

ارزیابی روش‌های زمین‌آمار و شبکه عصبی مصنوعی در تعیین پراکنش مکانی کنه تارتن دولکه‌ای

Tetranychus urticae (Acari: Tetranychidae) در مزرعه خیار شهرستان رامهرمز

علیرضا شعبانی نژاد^۱ و بهرام تفقیدی نیا^۲✉

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

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

(تاریخ دریافت: مرداد ۱۳۹۵؛ تاریخ پذیرش: خرداد ۱۳۹۶)

چکیده

پژوهش حاضر با هدف پیش‌بینی تراکم کنه تارتن دولکه‌ای با روش‌های زمین‌آمار و شبکه‌ی عصبی مصنوعی در مزرعه خیار استان خوزستان شهرستان رامهرمز انجام شد. بدین منظور مختصات طول و عرض ۱۰۰ نقطه با فاصله ۱۰ متر، در سطح مزرعه مشخص و به عنوان ورودی‌های هر دو روش تعریف شد. خروجی هر روش نیز تعداد این آفت در آن نقاط بود. در بخش زمین‌آمار از روش کریجینگ معمولی و در بخش شبکه عصبی مصنوعی، ساختار پرسپترون سه لایه با الگوریتم پس انتشار خطا، مورد ارزیابی قرار گرفت. مقایسه نتایج زمین‌آمار و شبکه عصبی مصنوعی بیانگر توانایی بالای شبکه عصبی در مقایسه با روش زمین‌آمار بود، به طوری که به ترتیب شبکه عصبی مصنوعی و زمین‌آمار با ضریب تبیین ۰/۸۹۱، ۰/۶۰۱ و مجموع مربعات باقیمانده ۰/۱۴، ۰/۰۷۱، نسبت به زمین‌آمار خطای کمتری داشت. در مجموع می‌توان چنین نتیجه گرفت که روش شبکه عصبی مصنوعی با تلفیق دو عامل طول و عرض جغرافیایی، قادر به پیش‌بینی تراکم آفت با دقت مناسب بود. **واژه‌های کلیدی:** تغییر نما، شبکه عصبی مصنوعی، کنه تارتن دولکه‌ای، کریجینگ.

Evaluation of the Geostatistical and Artificial Neural Network Methods to estimate the Spatial Distribution of *Tetranychus urticae* (Acari: Tetranychidae) in Ramhormoz Cucumber fields

A. SHABANI NEJAD¹ and B. TAFAGHODINIYA²✉

1- Graduated Student of Entomology, Faculty of Agriculture, Shahrood University. Iran

2- Assistant Professor of Entomology, Iranian Research Organization for Science and Technology, Iran

Abstract

In this study, the geostatistical and artificial neural network methods were used to estimate the spatial distribution of *Tetranychus urticae* in Ramhormoz Cucumber fields. For this purpose, latitude and longitude of 100 points with 10 meters distance of each point were defined as inputs and output of each method was number of these pests on those points. Ordinary kriging, and perceptron with propagation algorithm were evaluated in geostatistical and artificial neural network method, respectively. In neural network a hidden layer and three-layer were considered as input. Results of the aforementioned two methods showed that artificial neural network capability is more than kriging method. So that, the artificial neural network predicts distribution of this pest with 0.891 coefficient of determination and 0.14 residual sums of squares. While in the geostatistical methods coefficient of determination and residual sums of squares were 0.601 and 0.071, respectively. So it can be concluded that the Artificial Neural Network approach with combining latitude and longitude can forecast pest density with sufficient accuracy.

Key words: Artificial Neural Network, Kriging, *Tetranychus urticae*, Variogram.

مقدمه

خیار (*Cucumis sativus* Linnaeus) 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 ۱۴۰۰۰۰ تن می‌باشد که اغلب در سیستم‌های مزرعه و گلخانه کشت می‌شود (Anonymous, 2011). خیار دارای آفات متعددی است که یکی از آفات مهم آن، کنه تارتن دولکه‌ای (*Tetranychus urticae* Koch (Acari: Tetranychidae)) می‌باشد که علاوه بر خیار به محصول زراعی و صیفی در اکثر مناطق جهان به‌ویژه در نواحی گرم و معتدل خسارت می‌زند. کنه تارتن دولکه‌ای با تغذیه از برگ‌ها سبب از بین رفتن کلروفیل و کاهش سطح فعال فتوسنتزی گیاه می‌شود و در صورت شدید بودن خسارت، ریزش برگ‌ها را نیز به همراه دارد (Gorman et al., 2001). سالانه مقدار زیادی از آفت‌کش‌های مصنوعی برای کنترل این کنه مورد استفاده قرار می‌گیرند. این آفت به علت کوتاه بودن دوره زندگی و تولید مثل بسیار سریع، به سرعت به ترکیبات مصنوعی مقاوم شده و عملاً استفاده مکرر از کنه‌کش‌ها فقط باعث آلودگی محصولات و افزایش اثرات جانبی زیان‌بار آن‌ها بر موجودات غیر هدف و محیط زیست شده است (Isman, 1999).

برای تدوین برنامه‌های مدیریت تلفیقی این آفت مهم، آگاهی از تغییرات جمعیت آن در مزرعه در طی زمان ضروری است. اما آنچه رسیدن به این اهداف را محقق می‌سازد افزایش صحت و دقت روش‌های درون‌یابی و تهیه نقشه‌های کاربردی از جمعیت آفات است. درون‌یابی مکانی شامل تخمین متغیرهایی مانند تراکم آفت 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 آفات در تعداد

نقاط محدود نمونه‌برداری شده، تراکم آفت را در نقاط نمونه برداری نشده به درستی تخمین بزند (Makarjian, 2007). از روش‌های درون‌یابی مورد استفاده در مطالعات حشره‌شناسی روش‌های کریجینگ^۱ و شبکه عصبی مصنوعی^۲ را می‌توان نام برد. از مثال‌های موفقیت‌آمیز در درون‌یابی کریجینگ می‌توان به پیش‌بینی جمعیت پروانه ابریشم باف ناجور (*Lymantria dispar* (L.)) اشاره نمود که با کمک این روش می‌توان مسیر مهاجرت این آفت را در مناطق جنگلی پیش‌بینی نمود (Liebhold et al., 1991). پراکنندگی حشرات کامل سوسک ساقه خوار ذرت (*Ostrinia nubilalis* (H.)) در مزارع شمال آمریکا به کمک روش‌های زمین‌آماري تخمین و متعاقباً ردیابی و پیش‌بینی شروع فعالیت آن در ابتدای فصل انجام شده است (Wright et al., 2002). در سال‌های اخیر کانون‌یابی جمعیت‌های انواع ملخ که به یک مشکل بین‌المللی تبدیل شده، به کمک روش‌های زمین‌آمار انجام می‌شود (Story and Congalton, 1994). در باغ‌های آلو با هدف مدیریت بهتر کرم آلو (*Cydia funebrana* (T.)) ویژگی‌های زمین‌آماري جلب این حشره توسط تله‌های فرمونی مورد بررسی قرار داده شد (Sciarretta et al., 2001). مشخصات زمین‌آماري ساقه‌خوار (*Hypothenemus hampei* (F.)) و مینوز (*Leucoptera coffeella*) (G. De Alves et al., 2011). در مزرعه قهوه، امکان پیش‌بینی جمعیت و میزان خسارت این دو حشره را فراهم ساخت (De Alves et al., 2011). به علاوه، به منظور اجرای سیستم کشاورزی دقیق در مدیریت کرم سیب (*Cydia pomonella* (L.)) زمین‌آمار و سیستم اطلاعات جغرافیایی (GIS) مورد استفاده قرار گرفت (Ribes-Dasi et al., 2005). مشخصات زمین‌آماري و الگوی پراکنندگی سفید بالک پنبه (*Bemisia tabaci*) در مراحل مختلف رشد توتون در چین بررسی شد (Zhao et al., 2011). در ایران نیز تحقیقاتی مشابه انجام شده است. چنانکه میزان پراکنندگی و خسارت کرم میوه‌خوار خرما (*Batrachedra amydraula* (M))

۱- Kriging

۲- Artificial Neural Network

اطراف شهرستان رامهرمز با طول ۴۹ درجه و ۳۶ دقیقه و عرض ۳۰ درجه و ۳۳ دقیقه جغرافیایی و بلندی ۱۵۰ متر از سطح دریا، انتخاب شد. در درون مزرعه موقعیت مکانی هر نقطه 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 برای آماربرداری مشخص شد.

روش نمونه‌برداری: در تمامی نقاط نمونه‌برداری یک

بلوک ۲×۲ متر مربع انتخاب و درون آن تعداد چهار بوته به صورت تصادفی به عنوان واحد نمونه‌برداری انتخاب، و تعداد کنه‌های بالغ موجود در پشت برگ گیاه شمارش و ثبت شد.

زمین‌آمار^۴: روش‌های زمین‌آمار بر پایه نظریه متغیر


مکانی استوار است. یک متغیر مکانی عبارت است از هر خصوصیت محیطی یا زیستی که در فضای دو بعدی یا سه بعدی توزیع شده باشد. تغییرات این دسته از متغیرها از نقطه‌ای به نقطه‌ای دیگر مشخص و دارای پیوستگی آشکاری می‌باشند. شدت خسارت و تراکم، نمونه‌هایی از متغیرهای مکانی هستند (Katherine, 2001). تفاوت اصلی این روش با آمار کلاسیک این است که در آمار کلاسیک^۵ نمونه‌های گرفته شده از یک جامعه آماری، مستقل از یکدیگر بوده و وجود یک نمونه هیچ گونه اطلاعاتی درباره نمونه بعدی نمی‌دهد. اما روش‌های زمین‌آمار، وجود همبستگی مکانی بین مقادیر یک متغیر، در یک ناحیه را بررسی می‌نماید. وابستگی مکانی بین نمونه‌ها را می‌توان به صورت یک مدل ریاضی تحت عنوان ساختار مکانی بررسی نمود (Hassani-pak, 2007). به صورت کلی زمین‌آمار دارای دو بخش اصلی واریوگرام و کریجینگ می‌باشد (Gressie, 1993).

با استفاده از روش زمین‌آمار در استان خوزستان تعیین شده است (Latifian and Soleymannejadian, 2009). همچنین می‌توان به استفاده از ویژگی‌های زمین‌آمار، جهت حرکت و میزان تراکم کرم پبله‌خوار نخود (*Heliothis virescens* (H.)) در مزارع نخود دیم شهرستان دلفان از استان لرستان اشاره نمود (Shafiee Nasab et al., 2015). 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^۳ توسط Zhang et al. (2008) برای مطالعه توزیع مکانی حشرات در اراضی مرتعی استفاده شد که کارایی مطلوبی را نشان داد. شبکه عصبی مصنوعی ترکیب شده با الگوریتم ژنتیک برای پیش‌بینی الگوی پراکنش کنه تارتن دو لکه‌ای در مزرعه خیار نیز نتایج کارایی بسیار بالای این شبکه را نشان داد (Shabani nejad et al., 2017)، شعبانی نژاد و تفقیدی‌نیا (Shabani nejad and Tafaghodinia, 2017) کارایی بالای مدل شبکه عصبی بردار چند ساز یادگیر LVQ₄ را در تعیین پراکنش شب‌پره مینوز گوجه‌فرنگی در مزرعه گوجه‌فرنگی را نشان دادند. بنا بر بررسی‌های انجام شده، تا کنون پژوهشی به منظور ارزیابی روش زمین‌آمار و شبکه عصبی مصنوعی در راستای تحقق برنامه مدیریت این آفت، در مزرعه خیار صورت نگرفته است. به همین دلیل، تحقیق حاضر با هدف شناخت وضعیت پراکنش این آفت در مزرعه خیار شهرستان رامهرمز انجام شد. به نظر می‌رسد که با تعیین مسیرهای ورود و خروج این حشره به مزرعه بهتر بتوان از عوامل کنترل‌کننده طبیعی و یا شیمیایی در کنترل آفت در کانون‌های آلودگی بهره گرفت.

روش بررسی

موقعیت جغرافیایی و تهیه نقشه نمونه‌برداری: به منظور


انجام این پژوهش یک مزرعه خیار به ابعاد یک هکتار در



شکل ۱- نقاط نمونه‌برداری در مزرعه

Fig. 1. Sampling points in the field

و آن‌ها را می‌توان جدا از هم فرض کرد (Goovaets, 1997). از پارامترهای مدل انتخاب شده برای واریوگرام می‌توان جهت تخمین مقدار بهینه خصوصیت بر اساس داده‌های جمع‌آوری شده استفاده نمود. چنین تخمین بهینه‌ای را می‌توان توسط تخمین‌گرهای آماری، که اصطلاحاً کریجینگ نامیده می‌شود انجام داد (Kriging and Magri, 1982).



شکل ۲- واریوگرام عمومی نشان دهنده‌ی دامنه وابستگی مکانی، اثر ناگت (C_0)، مرتبط بودن تغییر پذیری با وابستگی مکانی (C) و آستانه (C_0+C)

Fig. 2. Generalized semivariogram showing the range of spatial dependence, nugget effect (C_0) variability associated with spatial dependence (C); and sill ($C+C_0$)

کریجینگ^۸: اصولاً کریجینگ یک نام تعمیم یافته برای کلیه روش‌های آماری تخمین و برآورد متغیرهای مکانی بوده که در این روش‌ها مقادیر برآوردی از مجموع حاصل ضرب یک ضریب وزنی^۹ در مقادیر نقاط مشاهده‌ای به دست می‌آید

واریوگرام^۱: واریوگرام نمودار واریانس بر مبنای بین نمونه‌ها است، که ساختار ارتباط مکانی بین نمونه‌ها را نشان می‌دهد. برای محاسبه و تعیین واریوگرام تجربی، در قدم اول مجذور اختلاف یک ویژگی معین در دو نقطه با فاصله مشخص h محاسبه می‌شود و سپس میانگین این مجذور اختلاف‌ها محاسبه شده و مدلی تجربی بر آن برازش می‌شود. میانگین حاصل مجذور اختلاف کمیت مورد نظر در تمام نقاط با فاصله h از هم می‌باشد که واریوگرام (h) نامیده می‌شود و از رابطه ۱ به دست می‌آید (Habashi et al., 2007).

$$\hat{Y}(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [z(X_i) - z(X_i + h)]^2 \quad (1)$$

(h) مقدار واریوگرام برای تعداد N جفت نمونه است که با فاصله h از یکدیگر جدا شده‌اند، و $z(x_i)$ و $z(x_i + h)$ نیز مقادیر متغیر ناحیه‌ای x در نقاط i و $i+h$ هستند. با افزایش فاصله h ، مقدار واریوگرام نیز به تدریج تا فاصله معینی زیاد شده و از آن به بعد به حد ثابتی می‌رسد که به آن حد آستانه^۷ می‌گویند. باید توجه داشت که تنها گروهی از مدل‌های واریوگرام دارای حد آستانه هستند مانند (مدل نمایی، کروی، گوسی) و دسته‌ای دیگر مانند مدل‌های خطی فاقد حد آستانه می‌باشند و این موضوع نشان می‌دهد که با افزایش فاصله h مقدار واریوگرام نیز افزوده شده اما به حد ثابتی نخواهد رسید (Journel and Huijbregts, 1978).

فاصله‌ای که در آن واریوگرام به حد ثابتی می‌رسد در اصطلاح دامنه تاثیر می‌نامند. به عبارت دیگر دامنه تاثیر فاصله‌ای است که در ماورای آن نمونه‌ها بر هم تأثیری نداشته

۸-Kriging
۹-Weighted Coefficient

۱-Variogram
۷-Sill

مطلوبی هم به دست نمی‌آید (Yuxin *et al.*, 2006). زمانی که از تابع فعالیت سیگموئیدی استفاده می‌شود، بهترین دامنه تبدیل داده‌ها بین (۰/۹ و ۰/۱) می‌باشد (Vakil-Baghmisheh and Pavešić, 2003b). برای تبدیل داده‌ها از روش نرمالیزاسیون خطی معادله ۲ استفاده شد:

$$x_n = \frac{x - x_{min}}{x_{max} - x_{min}} \times (r_{max} - r_{min}) + r_{min} \quad (2)$$

در اینجا X داده‌ی خام اولیه، X_n داده‌ی نرمالیزه شده، x_{max} و x_{min} به ترتیب مقادیر بیشینه و کمینه داده‌های اولیه، و r_{max} و r_{min} هم به ترتیب حد بالایی و پایینی دامنه تغییرات داده‌های تبدیل شده است.

شبکه عصبی پرسپترون چند لایه: بر اساس قضیه تقریب عمومی، شبکه عصبی با یک لایه مخفی و با تعداد کافی نورون در آن لایه قادر به تقریب هر تابع پیوسته دلخواه است (Gutierrez *et al.*, 2008)، بنابراین یک لایه مخفی برای شبکه عصبی انتخاب شد. شبکه MLP با دریافت بردار ورودی X^q ، بردار خروجی Z^q برای هر q (q=1,Q) تولید خواهد کرد. هدف اتخاذ پارامترهای صحیح شبکه، به منظور دستیابی به خروجی واقعی Z^q که تا حد ممکن نزدیک به خروجی مطلوب d^q متناظر با خود می‌باشد. برای آموزش شبکه از الگوریتم پس انتشار^{۱۱} استفاده شد.

در این الگوریتم خطای خروجی شبکه برآورد و به عقب (به داخل سیستم) انتشار یافته و بر این اساس وزن‌های انتخاب شده در مدل اصلاح می‌گردد. این فرایند مربوط به اصلاح وزن‌ها در تمام عناصر سیستم ادامه می‌یابد تا بهترین وزن‌ها که صحیح‌ترین خروجی را برای سیستم ایجاد می‌کند، شناسایی و انتخاب شوند. در حقیقت در این روش با تصحیح مرتب خطا وزن‌های مناسب به دست می‌آید. مفهوم حالتی که مناسب‌ترین وزن‌ها به دست آمده است، این است که مدل آموزش کافی دیده است و بنابراین وزن‌های مربوط تثبیت شده و در مورد داده‌های ورودی جدید که در قالب داده‌های مربوط به کارایی مدل است اعمال می‌گردد. در این حالت با

به این صورت که هرچه متغیر به مبدا (منبع کلنی) نزدیک‌تر باشد وزن آن بیشتر و هرچه فاصله نقاط دورتر وزن آن کمتر خواهد بود (Hassani-pak, 2007).

شبکه عصبی مصنوعی: شبکه عصبی مصنوعی دارای ساختاری شبیه سیستم عصبی زیست‌شناسی مغز انسان است (Torrecilla *et al.*, 2004). امروزه شبکه‌های عصبی در بسیاری از زمینه‌ها از جمله طبقه‌بندی، تشخیص الگو، پیش‌بینی و مدل‌سازی فرآیندها در علوم مختلف به کار گرفته می‌شوند. مزیت روش شبکه عصبی یادگیری مستقیم از روی داده‌ها، بدون نیاز به برآورد مشخصات آماری آن‌ها است (Vakil-Baghmisheh and Pavešić, 2003a). شبکه عصبی بدون در نظر گرفتن هیچ فرضیه اولیه و همچنین دانش قبلی از روابط بین پارامترهای مورد مطالعه، قادر به پیدا کردن رابطه بین مجموعه‌ای از ورودی‌ها و خروجی‌ها برای پیش‌بینی هر خروجی متناظر با ورودی دلخواه می‌باشد (Torrecilla *et al.*, 2005; Kaul *et al.*, 2004). ویژگی دیگر شبکه عصبی، تحمل پذیری در مقابل خطا می‌باشد (Azadeh *et al.*, 2006). این مزایا دلایل به‌کارگیری شبکه عصبی در پیش‌بینی تراکم آفت را برای ما روشن می‌سازد.

پیش‌پردازش داده‌ها: در ابتدا داده‌ها به‌طور تصادفی به دو دسته مجموعه آموزش با ۷۰ عضو (۷۰ درصد کل داده‌ها) و مجموع آزمایش با ۳۰ عضو (۳۰ درصد کل داده‌ها) تقسیم‌بندی شد. البته اگر این تقسیم‌بندی منجر به نتایج مطلوب نشود، می‌توان این مرحله را مجدداً تکرار کرد (Zhang and fuh, 1998). قبل از به‌کارگیری 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^{۱۰} 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

۱۱ - Back-propagation

۱۰ - Sigmoid transfer function

آمد. همچنین مقدار بهینه تعداد تکرارها برای یادگیری شبکه عصبی در تشخیص پراکنندگی کنه تارتن دولکه‌ای هم ۱۰۰۰۰ مشخص شد.

تجزیه و تحلیل آماری: تست نرمالیتة 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 باکس نرمال شدند. تجزیه داده‌ها برای روش زمین‌آمار با نرم‌افزار GS⁺ نسخه ۵.۱.۱ صورت گرفت. کد کامپیوتری شبکه عصبی و الگوریتم پس‌انتشار خطا در محیط نرم افزار Matlab نسخه ۱/۸ تهیه شد.

نتیجه و بحث

نتایج برازش داده‌ها در روش زمین‌آمار مطابق جدول ۱ نشان داد که به صورت کلی از مجموع چهار مرحله نمونه برداری، سه مورد با مدل کروی و یک مورد با مدل نمایی تطابق داشتند که بر اساس این نتیجه با اطمینان می‌توان استنباط نمود که پراکنندگی کنه تارتن دولکه‌ای به صورت تجمع‌ی است. با توجه به نتایج، ضریب تبیین در تمامی موارد بالای ۰/۵۰ است و درجه وابستگی مکانی در همه موارد، بیش از نصف آستانه واریوگرام و بین ۰/۶۰ و ۰/۵۰ بود که مقدار درجه وابستگی مکانی نامناسبی است. این موضوع بیان کننده این حقیقت است که تنها ۰/۶۰ درصد از واریانس بین داده‌ها دارای ساختار مکانی هستند و نمی‌توان به این نتایج اطمینان کافی داشت.

در شبکه عصبی مصنوعی برای اطمینان از یادگیری شبکه عصبی آموزش دیده برای پیش‌بینی الگوی پراکنش کنه تارتن دولکه‌ای، 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 - اسمیرنوف استفاده شد. مقادیر P

مقایسه نتایج مدل با مقادیر مشاهده شده، در مورد کارایی مدل قضاوت می‌شود (Heykin, 1999). مراحل آموزش به کمک این الگوریتم عبارتند از: (الف) - اختصاص ماتریس وزن تصادفی به هریک از اتصالات (ب) - انتخاب بردار ورودی و خروجی متناسب با آن (پ) - محاسبه خروجی نرون در هر لایه و در نتیجه محاسبه خروجی نرون‌ها در لایه خروجی (ت) - بهنگام سازی وزن‌ها به روش انتشار خطای شبکه به لایه‌های قبل که خطای یاد شده ناشی از اختلاف بین خروجی واقعی و خروجی محاسبه شده است. (ث) - ارزیابی عملکرد شبکه آموزش دیده به کمک برخی شاخص‌های تعریف شده مانند جذر میانگین مربعات خطا و سرانجام برگشت به قسمت پ یا پایان آموزش (Lee et al., 2002). برای طراحی شبکه عصبی MLP جهت تعیین رابطه بین تراکم کنه تارتن دو لکه‌ای^{۱۲} (Td) و مختصات مکانی (X,Y) در ابتدا نیاز به تعیین پارامترهای بهینه شبکه عصبی می‌باشد. در رابطه (Td) $(X,Y)=f$ تابع f شبکه عصبی MLP است.

تنظیم پارامترهای شبکه: لایه ورودی شامل سه نرون می‌باشد زیرا ورودی‌های شبکه شامل عامل بایاس و مختصات مکانی کنه تارتن دولکه‌ای می‌باشد. تعیین توپولوژی بهینه، تعداد نرون‌ها در لایه مخفی شبکه از طریق آزمون سعی و خطا به دست آمد. اگر تعداد نرون‌ها در لایه مخفی کافی نباشد، شبکه قادر به یادگیری خوب نخواهد شد. ولی در تعداد بسیار زیاد آن هم مسئله بیش برازشی^{۱۳} پیش خواهد آمد که این منجر به تضعیف تعمیم‌پذیری شبکه می‌شود (Wang and Elhag, 2007). در طول آزمون آهنگ یادگیری (η)، عامل مومنتوم (α)، و تعداد تکرارها ثابت در نظر گرفته شد. این فرآیند برای تعداد نرون‌های لایه مخفی ۴ تا ۱۳ انجام شد. نهایتاً بهترین نتیجه در نرون ۵ به دست آمد. مقدار آهنگ یادگیری و عامل مومنتوم هم بر اساس سعی و خطا انتخاب شد که مقدار مطلوب آن‌ها به ترتیب ۰/۲۴ و ۰/۷۱ به دست

۱۲- Two-spotted spider mite density

۱۳-Over-fitting

وجود $p > 0.89$ در مورد توزیع آماری بین مقادیر پیش‌بینی شده و مقادیر واقعی تراکم کنه تارتن دولکه‌ای در سطح مزرعه، نشان از دقت بالا و نیز قابلیت شبکه عصبی مصنوعی است.

محاسبه شده برای هر مورد در جدول ۲ نشان داده شده است. نتایج نشان می‌دهد که میان میانگین، واریانس و توزیع آماری، مقادیر واقعی و پیش‌بینی شده توسط شبکه عصبی اختلاف معنی داری در سطح ۹۵ درصد وجود ندارد ($p > 0.3$).

جدول ۱- ویژگی زمین‌آماري بوته‌های آلوده به کنه تارتن دولکه‌ای در مزرعه خیار

Table 1. Geostatistical characteristics of the infected plants to *Tetranychus urticae* in the Cucumber farm

Sampling date	Model	Coefficient of Determination	RSS	Degree of spatial dependence	Range of spatial dependence	Nugget
16/03/2016	Exponential	0.425	0.051	0.641	840.33	0.0745
23/03/2016	Spherical	0.543	0.042	0.547	331.19	0.0441
30/03/2016	Spherical	0.553	0.040	0.652	309.9	0.0466
06/04/2016	Spherical	0.601	0.072	0.543	427.11	0.0745

جدول ۲- مقایسات آماری مقادیر واقعی و پیش‌بینی تراکم کنه تارتن دو لکه‌ای توسط شبکه عصبی MLP

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

Sampling date	Utilization phase	Comparisons	Comparisons	Comparisons
		of means	of variance	of distribution
16/03/2016	Training	0.868	0783	0.74
	Test	0.996	0.887	0.56
23/03/2016	Training	0.681	0.343	0.71
	Test	0.645	0.543	0.63
30/03/2016	Training	0.734	0.841	0.81
	Test	0.578	0.456	0.71
06/04/2016	Training	0.520	0.785	0.89
	Test	0.433	0.578	0.72

مرتج به وسیله شبکه عصبی مصنوعی انجام شد، مشخص شد که شبکه عصبی MLP، LVQ و خطی به خوبی می‌توانند الگوهای توزیع حشرات را تشخیص دهند. اما در بین شبکه‌های مذکور شبکه‌های MLP دارای قوی‌ترین الگوریتم در تشخیص الگوها بود (Zhang et al., 2008) و همچنین نتایج پژوهش یونگ و همکاران (Young et al., 2000) بیانگر کارایی بالای شبکه عصبی مصنوعی MLP در پیش‌بینی پویایی جمعیت مگس گالزا (*Thecodiplosis* (Diptera: Cecidomyiida) japonensis در جنگل‌های سوزنی‌برگ آمریکا بود. از طرفی شعبانی نژاد و همکاران (Shabani nejad et al., 2017) به منظور پیش‌بینی الگوی پراکنش کنه تارتن دولکه‌ای از شبکه عصبی مصنوعی ترکیب شده با الگوریتم ژنتیک استفاده کردند که نتایج بیانگر کارایی بالای این روش در تخمین پراکنندگی بود.

ضرایب تبیین، رابطه خطی رگرسیونی و معنی داری آن، بین مقادیر واقعی هر نمونه برداری در مقابل مقادیر پیش‌بینی شده توسط شبکه عصبی در جدول ۳ نشان داده شده است. نتایج بیانگر قدرت تعمیم پذیری بیشتر شبکه عصبی در تخمین تراکم کنه تارتن دو لکه‌ای در مزرعه است. بنابراین از خروجی این روش برای رسم نقشه‌های تراکم استفاده شد. برای ارزیابی کارایی این دو روش از ضریب تبیین R^2 و مجموع مربعات باقیمانده^{۱۴} استفاده شد که این مقادیر به ترتیب برای روش کریجینگ (۰/۶۰۱ و ۰/۰۷۲) و برای شبکه عصبی (۰/۸۹۱ و ۰/۱۴) به دست آمد که این نتایج حاکی از دقت بیشتر شبکه عصبی در تخمین تراکم این آفت بود. در پژوهشی که به منظور تعیین الگوهای پراکنش حشرات در یک

^{۱۴}-Residual sums of squares

نتایج به دست آمده از پژوهش‌های فوق با نتایج حاصل از این پژوهش هماهنگی داشت.

نقشه‌های توزیع مکانی کنه تارتن دولکه‌ای: بر اساس


راهنمای شکل شماره ۳ محدوده سبز تا قرمز آلوده‌ترین منطقه در مزرعه است، که بنا به نمونه‌برداری‌های مختلف در ابتدای کار یک کانون آلودگی در جنوب شرق زمین وجود داشت که با گذشت زمان به سمت مرکز زمین و در نهایت به سمت

شمال شرق زمین گسترش پیدا کرد. بنابراین می‌توان به صورت موضعی نقاط آلوده را سم‌پاشی کرد و از سم‌پاشی سراسری مزرعه و آلودگی بیشتر محیط زیست جلوگیری کرد و از طرف دیگر، می‌توان جهت کارایی بیشتر عوامل کنترل کننده طبیعی مانند کنه شکارگر *Phytoseiulus persimilis* (A.H) را در نقاط آلوده، متمرکز ساخت.


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)

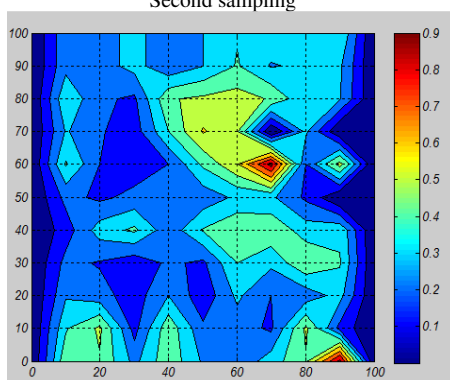
Sampling date	Network Utilization phase	Linear regression relationship	p- value	R ²	RSS
16/03/2016	Training Phase	pv= 0.671 av +0.027	0.04	0.701	2.21
	Test Phase	pv= 0.523 av +0.012	0.05	0.579	0.03
23/03/2016	Training Phase	pv= 0.721 av +0.001	0.04	0.711	2.45
	Test Phase	pv= 0.695 av +0.195	0.05	0.699	5.43
30/03/2016	Training Phase	pv= 0.845 av +0.021	0.02	0.875	0.12
	Test Phase	pv= 0.720 av +0.025	0.04	0.731	2.01
06/04/2016	Training Phase	pv= 0.868 av +0.032	0.02	0.891	0.14
	Test Phase	pv= 0.703 av +0.015	0.03	0.711	0.01



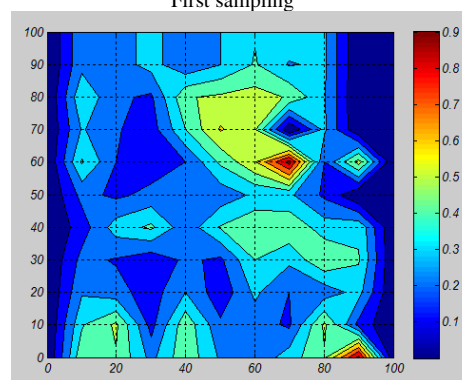
نمونه‌برداری دوم
Second sampling



نمونه‌برداری اول
First sampling



نمونه‌برداری چهارم
Fourth Sampling



نمونه‌برداری سوم
Third Sampling

شکل ۳- پراکنش مکانی کنه تارتن دولکه‌ای در مراحل مختلف نمونه‌برداری توسط شبکه عصبی مصنوعی

Fig.3. Distribution of *Tetranychus urticae* in different stages of sampling by Artificial Neural Network

References

- ANONYMOUS, 2011. Agricultural statistics, Department of Planning and Economy, The office of Statistics and Information Technology, Tehran.
- AZADEH, A., S. F. GHADERI and S. SOHRABKHANI, 2006. Forecasting electrical consumption by integration of Neural Network, time series and ANOVA. *Applied Mathematics and Computation*, 186: 1753-1761.
- DE ALVES, M. C., F. M. DA SILVA, J. C. MORAES, E. A. POZZA, M. S. DE OIVIRA, J. C. S. SOUZA and L. S. ALVES, 2011. Geostatistical analysis of the spatial variation of the berry borer and leaf miner in a coffee agroecosystem. *Precision Agriculture*, 12:18–31.
- GOEL, P. K., S. O. PRASHER, R. M. PATEL, J. A. LANDRY, R. B. BBONNELL and A. A. VIAU, 2003. Classification of hyperspectral 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.
- GOOVAETS, P. 1997. *Geostatistics for Natural Resources Evaluation*. 512pp. Oxford University presses. London.
- GORMAN, K., F. HEWITT, L. DENHOLM and G. J. DEVINE, 2001. New developments in insecticide resistance in the glasshouse whitefly (*Trialeurodes vaporariorum*) and the two-spotted spider mite (*Tetranychus urticae*) in the UK. *Pest Management Science*, 58: 123-130.
- GRESSIE, N. 1993. *Statistics for spatial data*. 430PP. John Wiley and Sons, New York.
- GUTIERREZ, P. A., F. LOPEZ-GRANADOS, J. M. PENABARRAGAN, M. JURADIO-EXPOSITO, M. T. GOMEZ-CASERO and C. HERVAS-MARTINEZ, 2008. Mapping sunflower yield as affected by *Ridolfia segetum* patches and elevation by applying evolutionary product unit neural networks to remote sensed data. *Computers and electronics in agriculture*, 60: 122-132.
- HABASHI, H., M. HOSSEINI, J. MOHAMMADI and R. RAHMANI, 2007. Geostatistic applied in forest soil studing process. *Journal of Agricultural Science and natural Resources*, 14: 1-10 (in Persian with English summary).
- HASSANI-PAK, A. A. 2007. *Geostatistics*. 314pp. University of Tehran Press. Tehran, Iran. (In Persian).
- HEYKIN, S. 1999. *Neural Networks A Comprehensive Foundation*, Second Edition. 14-29.
- IRMAK, A., J. W. JONES, W. D. BATCHELOR, S. IRMAK, K. J. BOOTE and J. PAZ, 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.
- ISMAN, M. 1999. Pesticides based on plant essential oils. *Pesticide Outlook*, 5: 68 – 72.
- JOURNEL, A. G. and C. J. HUIJBREGTS, 1978. *Mining Geostatistics*. 599pp. Academic press. USA.
- KATHRINE, A. R. 2001. *Geostatistic using SAS software*. Own analyticinc. 360 PP. Oxford University Press. Londen.
- KAUL, M., R. L. HILL and C. WALTHALL, 2005. Artificial neural networks for corn and soybean yield prediction. *Agriculture system*, 85: 1-18.
- KRIGE, D. G. and E. J. MAGRI, 1982. Studies of the effects of outliers and data transformation on variogram estimates for a base metal and a gold ore body. *Mathematical Geology*, 14: 557-567.
- LATIFIAN, M. and E. SOLEYMANNEJADIAN, 2009. Study of the Lesser moth *Batrachedra amydraula* (Lep.: Batrachedridae) distribution based on geostatistical models in Khuzestan province. *Journal of Entomological Research- Iran*, 1: 43-55 (in Persian with English summary).
- LEE, D. S., C. O. JOEN, J. M. PARK and K. S. CHANG, 2002. Hybrid neural network modeling of a full-scale industrial wastewater treatment plant. *Biotechnology and Bioengineering*, 78: 670–682.
- LIEBHOLD, A. M., X. ZHANG, M. E. HOHN, J. S., ELKINTON, M. TICEHURST, C. L. BENZON and R. W. CAMPBELL, 1991. Geostatistical analysis of Gypsy moth (Lepidoptera: Lymantridae) egg mass population. *Environmental Entomology*, 20: 1407-1417.
- MAKARIAN, H., M. H. RASHED, M. BANNAYAN and M. NASSIRI, 2007. Soil seed bank and seedling

- populations of *Hordeum murinum* and *Cardaria draba* in saffron fields. *Agriculture Ecosystems and Environment*, 120: 307- 312.
- NARIO, L. S., J. OLIVER-VEREL, E. E. STASHENKO, 2010. Repellent activity of essential oils:A review. *Bioresource Technology*, 101: 372-378.
- RIBES-DASI, M., J. AIMACELLAS, J. SIO, R. TORIA, S. PLANAS and J. AVILLA, 2005. The use of Geostatistics and GIS to optimize pest control practices in precision farming systems. *Information and Technology for Sustainable Fruit and Vegetable Production*, 10: 583-590.
- SCIARRETTA, A., P. TREMATERRA and J. BAUMGARTNER, 2001. Geostatistical analysis of *Cydia funebrana* (Lepidoptera: Tortricidae) pheromone trap catches at two spatial scales. *American Entomologist* 47: 174-184.
- SHABANI NEJAD, A. R. and B. TAFAGHODINIA, 2017. 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).
- SHABANI NEJAD, A. R., B. TAFAGHODINIA and N. ZANDI SOHANI, 2017. 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.
- SHAFIEENASAB, B., J. SHAKARAMI, A. MOHISENI, and H. JAFARI, 2015. Geostatistical characteristics of the spatial distribution of the infestation pods by the pod borer, *Heliothis virescens* Huf. (Lep.: Noctuidae) in rain-fed chickpea (*Cicer arietinum*L.) fields in Delfan (Lorestan province). *Plant Pests Research*, 5: 49-59 (in Persian with English summary).
- STORY, M. and R. G. CONGALTON, 1994. Accuracy assessment: A user's perspective:L.K. Fenestermaleer. *Remote sensing thematic assessment. American society for photogrammetry and remote sensing*, 10: 257-259.
- TORRECILLA, J. S., L. OTERO and P. D. SANZ, 2004. A neural network approach for thermal/pressure food processing. *Food Engineer*, 62: 89-95.
- VAKIL-BAGHMISHEH, M. T. and N. PAVEŠIĆ, 2003. A Fast simplified fuzzy ARTMAP network. *Neural Processing Letters*, 17: 273-301.
- VAKIL-BAGHMISHEH, M. T. and N. PAVEŠIĆ, 2003. Premature clustering phenomenon and new training algorithms for LVQ. *Pattern recognition*, 36: 1901-1921.
- WANG, Y. M. and T. M. S. ELHAG, 2007. A comparison of neural network, evidential reasoning and multiple regression analysis in modeling bridge risks. *Expert Systems with Applications*, 32: 336-348.
- WRIGHT, R. J., T. A. DEVRIES, L. J. YOUNG, K. J. JARVI and R. C. SEYMOUR, 2002. Geostatistical analysis of small-scale distribution of European corn borer (Lepidoptera: Crambidae) larvae and damage in whorl stage corn. *Environmental Entomology*, 31: 160-167.
- YOUNG, P., K. JA-MYUNG, L. BUOM-YOUNG, YEONG-JIN. and K. YOOSHIN, 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 and C. R. PIERRE, 2006. Identifying important factors influencing corn yield and grain quality variability using artificial neural networks. *Precision Agriculture*, 7: 117-135.
- ZHANG, W. J., X. Q. ZHONG and G. H. LIU, 2008. Recognizing spatial distribution patterns of grassland insects: neural network approaches. *Stochastic Environmental. Research and Risk Assessment*, 22:207-216.
- ZHANG, Y. F. and J. Y. H. FUH, 1998. A neural network approach for early cost estimation of packaging products. *Computers & Industrial Engineering*, 34: 433-50.
- ZHAO, J., F. Q. ZHENG, Y. J. WANG, B. H. YE, M. H. Y. ZHAOXIN and L. U. HAO, 2011. Geostatistical Analysis of Spatial Patterns of *Bemisia tabaci* (Homoptera: Aleyrodidae) Adults in Tobacco Field. 6th IEEE Conference on Industrial Electronics and Applications. 2394 – 2398.