



مقاله پژوهشی

مقایسه پراکنش فضایی کرم میوه گوجه‌فرنگی، *Helicoverpa armigera*، با روش‌های زمین‌آمار و شبکه فازی-عصبیروناک محمدی^۱، عباسعلی زمانی^{۱*}، حسنعلی واحدی^۳، حمیدرضا پوریان^۴، بهرام تفقیدی نیا^۵

۱، ۲، ۳، ۴- دانشجوی دکتری، دانشیار، دانشیار، استادیار، گروه گیاه‌پزشکی، دانشکده کشاورزی، دانشگاه رازی، کرمانشاه، ایران؛

۵- دانشیار، گروه گیاه‌پزشکی و کشاورزی پایدار، سازمان پژوهش‌های علمی و صنعتی ایران، تهران، ایران

(تاریخ دریافت: اسفند ۱۴۰۲؛ تاریخ پذیرش: تیر ۱۴۰۳)

چکیده

با وجود روش‌های آماری قوی و پیدایش شبکه‌های فازی-عصبی، مدل‌های پیش‌بینی کننده پراکنش موجودات به‌سرعت در علم اکولوژی توسعه پیدا کرده است. با توجه به دشواری نمونه‌برداری، معمولاً در این گونه مطالعات تعداد نمونه کافی وجود ندارد. لذا در این پژوهش به مقایسه روش زمین‌آمار و شبکه‌ی فازی-عصبی جهت تخمین پراکنندگی کرم میوه گوجه‌فرنگی، *Helicoverpa armigera* (Hubner)(Lep., Noctuidae) در مزرعه گوجه‌فرنگی شهر کرمانشاه پرداخته شد. بدین منظور، مختصات طول و عرض جغرافیایی نقاط نمونه‌برداری در سطح مزرعه مشخص و به‌عنوان 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 فازی-عصبی مصنوعی، از تابع فعال سازی سیگموئیدی استفاده شد. مقایسه نتایج زمین‌آمار و شبکه فازی - عصبی، بیانگر توانایی بالای شبکه فازی - عصبی در مقایسه با روش زمین‌آمار بود، به‌طوری که ضریب تبیین برای شبکه فازی - عصبی و زمین‌آمار به‌ترتیب ۰/۹ و ۰/۶ به‌دست آمد. در مجموع می‌توان نتیجه گرفت که روش شبکه فازی-عصبی با تلفیق دو عامل طول و عرض جغرافیایی و تراکم جمعیت آفت، قادر به پیش‌بینی تراکم کرم میوه گوجه‌فرنگی با دقت بسیار مناسب است.

واژه‌های کلیدی: شبکه فازی-عصبی (ANFIS)، کریجینگ، *Helicoverpa armigera*

Comparison of Spatial distribution of tomato fruit borer, *Helicoverpa armigera* using geostatistics and fuzzy-neural network methods

R. MOHAMMADI¹, A.A. ZAMANI^{1*}, H.A. VAHEDI¹, H.R. POURIAN¹, B. TAFAGHODINIA²

1, 2, 3, 4. Ph.D. candidate, Associate Professor, Associate Professor, Assistant Professor, Department of Plant Production, College of Agriculture, Razi University, Kermanshah, Iran; 2: Associate Professor, Department of Plant Protection and Sustainable Agriculture, Iranian Research Organization for Science and Technology, Tehran, Iran

Abstract

Despite the use of robust statistical methods and fuzzy-neural networks, models that predict the distribution of organisms have seen rapid development in the field of ecology. However, due to the challenges associated with sampling, these studies often lack sufficient samples. In this research, we compared geostatistics and fuzzy-neural networks to estimate the distribution of the tomato fruit worm in a tomato farm in Kermanshah city. For this purpose, the length and width coordinates of the sampling points at the field level were identified and used as inputs for both methods. The output of each method was the count of this pest at those locations. In the geostatistics approach, we employed the normal Kriging method, while in the fuzzy-artificial neural network approach, we used the sigmoid activation function. A comparison of the results from geostatistics and the fuzzy-neural network demonstrated the superior performance of the fuzzy-neural network. The coefficient of determination for the fuzzy-neural network and geostatistics was 0.9 and 0.6, respectively. In conclusion, the fuzzy-neural network method, by integrating latitude and longitude factors, was able to predict the density of the tomato fruit worm with high accuracy.

Keywords: Fuzzy-Neural Network (ANFIS), Kriging, *Helicoverpa armigera*

✉ azamani@razi.ac.ir

© 2024, The Author(s). Published by Iranian Research Institute of Plant Protection (IRIPP). This is an open-access article distributed under the terms of the Creative Commons Attribution License (<http://creativecommons.org/licenses/by/4.0>)

مقدمه

(Tafaghodinia, 2017). کریجینگ به‌طور کلی، یک روش زمین آماری است که طی آن می‌توان مقدار یک کمیت در نقطه‌ای نامعلوم را، با استفاده از مقدار همان کمیت در نقاط دیگری با مختصات معلوم به‌دست آورد (Gonadishi, 2008).

استفاده از روش‌های مختلف زمین آمار در تجزیه و تحلیل الگوهای فضایی جمعیت آفات در سال‌های اخیر اهمیت فزاینده‌ای پیدا کرده است. پراکنندگی فضایی *H. armigera* روی گیاه نخود، با استفاده از روش‌های زمین آمار مورد مطالعه قرار گرفت (Seethalam et al., 2021). همچنین مطالعه‌ای با هدف تحلیل مکانی-زمانی جمعیت *H. armigera* در منطقه جنوب شرقی دریای خزر با استفاده از سیستم اطلاعات جغرافیایی (GIS) انجام شد. نتایج تحلیل فضایی نشان داد که این گونه، الگوی پراکنش تجمعی را در طول فصل رشد پنبه دارد (Jokar, 2023).

یکی از نارسایی‌های روش‌های متداول در آمار کلاسیک، عدم توجه به سودمندی اطلاعات مربوط به موقعیت جغرافیایی مشاهدات است و متعاقب آن در تجزیه و تحلیل چنین داده‌هایی، هیچ‌گونه ارتباط ریاضی بین تغییرات مکانی نمونه‌ها به‌عنوان تابعی از فاصله بین آن‌ها برقرار نمی‌شود (Makarjian et al., 2007). از طرفی مطالعات متعددی نشان داده است که شبکه‌های عصبی، توانایی بالایی در تشخیص الگوهای توزیع مکانی جمعیت‌های اکولوژیک دارند (Irmak et al., 2006). شبکه‌های عصبی مصنوعی و سیستم استنتاج فازی مبتنی بر شبکه (ANFIS)، الگوریتم‌های ضروری برای محاسبات نرم (Soft Computing) هستند. شبکه عصبی ANFIS که برای اولین بار توسط جانگ برای شناسایی سیستم و پیش‌بینی سری‌های زمانی پیشنهاد شد، یک سیستم فازی است که با بهره‌برداری از شباهت‌های بین منطق فازی و اشکال خاصی از شبکه‌های عصبی، توسعه یافته است (Jang, 1993). شبکه ANFIS، به‌دلیل توانایی آن در ساختار رابطه غیرخطی بین مجموعه‌ای از پیش‌بینی کننده‌ها و مجموعه‌ای از متغیرهای وابسته، در کشاورزی مورد استفاده قرار گرفته است (Mohammadi et al., 2018). به‌عنوان

کرم میوه‌گوجه‌فرنگی یا کرم غوزه پنبه، *Helicoverpa armigera* (Hubner) (Lep., Noctuidae)، یک آفت جدی در طیف وسیعی از محصولات است که به‌بیش از ۲۰۰ گونه گیاهی حمله می‌کند. امروزه، به‌دلیل افزایش خسارت این آفت روی گوجه‌فرنگی، به نگرانی مهم تولیدکنندگان این محصول در ایران و سایر نقاط دنیا تبدیل شده است (Guo et al., 2020; Singla and Singh, 2020). ترجیح سنبلین مختلف لاروی این آفت به تغذیه از میوه گوجه‌فرنگی، موجب وارد آمدن خسارت‌های جدی و کاهش شدید عملکرد محصول می‌شود (Sousa et al., 2020). معمولاً کشاورزان برای کنترل کرم میوه گوجه‌فرنگی متکی به استفاده مداوم از آفت‌کش‌های شیمیایی هستند (Vivan et al., 2016). اما تعدد کاربرد آفت‌کش‌های شیمیایی برای کنترل این آفت، علاوه بر ایجاد مقاومت، منجر به از بین بردن عوامل کنترل زیستی، بروز آلودگی‌های زیست محیطی و افزایش هزینه‌های تولید خواهد شد. بنابراین، اتخاذ مدیریت تلفیقی برای این آفت امری ضروری است تا از کاربرد نادرست آفت‌کش‌ها جلوگیری شود (Fite and Tefera, 2022). برای تدوین برنامه‌های مدیریت تلفیقی این آفت، آگاهی از تغییرات جمعیت آن در مزرعه در طی زمان ضروری است (Garzia et al., 2011). تحلیل‌های زمین‌آمار با ارائه درک درستی از پراکنش آفات به‌عنوان روش‌های سازگار با محیط زیست شناخته می‌شوند، زیرا اتخاذ آن‌ها می‌تواند منجر به کاهش استفاده از آفت‌کش‌های شیمیایی شود. به‌همین دلیل، در اجرای مدیریت تلفیقی آفات در سطح منطقه، استفاده از زمین آمار و ابزارهای مرتبط با آن حائز اهمیت است (Milonas et al., 2017; Dionisio et al., 2016). درون‌یابی مکانی، شامل تخمین متغیرهایی مانند تراکم آفت، در نقاط نمونه‌برداری نشده، با استفاده از داده‌های حاصل از نقاط نمونه‌برداری شده است. از روش‌های درون‌یابی مورد استفاده در مطالعات حشره‌شناسی، روش‌های کریجینگ و شبکه عصبی مصنوعی را می‌توان نام برد (Shabani Nejad and

دانشگاه رازی با مختصات جغرافیایی (38S, 693942E, 3800263N) انتخاب و نشاءهای گوجه‌فرنگی در آن کشت شد. مزرعه به ۳۲ ردیف کشت با فاصله ۱۵۰ سانتی‌متر از هم تقسیم و فاصله بین بوته‌ها در هر ردیف کشت ۴۰ سانتی‌متر در نظر گرفته شد. زمین کشت شده به ۹ کرت مجزا تقسیم گردید و برای هر کرت، ۹ ردیف کشت با ۳۵ بوته گوجه‌فرنگی در هر ردیف در نظر گرفته شد. روند تغییرات جمعیت آفت به‌صورت هفتگی و مطابق با الگوی نمونه‌برداری سیستماتیک، از طریق شمارش لاروهای سنین مختلف کرم میوه گوجه‌فرنگی، روی بوته‌های شماره ۵، ۱۳، ۲۱ و ۲۹ از ردیف‌های ۲، ۵ و ۸ بررسی شد.

زمین‌آمار (Geostatistic)

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 هستند. شدت خسارت و تراکم، نمونه‌هایی از متغیرهای مکانی هستند (Katherine, 2001). در روش‌های زمین‌آمار، وجود همبستگی مکانی بین مقادیر یک متغیر، در یک ناحیه را بررسی می‌نماید. وابستگی مکانی بین نمونه‌ها را می‌توان به‌صورت یک مدل ریاضی تحت عنوان ساختار مکانی بررسی نمود (Hassani-pak, 2007). به‌صورت کلی، زمین‌آمار دارای دو بخش اصلی واریوگرام و کریجینگ است (Gressie, 1993).

واریوگرام (Variogram)

واریوگرام نمودار واریانس بر مبنای فاصله 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 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

مثال، مطالعه‌ای با هدف ایجاد سیستمی برای پیش‌بینی سطح خطر تریپس غربی گل با استفاده از شبکه‌های عصبی مصنوعی و سیستم استنتاج عصبی فازی تطبیقی انجام شد. نتایج عددی، عملکرد قابل توجه هر دو مدل را نشان داد که نشان دهنده کارایی آن‌ها برای پیش‌بینی آفات است (Tay et al., 2020). در ایران پژوهشی با هدف مقایسه بین روش‌های زمین‌آمار و شبکه عصبی مصنوعی در تعیین پراکنش مکانی کنه تارتن دو لکه‌ای *Tetranychus urticae* (Koch) (Acari: Tetranychidae) انجام شد و نتایج آن نشان داد که روش شبکه عصبی مصنوعی مناسب‌تر است (Shabani Nejad and Tafaghodinia, 2017). در پژوهشی از هوش محاسباتی برای پیش‌بینی و تخمین آفات غلات استفاده شد که نتایج نشان از دقت بالای این روش‌ها داشت (Mensah Agboka et al., 2024).

اگرچه با توسعه سریع روش‌های زمین‌آمار و تکنیک‌های شبکه عصبی در سال‌های اخیر، تحقیقات متعددی برای بهبود دقت در بررسی پراکنش جمعیت آفات انجام شده است، اما تاکنون، پژوهشی به‌صورت مدون به مقایسه عملکرد روش زمین‌آمار با سیستم استنتاج عصبی فازی تطبیقی، به‌منظور تخمین پراکنش فضایی *H. armigera* روی محصول گوجه‌فرنگی نپرداخته است. بنابراین، این پژوهش، با هدف مقایسه روش زمین‌آمار با شبکه عصبی ANFIS، برای تعیین نحوه پراکنش جمعیت کرم میوه گوجه‌فرنگی در سطح مزرعه گوجه‌فرنگی انجام شد. بر اساس نتایج این تحقیق می‌توان، اطلاعات کارآمدتر و دقیق‌تر، برای تفسیر پراکنش جمعیت کرم میوه گوجه‌فرنگی ارائه نمود و بر اساس نقشه‌های حاصل از درون‌یابی می‌توان، آفت‌کش‌های شیمیایی را به‌صورت هدفمند و دقیق‌تر، برای مدیریت موثر این آفت در سطح مزرعه، روی گیاه گوجه‌فرنگی استفاده نمود.

مواد و روش‌ها

موقعیت جغرافیایی و شیوه نمونه‌برداری

برای انجام این پژوهش، قطعه زمینی به مساحت تقریبی ۲۰۰۰ متر مربع واقع در مزرعه تحقیقاتی پردیس کشاورزی

که در آن X (و یا Y) ورودی‌های گره i ام بوده و A_i (و یا B_{i-2}) برچسب‌های زبانی (مانند کوچک یا بزرگ) مربوط به این گروه هستند. $O_{i,i}$ درجه عضویت فازی $A=(A_1, A_2, B_1, B_2)$ می‌باشد و درجه‌ای را مشخص می‌کند که متغیر ورودی X (و یا Y) با کمیت A مطابقت دارد. معمولاً تابع عضویت A و B توسط توابع زنگوله‌ای بیان می‌شود.

لایه دوم (ورودی تابع عضویت): این لایه از گره‌ای با عنوان II تشکیل شده که سیگنال‌های ورودی را درهم ضرب نموده و به خروجی ارسال می‌کند. به‌عنوان مثال:

$$O_{2,i} = w_i = \mu_{A_i}(x) \mu_{B_i}(y) \quad i = 1, 2$$

به‌عبارت دیگر در این لایه عملگر (و) به کار برده می‌شود.

لایه سوم (قانون): در این لایه گره‌ها دارای برچسب N نسبت i امین قانون قوه اشتعال را به مجموع قوه اشتعال‌های همه قوانین محاسبه می‌کند.

$$O_{3,i} = \bar{w}_i = \frac{w_i}{w_1 + w_2}$$

خروجی این لایه قوه اشتعال نرمال شده نامیده می‌شود.

لایه چهارم (خروجی تابع عضویت): گره‌های این لایه با گره‌های توابع مطابقت دارند. $O_{4,i} = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i)$ که در آن \bar{w}_i خروجی لایه سوم بوده و $\{p_i, q_i, r_i\}$ مجموعه پارامترها هستند. پارامترهای این لایه به‌عنوان مجموعه پارامترهای بخش تالی مدل فازی می‌باشند.

لایه پنجم (خروجی): این لایه با گره ثابت با نام Σ ، خروجی کلی را با جمع کردن همه سیگنال‌های ورودی محاسبه می‌کند. بنابراین در این لایه فرآیند غیر فازی‌سازی، نتایج هر قانون فازی را به خروجی غیر فازی تبدیل می‌کند

$$O_{5,i} = \sum_{i=1} \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (\text{Afrous et al., 2007})$$

انتخاب تابع عضویت

برای در نظر گرفتن درجه عضویت، از توابع عضویت استفاده می‌شود که شامل توابع عضویت مثلثی، ذورنقه‌ای، گوسی، گوسی دو طرفه و سیگموئیدی است (Shrestha et al., 2007). با توجه به عدم وجود پیش فرض برای انتخاب مناسب این توابع، تمامی این توابع بررسی شدند. بر اساس جدول (1)، تابع سیگموئیدی با کمترین مربعات خطا به‌عنوان تابع عضویت انتخاب شد.

فاصله مشخصی از هم است که واریوگرام نامیده می‌شود (Habashi et al, 2007).

کریجینگ (KRIGING)

اصولاً کریجینگ یک نام تعمیم یافته برای کلیه روش‌های آماری تخمین و برآورد متغیرهای مکانی است که در این روش‌ها، مقادیر برآوردی از مجموع حاصل ضرب یک ضریب وزنی (Weighted Coefficient) در مقادیر نقاط مشاهده‌ای به دست می‌آید، به این صورت که هرچه متغیر به مبدا نزدیک‌تر باشد، وزن آن بیشتر و هرچه فاصله نقاط دورتر، وزن آن کمتر خواهد بود (Hassani-pak, 2007).

سیستم استنتاج تطبیقی فازی - عصبی

سیستم استنتاج تطبیقی فازی-عصبی (ANFIS) اولین بار در سال ۱۹۹۳ توسط ژانگ معرفی شد (Jang, 1993). این سیستم ابزاری جهانی جهت تخمین توابع پیوسته حقیقی در دامنه‌ای محدود می‌باشد که به‌ازای هر درجه‌ای از صحت قابل استفاده است (Jang, et al., 1997).

شبکه فازی-عصبی از نظر کارایی معادل سیستم استنتاج فازی می‌باشد. در ادامه الگوریتم‌های آموزش مختلط که از ترکیب روش گرادین کاهشی و حداقل مربعات استفاده می‌کند، معرفی شده و چگونگی تطبیق و آموزش سریع سیستم استنتاج فازی معادل با این الگوریتم بحث شده است.

اگر یک سیستم استنتاج فازی با دو ورودی X و Y و یک خروجی Z باشد. مدل فازی مرتبه اول سونگو با دو قانون فازی If - then می‌تواند به‌صورت زیر بیان شود:

قانون ۱ - اگر X برابر A_1 و Y برابر B_1 باشد آنگاه:

$$z_1 = p_1 x + q_1 y + r$$

قانون ۲ - اگر X برابر A_2 و Y برابر B_2 باشد آنگاه (Amini, et al., 2005):

$$z_2 = p_2 x + q_2 y + r$$

لایه اول (ورودی): هرگاه i از این لایه، مقادیر عضویتی

را که به‌هر یک از مجموعه‌های فازی مناسب تعلق دارند، با استفاده از توابع عضویت تولید می‌کند.

$$\begin{aligned} O_{1,i} &= \mu_{A_i}(x) & \text{for } i = 1, 2 \text{ or} \\ O_{1,i} &= \mu_{B_{i-2}}(y) & \text{for } i = 3, 4 \end{aligned}$$

پیش پردازش 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) تقسیم بندی شد. قبل از به‌کارگیری داده‌های خام اولیه در آموزش شبکه، باید داده‌ها در دامنه مناسبی نرمال‌سازی شوند، زیرا الگوریتم یادگیری، روی داده‌های خام نمی‌تواند عملکرد مناسبی داشته باشد و شبکه در طول فاز آموزش همگرا نخواهد شد و نتایج مطلوبی هم به‌دست نمی‌آید (Yuxin et al, 2006). برای تبدیل داده‌ها، از روش نرمال‌سازی خطی معادله (۱) استفاده شد:

$$X_n = \frac{(X - X_{min})}{(X_{max} - X_{min})} \times (r_{max} - r_{min}) + r_{min} \quad (1)$$

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

تجزیه و تحلیل آماری

تست نرمال‌سازی داده‌های مربوط به نمونه‌برداری به‌کمک نرم‌افزار SPSS 23 و آزمون کولموگروف-اسمیرنوف، بررسی شد. به‌دلیل عدم نرمال بودن آن‌ها، داده‌ها توسط روش Cox-Box نرمال شدند. کد نرم‌افزاری شبکه عصبی فازی، در محیط نرم افزار Matlab نسخه ۸/۱ تهیه شد.

جدول ۱- میانگین مربعات خطا استخراج شده برای هر تابع عضویت

Table 1. Mean squared error extracted for each membership function

Sampling date	MSE for each function			
	Trapezoidal	Gaussian	Triangular	Sigmoidal
2019/07/17	0.1306	0.1342	0.1003	0.00331
2019/07/22	0.1321	0.0921	0.0803	0.00189
2019/07/27	0.1234	0.231	0.0365	0.0031
2019/08/21	0.1410	0.1219	0.0994	0.00221
2019/08/27	0.1360	0.1875	0.0310	0.00412
2019/09/01	0.214	0.1032	0.0413	0.00201
2019/09/06	0.145	0.1130	0.0532	0.00311

نتیجه و بحث

نتایج پرازش داده‌ها در روش زمین آمار نشان داد (جدول ۲) که به‌صورت کلی از مجموع هفت مرحله نمونه‌برداری، پنج مورد با مدل کروی و دو مورد با مدل نمایی تطابق داشتند که بر این اساس می‌توان استنباط نمود که پراکنش جمعیت *H. armigera* در مزرعه به‌صورت تجمعی است. با توجه به نتایج، ضریب تبیین در تمامی موارد بالای ۰/۵ است و درجه وابستگی مکانی در همه موارد بیش از نصف آستانه واریوگرام و بین ۰/۵۰ و ۰/۶۰ بود که مقدار درجه وابستگی مکانی نامناسبی است و نشان از دقت پایین این مدل دارد. این موضوع بیان‌کننده این حقیقت است که تنها ۶۰ درصد از واریانس بین داده‌ها دارای ساختار مکانی هستند و نمی‌توان به این نتایج اطمینان کافی داشت.

به‌منظور بررسی دقت شبکه فازی - عصبی در پراکنش فضایی جمعیت کرم میوه گوجه‌فرنگی نیز از ضرایب تبیین و رابطه خطی رگرسیونی بین مقادیر واقعی در مقابل مقادیر پیش‌بینی شده استفاده شد (جدول ۳). بهترین نتایج بر اساس این دو معیار وقتی به‌دست می‌آید که معادله خطی بین تراکم واقعی و تراکم پیش‌بینی شده این آفت توسط شبکه فازی-عصبی علاوه بر داشتن ضریب تبیین بالا، دارای عرض از مبدا کم و شیب نزدیک به یک باشد. کاملاً واضح است که ضرایب تبیین بین داده‌های واقعی و پیش‌بینی شده بسیار بالا هستند (بیش از ۰/۸). این نتایج نشان می‌دهد که قابلیت تعمیم‌پذیری شبکه عصبی آموزش دیده بسیار بالا است، زیرا فاز آزمایش در مقایسه با فاز آموزش، دارای ضریب تبیین بالاتر و نیز

آفت را در مناطق جنگلی پیش‌بینی نمود (Liebhold et al., 1991). بررسی پراکنش مکانی جمعیت لاروهای *H. armigera* در منطقه Hanamkonda هند با استفاده از روش‌های زمین آمار انجام شد و نتایج حاکی از پراکنش تجمعی این آفت بود (Seethalam et al., 2021). در پژوهشی، به‌منظور پیش‌بینی پراکنش فضایی جمعیت تریس غربی گل، از شبکه فازی-عصبی استفاده شد، نتایج عددی، عملکرد قابل توجه این مدل را نشان داد که نشان دهنده کارایی آن‌ها برای پیش‌بینی جمعیت این آفت است (Tay et al., 2020). همچنین محمدی و همکاران (Mohammadi et al., 2018) نشان دادند که ترکیب روش زمین آمار با شبکه عصبی مصنوعی بهینه شده با الگوریتم ژنتیک، قدرت بالایی در پیش‌بینی الگوی توزیع مکانی جمعیت کفشدوزک هفت نقطه‌ای، *Coccinella septempunctata* (L.) در مزرعه یونجه داشت. نتایج به‌دست آمده از این پژوهش‌ها با نتایج تحقیق حاضر، هماهنگی دارد.

معادله خطی رگرسیونی بین مقادیر واقعی و پیش‌بینی شده از شیب نزدیک‌تر به واحد و عرض از مبدا نزدیک به صفر برخوردار است. بنابراین از خروجی این روش برای ترسیم نقشه پراکنش کرم میوه گوجه‌فرنگی استفاده شد. برای مقایسه کارایی دو روش کریجینگ و شبکه فازی-عصبی در تخمین پراکنش جمعیت *H. armigera* از پارامتر آماری ضریب تبیین استفاده شد. این مقادیر به‌ترتیب برای روش زمین آمار در بیشینه حالت (۰/۷۲) و برای شبکه فازی-عصبی در بیشینه حالت مرحله آموزش (۰/۹۷) و مرحله آزمایش (۰/۹۹) به‌دست آمد که این نتایج حاکی از قدرت تخمین بالای شبکه فازی-عصبی در تخمین پراکنش این آفت است. از مثال‌های موفقیت آمیز 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

جدول ۲- ویژگی‌های زمین آماری بوته‌های آلوده به *Helicoverpa armigera* در مزارع گوجه‌فرنگی


Table 2. Geostatistical characteristics of the infected plants to *Helicoverpa armigera* in the tomato farm

Sampling date	Model	Coefficient of determination	MSE	Degree of spatial dependence	Range of spatial dependence	Nugget
2019/07/17	Spherical	0.711	0.325	0.540	140.11	0.045
2019/07/22	Spherical	0.723	0.170	0.638	126.80	0.032
2019/07/27	Spherical	0.545	0.165	0.511	130.11	0.087
2019/08/21	Spherical	0.703	0.210	0.505	160.07	0.041
2019/08/27	Spherical	0.580	0.189	0.556	180.23	0.083
2019/09/01	Exponential	0.635	0.301	0.523	150.74	0.071
2019/09/06	Exponential	0.689	0.299	0.601	173.63	0.067


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 date	Network utilization phase	Linear regression	Coefficient of determination
2019/07/17	Training Phase	$pv = 0.8979 av + 2.87$	0.984
	Test Phase	$pv = 0.8474 dv + 4.18$	0.97
2019/07/22	Training Phase	$pv = 0.9988 av + 0.2961$	0.9988
	Test Phase	$pv = 0.91 av + 1.54$	0.9701
2019/07/27	Training Phase	$pv = 1.01 av + 0.79$	0.99
	Test Phase	$pv = 1.0089 av + 1.0024$	0.97
2019/08/21	Training Phase	$pv = 1.008 av + 0.0023$	0.9998
	Test Phase	$pv = 0.9656 av + 0.0206$	0.9749
2019/08/27	Training Phase	$pv = 1.02 av + 1.37$	0.9918
	Test Phase	$pv = 1.02 av + 0.037$	0.9824
2019/09/01	Training Phase	$pv = 1.0152 av + 1.150$	0.992
	Test Phase	$pv = 0.9673 av + 0.017$	0.9628
2019/09/06	Training Phase	$pv = 1.0052 av + 0.0031$	0.988
	Test Phase	$pv = 0.9919 av + 0.0097$	0.9738



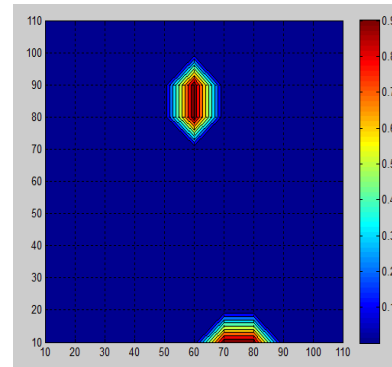
2019.07.17




2019.07.22




2019.07.27



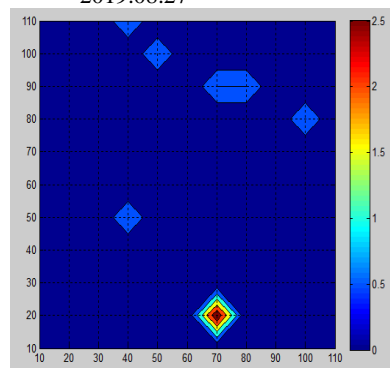
2019.08.21



2019.08.27



2019.09.01



2019.09.06

شکل ۱- نقشه پراکنش *Helicoverpa armigera* توسط مدل شبکه فازی - عصبی

Fig 1. *Helicoverpa armigera* distribution maps by ANFIS model

نقشه‌های پراکنش مکانی آفت

بررسی هفتگی روند تغییرات جمعیت *H. armigera* در طول فصل رشد گیاه گوجه‌فرنگی نشان داد که فعالیت لاروهای این آفت از اواسط تیرماه شروع و تا اواسط شهریورماه ادامه داشت. نقشه پراکنش مکانی کرم میوه گوجه‌فرنگی توسط شبکه فازی-عصبی ترسیم شد (شکل ۱). 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 در این مدل، می‌توان تراکم آفت را در نقطه مورد نظر پیش‌بینی و اقدامات کنترلی لازم را پیاده نمود. در این مطالعه، شبکه عصبی ANFIS توانست با دقت مناسبی الگوی توزیع *H. armigera* را مشخص و نقشه پراکنش این گونه را رسم کند. بر اساس راهنمای شکل (۱)، نواحی قرمز رنگ، آلوده‌ترین نقاط مزرعه هستند. همچنین نقشه‌های حاصل، پراکنش تجمعی این آفت در تاریخ‌های مختلف را نشان می‌دهد. در مدیریت سنتی آفات، تفاوت‌هایی که در مقیاس کوچک در مزارع وجود دارند، نادیده گرفته می‌شود. در مدیریت مکان-ویژه در مزارع، با استفاده از فناوری‌های نوین، جمعیت آفات در نقاط مختلف مزرعه در مقیاس کوچک مورد شناسایی و ارزیابی قرار می‌گیرد و نقشه تراکم جمعیت تهیه می‌شود. در این

نقشه، می‌توان نقاطی که جمعیت آفت بالاتر از حد آستانه اقتصادی است، مشخص نمود و کشاورز می‌تواند فقط در این نقاط، برای کنترل آفت اقدام نماید (Banderi et al., 2011). با توجه به محدودیت‌های روش‌های سنتی که بسیار وقت‌گیر و هزینه‌بر است و اغلب با خطا همراه است، استفاده از روش‌های نوین درون‌یابی و شبکه‌های عصبی مصنوعی، می‌تواند نقش مهمی را در فرآیند مکان‌یابی این نقاط و تسریع در روند برنامه‌ریزی و بهره‌برداری مناسب از اقدامات مدیریتی ایفا نماید. لذا با توجه به درک مناسب از الگوی پراکنش آفات، قدرت تصمیم‌گیری جهت اعمال برنامه‌های مدیریتی افزایش می‌یابد و می‌توان با کاهش هزینه‌ها، اعم از هزینه‌های اقتصادی و زیست محیطی (کاهش سمپاشی و یا محدود کردن سمپاشی در کانون‌های اولیه آلودگی)، اقدامات مناسبی را اعمال نمود. این مطالعه می‌تواند به‌عنوان گامی مؤثر برای تحقیقات آینده جهت کاربرد عملی از این روش‌ها برای بررسی الگوی پراکنش سایر آفات در مزارع به‌کار رود.

سپاسگزاری

این مقاله بخشی از رساله دکتری نگارنده اول است که توسط دانشگاه رازی حمایت مالی شده است.

References

- AMINI, M., AFYUNI, M., FATHIANPOUR, N., KHADEMI, H AND FLUHLER, H. 2005. Continuous soil pollution mapping using fuzzy logic and spatial interpolation. *Geoderma*, 124(11): 223-233. <https://doi.org/10.1016/j.geoderma.2004.05.009>
- AFROUS, A., HOSSEINI, S.M. AND GOUDARZI, SH. (2007) Assessment of the Ordinary Kriging and NeuroFuzzy approaches in interpolation of the groundwater level. *Journal of Groundwater*, 13(2): 978-984. <https://doi.org/10.22034/IWRR.2023.181576>
- AGBOKA, K. M., TONNANG, H. E., ABDEL-RAHMAN, E. M., ODINDI, J., MUTANGA, O., AND NIASSY, S. 2024. Leveraging computational intelligence to identify and map suitable sites for scaling up augmentative biological control of cereals crop pests. *Biological Control*, 105459. doi.org/10.1016/j.biocontrol.2024.105459
- BANDERI, A., GHARINEH, M.H., KARDONI, F., BAHAMIN, S. 2011. The need for accurate agricultural application in sustainable development.

- 1th National Conference on Strategies for Achieving Sustainable Agriculture, May 2627, Ahvaz, Iran. P. 8.
- DIONISIO, L.F.S., LIMA, A.C.S., IZIDÓRIO, R.M., SANTOS, A.V., ORRILLO, H.M., LIMA, G.L. 2016. Monitoramento de insetos e distribuição espacial de *Sitophilus* spp. (Coleoptera: Curculionidae) em unidade de beneficiamento e armazenamento de grãos. Revista Agroambiente Online, doi.org/10.18227/1982-8470ragro.v10i3.3273
- FITE, T., AND TEFERA, T. 2022. The cotton bollworm (*Helicoverpa armigera*) and Azuki bean beetle (*Callosobruchus chinensis*): major chickpea (*Cicer arietinum* L.) production challenges on smallholder farmers in Ethiopia. The Journal of Basic and Applied Zoology, 83(11): 1-12. doi.org/10.1186/s41936-022-00275-w
- GARZIA, T. G., SISCARO, G., BIONDI, A. AND ZAPPALA, L. 2011. Distribution and damage of *Tuta absoluta*, an exotic invasive pest from South America. In: International symposium on management of *Tuta absoluta* (Tomato borer) Proceeding. Agadir, Morocco, November, 16-18.
- GRESSIE, N. 1993. Statistics for spatial data. 430PP. John Wiley and Sons, New York. doi.org/10.1002/9781119115151
- GUO, J., FU, X., ZHAO, S., SHEN, X., WYCKHUYS, K. A. G. AND WU, K. 2020. Long-term shifts in abundance of (migratory) crop-feeding and beneficial insect species in northeastern Asia. Journal of Pest Science, 25(11): 35-37. doi.org/10.1007/s10340-019-01191-9
- HABASHI, H., M. HOSSEINI, J. MOHAMMADI and R. RAHMANI, 2007. Geostatistic applied in forest soil studying process. Journal of Agricultural Science and natural Resources, 14(1): 1-10. [In Persian with English summary].
- HASSANI-PAK, A. A. 2007. Geostatistics. 314pp. University of Tehran Press. Tehran, Iran. (In Persian).
- 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. doi.org/10.13031/2013.22264
- JANG, J.S.R. 1993. ANFIS: adaptive-network-based fuzzy inference system. IEEE T Syst Man Cy, 23(3):665-85. doi.org/10.1109/21.256541
- JOKAR, M. 2023. Spatial Distribution of Cotton Bollworm in Southeastern Shores of the Caspian Sea, Golestan Province, Iran. Current Applied Science and Technology, 23(1): 1-8. [In Persian with English summary]. doi.org/10.55003/cast.2022.01.23.014.
- KATHRINE, A. R. 2001. Geostatistic using SAS software. Own analyticinc. 360 PP. Oxford University Press. London. doi.org/10.1007/978-3-642-03647-7_8
- 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. doi.org/10.1093/ee/20.5.1407
- 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(13): 307-312. doi.org/10.1016/j.agee.2006.10.020
- MERTENS, M. & HUWE B. 2002. Fun-Balance: a fuzzy balance approach for the calculation of nitrate leaching with incorporation of data imprecision. Geoderma, 109(12):269-287. doi.org/10.1016/S0016-7061(02)00179-9
- MOUSAVI, S.F. AMIRI, M.J. 2012. Modelling nitrate concentration of groundwater using adaptive neural based fuzzy inference system. Journal of Soil and water Research 7(11): 73-83. [In Persian with English summary]. doi.org/10.17221/46/2010-SWR.
- MOHAMMADI, R., SHABANI NEJAD, A. AND ALICHI, M. 2018. Application of combined geostatistics with optimized artificial neuralnetwork by genetic algorithm to estimate the distribution of *Coccinella septempunctata* in the alfalfa farm of Bajgah. Journal of Entomological Society of Iran, 38 (1):1-14. [In

- Persian with English summary] doi.org/10.22117/JESI.2018.116187.1154.
- MILONAS, P., GOGOU, C., PAPADOPOULOU, A., FOUNTAS, S., LIAKOS, V., AND PAPADOPOULOS, N. T. 2016. Spatio-temporal distribution of *Helicoverpa armigera* (Hübner)(Lepidoptera: Noctuidae) and *Pectinophora gossypiella* (Saunders)(Lepidoptera: Gelechiidae) in a cotton production area. Neotropical entomology, 45(10): 240-251. doi.org/10.1007/s13744-015-0358-6.
- SINGLA, A., AND SINGH, R. 2020. Estimation of avoidable yield losses in chickpea caused by *Helicoverpa armigera* (Hübner) (Lepidoptera: Noctuidae). Phytoparasitica, 12(9):14-25. doi.org/10.1007/s12600-020-00833-4.
- SOUSA, N., FILHO, M.F., SILVA, P.A., TORRES, J.B. 2020. Determination of an Economic Injury Level for Old World Bollworm (Lepidoptera: Noctuidae) in Processing Tomato in Brazil. Journal of Economic Entomology, 113(4): 1881–1887. doi.org/10.1093/jee/toaa082.
- SEETHALAM, M., BAPATLA, K. G., KUMAR, M., NISA, S., CHANDRA, P., MATHYAM, P., AND SENGOTTAIYAN, V. 2021. Characterization of *Helicoverpa armigera* spatial distribution in pigeonpea crop using geostatistical methods. Pest Management Science, 77(11): 4942-4950. doi.org/10.1002/ps.6536.
- SHABANI NEJAD, A. AND 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(11): 22-30. [In Persian with English summary]. doi.org/10.22092/jaep.2017.107121.1110.
- SHRESTHA, R.R, BARDOSSY, A., RODE, M. 2007. A hybrid deterministic fuzzy rule based model for catchment scale nitrate dynamics. Journal of Hydrology, 342(1): 143–156. doi.org/10.1016/j.jhydrol.2007.05.020.
- TAY, A., LAFONT, F., BALMAT, J.F. 2021. Forecasting pest risk level in roses greenhouse: Adaptive neuro-fuzzy inference system vs artificial neural networks. Information Processing in Agriculture, 8(3): 386-397. doi.org/10.1016/j.inpa.2020.10.005.
- VIVAN, L. M., TORRES, J.B., AND FERNANDES, L.S. 2016. Activity of selected formulated biorational and synthetic insecticides against larvae of *Helicoverpa armigera* (Lepidoptera: Noctuidae). Journal of Economic Entomology, 101(25): 118–126. doi.org/10.1093/jee/tow244.
- 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(2): 117–135. doi.org/10.1007/s11119-006-9004-