگیری داده‌های خام نخستین در آموزش شبکه، باید داده‌ها در دامنه مناسبی نرمال‌سازی شوند زیرا الگوریتم یادگیری همراه با داده‌های خام نمی‌تواند کارکرد درخوری داشته باشد و همچنین به دلیل دامنه دگرگونی‌های خروجی تابع فعالیت سیگموئیدی<sup>۲</sup> به‌کار گرفته شده در لایه میانی، این امر ناگزیر به نظر می‌رسد. در غیر این صورت شبکه در طول فاز آموزش همگرا نخواهد شد. در نتیجه دستاوردهای دلخواهی هم به دست نمی‌آیند (Yuxin *et al.*, 2006). هنگامی که از تابع فعالیت سیگموئیدی استفاده می‌شود، بهترین دامنه تبدیل داده‌ها میان ۰/۹ و ۰/۱ است (Vakil-Baghmisheh & Pavešic, 2003). برای تبدیل داده‌ها از روش نرمال‌سازی خطی استفاده شد.

از شبکه عصبی GMDH با هدف طبقه‌بندی سطح شهرستان به دو کلاس برای سه حالت گوناگون استفاده شد. حالت نخست برای هنگامی است که منطقه را به دو منطقه عدم وجود و کوچک‌تر یا برابر ۱۰۰ کنه و به ترتیب حالت دوم و سوم برای هنگامی است که انبوهی کنه برای نقاطی از مزرعه کوچک‌تر یا برابر و یا بزرگ‌تر ۲۰۰ و ۳۰۰ کنه است. به صورت کاملاً تصادفی، ۷۰ درصد از همه داده‌ها برای آموزش شبکه و ۳۰ درصد باقی‌مانده برای آزمایش شبکه به منظور طبقه‌بندی گزینش شدند. با آگاهی به فراوانی

1. Kolmogorov-smirnov

2. Sigmoid transfer function

جمعیت، نرخ چلیپایی (کراسینگ آور)، نرخ جهش که مقدار این مؤلفه‌ها در جدول ۱ آورده شده است.

جدول ۱. مقدارهای مؤلفه‌های ورودی الگوریتم  
Table 1. The values of input parameters of the Algorithm

Maximum number of generations (Max - gen)	150
Crossover rate (Pc)	0.5
Mutation rate (Pm)	0.03
Population size	50

### نتایج و بحث

برای اطمینان از یادگیری شبکه عصبی آموزش دیده برای پیش‌بینی الگوی پراکنش کنه‌های خانواده Laelapidae، داده‌های واقعی و پیش‌بینی شده به وسیله شبکه از دید آماری با هم هم سنجی شدند. در اینجا فرض صفر بر برابری میانگین، واریانس و توزیع آماری دلالت دارد. هر فرضیه در سطح احتمال ۹۵ درصد به یاری مؤلفه  $P$  آزمون شد. به ترتیب برای هم سنجی میانگین، واریانس و توزیع آماری از آزمون  $F$ ،  $T$  و کولموگروف-اسمیرنو استفاده شد. مقدارهای  $P$  محاسبه شده برای هر مورد در جدول ۲ نشان داده شده‌اند. نتیجه‌ها نشان می‌دهند که میانگین و واریانس برای شبکه عصبی - فازی اختلاف معنی‌داری را نشان نمی‌دهد ( $P > 0.06$ ) و میان توزیع آماری مقدارهای واقعی و پیش‌بینی شده به وسیله شبکه GMDH اختلاف معنی‌داری در سطح ۹۵ درصد وجود ندارد ( $P > 0.04$ ). وجود  $P=1$  در مورد توزیع آماری میان مقدارهای پیش‌بینی شده و واقعی انبوهی کنه‌های Laelapidae در فاز آموزش و همچنین وجود  $P=1.00$  در فاز آزمایش در سطح استان، نشان از دقت بالا و نیز توانایی همخوانی با مقدارهای بحرانی را دارد.

ضریب‌های تبیین و رابطه خطی رگرسیونی میان مقدارهای واقعی هر کلاس در برابر مقدارهای پیش‌بینی شده به وسیله شبکه GMDH در جدول ۳ نشان داده شده است. بهترین نتیجه‌ها بر پایه این دو سنجه هنگامی به دست می‌آید که معادله خطی مابین انبوهی کنه‌های Laelapidae واقعی و انبوهی کنه‌های Laelapidae پیش‌بینی شده به وسیله شبکه GMDH افزون بر داشتن ضریب تبیین بالا دارای عرض از مبدأ

ژنوم یا کروموزومی که برای نمایش ساختار شبکه عصبی در نظر گرفته‌ایم، دربرگیرنده یک رشته نمایشی ساده، برآمده از آمیختن حرف‌های الفبا است که در آن هر حرف نشان از یکی از ورودی‌های شبکه عصبی است. در این گونه کدگذاری، هر ورودی با یک حرف جایگزین می‌شود و هر کروموزوم به صورت رشته‌ای ساخته شده از این حرف‌های 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 آمیخته از  $\{a_i \in \{a, b, c, d, \dots\}\}$  به شکل  $a_1 a_2 \dots a_i \dots$  شکل می‌گیرد که در آن  $a$ ،  $b$  و  $c$  به ترتیب جایگزین ورودی‌های  $x_1, x_2, x_3, \dots$  می‌شوند. در این پژوهش شبکه با دو ورودی، دو حرف می‌تواند برای ساختن ژنوم‌ها استفاده شود. آشکار است که هر کروموزوم با طول برابر  $2k$  که  $k \in \{1, 2, 3, \dots, (n_1 + 1)\}$  که  $n_1$  شمار لایه پنهان است، می‌تواند نشان‌دهنده یک ساختار شبکه عصبی باشد. نخست فرض می‌کنیم که هر نورون از آمیختن دو نورون در لایه مجاور ساخته شده است. به طور کلی، رابطه  $2^{HL+1} = \text{Length of noron}$  که  $HL$  نشان از لایه پنهان است، همبستگی میان طول نورون و شمار لایه‌های پنهان را در این کدگذاری نشان می‌دهد؛ بنابراین، این شبکه دارای دو لایه پنهان است. آشکار است که هر نورون به طول  $2n$  از آن لایه  $n$  ام است. در شبکه عصبی نوع GS نورون‌ها با طول‌های گوناگون با یکدیگر آمیخته می‌شوند، درواقع، نورون با طول کوچک‌تر باید از چند لایه پنهان جهش کرده و با نورون با طول بزرگ‌تر آمیخته شود. برای چاره‌گری این چالش نام نورون‌هایی را که از لایه‌ها جهش می‌کنند، تکرار می‌کنیم (Atashkari et al., 2010).

### شرط توقف

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

### تنظیم مؤلفه‌های ورودی الگوریتم

مقدار مؤلفه‌های ورودی الگوریتم دربرگیرنده اندازه

کارایی یک مدل نمی‌توان تنها با هم سنجی یک یا چند نقطه داوری کرد (Zhang & Fuh, 1998).

انبوهی اصلی این خانواده در بخش‌های مرکزی و کمی گراینده به غرب و هم‌چنین کم‌وبیش در بخش جنوب شرقی مناطق نمونه‌برداری شده بیشتر است و در نقشه به‌خوبی نمایان است که یکی از نشانه‌های بزرگ آن می‌تواند وجود منطقه‌های جنگلی در این مختصات باشد و این منطقه‌ها به‌صورت دست‌نخورده هستند و مهارهای شیمیایی در آن‌ها انجام نمی‌شود. از طرفی در این منطقه‌ها خاک هوموسی پر بار امکان انبوهی شکار برای این کنه‌های شکارگر را فراهم کرده است و از این‌رو انبوهی جمعیت این خانواده در سنجش با دیگر منطقه‌ها بیشتر است. در هم سنجی سه مدل شبکه عصبی برای گزینش الگوهای پراکنندگی حشرات در سطح یک چمنزار، Zhang & Fuh (1998) بیان کردند که شبکه عصبی MLP الگوریتم توانمندتری در شناسایی الگوی پراکنندگی حشرات بود. آن‌ها رفتارهای بوم‌شناختی حشرات را در کارایی مدل‌های شبکه عصبی دخیل دانستند. از این‌رو ذکر کردند برای بالا بردن کارایی یک شبکه عصبی برای شناسایی پراکنندگی شمار لایه‌های پنهان، مرحله زیستی حشره و توابع تحریک باید در نظر گرفته شوند. در پژوهش دیگری که با به‌کارگیری شبکه عصبی LVQ4 انجام شد، پژوهش‌گران پراکنندگی شب‌پره مینوز گوجه‌فرنگی را در سه سطح بررسی کردند و نتیجه‌ها نشان از توانایی جداسازی و کارایی بسیار بالای شبکه عصبی LVQ4 و توزیع تجمعی این آفت داشت (Shabani nejad & Tafaghodinia, 2016). هم‌چنین، در پژوهشی دیگر کارایی بالای شبکه عصبی مصنوعی MLP در پیش‌بینی پویایی جمعیت مگس گالزا (Diptera, Cecidomyiida) در جنگل‌های سوزنی‌برگ آمریکا بود بررسی شد (Yeong et al., 2000). حکیمی تبار و همکاران (Hakimitabar et al., 2017) با به‌کارگیری شبکه عصبی چندلایه پرسپترون پراکنندگی کنه‌های خانواده Ascidae در منطقه دامغان را ارزیابی کردند و مدل به‌درستی پراکنندگی را تشخیص داد، نتیجه‌های به‌دست‌آمده از این پژوهش‌ها با نتیجه‌های برآمده از این پژوهش هماهنگی داشت.

کم و شیب نزدیک به یک باشد. به‌درستی آشکار است که ضریب‌های تبیین میان داده‌های واقعی و پیش‌بینی‌شده بسیار بالا هستند (۰/۸). نتیجه‌های جدول ۳ نشان می‌دهند که توانایی تعمیم‌پذیری شبکه عصبی آموزش‌دیده بسیار بالا است زیرا فاز آزمایش در سنجش با فاز آموزش دارای ضریب تبیین بالاتر و نیز معادله خطی رگرسیونی مابین مقدارهای واقعی و پیش‌بینی‌شده از شیب نزدیک‌تر به واحد و عرض از مبدأ نزدیک به صفر برخوردار است.

### نقشه‌های توزیع مکانی کنه‌های Laelapidae

نقشه پراکنندگی مکانی کنه‌های Laelapidae به‌وسیله شبکه GMDH جداسازی و ترسیم‌شده و در شکل ۱ نشان داده شده است. عرض و طول جغرافیایی محل‌های نمونه‌برداری دارای کمینه و بیشینه‌ای هستند. به علت گستردگی منطقه نمونه‌برداری و ترسیم نقشه‌ای که همه منطقه را پوشش دهد، یک مبدأ مختصات فرضی (صفر) تعیین شد و از صفر تا کمینه طول و عرض جغرافیایی هم میان یابی صورت گرفت و این روند تا بیشینه مقدار ثبت‌شده از طول و عرض جغرافیایی ادامه پیدا کرد. از این‌رو عددی روی محور در شکل ۱ درجه‌های جغرافیایی هستند. در شکل ۱ نقطه‌های تیره نشان از نبود آن کنه در گستره موردبررسی است و نقطه‌های روشن گویای وجود هستند (میزان روشنایی‌ها در انبوهی‌های بالا بیشتر است).

در این شکل نخست نقشه‌های انبوهی این کنه‌ها بر پایه دو کلاس فاقد و دارای ۱۰۰ کنه رسم شد (شکل‌های  $a$  و  $b$ )، سپس در شکل‌های  $c$  و  $d$  و نیز در شکل‌های  $e$  و  $f$  به ترتیب، انبوهی جمعیت این خانواده بر پایه دو کلاس ۲۰۰ و ۳۰۰ عدد ترسیم‌شده است. این حدود انتخابی یک حد آستانه برآورد است تا به‌وسیله آن‌ها توانایی شبکه GMDH نشان داده شود؛ اما اکنون با هم سنجی میان نقشه‌های به‌دست‌آمده از داده‌های واقعی و پیش‌بینی‌شده به‌وسیله شبکه متوجه خواهیم شد، میان نقطه‌های همسان در نقشه در برخی از مکان‌ها تفاوت‌هایی وجود دارد که برآمده از خطای مدل شبکه GMDH است. ولی درباره درستی

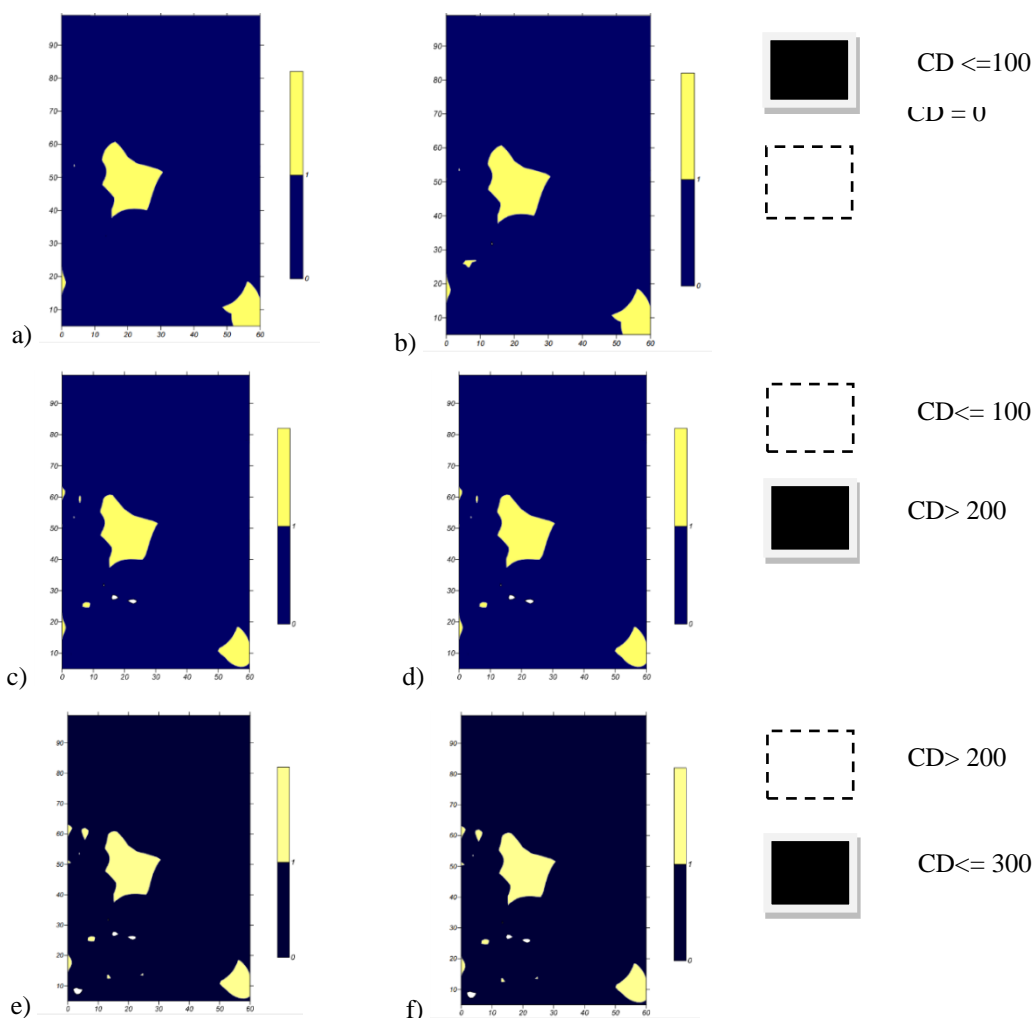
جدول ۲. هم‌سنجی‌های آماری مقدرهای واقعی و پیش‌بینی تراکم کنه‌های Laelapidae به‌وسیله شبکه عصبی GMDH

Table 2. Statistical comparisons between the observed and estimated Laelapid mites density by GMDH neural networks

Classification	Utilization phase	Comparisons of means	Comparisons of variance	Comparisons of distribution
CD=0, CD≤ 100	Training Phase	0.635	0.919	0.82
	Test Phase	0.990	0.995	0.95
CD>100, CD≤200	Training Phase	0.773	0.982	1.00
	Test Phase	0.976	1.00	1.00
CD>200, CD≤300	Training Phase	0.812	0.993	1.00
	Test Phase	0.990	1.00	1.00

جدول ۳. رابطه خطی رگرسیونی و ضریب تبیین میان  $av$  (مقدرهای واقعی داده‌ها) و  $pv$  (مقدرهای پیش‌بینی شده) به‌وسیله مدل  
Table 3. Linear regression relationship and coefficient of determination between  $dv$  (actual values) and  $pv$  (predicted values) by the model

Network goals for classification	Network Utilization phase	Linear regression relationship	R2
CD=0, CD≤ 100	Training Phase	$pv= 0.9558 av +0.0049$	0.9477
	Test Phase	$pv= 0.8755 av +0.0112$	0.8987
CD>100, CD≤200	Training Phase	$pv= 0.9799 av +0.0100$	0.9701
	Test Phase	$pv= 0.9254 av +0.0124$	0.9441
CD>200, CD≤300	Training Phase	$pv= 0.9813 av +0.0091$	0.9815
	Test Phase	$pv= 0.9039 av +0.0004$	0.9687



شکل ۱. نقشه توزیع کنه‌های Laelapidea در دو حالت واقعی (شکل‌های  $d$  و  $f$ ) و تفکیک شده به‌وسیله مدل شبکه عصبی GMDH (شکل‌های  $a$ ،  $c$  و  $e$ ). نقشه‌های  $(b, a)$  بر پایه حد آستانه ۱۰۰ کنه، نقشه‌های  $(d, c)$  حد آستانه ۲۰۰ کنه و نقشه‌های  $(f, e)$  بر پایه حد آستانه ۳۰۰ کنه.

Figure 1. Laelapid mites distribution maps in actual ( $b, d$  and  $f$ ) and classified conditions by GMDH neural networks ( $a, c$  and  $e$ ). The maps of  $a$  and  $b, c$  and  $d, e$  and  $f$  have been drawn according to economic thresholds of 100, 200 and 300 mites, respectively.

## نتیجه‌گیری

همان‌طور که یاد شد این کنه‌ها نقش مهمی در تعدیل و کم کردن آفت‌های خاکزی و نماتدها دارند و از این‌روی دانستن مکان‌های انبوهی این کنه‌ها می‌تواند در انجام برنامه‌های کشاورزی پایدار نقش مهمی ایفا کند. برای تهیه و پیشبرد برنامه‌های مهار تلفیقی آفت‌ها آگاهی از دگرگونی‌های جمعیت آفت هدف و شکارگرهای آن‌ها امری نیازین است. همچنین انجام برنامه‌های حفاظتی برای افزایش و پایداری جمعیت دشمنان طبیعی نیاز به ایجاد شرایطی پسندیده دارد که کمترین استرس را دارا باشند. یکی از عامل‌هایی که می‌تواند به این موضوع یاری کند دگرگونی در عملیات زراعی (حفظ پوشش گیاهی و پناهگاه‌های طبیعی آن‌ها) و توان‌بخشی جمعیت‌های محلی است (Obrycki & Kring, 1998). آماده کردن نقشه‌های دقیق و مدیریت مکان-ویژه دشمنان طبیعی و آفت‌ها راهکاری برای دستیابی به این آرمان است و آنچه رسیدن به این آرمان را محقق می‌کند افزایش دقت و درستی در نقشه‌های پراکندگی جمعیت آن‌ها است.

نقشه‌های به‌دست‌آمده از شبکه‌های عصبی مصنوعی می‌توانند به برنامه‌ریزان جهت بکار بردن برنامه‌های مهار آفت‌ها یاری کنند به‌ویژه اگر نقشه‌ها با مختصات جغرافیایی هر مکان برابری داشته باشند. اگر نقشه پراکندگی مربوط به آفت‌های کشاورزی باشد به کشاورز یاری خواهد کرد که در مکان‌های تجمع آفت‌ها برنامه‌های مهاری را انجام دهد و اگر این نقشه‌ها برای آشکار ساختن پراکندگی و انبوهی بندپایان سودمند آماده شده باشد (پژوهش اکنون) کشاورز باید در این مکان‌ها کمترین نهاده شیمیایی را وارد کند و تمرکز بیشتر برنامه‌های کنترل به منطقه‌هایی معطوف شود که انبوهی بندپایان سودمند کمتر است تا به جمعیت آن‌ها آسیبی نرسد. نتیجه‌های برآمده از این پژوهش می‌توانند در مدیریت مکان - ویژه این خانواده از کنه‌های سودمند مورد استفاده قرار گیرند بدین‌سان که با به‌کارگیری آن‌ها می‌توان برنامه‌های مدیریتی، جهت پشتیبانی و نگهداری از کنه‌های شکارگر و توانایی دادن به جمعیت‌های بومی محلی را در نقاط پراکندگی آن‌ها متمرکز کرد.

## REFERENCES

1. Amanifard, N., Nariman-Zadeh, N., Borji, M., Khalkhali, A. & Habibdoust, A. (2007). Modelling and Pareto optimization of heat transfer and flow coefficients in microchannels using GMDH type neural networks and genetic algorithms. *Energy Conversion and Management*, 15, 32-40.
2. Atashkari, K., Nariman-Zadeh, N., Gölcü, M., Khalkhali, A. & Jamali, A. (2010). Modelling 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.
3. Obrycki, J. J. & Kring, T. J. (1998). Pradaceus Coccinellidae in biological control. *Annual Review of Entomology*, 43, 295-321.
4. 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.
5. 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.
6. Hakimitabar, M., Shabaninejad, A., Saboori, A. & Shmas, M. (2017). Evaluation of Artificial Neural Network for determining distribution pattern of ascid family (Acari, Mesostigmata) in Damghan city, Semnan province. *Journal of Entomological Society of Iran*, 37(3), 361-368.
7. 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.
8. Joharchi, O. (2011). *Funistic Survey of Family Laelapidae (Acari, Mesostigmata) in Tehran province*. Ph.D. Thesis. Faculty of Agriculture, Islamic Azad University, Science and Research Branch, Tehran.
9. Krantz, G. W. & Walter, D. E. (Eds). (2009). *A manual of acarology*. 3<sup>rd</sup> ed. 807 pp. Texas Technology University Press.
10. 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.



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.
12. Nariman-Zadeh, N., Darvizeh, A. & Ahmad-Zadeh, G. R. (2013). Hybrid genetic design of GMDH-type neural networks using singular value decomposition for modelling and prediction of the explosive cutting process. *Energy Conversion and Management*, 217, 79-90.
13. Shabaninejad, A. & Tafaghodiniya, B. (2017a). Automatic clustering of data from sampling and evaluation of neuro-fuzzy network to estimate the distribution of *Bemisia. Tabaci* (Hem., Aleyrodidae). *Journal of Entomological Society of Iran*, 37, 91-105.
14. Shabaninejad, A. & Tafaghodinia, B. (2017b). Evaluation of the geostatistical and artificial neural network methods to estimate the spatial distribution of *Tetranychus urticae* (Acari, Tetranychidae) in Ramhormoz cucumber fields. *Journal of Applied Entomology and Pathology*, 85(1), 21-29.
15. Shabaninejad, A. & Tafaghodinia, B. (2016). Evaluation of the ability of LVQ4 artificial neural network model for predicting spatial distribution pattern of *Tuta absoluta* in Ramhormoz, Iran. *Journal of Entomological Society of Iran*, 36, 195-204.
16. Shabaninejad, A., Tafaghodinia, B. & Zandi-Sohani, N. (2017a). 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*, 6(4), 315-328.
17. Shabaninejad, A., Tafaghodinia, B. & Zandi-Sohani, N. (2017b). 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, 53-62.
18. Vakil-Baghmisheh, M. T. & Pavešic, N. (2003). Premature clustering phenomenon and new training algorithms for LVQ. *Pattern Recognition*, 36(5), 1901-1921.
19. Walter, D. E. & Proctor, H. C. (1999). *Mites, Ecology, Evolution, and Behaviour*. Springer, Dordrecht, the Netherlands, 494.
20. Chon, T. S., Park, Y. S., Kim, J. M., Lee, B. Y., Chung, Y. J. & Kim, Y. (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.
21. 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(2), 117-135.
22. Zhang, Y. F. & Fuh, J. Y. H. (1998). A neural network approach for early cost estimation of packaging products. *Computers and Industrial Engineering*, 34(2), 433-50.
23. 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.