



## مقاله پژوهشی

مقایسه پراکنش فضایی کرم میوه گوجه‌فرنگی، *Helicoverpa armigera* (Hubner) (Lep., Noctuidae)، با روش‌های زمین آمار و

## شبکه فازی-عصبی

روناک محمدی<sup>۱</sup>، عباسعلی زمانی<sup>۱</sup>✉، حسنعلی واحدی<sup>۱</sup>، حمیدرضا پوریان<sup>۱</sup>، بهرام تفقدی نیا<sup>۲</sup>

۱- دانشجوی دکتری، دانشیار، دانشیار، استادیار گروه گیاه‌پزشکی، دانشکده کشاورزی، دانشگاه رازی، کرمانشاه، ایران

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

## چکیده

با وجود روش‌های آماری قوی و پیدایش شبکه‌های فازی-عصبی، مدل‌های پیش‌بینی کننده پراکنش موجودات به سرعت 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 زمین آمار و شبکه‌های 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 به عنوان ورودی‌های هر دو روش تعریف شد. خروجی هر روش نیز، تعداد این آفت در آن نقاط بود. در بخش زمین آمار، از روش کریجینگ معمولی و در بخش شبکه فازی-عصبی مصنوعی، از تابع فعال سازی سیگموئیدی استفاده شد. مقایسه نتایج زمین آمار و شبکه فازی - عصبی، بیانگر توانایی بالای شبکه فازی - عصبی در مقایسه با روش زمین آمار بود، به طوری که ضریب تبیین برای شبکه فازی - عصبی و زمین آمار به ترتیب ۰/۹ و ۰/۶ به دست 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: کریجینگ، شبکه فازی-عصبی (ANFIS)، *Helicoverpa armigera*

## Comparison of Spatial distribution of tomato fruit borer, *Helicoverpa armigera* (Hubner)(Lep., Noctuidae) using geostatistics and fuzzy-neural network methods

R. MOHAMMADI<sup>1</sup>, A. A. ZAMANI<sup>1✉</sup>, H. A. VAHEDI<sup>1</sup>, H. A. POURIAM<sup>1</sup>, B. TAFAGHODINIA<sup>2</sup>

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

## مقدمه

کرم میوه گوجه فرنگی یا کرم غوزه پنبه، (*Helicoverpa armigera* (Hubner)(Lep., Noctuidae)، یک آفت جدی در طیف وسیعی از محصولات است که به بیش از ۲۰۰ گونه گیاهی حمله می‌کند. امروزه، به دلیل افزایش ضررهای اقتصادی این آفت روی گوجه فرنگی، به نگرانی مهم تولیدکنندگان این محصول در ایران و سایر نقاط دنیا تبدیل شده است (Guo et al., 2020; Singla and Singh, 2020). ترجیح سنین مختلف لاروی این آفت به تغذیه از میوه گوجه فرنگی، موجب وارد آمدن خسارت‌های جدی و کاهش شدید عملکرد محصول می‌شود (Sousa et al., 2020). معمولاً کشاورزان برای کنترل کرم میوه گوجه فرنگی 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 زمین‌آماری با ارائه درک درستی از پراکنش آفات به عنوان روش‌های سازگار با محیط زیست شناخته می‌شوند، زیرا اتخاذ آنها می‌تواند منجر به کاهش استفاده از آفت‌کش‌های شیمیایی شود. به همین دلیل، در اجرای مدیریت تلفیقی آفات در سطح منطقه، استفاده از زمین‌آمار 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 Tafaghodinia, 2017). کریجینگ به طور کلی، یک روش زمین‌آماری است که طی آن می‌توان مقدار یک کمیت در نقطه‌ای نامعلوم را، با استفاده از مقدار همان کمیت در نقاط دیگری با مختصات معلوم بدست آورد (Gonadishi, 2008).

استفاده از روش‌های مختلف زمین‌آمار 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 زمین‌آمار 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 به عنوان 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<sup>1</sup> 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، به دلیل 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). به عنوان 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 پیش‌آفات است (Tay *et al.*, 2020). در ایران پژوهشی با هدف مقایسه بین روش‌های زمین آمار 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 بالایی این روش‌ها داشت (Mensah Agboka *et al.*, 2024).

اگرچه با توسعه سریع روش‌های زمین آمار و تکنیک‌های شبکه عصبی در سال‌های اخیر، تحقیقات متعددی برای بهبود دقت در بررسی پراکنش جمعیت آفات انجام شده است، اما تاکنون، پژوهشی به صورت مدون به مقایسه عملکرد روش زمین آمار با سیستم استنتاج عصبی فازی تطبیقی، به منظور تخمین پراکنش فضایی *H. armigera* روی محصول گوجه‌فرنگی نپرداخته است. بنابراین، این پژوهش، با هدف مقایسه روش زمین آمار 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 به صورت هدفمند و دقیق‌تر، برای مدیریت موثر این آفت در سطح مزرعه، روی گیاه گوجه-فرنگی استفاده نمود.

---

<sup>1</sup> -Soft Computing

## مواد و روش‌ها

### موقعیت جغرافیایی و شیوه نمونه برداری

برای انجام این پژوهش، قطعه زمینی به مساحت تقریبی ۲۰۰۰ متر مربع واقع در مزرعه تحقیقاتی پردیس کشاورزی 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 به صورت 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<sup>۲</sup>

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 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 است (Gressie, 1993).

### واریوگرام<sup>۳</sup>:

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

### کریجینگ<sup>۴</sup>:

---

<sup>۲</sup>-Geostatistic

<sup>۳</sup>-Variogram

<sup>۴</sup>-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<sup>۵</sup> 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 به ازای 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 گرادیان 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 به صورت زیر بیان شود:

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

$$z_1 = p_1x + q_1y + r$$

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

$$z_2 = p_2x + q_2y + r$$

لایه اول (ورودی): هرگاه  $i$  از این لایه، مقادیر عضویتی را که به هر یک از مجموعه‌های فازی مناسب تعلق دارند، با استفاده از توابع عضویت تولید می‌کند.

$$O_{1i} = \mu_{A_i}(x) \quad \text{for } i = 1, 2 \text{ or}$$

$$O_{2i} = \mu_{B_{i=2}}(y) \quad \text{for } i = 3, 4$$

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.  $O_{1i}$  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.

<sup>5</sup>-Weighted Coefficient

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. به عنوان مثال:

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

به عبارت 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 به عنوان مجموعه پارامترهای بخش تالی مدل فازی می‌باشند.

لایه پنجم (خروجی): این لایه با گره ثابت با نام  $\Sigma$ ، 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 (Afrous et al., 2007).

$$O_{5,i} = \sum_{i=1} \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i}$$

### انتخاب تابع عضویت

برای در نظر گرفتن درجه عضویت، از توابع عضویت استفاده می‌شود که شامل توابع عضویت مثلثی، ذورنقه‌ای، 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 (۱)، تابع سیگموئیدی با کمترین مربعات خطا به عنوان تابع عضویت انتخاب 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

### پیش پردازش داده‌ها

در ابتدا داده‌ها به طور 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 یکارگیری 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 به دست 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  $X_{min}$  به ترتیب مقادیر بیشینه و کمینه داده‌های اولیه،  $r_{max}$  و  $r_{min}$  هم به ترتیب حد بالایی و پایینی دامنه تغییرات داده‌های تبدیل شده است.

### تجزیه و تحلیل آماری

تست نرمال‌سازی داده‌های مربوط به نمونه‌برداری به کمک نرم‌افزار SPSS 23 و آزمون کولموگروف - اسمیرنوف، بررسی شد. به دلیل 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.

### نتیجه و بحث

نتایج برازش داده‌ها در روش زمین آمار نشان داد (جدول ۲) که به صورت 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 به صورت 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 بیان کننده این حقیقت است که تنها ۶۰ درصد از واریانس بین داده‌ها دارای ساختار مکانی هستند و نمی‌توان به این نتایج اطمینان کافی داشت.

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

### فرنگی

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

به منظور 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 به دست 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 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 پراکندگی کرم میوه گوجه‌فرنگی استفاده شد.

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	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




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 به ترتیب 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) به دست 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 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، به منظور 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 به دست آمده از این پژوهش‌ها با نتایج تحقیق حاضر، هماهنگی دارد.

### 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.



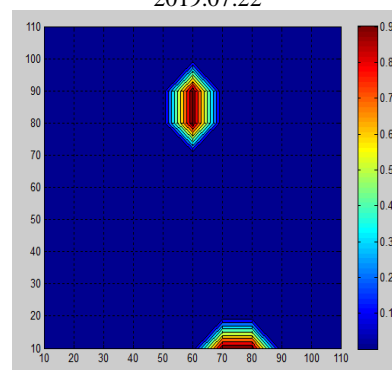
2019.07.17




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

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 به عنوان گامی مؤثر برای تحقیقات آینده جهت کاربرد عملی از این روش‌ها برای بررسی الگوی پراکنش سایر آفات در مزارع بکار 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. doi.org/10.1016/j.geoderma.2004.05.009
- AFROUS, A., HOSSEINI, S.M. AND GOUDARZI, SH. (2007) Assesment of the Ordinary Kriging and NeuroFuzzy appraoches in interpolation of the groundwater level. *Journal of Groundwater*,13(2): 978-984. 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. 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 On-line*, 10: 253-262. 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. https://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: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. https://doi.org/10.1007/s10340-019-01191-9
- 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): 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: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: 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:10.55003/cast.2022.01.23.014.

KATHRINE, A. R. 2001. Geostatistic using SAS software. Own analyticinc. 360 PP. Oxford University Press. Londen. DOI: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. <https://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. <https://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. [https://doi.org/10.1016/S0016-7061\(02\)00179-9](https://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: 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]. 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. <https://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. <https://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. <https://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. <https://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]. <https://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. <https://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](https://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. <https://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. <https://doi.org/10.1007/s11119-006-9004->