

پیش‌بینی الگوی توزیع (*Bemisia tabaci* G. (Hem.: Aleyrodidae) با استفاده از شبکه

عصبی مصنوعی بهینه شده توسط الگوریتم حرکت تجمعی ذرات

Predicting distribution pattern of *Bemisia tabaci* G. (Hem.: Aleyrodidae) by Hybrid neural network With Particle Swarm Optimization Algorithm

علیرضا شعبانی‌نژاد^{۱*} و بهرام تفقیدی‌نیا^۲

تاریخ دریافت: ۱۳۹۵/۴/۳

تاریخ پذیرش: ۱۳۹۵/۹/۲۱

چکیده

با پدید آمدن تکنیک‌های آماری قوی و شبکه‌های عصبی، مدل‌های پیش‌بینی کننده پراکنش آفات به سرعت در اکولوژی توسعه پیدا کرده است. این پژوهش به منظور پیش‌بینی و ترسیم نقشه توزیع *Bemisia tabaci* G. با استفاده از شبکه‌های عصبی پرسپترون چند لایه (MLP) ترکیب شده با حرکت تجمعی ذرات در سطح مزرعه خیار انجام شد. داده‌های مربوط به جمعیت این آفت از طریق نمونه‌برداری از ۱۰۰ نقطه از سطح مزرعه شهرستان رامهرمز در سال ۱۳۹۶ به دست آمد. به منظور ارزیابی قابلیت شبکه‌های عصبی مورد استفاده در پیش‌بینی توزیع 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 ویژگی‌های آماری واریانس، توزیع آماری و میانگین مجموعه داده‌های واقعی و پیش‌بینی شده مکانی این آفت توسط شبکه عصبی ترکیب شده، تفاوت معنی‌داری وجود نداشت. نقشه‌های ترسیم شده نشان داد که توزیع این آفت تجمعی است و امکان کنترل متناسب با توزیع مکانی را در مزرعه دارد.

واژگان کلیدی: الگوریتم حرکت تجمعی ذرات، توزیع مکانی، شبکه عصبی مصنوعی.

۱- دانش‌آموخته کارشناسی ارشد حشره شناسی، دانشکده کشاورزی، دانشگاه صنعتی شاهرود، شاهرود، ایران.

۲- استادیار گروه گیاه پزشکی سازمان پژوهش‌های علمی و صنعتی ایران، تهران، ایران.

*نویسنده مسئول مکاتبات: Shabaniarezza565@gmail.com

مقدمه

خیار (*Cucumis sativus* L.) با ۱۴ کروموزوم، گیاه یک‌ساله دو جنسی، و متعلق به تیره کدوئیان است. این گیاه بومی کشور هندوستان است و به عنوان اقتصادی‌ترین گیاه تیره کدوئیان، یکی از محصولات ارزشمند سبزی و جالیز در خاورمیانه به شمار می‌رود (Nario *et al.*, 2010). سطح زیر کشت و میزان تولید این محصول در ایران، به ترتیب ۸۰۰۰۰ هکتار و ۱۴۰۰۰۰۰ تن می‌باشد که اغلب در سیستم‌های مزرعه و گلخانه کشت می‌شود (Anonymous, 2011). خیار دارای آفات و بیماری‌های متعددی است که یکی از آفات مهم آن، سفیدبالک پنبه (*Bemisia* (Hem.: Aleyrodidae) می‌باشد که علاوه بر خیار به حدود ۲۰۰ محصول زراعی و صیفی در اکثر مناطق جهان به‌ویژه در نواحی گرم، معتدل و خشک خسارت وارد می‌کند. حشرات بالغ و پوره‌های این آفت با تغذیه از شیر گیاهی سبب کاهش عملکرد محصول می‌گردند (Shishehbor, 2001). این آفت به صورت غیرمستقیم نیز با تولید عسلک، سبب چسبندگی ذرات گرد و غبار به سطح برگ‌ها شده و میزان فتوسنتز را کاهش می‌دهد. عسلک ناشی از این آفت موجب جلب قارچ‌های ساپروفیت موسوم به کپک سیاه یا دوده (مانند *Capnodium spp.*) می‌گردد که منجر به تضعیف گیاه و ایجاد لکه‌های رنگ پریده روی اندام‌های مختلف گیاه می‌شود (Gerling, 1990). سفیدبالک پنبه ناقل بیماری‌های ویروسی متعددی مانند موزاییک خیار است که خسارت جبران‌ناپذیری به گیاه وارد می‌کند (Yang *et al.*, 2010).

برای تدوین برنامه‌های مدیریت تلفیقی این آفت مهم، آگاهی از تغییرات جمعیت آن در مزرعه در طی زمان ضروری است. تراکم جمعیت‌های حشرات به صورت طبیعی در نقاط مختلف یک اکوسیستم زراعی متفاوت است. این عدم یکنواختی تراکم جمعیت در انتخاب روش‌های نمونه‌برداری، درک روابط طعمه و شکارچی در برنامه‌های کنترل بیولوژیک و بهینه‌سازی مصرف سم بسیار موثر است (Garzia *et al.*, 2011). مطالعات متعددی نشان داده است که شبکه‌های عصبی توانایی بالایی در تشخیص الگوهای توزیع مکانی اکولوژیک جمعیت‌ها دارند (Goel *et al.*, 2003; Irmak *et al.*, 2006).

در پژوهشی به منظور مطالعه نحوه توزیع مکانی حشرات در مراتع از مدل Learning Vector Quantization Neural Network استفاده شد و کارایی مطلوبی نشان داد (Zhang *et al.*, 2008). در پژوهشی توزیع مکانی سفیدبالک پنبه بر اساس داده‌های حاصل از نمونه‌برداری از مزرعه خیار با روش خوشه‌بندی اتوماتیک تقسیم‌بندی و بر مبنای شبکه نرو-فازی ترسیم شد (Shabani nejad and Tafaghodinya, 2017).

امروزه به موازات مدل‌های سری زمانی، دیدگاه دیگری در زمینه پیش‌بینی مطرح 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 دارند. مغز انسان به عنوان یک سیستم پردازش اطلاعات از عناصر اصلی ساختاری به عنوان نورون تشکیل شده است. شبکه‌های عصبی مصنوعی نیز شامل مجموعه‌ای از نورون‌های به هم متصل می‌باشند که به هر مجموعه از این نورون‌ها یک لایه گفته می‌شود. در نهایت برای اجرای این لایه‌ها، نورون‌ها به وسیله توابع فعال‌سازی به یکدیگر متصل می‌شوند (Ray and Parry, 2009).

یک شبکه عصبی به طور متداول از سه لایه ورودی، پنهان و خروجی تشکیل می‌شود. لایه ورودی فقط اطلاعات را دریافت می‌کند و مشابه متغیر مستقل عمل می‌کند. از این‌رو تعداد نورون‌های لایه ورودی بر اساس تعداد متغیرهای مستقل تعیین می‌شوند. لایه خروجی نیز همانند متغیر وابسته عمل می‌کند و تعداد نورون‌های آن به تعداد متغیرهای وابسته بستگی دارد. برخلاف لایه‌های ورودی و خروجی، لایه پنهان هیچ مفهومی را نشان نمی‌دهد و صرفاً یک نتیجه در روند محاسبه ارزش خروجی است. شبکه‌های عصبی مصنوعی انواع مختلفی دارند اما یکی از پرکاربردترین نوع شبکه‌های عصبی، شبکه‌عصبی پرسپترون چند لایه است. در این نوع شبکه‌ی 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 به گره‌های بعدی سیگنال منتقل می‌کند (Heykin, 1999).

فرآیند یادگیری شبکه عصبی

یکی از مهم‌ترین ویژگی‌های یادگیری شبکه‌های عصبی مصنوعی که عملکرد آن را به انسان نزدیک‌تر می‌کند، قدرت یادگیری است. در شبکه‌های عصبی از آن جهت به یادگیری نیاز است که ارتباط میان ورودی‌ها و خروجی‌ها به طور دقیق و کامل مشخص نیست. از آنجا که تجربه‌ها در طول زمان حاصل می‌شوند، لذا درجه 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 دلتا نامیده می‌شود. در اینجا هدف به حداقل رساندن دلتا یا به صفر رساندن آن است. کاهش دلتا 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 سیستم ارایه 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 فرا گیرد. عملکرد شبکه از طریق به‌هنگام سازی وزن‌ها بهبود می‌یابد. سپس کیفیت و توانایی شبکه با اعمال داده‌های آزمایشی برآورد می‌شود (Heykin, 1999). 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 (Kennedy and 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 (Kennedy and 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 G_{best} استفاده می‌شود. یعنی هر ذره بهترین موقعیت قبلی خود و بهترین موقعیت قبلی هر یک از ذرات موجود در جمعیت را به‌خاطر می‌آورد و به عبارت دیگر هر ذره در جهت بهترین موقعیت قبلی خود و به سمت بهترین ذره در حرکت است (Kennedy and Eberhart, 1995). در این الگوریتم، هر ذره نماینده یک جواب ممکن است که به صورت تصادفی در فضای مساله حرکت می‌کند. 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 می‌گذارد. نتیجه مدل‌سازی این رفتار اجتماعی، فرآیند جست و

جویی است که در آن ذرات به سمت نواحی مناسب میل می‌کنند. ذرات در گروه از یکدیگر می‌آموزند و بر مبنای دانش به دست آمده، به سمت بهترین همسایگان خود حرکت می‌کنند (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 همسایگی‌اش وجود دارد، تنظیم می‌کند (Kennedy and Eberhart, 1995). شکل (۱) فرآیند تغییر موقعیت ذره‌ها را نشان می‌دهد.



شکل ۱- تغییر موقعیت ذرات در الگوریتم بهینه‌سازی حرکت تجمعی ذرات

Fig. 1. Position change of each particle

فرض کنید یک فضای D بعدی وجود دارد و i امین ذره از گروه می‌تواند با یک بردار سرعت و یک بردار موقعیت نشان داده شود. تغییر موقعیت هر ذره، با تغییر در ساختار موقعیت و سرعت قبلی امکان‌پذیر است. هر ذره اطلاعاتی شامل بهترین مقداری را که تا کنون به آن رسیده ($Pbest$) و موقعیت X_i ، را داراست. این اطلاعات از مقایسه تلاش‌هایی که هر ذره برای یافتن بهترین جواب انجام می‌دهد، به دست می‌آید. همچنین هر ذره بهترین جوابی که تا کنون از مقدار $Pbest$ در گروه به دست آمده است را می‌شناسد ($Gbest$). هر ذره برای رسیدن به بهترین جواب سعی می‌کند 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 می‌کند:

$$V_i^{k+1} = W \cdot V_i^k + c_1 r_1 (Pbest_i - X_i^k) + c_2 r_2 (Gbest_i - X_i^k)$$

در رابطه فوق:

V_i^k سرعت هر ذره در تکرار K ام، W پارامتر 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 ذره I و $Gbest_i$ نیز $Gbest$ در گروه است (Poli *et al.*, 2007). موقعیت هر ذره نیز بر اساس رابطه زیر تعیین می‌شوند:

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

پارامترهای این الگوریتم

پارامتر وزنی W در رابطه اول برای تضمین همگرایی در این الگوریتم و همچنین کنترل تاثیر سوابق سرعت پیشین بر سرعت‌های جاری مورد استفاده قرار می‌گیرد. یک مقدار مناسب پارامتر وزنی، معمولاً تعادلی را بین قابلیت جست و جوی کلی و جست و جوی محلی ایجاد می‌کند (Kennedy and Eberhart, 1995). با انتخاب مناسب پارامتر وزنی، میزان تکرار برای یافتن جواب بهینه کاهش می‌یابد. ضریب ثابت اینرسی بزرگتر از یک هرچند سبب می‌شود فضای جست و

جوی الگوریتم وسیع تر گردد، اما الگوریتم را ناپایدار می‌کند. زیرا اثر سرعت پیشین را افزایش می‌دهد. در ابتدا مقدار W ثابت در نظر گرفته می‌شود، اما بعدها مطالعات ابرهارت در سال‌های ۱۹۹۸ و ۱۹۹۹ در این زمینه منجر به تغییر شگرفی در این الگوریتم شد. آن‌ها پارامتر 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 مذکور W_{Max} وزن ابتدایی، W_{Min} وزن انتهایی، $iter$ شماره تکرار و $iter_{Max}$ بزرگترین شماره تکرار است (Poli et al., 2007).

پارامترهای 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 مینیموم محلی جلوگیری می‌کند. در ابتدا مقدار $2C_1 = C_2$ 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 and Eberhart, 1995). پارامترهای r_1 و r_2 برای حفظ تنوع و گوناگونی در گروه به کار می‌روند. مقدار مناسب این پارامترها، در یکنواختی جواب‌ها تاثیرگذار است و این پارامترها 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 G_{best} و P_{best} حرکت کنند (Poli et al., 2007). نرمال‌سازی داده‌ها که به مفهوم پیش‌پردازش داده‌ها است، سبب بهبود عملکرد شبکه می‌شود (Shanker et al., 1996). روش‌های گوناگونی برای نرمال‌سازی داده‌ها وجود دارد؛ یکی از روش‌های معمول در این زمینه، نرمال‌سازی آماری است. در این روش، میانگین داده‌ها صفر و انحراف معیار آن‌ها برابر یک خواهد شد. بدین منظور از رابطه زیر استفاده می‌شود:

$$X_n = \frac{x_n - \bar{X}}{S}$$

که در آن X_n ، x_n و \bar{X} به ترتیب داده‌های نرمال شده، داده‌های اصلی و میانگین داده‌ها و S انحراف معیار 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 شوند. در این پژوهش از شاخص میانگین مجذور خطا برای بررسی ارزیابی عملکرد شبکه عصبی مصنوعی استفاده می‌شود. بنا به بررسی‌های انجام شده، تا کنون پژوهشی به منظور بررسی پراکندگی سفیدبالک پنبه با استفاده از شبکه عصبی مصنوعی ترکیب شده با الگوریتم حرکت تجمعی ذرات، و در راستای تحقق برنامه مدیریت این آفت، صورت نگرفته است. به همین دلیل، تحقیق حاضر با هدف شناخت وضعیت پراکنش این آفت در مزرعه خیار شهرستان رامهرمز انجام شد.

مواد و روش‌ها

موقعیت جغرافیایی و تهیه نقشه نمونه‌برداری

به منظور انجام این پژوهش یک مزرعه خیار به مساحت یک هکتار در اطراف شهرستان رامهرمز در استان خوزستان با مختصات ۴۹ درجه و ۳۶ دقیقه پهناي طولی و ۳۰ درجه و ۳۳ دقیقه پهناي عرضی و بلندی آن از سطح دریا ۱۵۰ متر، انتخاب شد. 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 روی زمین مشخص شد.

روش نمونه‌برداری

در تمامی نقاط نمونه‌برداری یک بلوک با ابعاد ۲×۲ متر مربع انتخاب و درون آن تعداد ۴ بوته به صورت تصادفی به عنوان واحد نمونه‌برداری انتخاب، و تعداد حشرات بالغ موجود در پشت برگ گیاه شمارش و ثبت شد.

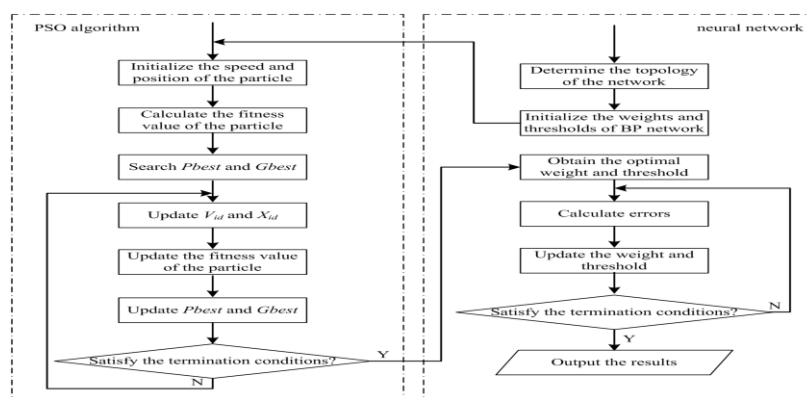
شبکه عصبی مصنوعی

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.

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. در این مقاله از شبکه عصبی پرسپترون استفاده شد. پس از تعیین نوع شبکه و شیوه آموزش باید تعداد گره‌ها یا نورون‌های 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 نمونه‌برداری است لذا 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 نگاهی پیچیده غیرخطی را بین متغیرهای ورودی و خروجی برقرار کنند. از لحاظ تئوریک 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. برای انتخاب بهترین اوزان شبکه نیز از این الگوریتمی که در شکل ۱ کاملاً تشریح شده است.



شکل ۳- فلوچارت ترکیب شبکه عصبی با الگوریتم PSO (Cao et al., 2016)

Fig. 3. Combine PSO with artificial neural network flowchart (Cao et al., 2016)

جدول ۱- مقدار پارامترهای محاسبه شده در الگوریتم PSO

Table 1. Calculated Parameter of PSO Algorithm

Parameters	Value
Population size	100
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 سفیدبالک پنبه، 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 درصد به کمک پارامتر 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 ($p < 0.001$). وجود $p=1$ در مورد توزیع آماری بین مقادیر پیش‌بینی شده و مقادیر واقعی تراکم سفیدبالک پنبه 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 پراکنندگی این آفت داشت.

جدول ۲- مقایسات آماری مقادیر واقعی و پیش‌بینی تراکم سفیدبالک پنبه توسط شبکه عصبی MLP

Table 2. Statistical comparisons between the observed and estimated weed density by MLP neural networks

Sampling date	Utilization phase	Comparisons of means	Comparisons of variance	Comparisons of distribution
10.04.2017	Training	0.898	0.883	0.79
17.04.2017	Test	0.978	0.877	0.62
	Training	0.614	0.906	0.84
24.04.2017	Test	0.994	0.999	0.99
	Training	0.762	0.993	1.00
1.05.2017	Test	0.997	1.00	1.00
	Training	0.809	0.999	1.00
	Test	0.996	1.00	1.00

ضرایب تبیین و رابطه خطی رگرسیونی بین مقادیر واقعی هر کلاس در مقابل مقادیر پیش‌بینی شده توسط شبکه عصبی در جدول ۳ نشان داده شده است. بهترین نتایج بر اساس این دو معیار وقتی به دست می‌آید که معادله خطی مابین تراکم آفت و تراکم آفت پیش‌بینی شده توسط شبکه عصبی علاوه بر داشتن ضریب تبیین بالا دارای عرض از مبدا کم و شیب نزدیک به یک باشد. نتایج جدول ۳ بیانگر قدرت تعمیم‌پذیر بودن شبکه عصبی در تخمین تراکم سفیدبالک پنبه در مزرعه است. در پژوهشی 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 مذکور شبکه‌ی MLP دارای قوی‌ترین الگوریتم در تشخیص الگوها بود (Zhang et al., 2008) و همچنین

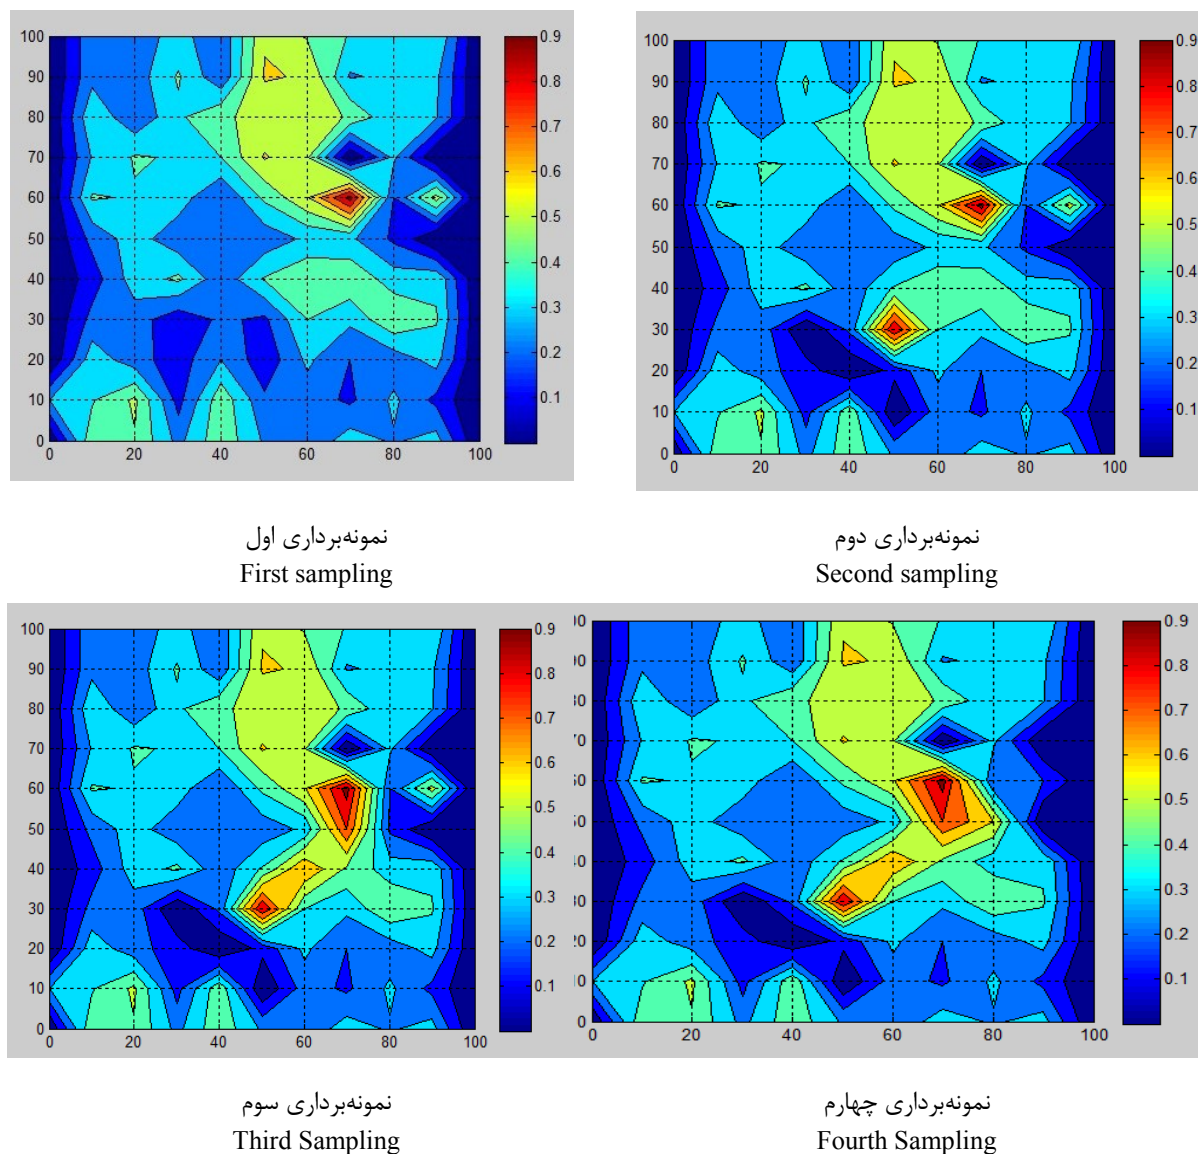
پژوهش (Yeong *et al.*, 2010) بیانگر کارایی بالای شبکه عصبی مصنوعی MLP در پیش‌بینی پویایی جمعیت مگس گالزا (Diptera: Cecidomyiida) در جنگل‌های سوزنی‌برگ آمریکا بود. در پژوهشی روی خیار پاییزه در منطقه ملاتانی استان خوزستان با استفاده از قانون تیلور پراکندگی سفید بالک پنبه مورد بررسی قرار گرفت که نتایج نشان از تجمعی بودن تراکم این آفت داشت (Zandi sohani *et al.*, 2012). همچنین در پژوهشی مستقل که بر روی گیاه طالبی انجام شد نیز پراکندگی این آفت به صورت تجمعی گزارش شد (Tonhasca *et al.*, 1994). در بررسی دیگری که با استفاده از قانون تیلور و آیوائو پراکندگی سفید بالک پنبه را روی خیار مورد بررسی قرار داد، بیان شد که پراکنش این آفت به صورت تجمعی است (Naranio and Flint, 1994). مطالعه‌ای که روی پراکندگی سفید بالک پنبه روی بادنجان منطقه ورامین انجام شد نشان داد که پراکندگی این آفت روی این گیاه نیز تجمعی است (Kianpour *et al.*, 2009).

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)

Sampling date	Network Utilization phase	Linear regression relationship	R^2
10.04.2017	Training Phase	$pv= 0.8601 av +0.012$	0/8999
17.04.2017	Test Phase	$pv= 0.821 dv +0.019$	0/8001
	Training Phase	$pv= 0.9523 av +0.0101$	0.9457
24.04.2017	Test Phase	$pv= 0.8711 dv +0.0139$	0.890
	Training Phase	$pv= 0.9896 av +0.0326$	0.9701
1.05.2017	Test Phase	$pv= 0.9429 av +0.0100$	0.9653
	Training Phase	$pv= 0.9921 av +0.0084$	0.9901
	Test Phase	$pv= 0.9120 av +0.0099$	0.9415

نقشه‌های توزیع مکانی سفیدبالک پنبه

بر اساس راهنمای شکل شماره ۳ محدود سبز تا قرمز آلوده‌ترین منطقه در مزرعه است، بنا به نمونه‌برداری‌های مختلف در ابتدای کار یک کانون آلودگی در شمال شرق زمین وجود داشت، با گذشت زمان مرکز دیگری در قسمت جنوبی زمین تشکیل شد و این مرکز هم به سمت شرق گسترش پیدا کرد و تمرکز اصلی این آفت شد، لذا می‌توان به صورت موضعی نقاط آلوده را سم‌پاشی کرد و از سم‌پاشی سراسری مزرعه و آلودگی بیش‌تر محیط زیست جلوگیری کرد.



شکل ۳- پراکندگی سفیدبالک پنبه در مراحل مختلف نمونه برداری
 Fig. 3. Distribution of *B. tabaci* in different stages of sampling

نتیجه گیری کلی

خیار در بین گیاهان زراعی از اهمیت خاصی برخوردار است و سفیدبالک پنبه یکی از مهم ترین آفت آن می باشد. هر ساله مقادیر زیادی حشره کش برای کنترل این آفت در مزارع خیار استفاده می شود که علاوه بر هزینه های سم پاشی و آلودگی محیط زیست، از بین رفتن موجودات غیر هدف را به دنبال دارد (Pedigo, 2004). بنابراین کاهش مصرف آفت کش های شیمیایی و در عین حال کنترل موثر این آفت، منافع اقتصادی و زیست محیطی بسیاری را به همراه دارد. مدیریت مکان - ویژه آفات راهکاری برای رسیدن به این اهداف می باشد. نتایج حاصل از این پژوهش می توانند در مدیریت مکان - ویژه این آفت نیز مورد استفاده قرار گیرند به این صورت که با استفاده از نقشه های پراکندگی، می توان عوامل کنترل طبیعی مانند کفشدوزک های شکارگر را در نقاط آلوده، متمرکز ساخت.

References

- Anonymous.** 2011. Agricultural statistics, Department of Planning and Economy, The office of Statistics and Information Technology, Tehran.
- Ray Qing C. and 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.
- Goel, P. K., Prasher, S. O., Patel, R. M., Landry, J. A., Bonnell, R. B. and 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.
- Garzia, T. G., Siscaro, G., Biondi, A. and Zappala, L.** 2011. Distribution and damage of *Tuta absoluta*, an exotic invasive pest from South America. Proceeding of 1th In: International symposium on management of *Tuta absoluta* (Tomato borer). 13 -15 November, Morocco. P. 16.
- Gerling, D.** 1990. Whiteflies: their bionomics, pest status and management. John Wiley and Sons, New York. 430PP.
- Heykin, S.** 1999. Neural network A Comprehensive Foundation John Wiley & Sons, New York. 572PP.
- Irmak, A., Jones, J. W., Batchelor, W. D., Irmak, S., Boote, k. J. and Paz, J.** 2006. Artificial neural network model as a data analysis tool in precision farming. *Transactions of the American Society of Agricultural and Biological Engineers* 49: 2027-2037.
- Kennedy, J. and Eberhart, R. C.** 1995. Particle Swarm Optimization. In Proceedings of the IEEE International Conference on Neural Networks IV.
- Kianpour, R., Fathipour, Y. and Kamali, K.** 2002. Population Fluctuation and spatial distribution patterns *B. Tabasi* on eggplants in varamin. *Journal of Plant protection* 77: 71-94.
- Naranjo, S. E. and Flint, H. M.** 1994. Spatial distribution *Bemisia tabaci* in cotton and development of fixed- precision sequential plant. *Environmental Entomology* 23: 245-266.
- Nario, L. S., Oliver-Verel, J. and Stashenko, E. E.** 2010. Repellent activity of essential oilsA. *Bioresource Technology* 101: 372-378.
- Pedigo, L. P.** 2004. Entomology and Pest Management (4thEd). Prentice-Hall of India Pvt. Ltd, New Delhi, India. 521pp.
- Poli, R., Kennedy, J. and Blackwell, T.** 2007. Particle Swarm Optimization: an overview. *Swarm Intell*, 1: 33-57.
- Shishehbor P.** 2001. white fly. University of Shahid Chamran press. 750pp.
- Shanker, M., Hu M. Y. and Hung, M. S.** 1996. Effect of Data Standardization on Neural Networks Training. *Omega* 24: 385-397.
- Shabani nejad, A. R. and Tafaghodiniya, B.** 2017. Automatic clustering of data from sampling and evaluation of neuro-fuzzy network to for estimating the distribution of *Bemisia. tabaci* (Hem.: Aleyrodidae). *Journal if Iranian entomology society* 37:91-105.
- Tonhasca, A., Palumbo, J. C. and Byrne, D. N.** 1994. Distribution pattern of *Bemisia tabaci* in cantaloupe fields in Arizona. *Environmental Entomology* 23: 949 – 954.
- Young-S. P., K, Ja-Myung, L, Buom-Young, L, Yeong-Jin and YooShin, K.** 2010. Use of an Artificial Neural Network to Predict Population Dynamics of the Forest-Pest Pine Needle Gall Midge (Diptera: Cecidomyiida). *Environmental Entomology* 29: 1208-1215
- Yang, N. W., Li AL Wan, F. H., Liu, W. X. and Johnsom, D.** 2010. Effects of on essential oils on immature and adult sweet potato whitefly, *Bemisia tabaci* biotype B. *Crop protection* 29: 1200-1207.
- Zhang, W. J., Zhong, X. Q. and Liu, G. H.** 2008. Recognizing spatial distribution patterns of grassland insects: neural network approaches. *Stochastic Environmental. Research and Risk Assessment* 22: 207–216.
- Zandi sohani, N., Shishehbor, P. and Kocheli, F.** 2012 Seasonal changes and spatial distribution of *Bemisia tabaci* on cucumbe in Ahvaz. *Plant Protection* 35: 73-85.