

پیش‌بینی الگوی توزیع (*Rhopalosiphum padi* (Hemiptera: Aphididae) با استفاده از شبکه عصبی مصنوعی بهینه شده توسط الگوریتم حرکت تجمعی ذرات

مریم آل عصفور*، کامبیز مینایی و فائزه باقری

گروه گیاه‌پزشکی، دانشکده کشاورزی، دانشگاه شیراز، شیراز، ایران.

* مسئول مکاتبات، پست الکترونیکی: aosfoor@shirazu.ac.ir

چکیده

امروزه با پدید آمدن فنون آماری قوی و شبکه‌های عصبی، مدل‌های پیش‌بینی کننده پراکنش آفات به سرعت در بوم‌شناسی توسعه پیدا کرده است. این پژوهش به منظور پیش‌بینی و ترسیم نقشه توزیع شته *Rhopalosiphum padi* با استفاده از شبکه‌های عصبی پرسپترون چندلایه (MLP) ترکیب شده با حرکت تجمعی ذرات در مزرعه گندم منطقه باجگاه، استان فارس انجام شد. داده‌های مربوط به جمعیت این آفت از طریق نمونه برداری از ۱۰۰ نقطه از سطح مزرعه گندم در سال ۱۳۹۵ به دست آمد. برای ارزیابی قابلیت شبکه‌های عصبی مورد استفاده در پیش‌بینی توزیع، از مقایسه آماری پراسنجه‌هایی مانند میانگین، واریانس و توزیع آماری بین مقادیر پیش‌بینی شده مکانی توسط شبکه عصبی و مقادیر واقعی آن‌ها استفاده شد. نتایج نشان داد، در مراحل آموزش و آزمایش بین مقادیر ویژگی‌های آماری واریانس، توزیع آماری و میانگین مجموعه داده‌های واقعی و پیش‌بینی شده مکانی این آفت توسط شبکه عصبی ترکیب شده، تفاوت معنی‌داری وجود ندارد. نقشه‌های ترسیم شده نشان داد، توزیع این آفت تجمعی است و امکان کنترل متناسب با مکان را در مزرعه مورد مطالعه دارد.

واژه‌های کلیدی: توزیع مکانی، شبکه عصبی مصنوعی، شته برگ برنج.

Predicting distribution pattern of *Rhopalosiphum padi* (Hemiptera: Aphididae) by hybrid neural network using particle swarm optimization algorithm

Maryam Aleosfoor*, Kambiz Minaei & Faezeh Bagheri

Department of Plant Protection, College of Agriculture, Shiraz University, Shiraz, Iran.

* Corresponding author, E-mail: aosfoor@shirazu.ac.ir

Abstract

Nowadays, with the advent of powerful statistical techniques and neural networks, predictive models of distribution have been rapidly developed in ecology. This study was carried out to model distribution of aphid, *Rhopalosiphum padi*, using MLP neural networks combined with Particle Swarm Optimization in wheat fields of Badjgah area, Fars province. Population data of the pest was obtained by sampling at 100 locations across wheat fields during 2013. For evaluation the capability of neural networks used in dispersal prediction, statistical comparison of parameters such as mean, variance, statistical distribution of spatial predicted values by neural network and their actual values, were conducted. Results showed that there were not significant differences between variance, mean and statistical distribution of actual and predicted values in training and test phases of neural network combined Particle Swarm Optimization algorithm. Our map showed a patchy pest distribution offers large potential for using site-specific pest control on this field.

Key words: Neural network, spatial distribution, Bird cherry-oat aphid.

Received: 29 February 2020, Accepted: 19 December 2020.

مقدمه

غلات گیاهانی علفی و تک لپه‌ای از خانواده گندمیان هستند که دانه‌های ریز آنها، مصرف خوراکی دارد. این گروه از گیاهان مهمترین گیاهان غذایی بوده و تأمین کننده غذای ۷۰ درصد مردم کره زمین می‌باشند (Tiwari & Cummins, 2009). شته *Rhopalosiphum padi* L. (Hemiptera: Aphididae) یکی از آفات بسیار مهم غلات در بیشتر کشورهای آسیایی و اروپایی می‌باشد (Park et al., 2017). این شته احتمالاً از منطقه دیرین شمالگان منشاء گرفته و هم اکنون در تمام دنیا یافت می‌شود. این آفت در ایران تقریباً در همه نقاط کشور یافت می‌شود (Taheri et al., 2010). خسارت مستقیم این شته به صورت پیچیده شدن برگ‌ها در امتداد حاشیه و به زردی گراییدن آنها است به طوری که غالباً در جمعیت‌های زیاد باعث پيچش برگ پرچم به سمت بالا و به دام افتادن ریشک خوشه، کاهش طول ریشه، وزن خشک ساقه و وزن هزار دانه می‌شود (Riedell et al., 2003). همچنین این شته یکی از ناقلین موثر ویروس کوتولگی زرد جو در ایران و سایر نقاط جهان به شمار آمده (Aleosfoor et al., 2010; Ingwell et al., 2017) و در صورت ایجاد شرایط مساعد برای ظهور بیماری کوتولگی زرد جو، کل محصول را از بین می‌برد (Vandegeer et al., 2016). میزبان اولیه این آفت را گیاهان متعلق به جنس *Prunus* و به ویژه انواع وحشی آن تشکیل می‌دهند و اغلب اوقات در اروپا روی *Prunus padus* (Rosales: Rosaceae) (Linnaeus) و در شمال آمریکا روی *P. virginiana* (Rosales: Rosaceae) L. دیده شده است. میزبان ثانویه این حشره را گونه‌های زیادی از Graminae (غلات مهم و علف‌های هرز)، Juncaceae, Iridaceae, Cyperaceae و Typhaceae تشکیل می‌دهند.

جمعیت‌های حشرات به صورت طبیعی از نظر تراکم در نقاط مختلف متفاوت می‌باشند. این عدم یکنواختی تراکم جمعیت در روش‌های نمونه‌برداری، درک روابط شکار و شکارگر در برنامه‌های مهار زیستی و بهینه‌سازی مصرف سم بسیار موثر است (Garzia et al., 2011). یکی از بهترین روش‌ها برای دستیابی به این منظور، تهیه نقشه‌های کاربردی از جمعیت حشرات می‌باشد. یکی از روش‌های تخمین توزیع مکانی، استفاده از شبکه عصبی مصنوعی با استفاده از الگوریتم‌های مختلف می‌باشد. شبکه‌های عصبی قابلیت درونیابی دارند و می‌توانند متغیرهایی مانند تراکم آفت را به درستی در نقاط نمونه‌برداری نشده با استفاده از داده‌های به دست آمده از نقاط نمونه‌برداری شده تخمین بزنند (Torrecilla et al., 2004). مدل‌های شبکه عصبی مصنوعی در مقایسه با مدل‌های ریاضی دقیق‌ترند و با دقت و صحت بیشتری می‌توانند رابطه بین متغیرها را شبیه‌سازی کنند. در شبکه عصبی مصنوعی بدون هیچ دانش اولیه‌ای از روابط بین پراسنجه‌های مورد مطالعه، به کمک فرایند یادگیری و با استفاده از سلول‌های عصبی می‌توان بین مجموعه‌ای از ورودی‌ها و خروجی‌ها ارتباط برقرار کرد (Kaul et al., 2005).

مطالعات متعددی نشان داده است که شبکه‌های عصبی توانایی بالایی در تشخیص الگوهای توزیع مکانی جمعیت‌های بوم شناختی دارند (Goel et al., 2003; Irmak et al., 2006) به طوری که استفاده از مدل شبکه عصبی بردار چندی ساز یادگیر برای مطالعه توزیع مکانی حشرات در اراضی مرتعی کارایی مطلوبی را نشان داده است (Zhang et al., 2008). در مطالعه‌ای (Peacock et al., 2007) با استفاده از شبکه عصبی مصنوعی و رگرسیون لجستیک باینری پراکنش حشرات چندخوار را بر مبنای پراسنجه‌های آب و هوایی بررسی کرده و نشان دادند که شبکه‌های عصبی با دقت بسیار بالاتری پراکنش حشرات را تخمین می‌زنند. از شبکه عصبی مصنوعی برای پیش‌بینی جمعیت کرم ساقه خوار برنج *Scirpophya gaincertulas* Walker (Lep.: Crambidae) استفاده شد و این مدل به خوبی توانست جمعیت آفت را پیش‌بینی کند (Yang et al., 2010). نتایج پژوهش (Lv et al., 2009) نشان داد که ترکیب شبکه عصبی با الگوریتم حرکت تجمعی ذرات قدرت بالایی در تشخیص و تخمین الگوی

پراکنندگی آفات توتون داشت. نتایج استفاده از این فن برای پیش‌بینی تراکم جمعیت پروانه پشت الماسی، *Plutella Diadegma semiclausum* (Hellen) و انگل‌واره مرحله لاروی آن *Axylostella* (Linnaeus) (Lep.: Plutellidae) (Hymenoptera: Ichneumonidae) بسیار موفقیت‌آمیز بوده است (Tonnange et al., 2010). همچنین از شبکه عصبی مصنوعی ترکیب شده با الگوریتم ژنتیک برای پیش‌بینی الگوی پراکنش کنه تارتن دو لکه‌ای *Tetranychus urticae* Koch در مزرعه خیار استفاده شده و نتایج این تحقیق، کارایی بسیار بالای این شبکه را نشان داده است (Shabani nejad et al., 2017). همچنین (Tafaghodinia & Shabani nejad 2016) از شبکه عصبی LVQ4 در تخمین توزیع پراکنندگی شب‌پره مینوز گوجه فرنگی *Tuta absoluta* (Meyrick) (Lep.: Gelechiidae) استفاده کردند نتایج تحقیقات آنها کارایی بالای این روش در تخمین توزیع پراکنندگی شب‌پره مینوز گوجه فرنگی را تایید کرد. در پژوهش دیگری داده‌های حاصل از نمونه‌برداری مزرعه خیار توسط روش خوشه‌بندی اتوماتیک تقسیم‌بندی و توسط شبکه نو-فازی، پراکنندگی سفید بالک پنبه *Bemisia tabaci* Gennadius (Hem., Aleyrodidae) ترسیم (Tafaghodinia & Shabani nejad, 2017) و در نهایت مقایسه‌ای بین روش‌های زمین‌آمار و شبکه عصبی مصنوعی در تعیین پراکنش مکانی کنه تارتن دو لکه‌ای *Tetranychus urticae* Koch در مزرعه خیار شهرستان رامهرمز انجام شد که نتایج برتری روش شبکه عصبی مصنوعی را نشان داد (Shabani nejad & Tafaghodinia, 2017).

با وجود اهمیت بسیار زیاد شته *R. padi* روی غلات، در راستای تحقق برنامه مدیریت این آفت، تاکنون پژوهشی به منظور بررسی پراکنندگی این شته با استفاده از شبکه عصبی مصنوعی ترکیب شده با الگوریتم حرکت جمعی ذرات صورت نگرفته است. از آنجا که درک و تجزیه و تحلیل فرایندهای زیستی شته در مطالعات رشد جمعیت و پایه‌ریزی برنامه‌های مدیریتی ضروری است، تحقیق حاضر با هدف شناخت وضعیت پراکنش این آفت در مزرعه گندم منطقه باجگاه با استفاده از شبکه عصبی مصنوعی ترکیب شده با الگوریتم حرکت جمعی ذرات انجام شد.


مواد و روش‌ها

موقعیت جغرافیایی و تهیه نقشه نمونه‌برداری

به منظور انجام این پژوهش یک مزرعه گندم به مساحت ۵/۲ هکتار در اطراف شهرستان شیراز در منطقه باجگاه در محدوده جغرافیایی بین ۴۸ درجه و ۴۴ دقیقه تا ۵۲ درجه و ۲۷ دقیقه طول شرقی از نصف النهار گرینویچ و ۳۱ درجه و ۶۰ دقیقه تا ۴۳ درجه و ۶ دقیقه عرض شمالی از خط استوا انتخاب شد.

روش نمونه‌برداری

در درون 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 که از اول اردیبهشت ۱۳۹۵ تا پایان اردیبهشت سال ۱۳۹۵ به صورت هفتگی از مزرعه انتخابی صورت گرفت یک بلوک ۲×۲ متر مربع انتخاب و درون آن تعداد ۱۰ بوته به صورت تصادفی به عنوان واحد نمونه‌برداری 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

تجزیه و تحلیل آماری داده‌ها

نرمال بودن داده‌های مربوط به نمونه برداری با آزمون کولموگروف-اسمیرنوف ضمن بکارگیری نرم افزار SPSS ver. 19 بررسی شد و به دلیل نرمال نبودن، داده‌ها توسط روش کاکس باکس نرمال شدند. کد رایانه‌ای شبکه عصبی در محیط نرم افزار Matlab ver. 8.1 تهیه شد. برای ارزیابی الگوریتم شبکه عصبی از رابطه خطی رگرسیونی بین تراکم مشاهده شده و پیش‌بینی شده توسط شبکه و ضریب تبیین (R^2) استفاده شد. بهترین نتایج بر اساس این دو معیار زمانی است، یعنی معادله علاوه بر داشتن مقدار R^2 بالا و عرض از مبدا کم، شیب نزدیک به یک داشته باشد. برای اطمینان از یادگیری شبکه عصبی آموزش دیده برای پیش‌بینی الگوی پراکنش شته R . *padi* میانگین و واریانس بین داده‌های مشاهده شده و پیش‌بینی شده توسط شبکه از آزمون‌های t و F با بکارگیری نرم افزار SPSS ver. 19 استفاده شد.

شبکه عصبی مصنوعی

امروزه به موازات مدل‌های سری زمانی، روش‌های دیگری نظیر شبکه‌های عصبی مورد توجه قرار گرفته است. برتری این روش‌ها که به شبکه‌های عصبی مصنوعی معروف است، عدم نیاز به اجرای فرضیه‌های خاص در مورد رفتار متغیرها است. شبکه عصبی مصنوعی، ساختاری شبیه به مغز انسان دارد و شامل مجموعه‌ای از سلول عصبی‌های متصل به هم می‌باشد که به هر مجموعه از این سلول عصبی‌ها یک لایه گفته می‌شود. در نهایت برای اجرای این لایه‌ها، سلول عصبی‌ها به وسیله توابع فعال‌سازی به یکدیگر متصل می‌شوند (Cao & Parry, 2009).

یک شبکه عصبی به طور متداول از سه لایه ورودی، پنهان و خروجی تشکیل شده است. لایه ورودی فقط اطلاعات را دریافت می‌کند و مشابه متغیر مستقل عمل می‌کند. از این رو تعداد سلول عصبی‌های لایه ورودی بر اساس تعداد متغیرهای مستقل تعیین می‌شوند. لایه خروجی نیز همانند متغیر وابسته عمل می‌کند و تعداد سلول عصبی‌های آن به تعداد متغیرهای وابسته بستگی دارد. برخلاف لایه‌های ورودی و خروجی، لایه پنهان هیچ مفهومی را نشان نمی‌دهد و فقط یک نتیجه در روند محاسبه ارزش خروجی است. شبکه‌های عصبی مصنوعی انواع مختلفی دارند، اما یکی از پرکاربردترین نوع شبکه‌های عصبی، شبکه عصبی پرسپترون چند لایه است. در این نوع شبکه عصبی، گره‌ها در لایه‌های متوالی قرار گرفته و ارتباط بین آنها یک‌طرفه است و زمانی که یک الگوی ورودی به شبکه وارد می‌شود، اولین لایه، مقادیر خروجی خود را محاسبه می‌کند و در اختیار لایه بعدی قرار می‌دهد. لایه بعدی این اطلاعات را به عنوان ورودی دریافت کرده و مقادیر خروجی خود را به لایه بعدی منتقل می‌کند. در واقع در این نوع شبکه، هر گره سیگنالی به گره‌های بعدی منتقل می‌کند (Heykin, 1999).

فرآیند یادگیری شبکه عصبی

یکی از مهمترین ویژگی‌های شبکه‌های عصبی مصنوعی که عملکرد آن را به انسان نزدیک‌تر می‌کند، قدرت یادگیری است. به دلیل اینکه ارتباط میان ورودی‌ها و خروجی‌ها به طور دقیق و کامل مشخص نیست، شبکه‌های عصبی به یادگیری نیاز دارند. از آنجا که تجربه‌ها در طول زمان حاصل می‌شوند، بر این اساس میزان یادگیری به درجه کامل بودن اطلاعات بستگی دارد. شبکه‌های عصبی از اشتباهاتی که مرتکب می‌شوند، می‌آموزند (Shanker *et al.*, 1996). فرآیند یادگیری یا آموزش شبکه‌های عصبی، معمولاً طی سه مرحله زیر صورت می‌گیرد:

- محاسبه برون داده‌ها

- مقایسه برون داده‌ها با پاسخ‌های مطلوب و مورد نظر

- تعدیل وزن‌ها و تکرار فرآیند

فرآیند یادگیری با انتخاب تصادفی وزن‌ها آغاز می‌شود. تفاوت میان برون‌داد واقعی و برون‌داد مورد نظر، دلالتا نامیده می‌شود. در اینجا هدف به حداقل رساندن دلالتا یا به صفر رساندن آن است. کاهش دلالتا از طریق ایجاد تغییرات تدریجی در وزن‌ها انجام می‌شود. پردازش اطلاعات با استفاده از شبکه‌های عصبی، شامل شناسایی و تجزیه و تحلیل الگوهای فعالیت نیز هست. یکی از ویژگی‌های مشترک شبکه‌های عصبی، این است که می‌توانند علی‌رغم نداشتن دانش واضح از قواعد، داده‌های ورودی را طبقه‌بندی کنند و برای محاسبه سپردن دسته‌ها از الگوهای وزنی اختیاری استفاده کنند. در طول مراحل یادگیری، وزن ارتباطی در پاسخ به داده‌های آموزشی که به سامانه ارائه می‌شود، تغییر می‌کند (Heykin, 1999). شبکه‌های عصبی مختلف، خطا را به شیوه‌های مختلف محاسبه می‌کنند. این امر به الگوریتم مورد استفاده برای یادگیری شبکه عصبی مصنوعی بستگی دارد. در فرآیند آموزش شبکه‌های عصبی، مجموعه داده‌ها به دو دسته تقسیم می‌شوند: داده‌های آزمایشی و داده‌های آموزشی. داده‌های آموزشی برای بالابردن توان یادگیری وارد شبکه می‌شوند و شبکه باید وزن‌های ارتباطی را از الگوهای آموزشی موجود یاد بگیرد. عملکرد شبکه از طریق به‌هنگام‌سازی وزن‌ها بهبود می‌یابد. سپس کیفیت و توانایی شبکه با اعمال داده‌های آزمایشی برآورد می‌شود (Heykin, 1999).

ترکیب شبکه عصبی مصنوعی با الگوریتم حرکت تجمعی ذرات

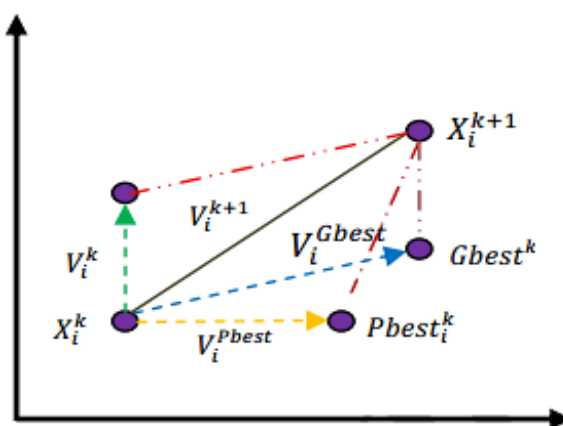
در این پژوهش از ۷۰ درصد داده‌های جمع‌آوری شده به عنوان داده‌های آموزشی و از ۳۰ درصد داده‌ها برای آزمایش استفاده شده است. همچنین به منظور آموزش شبکه از الگوریتم حرکت تجمعی ذرات استفاده شده است.

الگوریتم بهینه‌سازی حرکت تجمعی ذرات

در سال‌های اخیر با توجه به محدودیت‌های موجود در روش‌های ریاضی، پژوهش‌های بسیاری در زمینه استفاده از الگوریتم‌های تکاملی در جهت بهینه‌سازی انجام شده است. یکی از کاراترین تکنیک‌ها در این زمینه، تکنیک بهینه‌سازی حرکت تجمعی ذرات است. این الگوریتم برای اولین بار توسط کندی و ابرهارت (Kenndy & Eberhart, 1995) به کار برده شد. این الگوریتم الهام گرفته از پرواز همزمان پرندگان، شنای دسته جمعی ماهی‌ها و زندگی اجتماعی آنها می‌باشد که با استفاده از یکسری روابط ساده ترکیب‌بندی شده است (Kenndy & Eberhart, 1995). جمعیت (حرکت تجمعی) در این الگوریتم، شامل مجموعه‌ای از اعضا است که به هر عضو داخل جمعیت، یک ذره گفته می‌شود. در این تکنیک از مفهوم جانمایی همسایگی جی‌بست (G best) استفاده می‌شود. یعنی هر ذره بهترین موقعیت قبلی خود و بهترین موقعیت قبلی هر یک از ذرات موجود در جمعیت را

به خاطر می آورد و به عبارت دیگر هر ذره در جهت بهترین موقعیت قبلی خود و به سمت بهترین ذره در حرکت است (Kennedy & Eberhart, 1995).

در این الگوریتم، هر ذره نماینده یک جواب ممکن است که به صورت تصادفی در فضای مساله حرکت می کند. تغییر مکان هر ذره در فضای جست و جو، تحت تاثیر تجربه و دانش خود و همسایگانش است. بنابراین موقعیت ذرات دیگر گروه بر چگونگی جست و جوی یک ذره اثر می گذارد. نتیجه مدل سازی این رفتار اجتماعی، فرآیند جست و جویی است که در آن ذرات به سمت نواحی مناسب میل می کنند. ذرات در گروه از یکدیگر می آموزند و بر مبنای دانش به دست آمده، به سمت بهترین همسایگان خود حرکت می کنند (Poli et al., 2007). در واقع اساس کار این الگوریتم بر این اصل استوار است که در هر لحظه هر ذره مکان خود را در فضای جست و جو با توجه به بهترین مکانی که تا کنون در آن قرار گرفته و بهترین مکانی که در همسایگی اش وجود دارد، تنظیم می کند (Kennedy & Eberhart, 1995). شکل (۲) فرآیند تغییر موقعیت ذره ها را نشان می دهد.



شکل ۲- تغییر موقعیت ذرات در الگوریتم بهینه سازی حرکت تجمعی ذرات

Fig. 2. Position change of each particle with Particle Swarm Optimization Algorithm

فرض کنید یک فضای D بعدی وجود دارد و i امین ذره از گروه می تواند با یک بردار سرعت و یک بردار موقعیت نشان داده شود. تغییر موقعیت هر ذره، با تغییر در ساختار موقعیت و سرعت قبلی امکان پذیر است. هر ذره اطلاعاتی شامل بهترین مقداری را که تا کنون به آن رسیده ($P\ best$) و موقعیت X_i ، را داراست. این اطلاعات از مقایسه تلاش هایی که هر ذره برای یافتن بهترین جواب انجام می دهد، به دست می آید. همچنین هر ذره بهترین جوابی که تا کنون از مقدار $P\ best$ در گروه به دست آمده است را می شناسد ($G\ best$). هر ذره برای رسیدن به بهترین جواب سعی می کند موقعیت خود را با استفاده از اطلاعات زیر تغییر دهد:

موقعیت کنونی X_i سرعت کنونی V_i ، فاصله بین موقعیت کنونی و $Pbest$ و فاصله بین موقعیت کنونی و $Gbest$. بدین ترتیب سرعت ذره به صورت زیر تغییر می کند:

$$V_i^{K+1} = W.V_i^k + c_1r_1(Pbest_i - X_i^k) + c_2r_2(Gbest_i - X_i^k)$$

در رابطه فوق:

V_i^k سرعت هر ذره در تکرار K ام، W پراسنجه وزنی، C_1 و C_2 فاکتور وزنی، r_1 و r_2 عدد تصادفی در بازه صفر و یک، X_i^k موقعیت هر ذره در تکرار K ام، $Pbest_i$ برابر $Pbest$ در I و $Gbest_i$ نیز $Gbest$ در گروه است (Poli *et al.*, 2007). موقعیت هر ذره نیز بر اساس رابطه زیر تعیین می‌شوند:

$$X_i^{k+1} = X_i^k + V_i^{k+1}$$

پراسنجه‌های الگوریتم

با انتخاب مناسب پراسنجه وزنی، میزان تکرار برای یافتن جواب بهینه کاهش می‌یابد. ضریب ثابت اینرسی بزرگتر از یک هر چند سبب می‌شود فضای جست و جوی الگوریتم وسیع‌تر شود، اما الگوریتم را ناپایدار می‌کند. زیرا اثر سرعت پیشین را افزایش می‌دهد. در ابتدا مقدار W ثابت در نظر گرفته می‌شود، اما بعدها مطالعات ابرهات در سال‌های ۱۹۹۸ و ۱۹۹۹ در این زمینه منجر به تغییر شگرفی در این الگوریتم شد. آنها پراسنجه وزنی را به صورت خطی از مقدار بیشینه‌ای چون W_{max} تا حداقل آن W_{min} ، به صورت زیر تغییر دادند:

$$W = W_{Max} - \frac{W_{Max} - W_{Min}}{iter_{Max}} \times iter$$

در رابطه یاد شده، W_{Max} وزن ابتدایی، W_{Min} وزن انتهایی، $iter$ شماره تکرار و $iter_{Max}$ بزرگترین شماره تکرار است (Poli *et al.*, 2007).

پراسنجه‌های C_1 و C_2 در رابطه ۳ برای هم‌گرایی الگوریتم چندان بحرانی نیستند. مقدار مناسب ممکن است زودتر جواب را هم‌گرا کند و از احتمال گیر افتادن در نقطه کمینه محلی جلوگیری می‌کند. در ابتدا مقدار $C_2 = 2C_1$ پیشنهاد شد، اما مطالعات بعدی نشان داد که $C_1 = C_2 = 0.5$ می‌تواند در رسیدن به جواب بهینه مفیدتر باشد. در حالت کلی C_1 و C_2 می‌توانند متفاوت انتخاب شوند اما شرط $C_1 + C_2 < 4$ بایستی همواره برقرار باشد (Kennedy & Eberhart, 1995). پراسنجه‌های r_1 و r_2 برای حفظ تنوع و گوناگونی در گروه بکار می‌روند. مقدار مناسب این پراسنجه‌ها، در یکنواختی جواب‌ها تاثیرگذار است و این پراسنجه‌ها به صورت تصادفی در بازه صفر و یک انتخاب می‌شوند. این مقادیر به ذرات این اجازه را می‌دهد که در گام‌های تصادفی، در محدوده بین $Gbest$ و $Pbest$ حرکت کنند (Poli *et al.*, 2007).

نرمال سازی داده‌ها که به مفهوم پیش‌پردازش داده‌ها است، سبب بهبود عملکرد شبکه می‌شود. پیش‌پردازش داده‌ها، که معمولاً قبل از آموزش شبکه صورت می‌گیرد، به معنی انجام تبدیل‌هایی است بر روی داده‌های ورودی شبکه، به منظور بیرون کشیدن ویژگی‌ها از درون ورودی‌ها و تبدیل به خروجی به شکل قابل درک‌تر برای شبکه است (Shanker *et al.*, 1996). روش‌های گوناگونی برای نرمال‌سازی داده‌ها وجود دارد؛ که داده‌ها به اعدادی مابین صفر تا یک تبدیل شوند، در این پژوهش برای عناصر پردازش‌گر در لایه مخفی، تابع تحرک سیگموئیدی انتخاب شد که خروجی این تابع اعدادی بین صفر تا یک می‌باشد. بنابراین باید داده‌های ورودی به این تابع نیز اعدادی بین صفر و یک باشند (Agyare *et al.*, 2007). برای ورودی‌های نزدیک به صفر تا یک، تغییرات وزن نرون‌ها حداقل خواهد بود، زیرا در این اعداد، عناصر پردازشگر به دلیل شکل تابع سیگموئید، کند عمل می‌کنند. ولی برای مقادیر ورودی‌های نزدیک به نیم، پاسخ نرون‌ها به سیگنال ورودی سریع‌تر خواهد بود (Wosten *et al.*, 1999). با در نظر گرفتن این واقعیت، نرمال‌سازی داده‌ها به گونه‌ای انجام گرفت که میانگین سری داده‌ها برابر ۰/۵ گردد. بدین منظور از رابطه زیر برای نرمال‌سازی استفاده شد.

$$x_{norm} = 0.5 \left(\frac{x_0 - \bar{x}}{x_{max} - x_{min}} \right) + 0.5$$

که در آن x_{norm} ، x_0 ، \bar{x} ، x_{max} و x_{min} به ترتیب داده‌های نرمال شده، داده‌های اصلی و میانگین داده‌ها و S مقدار بشینه و کمینه داده‌ها است (Heykin, 1999). در این پژوهش از این روش برای نرمال‌سازی داده‌ها استفاده شده است.

به منظور مقایسه قدرت پیش‌بینی و انتخاب بهترین روش‌های پیش‌بینی، معمولاً داده‌ها را به دو مجموعه مجزا تقسیم می‌کنند. بخش اول داده‌های آموزش و بخش دوم مجموعه داده‌های آزمون است. ابتدا ضرایب مدل شبکه با استفاده از داده‌های مجموعه اول برآورد می‌شود و سپس با استفاده از داده‌های مجموعه دوم قدرت پیش‌بینی مدل خارج از مجموعه داده‌های آموزش ارزیابی می‌شود. در این پژوهش از شاخص میانگین مجذور خطا برای بررسی ارزیابی عملکرد شبکه عصبی مصنوعی استفاده شد.

شبکه عصبی طراحی شده و بهینه‌سازی شده توسط الگوریتم حرکت تجمعی ذرات

در طراحی شبکه‌های عصبی علاوه بر انتخاب مجموعه‌ای از متغیرهای ورودی باید ساختار شبکه‌ای که منجر به بهترین پیش‌بینی شود، شناسایی گردد. تغییر ساختمان یک شبکه حتی بدون تغییر متغیرهای ورودی و اندازه نمونه، می‌تواند پیش‌بینی‌های انجام شده را به طور اساسی تغییر دهد.

شبکه‌های عصبی پرسپترون چند لایه که از پرکاربردترین نوع شبکه‌های عصبی هستند نیز در این مقاله مورد استفاده قرار گرفت. پس از تعیین نوع شبکه و شیوه آموزش باید تعداد گره‌ها یا سلول عصبی‌های ورودی، تعداد لایه‌ها و گره‌های مخفی و تعداد گره‌های خروجی مشخص شود.

در این پژوهش، تعداد گره‌های ورودی دقیقاً به اندازه متغیرهای مستقل (طول و عرض جغرافیایی)، دو در نظر گرفته شده است. با توجه به اینکه متغیر وابسته تعداد آفت در محل نمونه برداری است، بر این اساس تعداد گره خروجی یک گره است. گره‌های پنهان نقش بسیار مهمی در عملکرد دقیق شبکه عصبی ایفا می‌کنند. این گره‌ها به شبکه عصبی اجازه می‌دهند تا خصوصیات داده‌ها را کشف و شناسایی نمایند و بدین وسیله نگاشت‌های پیچیده غیرخطی را بین متغیرهای ورودی و خروجی برقرار کنند. از لحاظ تنوریک شبکه‌های عصبی می‌توانند دقت دلخواه را برای تقریب توابع با استفاده از تعداد کافی گره در لایه یا لایه‌های مخفی به دست آورند. در این پژوهش از یک لایه پنهان استفاده شده است. توابع فعال‌سازی برای لایه میانی از نوع سیگموئیدی و برای لایه خروجی از یک تابع خطی استفاده شده است.

جدول ۱- مقدار پراسنجه‌های محاسبه شده در الگوریتم PSO

Table 1. Calculated Parameter of PSO Algorithm

Parameters	Value
Population size	300
Number of generations	2000
Learning factor	1.5
Weight inertia	0.5

نتایج و بحث

برای اطمینان از یادگیری شبکه عصبی آموزش دیده برای پیش‌بینی الگوی پراکنش *R. padi*، 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 ۹۵ در صد به کمک پراسنجه p آزمون شد. به

ترتیب برای مقایسه میانگین، واریانس و توزیع آماری از آزمون F, t و کولموگروف - اسمیرنو استفاده شد. مقادیر P محاسبه شده برای هر مورد در جدول (۲) نشان داده شده است. نتایج نشان می‌دهد که میانگین و واریانس برای شبکه عصبی مصنوعی اختلاف معنی‌داری را نشان نمی‌دهد ($p < 0.001$). عدم وجود اختلاف معنی‌دار بین توزیع آماری مقادیر مشاهده شده و پیش‌بینی شده تراکم شته *R. padi* در هر دو فاز آزمایش و آموزش، نشان‌دهنده دقت بالا و قابلیت شبکه عصبی بهینه شده توسط الگوریتم حرکت تجمعی ذرات، به منظور ترسیم نقشه پراکندگی این آفت در منطقه باجگاه می‌باشد. وجود $p = 1$ در مورد توزیع آماری بین مقادیر پیش‌بینی شده و مقادیر واقعی تراکم *R. padi* در فاز آموزش و همچنین وجود $p = 1.00$ در فاز آزمایش در سطح مزرعه، نشان از دقت بالا و نیز قابلیت شبکه عصبی ترکیب شده با الگوریتم حرکت تجمعی ذرات، به منظور ترسیم نقشه پراکندگی این آفت داشت.

جدول ۲- مقایسات آماری بین مقادیر واقعی و پیش‌بینی تراکم *R. padi* توسط شبکه عصبی MLP

Table 2. Statistical comparisons between the observed and estimated *R. padi* density by MLP neural networks

Sampling data	Utilization phase	Comparisons of means	Comparisons of variance	Comparisons of distribution
04.04.2013	Training Phase	0.988	0.958	0.85
	Test Phase	1.00	1.00	1.00
04.19.2013	Training Phase	0.992	0.965	1.00
	Test Phase	1.000	1.00	1.00
05.05.2013	Training Phase	0.995	0.999	1.00
	Test Phase	1.00	1.000	1.00
20.04.2013	Training Phase	0.514	0.866	0.75
	Test Phase	0.919	0.989	0.89

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 خط 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 قابلیت بالای تعمیم‌پذیر بودن شبکه عصبی در تخمین تراکم جمعیت شته *R. padi* در مزرعه است. زیرا مرحله آزمایش در مقایسه با مرحله آموزش دارای ضریب تبیین بالاتر بوده و معادله خطی رگرسیونی بین مقادیر واقعی و پیش‌بینی شده دارای شیب نزدیک‌تر به یک و عرض از مبدا نزدیک به صفر می‌باشد. در پژوهش Zhang et al. (2008) که به منظور تعیین الگوهای پراکنش حشرات در یک مرتع به وسیله شبکه عصبی انجام شد، بیان شد که شبکه‌های عصبی MLP، LVQ و خطی می‌توانند به خوبی الگوهای توزیع حشرات را تشخیص دهند. اما در بین شبکه‌های یاد شده شبکه MLP دارای قوی‌ترین الگوریتم در تشخیص الگوها بود (Zhang et al., 2008). پژوهش Young et al. (2010) نیز بیانگر کارایی بالای شبکه عصبی مصنوعی MLP در پیش‌بینی پویایی جمعیت مگس گالزا *Thecodiplosis japonensis* (Diptera: Cecidomyiida) در جنگل‌های سوزنی‌برگ آمریکا بود.

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 av (actual value) and pv (predicted value) by model

Sampling data	Network Utilization phase	Linear regression relationship	R ²
04.04.201	Training Phase	pv= 0.9606 av +0.0106	0.9511
	Test Phase	pv= 0.9315 av +0.0152	0.9311
04.19.2013	Training Phase	pv= 0.9877 av +0.0036	0.9974
	Test Phase	pv= 0.9316 av +0.0126	0.9396
05.05.2013	Training Phase	pv= 0.9901 av +0.0006	0.9981
	Test Phase	pv= 0.9680 av +0.0027	0.9796
20.04.2013	Training Phase	pv= 0.9190 av +0.0147	0.9203
	Test Phase	pv= 0.8103 av +0.0327	0.8545

نقشه‌های توزیع مکانی *R. padi*

نقشه پراکنندگی مکانی *R. padi* توسط شبکه عصبی ترسیم و به دو بخش واقعی و تخمینی در شکل ۳ نشان داده شده است. اگرچه که پیش‌تر بر اساس مقایسه‌های آماری بین مقادیر واقعی و پیش‌بینی شده به عدم وجود تفاوت معنی‌داری در توزیع آماری شته 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 & Fuh, 1998).

این شبکه به دلیل ایجاد رابطه دقیق بین داده‌های ورودی و خروجی، می‌تواند خروجی‌های مدل را با دقت بالایی پیش‌بینی نماید و در هر زمان با گذاشتن اطلاعاتی مانند طول و عرض جغرافیایی و یا ... در این مدل‌ها می‌توان ترکم آفت را پیش‌بینی نمود و اقدامات کنترلی لازم را پیاده نمود. در این مطالعه شبکه عصبی مصنوعی بهینه شده توسط الگوریتم حرکت تجمعی ذرات توانست با دقت مناسبی الگوی توزیع شته را مشخص و نقشه پراکنش *R. padi* را رسم کند. بر اساس راهنمای شکل شماره ۳، نقاط به رنگ قهوه‌ای پررنگ، آلوده‌ترین نقاط مزرعه هستند. همچنین نقشه‌های حاصل بیان‌کننده پراکنش تجمعی این آفت در مزرعه می‌باشد.



شکل ۳- نقشه توزیع *Rhopalosiphum padi* در دو حالت واقعی تخمینی توسط مدل شبکه عصبی

Fig. 3. *Rhopalosiphum padi* distribution maps in actual and predicted conditions by MLPNN

کشاورزی دقیق با تاکید بر افزایش عملکرد و کاهش اثرات زیان آور زیست محیطی، ابزاری نوین در عرصه کشاورزی محسوب می‌شود. یکی از مهمترین و کاربردی‌ترین ابزارها در کشاورزی دقیق، شبکه‌های عصبی می‌باشند. با تکیه بر این ابزار می‌توان اقدامات مدیریتی را متناسب با شرایط نقاط مختلف زمین انجام داد. بر اساس

یافته‌های این پژوهش، شبکه‌های عصبی ترکیب شده با الگوریتم‌های هوشمند نه تنها توانایی مناسبی در برآورد دقیق پراکندگی آفات دارند، بلکه با ترکیب این الگوریتم با شبکه عصبی، سرعت پردازش و دقت نقشه‌های خروجی افزایش یافته است. شناخت الگوهای پراکنش آفات و کنترل متناسب با مکان آنها می‌تواند به کاهش مصرف آفت‌کش‌های شیمیایی و به تبع آن کاهش آلودگی‌های زیست محیطی منجر شود. همچنین با استفاده از نقشه‌های پراکندگی، می‌توان عوامل کنترل طبیعی مانند کفشدوزک‌های شکارگر را در نقاط آلوده‌ی مزرعه رها-سازی کرد.

References

- Aleosfoor, M., Izadpanah, K., Mossadegh, M., Sadeghi, M., Afsharifar, A., Masumi, M., Yasaii, M., Jokar, L. & Hayati, J.** (2010) Efficiency of seven clones of *Rhopalosiphum padi* in transmission of four barley yellow dwarf virus-PAV isolates in Iran. *Iranian Journal of Plant Pathology* 43, 184-199.
- Agyare, W. A. & Park, S. J.** (2007) Artificial neural network estimation of saturated hydraulic conductivity. *Vadose Zone Journal* 6(2), 423-431.
- Cao, Q. & Parry M. E.** (2009) Neural Network Earning per Share Forecasting Models: A Comparison of Backward Propagation and Genetic Algorithm. *Decision Support Systems* 47, 32-41.
- Garzia, T. G., Siscaro, G., Biondi, A. & Zappala, L.** (2011) Distribution and damage of *Tuta absoluta*, an exotic invasive pest from South America. In: *Proceeding of 1th International symposium on management of Tuta absoluta (Tomato borer)*. 13pp. 13-15 November, Morocco.
- 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.
- Heykin, S.** (1999) *Neural network A Comprehensive Foundation*. 572 pp. John Wiley & Sons, New York.
- Ingwell, L. L., Lacroix, C., Rhoades, P. R., Karasev, A. V. & Bosque-Pérez, N. A.** (2017) Agroecological and environmental factors influence Barley yellow dwarf viruses in grasslands in the US Pacific Northwest. *Virus Research* 241, 185-195.
- 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.
- Kaul, M., Hill, R. L. & Walthall, C.** (2005) Artificial neural networks for corn and soybean yield prediction. *Agriculture System* 85(2), 1-18.
- Kenndy, J. & Eberhart, R. C.** (1995) Particle Swarm Optimization. In: *Proceedings the ICNN'95-International Conference on Neural Networks*. Vol. 4, pp. 1942-1948. IEEE.

- Lv, J., Wang, X. & Wei, X.** (2009) A hybrid approach of neural network with particle swarm optimization for tobacco pests prediction. *Computer and Computing Technologies in Agriculture* 22(2), 1251-1260.
- Park, C. G., Choi, B. R., Cho, J. R., Kim, J. H. & Ahn, J. J.** (2017) Thermal effects on the development, fecundity and life table parameters of *Rhopalosiphum padi* (Linnaeus) (Hemiptera: Aphididae) on barley. *Journal of Asia-Pacific Entomology* 20, 767-775.
- Peacock, L., Worner, S. & Pitt, J.** (2007) The application of artificial neural networks in plant protection. *EPPO Bulletin* 37, 277-282.
- Poli, R., Kennedy, J. & Blackwell, T.** (2007) Particle Swarm Optimization: an overview. *Swarm Intelligence* 1, 33-57.
- Riedell, W. E., Kieckhefer, R. W., Langham, M. A. C., & Hesler, L. S.** (2003) Root and shoot responses to bird cherry-oat aphid and Barley yellow dwarf virus in spring wheat. *Crop Science Society of America* 43, 1380-1386.
- Shabani nejad, A. & Tafaghodiniya, B.** (2017) 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. [In Persian with English summary].
- 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, 240-252.
- Shanker, M., Hu, M. Y. & Hung, M. S.** (1996) Effect of Data Standardization on Neural Networks Training. *Omega* 24: 385-397.
- Tafaghodinia, B. & Shabani nejad, A. R.** (2017) Automatic clustering of data from sampling and evaluation of neuro-fuzzy network for estimateing the distribution of *Bemisia tabaci* (Hem.:Aleyrodidae). *Journal of Entomological society of Iran* 37, 91-105. [In Persian with English summary]
- Tafaghodinia, B. & Shabani nejad, A. R.** (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]
- Taheri, S., Razmjou, J. & Rastegari, N.** (2010) Fecundity and Development Rate of the Bird Cherry-oat Aphid, *Rhopalosiphum padi* (L.) (Hom.: Aphididae) on Six Wheat Cultivars. *Plant Protection Science* 46, 72-78.
- Tiwari, U. & Cummins, E.** (2009) Nutritional importance and effect of processing on tocals in cereals. *Trends in Food Science & Technology* 20, 511-520.

- Tonnang, Z. E. H., Nedorezov, L. V., Ochanda, H., Owino, J. O. & Lohr, B.** (2010) Assessing the impact of biological control of *Plutella xylostella* through the application of Lotka–Volterra model. *Ecological Modeling* 220, 60–70.
- Torrecilla, J. S., Otero, L. & Sanz, P. D.** (2004) A neural network approach for thermal/pressure food processing. *Food Engineer* 62(9), 89–95.
- Vandegeer, R. K., Powell, K. S. & Tausz, M.** (2016) Barley yellow dwarf virus infection and elevated CO₂ alter the antioxidants ascorbate and glutathione in wheat. *Journal of Plant Physiology* 199, 96–99.
- Wosten, J. H. M., Lilly, A. & Nemes C.** (1999) Development and use of a database of hydraulic properties of European soils. *Geoderma* 90, 169–185.
- Young, S. P., Ja-Myung, K., Buom-Young, L., Yeong-Jin J. & 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(6), 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.
-