

پیش‌بینی الگوی توزیع سوسک پوست‌خوار کاج،

Orthotomicus erosus (Coleoptera: Curculionidae: Scolytinae)

با استفاده از زمین‌آمار و شبکه عصبی مصنوعی

نجمه شیروانی فارسانی، عباسعلی زمانی* و صمد جمالی

گروه گیاهپزشکی، دانشکده کشاورزی، دانشگاه رازی، کرمانشاه، ایران.

*مسئول مکاتبات، پست الکترونیک: azamani@razi.ac.ir

چکیده

سوسک‌پوست‌خوار کاج، *Orthotomicus erosus* (Wollaston) (Coleoptera: Curculionidae: Scolytinae)، یکی از مهم‌ترین آفات درختان کاج می‌باشد. حمله و تغذیه این سوسک‌ها بافت‌های آوند آبکش را در زیر پوست درختان آلوده تخریب و عبور شیره گیاهی را مختل نموده و باعث مرگ درختان آلوده می‌شود. این پژوهش به منظور پیش‌بینی الگوی توزیع و ترسیم نقشه پراکنش *O. erosus* با استفاده از شبکه‌های عصبی پرسپترون چند لایه (MLP)، شبکه عصبی MLP ترکیب شده با الگوریتم ژنتیک و شبکه عصبی MLP ترکیب شده با الگوریتم رقابت استعماری در سطح شهر کرمانشاه انجام شد. داده‌های مربوط به جمعیت این آفت از طریق نمونه‌برداری از درختان کاج در مناطق مختلف شهر کرمانشاه در سال‌های ۱۳۹۳ و ۱۳۹۴ به دست آمد. برای ارزیابی قابلیت شبکه‌های عصبی مورد استفاده در پیش‌بینی توزیع آفت از مقایسه آماری پارامترهایی مانند واریانس، میانگین و توزیع آماری بین مقادیر پیش‌بینی شده مکانی توسط شبکه عصبی MLP ترکیب شده با الگوریتم ژنتیک و الگوریتم رقابت استعماری و مقادیر واقعی آن‌ها استفاده شد. نتایج نشان داد که در فازهای آموزش و آزمایش، مقادیر پارامترهای مذکور بین داده‌های واقعی و پیش‌بینی شده آفت تفاوت معنی‌داری را نشان نداد که نشان‌دهنده دقت بالا و نیز قابلیت شبکه‌های عصبی به منظور ترسیم نقشه پراکنش این آفت در سطح شهر کرمانشاه می‌باشد. مقادیر ضریب تبیین (R^2) نشان داد که الگوریتم رقابت استعماری، دقت بالاتری در تخمین تراکم *O. erosus* نسبت به دو روش دیگر داشته است. همچنین مقایسه مقادیر ضریب تبیین بین شبکه‌های عصبی مختلف و روش زمین‌آمار نشان داد که هر سه مدل شبکه عصبی الگوی توزیع سوسک پوست‌خوار را نسبت به روش زمین‌آمار بهتر پیش‌بینی کردند. روش زمین‌آمار و نقشه‌های ترسیم شده توسط شبکه‌های عصبی نشان داد که توزیع این آفت به صورت تجمعی است. نتایج حاصل از روش زمین‌آمار نیز نشان‌دهنده توزیع تجمعی آفت می‌باشد.

واژه‌های کلیدی: الگوریتم ژنتیک، الگوریتم رقابت استعماری، کریجینگ، توزیع مکانی

**Predicting distribution pattern of the Mediterranean pine engraver,
Orthotomicus erosus (Coleoptera: Curculionidae: Scolytinae),
by geostatistics and artificial neural network**

Najmeh Shirvani Farsani, Abbas Ali Zamani* & Samad Jamali

Department of Plant Protection, College of Agriculture, Razi University, Kermanshah, Iran.

*Corresponding author, E-mail: azamani@razi.ac.ir

Abstract

The Mediterranean pine engraver, *Orthotomicus erosus* (Wollaston) (Coleoptera: Curculionidae: Scolytinae), is one of the most important pests of pine trees in Kermanshah. Attack and feeding of this pest destroy the floem tissues under the bark of the infected trees and disrupt the plant sap flow, causing the death of infected trees. The purpose of this study was to predict and mapping the distribution of *O.*

دریافت: ۱۳۹۶/۱۰/۱۹ پذیرش: ۱۳۹۷/۰۳/۰۵

دبیر تخصصی: یعقوب فتحی پور

erosus using multi-layer perceptron neural networks combined with genetic and imperialist competitive algorithms in Kermanshah. The sampling of pine trees was done in 2015-2016 in Kermanshah. To evaluate the ability of the used neural networks to predict the distribution was used statistical comparison the parameters such as mean, variance and statistical distribution between actual and predicted values by multi-layer perceptron neural networks combined with genetic and imperialist competitive algorithms. Results showed that in training and test phases, was no significant differences between average, variance and statistical distribution of actual and predicted data that indicates the high accuracy and the ability of neural networks to map the distribution of this pest in Kermanshah. The R^2 values revealed that imperialist competitive algorithm had a higher accuracy to estimate the density of *O. erosus* compared with the other two methods. In addition, the comparison of the coefficients of the R^2 between different neural networks and geostatistics method showed that all three neural network models predicted the distribution pattern of *O. erosus* better than the geostatistics method. The maps drawn by all three neural networks showed that the distribution of this pest was cumulative. The results obtained from the geostatistics method represented the cumulative distribution of the pest.

Keywords: Genetic algorithm, imperialist competitive algorithm, kriging, spatial distribution

Received: 09 January 2018, Accepted: 26 May 2018

مقدمه

درختان غیرمثمر از جمله درختان کاج یکی از مهم‌ترین مواد اولیه در صنایع چوب و کاغذسازی هستند که نقش قابل توجهی در اقتصاد کشور دارا می‌باشند. همچنین درختان کاج از جنبه‌های مختلف زیست محیطی از جمله کاهش آلودگی هوا، تولید اکسیژن، کاهش دما و تلطیف آن دارای اهمیت می‌باشند. پس هر تلاشی در حفظ و نگهداری آن‌ها از اهمیت فراوانی برخوردار است (Amani, 2004).

یکی از عوامل خسارت‌زا به درختان کاج، سوسک پوست‌خوار کاج، (*Orthotomicus erosus* (Wollaston) (Coleoptera: Curculionidae: Scolytinae)، می‌باشد. این سوسک به شاخه‌های شکسته، درختان صدمه دیده و درختانی که به تازگی بریده شده‌اند حمله می‌کند، همچنین درختان سالمی را که تحت استرس خشکی، آتش‌سوزی یا باد هستند آلوده می‌کند. حمله و تغذیه این سوسک‌ها بافت‌های آوند آبکش را در زیر پوست درختان آلوده تخریب و عبور شیره گیاهی را مختل نموده و باعث مرگ درختان آلوده می‌شود (Bevan, 1984; Mahhou & Dennis, 1992; Eglitis, 2000; Haack, 2004; Lee et al., 2005). علاوه بر خسارت مستقیم به درختان کاج، این آفت می‌تواند ناقل عوامل بیماری‌زای قارچی مثل *Leptographium*, *Ophiostoma ips* (Rumb.) Nannf. و *Graphium pseudormiticum* Mouton & Wingfield (Mouton et al., 1994; Zhou et al., 2001).

یکی از روش‌های تخمین توزیع مکانی، روش‌های زمین‌آمار می‌باشند (Shoji & Kitaura, 2006). 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 نقطه دیگر مشخص و دارای پیوستگی آشکاری می‌باشند. شدت خسارت و تراکم، نمونه‌هایی از متغیرهای مکانی هستند (Katherine, 2001). در زمین‌آمار، روش‌های مختلفی برای تخمین وجود دارد. یکی از این روش‌ها، کریجینگ نام دارد. کریجینگ یک روش درون‌یابی است که با استفاده از سمی واریوگرام‌ها با ترکیب وزن‌های داده شده به داده‌های نقاط مجاور، خطای مربوط به مقادیر پیش‌بینی شده را محاسبه می‌کند (Gotway et al., 1996). به فرآیند برآورد کمی، برای نقاط بدون داده، به کمک نقاط مجاور و معلوم، درون‌یابی می‌گویند (Asakereh, 2008). درون‌یابی روش پیش‌بینی ویژگی‌ها در مکان‌های نمونه‌برداری نشده با استفاده از نقاط نمونه‌برداری شده در همان منطقه می‌باشد (Sarmadian et al., 2014). شبکه عصبی مصنوعی نیز با استفاده از الگوریتم‌های مختلف دارای قابلیت درون‌یابی می‌باشد.

شبکه عصبی مصنوعی یکی از روش‌های هوشمند در پردازش داده‌ها است که ساختاری مشابه با سیستم عصبی مغز انسان دارد (Haykin, 1999; Torrecilla et al., 2004). شبکه‌های عصبی در بسیاری از زمینه‌ها از جمله تشخیص الگو، پیش‌بینی و مدل‌سازی فرآیندها و طبقه‌بندی در علوم مختلف به کار گرفته می‌شوند و در سال‌های اخیر بسیار مورد توجه قرار گرفته‌اند. مزیت روش شبکه عصبی یادگیری مستقیم از روی داده‌ها، بدون نیاز به برآورد مشخصات آماری آن‌ها است (Vakil-Baghmisheh & Pavešic, 2003). شبکه عصبی به کمک فرآیند یادگیری و با استفاده از پردازشگرهایی به نام نرون، بدون در نظر گرفتن هیچ فرضیه اولیه و دانش قبلی از روابط بین پارامترهای مورد مطالعه، تلاش می‌کند ارتباطی بین مجموعه‌ای از ورودی‌ها و خروجی‌ها برقرار کند (Dayhoff, 1990; Torrecilla et al., 2004; Kaul et al., 2005). تحمل‌پذیری در مقابل خطای یکی دیگر از ویژگی‌های شبکه عصبی می‌باشد (Azadeh et al., 2006). این مزایا دلایل به‌کارگیری شبکه عصبی را در پیش‌بینی تراکم آفت برای ما روشن می‌سازد. پیش‌بینی انتشار جهانی مگس میوه مدیترانه، *Ceratitidis capitata* (Wiedemann) (Diptera: Tephritidae)، و پروانه ابریشم‌باف ناجور، *Lymantria dispar* (L.) (Lepidoptera: Erebidae) بر اساس عوامل اقلیمی و با استفاده از شبکه عصبی مصنوعی صورت گرفته است. صحت پیش‌بینی این مدل برای انتشار جهانی هر دو گونه بالا بوده است (Gevery & Wornner, 2006). از شبکه عصبی مصنوعی برای تجزیه و تحلیل داده‌های مربوط به جمعیت کرم ساقه خوار برنج، *Scirpophya gaincertulas* Walker (Lepidoptera: Crambidae) استفاده شد. این مدل به خوبی توانست جمعیت این آفت را پیش‌بینی کند (Yang et al., 2009). در مطالعه انجام شده توسط Tonnang et al. (2010) از شبکه عصبی مصنوعی برای پیش‌بینی تراکم جمعیت پروانه پشت الماسی، *Diadegma* (Lepidoptera: Plutellidae) و پارازیتوئید مرحله لاروی آن، *Plutella xylostella* (Linnaeus) (Hymenoptera: Ichneumonidae) استفاده شد. ضریب تبیین، نشان دهنده توانایی این مدل در پیش‌بینی تراکم جمعیت میزبان-پارازیتوئید بوده است.

اولین هدف ما در این مطالعه، ارزیابی قابلیت شبکه عصبی پرسپترون چند لایه (MLPNN= Multilayer Perceptron Neural Network) ترکیب شده با الگوریتم ژنتیک و الگوریتم رقابت استعماری (ICA= Imperialist Competitive Algorithm) به عنوان یک روش نوین جایگزین در پیش‌بینی پراکنش *O. erosus* می‌باشد. ارزیابی کارایی شبکه‌های عصبی مصنوعی در کنار روش زمین‌آمار در تخمین توزیع سوسک پوست‌خوار هدف بعدی این پژوهش می‌باشد.

مواد و روش‌ها

نمونه‌برداری: نمونه‌برداری در سال‌های ۱۳۹۳ و ۱۳۹۴ روی درختان کاج شهر کرمانشاه انجام شد. برای این منظور از دو ارتفاع یک و دو متری تنه هر درخت نمونه‌های دایره‌ای شکل جمع‌آوری شد. مطابق روش Gonzalez et al. (1996) نمونه‌ها با استفاده از یک لوله فلزی تیز به قطر ۱۱/۳۰ و ارتفاع شش سانتی‌متر از پوست جدا شدند. این لوله فلزی توسط چکش در پوست هدایت شد. در هر ارتفاع از چهار جهت اصلی (شمال، جنوب، شرق و غرب) نمونه‌برداری شد. از هر جهت سه نمونه جدا و در مجموع ۱۲ نمونه از هر ارتفاع جمع‌آوری گردید. نمونه‌های پوست به طور جداگانه در کیسه‌های پلاستیکی کدگذاری شده قرار داده شدند و در آزمایشگاه تعداد حشرات کامل سوسک پوست‌خوار کاج شمارش و ثبت گردید. در مجموع ۲۸ نقطه از هفت منطقه در شهر کرمانشاه نمونه‌داری شد. نمونه‌های جمع‌آوری شده توسط دکتر Anthony Cognato از دانشگاه میشیگان آمریکا

شناسایی شدند. همزمان با نمونه‌برداری طول و عرض جغرافیایی و ارتفاع هر منطقه با استفاده از دستگاه GPS ثبت شد. محدوده جغرافیایی مناطق نمونه‌برداری شده بین ۳۴ درجه و ۱۹ دقیقه تا ۳۴ درجه و ۲۳ دقیقه عرض شمالی و ۴۷ درجه و ۴ دقیقه تا ۴۷ درجه و ۸ دقیقه طول شرقی قرار دارد و ارتفاع از سطح دریا بین ۱۲۳۵ تا ۱۳۶۹ متر می‌باشد.

شبکه‌های عصبی مصنوعی: شبکه‌های عصبی مصنوعی در مواقعی که بین متغیرهای مشاهده شده (مستقل) و پیش‌بینی شده (وابسته) رابطه‌ای وجود دارد، قابل کاربرد هستند. این شبکه‌ها قادر هستند سیستم‌های غیرخطی ساده تا پیچیده را مدل‌سازی کنند. برای تعیین پراکنش و الگوی توزیع سوسک پوست‌خوار کاج، *O. erosus*، از سه روش شامل شبکه عصبی پرسپترون چند لایه (MLP)، شبکه عصبی MLP بهینه شده توسط الگوریتم ژنتیک و شبکه عصبی MLP بهینه شده توسط الگوریتم رقابت استعماری استفاده شد.

شبکه عصبی پرسپترون چند لایه: شبکه‌های عصبی پرسپترون چند لایه دارای لایه‌های ورودی، میانی (پنهانی) و خروجی می‌باشد. داده‌های لایه ورودی (مستقل) از طریق گره‌های ورودی به شبکه معرفی می‌شوند. به ازای هر متغیر مستقل یک گره در نظر گرفته می‌شود. در این شبکه، آموزش براساس الگوریتم پس انتشار خطا است (Choudhury & Bartarya, 2003). 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. فرآیند 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 مقایسه نتایج مدل با مقادیر مشاهده شده، در مورد کارایی مدل قضاوت می‌شود (Heykin, 1999). برای طراحی شبکه عصبی MLP جهت تعیین رابطه بین تراکم *O. erosus* و مختصات مکانی (طول و عرض جغرافیایی) در ابتدا نیاز به تعیین پارامترهای بهینه شبکه عصبی می‌باشد.

تنظیم پارامترهای شبکه: لایه ورودی دارای سه گره از متغیرهای ورودی شبکه شامل عامل بایاس، طول و عرض جغرافیایی می‌باشد. تعیین تعداد گره‌ها در لایه مخفی شبکه از طریق آزمون سعی و خطا به دست می‌آید. کم بودن تعداد گره‌ها در لایه مخفی، باعث عدم یادگیری شبکه خواهد شد، در حالی که زیاد بودن آن مسئله بیش برآزشی را ایجاد می‌کند که منجر به تضعیف تعمیم‌پذیری شبکه می‌شود (Wang & Elhag, 2007). پارامترهای شبکه عصبی MLP با عنوان نرخ یادگیری و عامل مومنتوم تنظیم شدند که مقدار مطلوب آن‌ها به ترتیب ۰/۲۰ و ۰/۶۱ به دست آمد. در مورد داده‌های جمع‌آوری شده در این پژوهش، این فرآیند برای تعداد گره‌های لایه مخفی ۳ تا ۱۶ انجام شد. نهایتاً بهترین نتیجه در گره ۱۰ به دست آمد. همچنین مقدار بهینه تعداد تکرارها برای یادگیری شبکه عصبی در تشخیص پراکنش سوسک پوست‌خوار کاج، ۱۰۰۰ تکرار در نظر گرفته شد.

با وجود موفقیت‌های کلی، در استفاده از الگوریتم پس انتشار خطا چند مشکل اصلی وجود دارد که شامل سرعت پایین هم‌گرایی این الگوریتم و همچنین وابستگی هم‌گرایی آن به انتخاب مقادیر اولیه وزن‌های شبکه، بردارهای بایاس و پارامترهای موجود در الگوریتم مانند نرخ یادگیری می‌باشد (Freeman & Sakura, 2005). با توجه به معایب این الگوریتم، جهت افزایش سرعت هم‌گرایی و تعیین وزن‌های مناسب شبکه، از الگوریتم‌های هوشمند دیگر مانند الگوریتم ژنتیک و رقابت استعماری نیز استفاده شد.

شبکه عصبی ترکیب شده با الگوریتم ژنتیک: الگوریتم ژنتیک یکی از الگوریتم‌های جست و جو است که بر اساس ژنتیک اندام‌های موجود زنده پایه‌گذاری شده است. این الگوریتم، اصل (انتخاب یا بقای اصلح) داروین را با یکسری اطلاعات تصادفی ساخت یافته ادغام نموده و یک الگوریتم جست و جو با خصوصیات روش‌های تکامل طبیعی ایجاد می‌نماید. به عبارت دیگر، در هر نسل مجموعه جدیدی از رشته‌ها با استفاده از مناسب‌ترین اجزای نسل قبل ایجاد می‌شود و اجزای جدید برای تناسب مورد آزمون قرار می‌گیرند (Shu-Heng, 2002). یکی از قابلیت‌های الگوریتم ژنتیک که به صورت ترکیبی با شبکه عصبی استفاده می‌شود، تنظیم وزن‌های اتصال شبکه است.

در طراحی ساختار و معماری شبکه عصبی، تعداد عناصر بردار ورودی از صورت مسئله مورد بررسی مشخص شده و با انتخاب طراح نیست، اما تعیین تعداد لایه‌های پنهان، تعداد گره‌ها، نوع ارتباط بین گره‌ها، نوع تابع فعال‌سازی و تعداد تکرارها در انتخاب طراح است و بنابراین در شبکه عصبی یک طراحی بهینه ضروری به نظر می‌رسد (Vellido *et al.*, 2010). برای انتخاب پارامترهای مدل و طراحی بهینه، از فرآیند هشت مرحله‌ای بیان شده توسط Castera & Boyd (1996) استفاده شد. تابع سیگموئیدی در لایه پنهان و تابع خطی در لایه خروجی به عنوان تابع فعال‌سازی مورد استفاده قرار گرفت. متغیرهای ورودی شبکه شامل عامل بایاس، طول و عرض جغرافیایی می‌باشد. پارامترهای این الگوریتم با عنوان جمعیت اولیه، نرخ جهش و نرخ تقاطع تنظیم شدند. تعداد کل تکرار الگوریتم ژنتیک برابر با ۲۰۰ در نظر گرفته شد و اگر بعد از ۴۰ تکرار بهبودی در مقدار برازش به وجود نیاید، الگوریتم متوقف می‌شود.

شبکه عصبی ترکیب شده با الگوریتم رقابت استعماری: یکی از مشکلات شبکه عصبی مصنوعی، پیدا نمودن ساختار مناسب شبکه برای تخمین است که معمولاً در مطالعات گذشته با روش آزمون و خطا به این ساختار می‌رسیدند. در این پژوهش از الگوریتم رقابت استعماری به عنوان الگوریتم آموزش شبکه استفاده شد، که قادر به تعیین بهترین حالت شبکه برای کار تخمین است، این کار توسط تعیین حالت مطلوب وزن‌ها و بایاس شبکه صورت می‌گیرد (Enayatifar *et al.*, 2013). در این پژوهش از تابع میانگین مربعات خطا (MSE) به عنوان تابع هزینه شبکه استفاده شد. هدف اصلی استفاده از این الگوریتم حداقل‌سازی مقدار تابع هزینه بود.

این الگوریتم یک الگوریتم جدید در زمینه محاسبات تکاملی است که بر مبنای تکامل اجتماعی-سیاسی انسان پایه‌گذاری شده است. روند این الگوریتم به این صورت است که در مرحله اول با تعدادی جمعیت اولیه، که در این الگوریتم کشور نام دارند، شروع می‌شود و سپس تابع هدف طبق تعریف مسئله برای هر کدام از کشورها به دست می‌آید. با مقایسه مقادیر تابع هدف تمامی کشورها، تعدادی از بهترین آن‌ها انتخاب و کشورهای استعمارگر نامیده می‌شوند و بقیه کشورها کشورهای مستعمره (کلونی) نامیده می‌شوند. باید توجه کرد که در شرایط مساوی که چندین مقدار تابع هدف یکسان برای انتخاب کشورهای استعمارگر وجود دارد به تصادف از بین آن‌ها، کشورهای استعمارگر انتخاب می‌شوند. حال کشورهای مستعمره به کشورهای استعمارگر اختصاص می‌یابند تا امپراطوری‌ها (هر امپراطوری از یک کشور استعمارگر و چند کشور مستعمره تشکیل شده است) تشکیل شوند. باید توجه کرد که هرچه قدرت یک کشور استعمارگر بیشتر باشد (تابع هدف آن بهتر باشد) تعداد بیشتری کشورهای مستعمره به آن اختصاص می‌یابد (Atashpaz-Gargari, 2009).

در الگوریتم رقابت استعماری همانند الگوریتم ژنتیک برای انتخاب پارامترهای مدل و طراحی بهینه، از فرآیند هشت مرحله‌ای Castera & Boyd (1996) استفاده شد. تابع سیگموئیدی در لایه پنهان و تابع خطی در لایه خروجی به عنوان تابع فعال‌سازی مورد استفاده گرفت. متغیرهای ورودی شبکه شامل عامل بایاس و طول و

عرض جغرافیایی می‌باشد. جمعیت اولیه، تعداد امپراطوری اولیه و نرخ انقلاب به عنوان پارامترهای شبکه در نظر گرفته شدند. تعداد کل تکرار الگوریتم رقابت استعماری برابر با ۸۰۰ در نظر گرفته شده است و اگر بعد از ۲۰۰ تکرار بهبودی در مقدار برازش به وجود نیاید، الگوریتم متوقف می‌شود.

زمین‌آمار: تفاوت اصلی این روش با آمار کلاسیک این است که در آمار کلاسیک، نمونه‌های گرفته شده از یک جامعه آماری، مستقل از یکدیگر بوده و وجود یک نمونه هیچ‌گونه 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). **واریوگرام:** واریوگرام 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 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 ($\gamma(h)$) نامیده می‌شود و معادله آن به شکل زیر است (Habashi et al., 2007):

$$\gamma(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [z(x_i) - z(x_i + h)]^2 \quad \text{معادله (۱)}$$

در این معادله، $N(h)$ زوج نمونه‌ای است که به فاصله h از یکدیگر واقع شده‌اند، $z(x_i)$ و $z(x_i+h)$ نیز متغیرهای مکانی مشاهده شده در نقاط x_i و x_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 می‌گویند. باید توجه داشت که تنها گروهی از مدل‌های واریوگرام مانند مدل نمایی، کروی و گوسی دارای حد آستانه هستند 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 & Huijbregts, 1978). فاصله‌ای که در آن واریوگرام به حد ثابتی می‌رسد در اصطلاح دامنه تأثیر می‌نامند. به عبارت دیگر دامنه تأثیر فاصله‌ای است که در ماورای آن نمونه‌ها بر هم تأثیری نداشته 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 & Magri, 1982).

کریجینگ: 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 در مقادیر نقاط مشاهده به دست می‌آید به این صورت که هرچه متغیر به مبدأ (منبع کلنی) نزدیک‌تر باشد، وزن آن بیشتر و هرچه فاصله نقاط دورتر، وزن آن کمتر خواهد بود (Hassani Pak, 2007).

از محدودیت‌های روش‌های زمین‌آمار و شبکه‌های عصبی مصنوعی، حساسیت آن‌ها به تعداد اطلاعات ورودی می‌باشد که هرچه تعداد این اطلاعات کمتر باشد خطای کار به نسبت بالاتر می‌رود. در این پژوهش، از ترکیب روش کریجینگ معمولی با شبکه عصبی مصنوعی بهینه شده با الگوریتم ژنتیک و الگوریتم رقابت استعماری، برای تخمین پراکندگی *O. erosus* استفاده شد. لازم به ذکر است که داده‌ها توسط روش کریجینگ به ۱۲۰۰۰ نقطه تخمینی تبدیل شدند.

نرمال کردن داده‌ها: در هر سه روش مورد استفاده، ابتدا داده‌ها به طور تصادفی به دو دسته مجموعه آموزش با ۱۲۶۰۰ عضو (۷۰ درصد کل داده‌ها) و مجموعه آزمایش با ۵۴۰۰ عضو (۳۰ درصد کل داده‌ها) تقسیم‌بندی شد. البته اگر این تقسیم‌بندی منجر به نتایج مطلوب نشود، می‌توان این مرحله را مجدداً تکرار کرد (Zhang & Fuh, 1998).

قبل از به‌کارگیری داده‌های خام اولیه در آموزش شبکه، باید داده‌ها در دامنه مناسبی نرمال شوند، زیرا الگوریتم یادگیری همراه با داده‌های خام نمی‌تواند عملکرد مناسبی داشته باشد و همچنین به دلیل دامنه تغییرات خروجی تابع فعالیت سیگموئیدی به کار گرفته شده در لایه میانی، این امر ضروری به نظر می‌رسد. در غیر این صورت شبکه در طول فاز آموزش هم‌گرا نخواهد شد و نتایج مطلوبی هم به دست نمی‌آید (Yuxin et al., 2006). زمانی که از تابع فعالیت سیگموئیدی استفاده می‌شود، بهترین دامنه تبدیل داده‌ها بین ۰/۱ و ۰/۹ می‌باشد (Vakil-Baghmisheh & Pavešic, 2003). برای تبدیل داده‌ها از روش نرمال‌سازی خطی استفاده شد:

$$r_{min} + (r_{max} - r_{min}) \times x_n = \frac{x - x_{min}}{x_{max} - x_{min}} \quad \text{معادله (۲)}$$

که در این معادله x داده خام اولیه، x_n داده نرمال شده، x_{min} و x_{max} به ترتیب مقادیر بیشینه و کمینه داده‌های اولیه، r_{min} و r_{max} هم به ترتیب حد بالا و پایین دامنه تغییرات داده‌های تبدیل شده می‌باشد.

تجزیه آماری: کدنویسی شبکه عصبی، الگوریتم ژنتیک و الگوریتم رقابت استعماری در نرم‌افزار آماری Matlab (2013) 8.1 انجام شد. همچنین برای تجزیه و تحلیل داده‌ها با مدل زمین‌آمار از نرم‌افزار Surfer 12.0 استفاده شد. برای ارزیابی الگوریتم‌های مختلف شبکه عصبی از رابطه خطی رگرسیونی بین تراکم مشاهده شده و پیش‌بینی شده توسط شبکه و ضریب تبیین (R^2) استفاده شد. بهترین نتایج بر اساس این دو معیار زمانی به دست می‌آید که معادله خطی علاوه بر داشتن مقدار R^2 بالا، دارای عرض از مبدأ کم و شیب نزدیک به یک باشد. برای اطمینان از یادگیری شبکه عصبی آموزش دیده برای پیش‌بینی الگوی پراکنش *O. erosus*، میانگین و واریانس بین داده‌های مشاهده شده و پیش‌بینی شده توسط شبکه به ترتیب با استفاده از آزمون‌های t و F در نرم‌افزار SPSS 19.0 (SPSS, 2014) مقایسه آماری شدند. همچنین نرمال بودن داده‌های مربوط به نمونه‌برداری با استفاده از آزمون Kolmogorov-Smirnov بررسی شد و به دلیل عدم نرمال بودن آن‌ها، داده‌ها توسط روش کاکس باکس نرمال شدند.

نتایج و بحث

به منظور به دست آوردن بهترین خروجی به ازای پارامترهای الگوریتم ژنتیک و الگوریتم رقابت استعماری، این الگوریتم‌ها چندین بار اجرا شدند. بر اساس نتایج حاصل از روش سعی و خطا، بهترین خروجی الگوریتم ژنتیک، با فرض جمعیت اولیه ۱۵۰ کروموزوم، احتمال تقاطع ۰/۹ و احتمال جهش ۰/۱ به دست آمد. همچنین بهترین خروجی الگوریتم رقابت استعماری، با فرض جمعیت اولیه ۲۰۰، تعداد امپراطوری اولیه ۸۰ و نرخ انقلاب ۰/۲ به دست آمد (جدول ۱). در واقع به ازای پارامترهای مذکور، مقدار میانگین مطلق خطای نسبی برای مولفه خروجی شبکه عصبی پیشنهادی کمینه می‌شود.

مقایسات آماری میانگین، واریانس و توزیع آماری بین تراکم مشاهده شده و پیش‌بینی شده *O. erosus* در جدول ۲ نشان داده شده است. میانگین و واریانس بین داده‌های واقعی و پیش‌بینی شده توسط شبکه عصبی MLP،

شبکه‌ی عصبی MLP ترکیب شده با الگوریتم ژنتیک و شبکه‌ی عصبی MLP ترکیب شده با الگوریتم رقابت استعماری اختلاف معنی‌داری را نشان ندادند. همچنین بین توزیع آماری مقادیر واقعی و پیش‌بینی شده اختلاف معنی‌داری مشاهده نشد. عدم وجود اختلاف معنی‌دار بین توزیع آماری مقادیر مشاهده شده و پیش‌بینی شده تراکم سوسک پوست‌خوار کاج در هر دو فاز آموزش و آزمایش، نشان‌دهنده دقت بالا و نیز قابلیت شبکه‌ی عصبی مصنوعی پرسپترون چندلایه ترکیب شده با الگوریتم ژنتیک و رقابت استعماری، به منظور ترسیم نقشه‌ی پراکندگی این آفت در سطح شهر کرمانشاه می‌باشد.

جدول ۱- درصد خطای شبکه‌ی عصبی پیشنهادی به ازای پارامترهای مختلف الگوریتم ژنتیک و رقابت استعماری

Table 1. Error percentage of proposed neural network for different parameters of genetic and imperialist competitive algorithms

Imperialist competitive algorithms				Genetic algorithms			
Average absolute of relative error (%)	Revolutionary Rate	Initial Empire	Population	Average absolute of relative error (%)	Mutation rate	Crossover rate	Population
0.092	0.5	50	100	2.60	0.4	0.6	50
0.089	0.4	60	100	2.49	0.3	0.7	50
0.087	0.3	70	100	2.61	0.2	0.8	50
0.059	0.2	80	100	2.27	0.1	0.9	50
0.033	0.5	50	150	2.18	0.4	0.6	100
0.025	0.4	60	150	2.15	0.3	0.7	100
0.022	0.3	70	150	1.97	0.2	0.8	100
0.012	0.2	80	150	1.95	0.1	0.9	100
0.006	0.5	50	200	1.95	0.4	0.6	150
0.005	0.4	60	200	1.95	0.3	0.7	150
0.005	0.3	70	200	1.95	0.2	0.8	150
0.005	0.2	80	200	1.93	0.1	0.9	150

مقادیر R^2 و رابطه‌ی خطی رگرسیونی بین تراکم واقعی و پیش‌بینی شده *O. erosus* توسط شبکه‌ی عصبی MLP و شبکه‌ی عصبی MLP ترکیب شده با الگوریتم ژنتیک و شبکه‌ی عصبی MLP ترکیب شده با الگوریتم رقابت استعماری در جدول ۳ نشان داده شده است. همان‌گونه که ملاحظه می‌شود مقدار ضریب تبیین در هر سه مورد استفاده رضایت‌بخش می‌باشد ($R^2 > 0.8$). بالا بودن مقادیر R^2 و همچنین عرض از مبدأ نزدیک به صفر و شیب خط نزدیک به یک، بیانگر قدرت تعمیم‌پذیر بودن شبکه‌های عصبی مورد استفاده در تخمین تراکم سوسک پوست‌خوار کاج در شهر کرمانشاه می‌باشد. الگوریتم رقابت استعماری دقت بالاتری در تخمین تراکم *O. erosus* نسبت به روش دیگر داشته است که مقدار بالاتر R^2 این مطلب را تأیید می‌کند. با توجه به بالاتر بودن مقدار R^2 در الگوریتم رقابت استعماری می‌توان نتیجه گرفت که نقشه‌های ترسیم شده توسط این روش نسبت به نقشه‌های ترسیم شده توسط روش دیگر مطلوب‌تر می‌باشد.

جدول ۲- مقایسه آماری میانگین، واریانس و توزیع آماری بین تراکم مشاهده شده و پیش‌بینی شده *Orthotomicus erosus* توسط شبکه‌ی عصبی پرسپترون چندلایه، شبکه‌ی عصبی MLP ترکیب شده با الگوریتم ژنتیک و شبکه‌ی عصبی MLP ترکیب شده با الگوریتم رقابت استعماری

Table 2. Statistical comparison of mean, variance and statistical distribution between observed and predicted density of *Orthotomicus erosus* by multilayer perceptron neural network, MLP neural network combined with genetic and imperialist competitive algorithms

Used procedure	Utilization phase	<i>P</i> value		
		mean	variance	statistical distribution
multilayer perceptron neural network	Training Phase	0.526	0.779	.0910
	Test Phase	.439	.563	0.800
MLP neural network combined with genetic algorithms	Training Phase	0.817	0.852	0.854
	Test Phase	0.901	0.891	0.890
MLP neural network combined with imperialist competitive algorithms	Training Phase	0.762	0.901	0.850
	Test Phase	0.910	0.942	0.900

جدول ۳- نتایج حاصل از رابطه رگرسیون خطی بین تراکم مشاهده شده (x) و پیش‌بینی شده (y) *Orthotomicus erosus* توسط شبکه عصبی پرسپترون چندلایه، شبکه عصبی MLP ترکیب شده با الگوریتم ژنتیک و شبکه عصبی MLP ترکیب شده با الگوریتم رقابت استعماری

Table 3. Results of Linear regression relationship between observed (x) and predicted (y) density of *Orthotomicus erosus* by multilayer perceptron neural network, MLP neural network combined with genetic and imperialist competitive algorithms

Used procedure	Utilization phase	Intercept	Slope	<i>R</i> ²
multilayer perceptron neural network	Training Phase	0.012	0.882	0.889
	Test Phase	0.020	0.799	0.801
MLP neural network combined with genetic algorithms	Training Phase	0.002	0.977	0.852
	Test Phase	0.021	0.851	0.891
MLP neural network combined with imperialist competitive algorithms	Training Phase	0.009	0.966	0.988
	Test Phase	0.001	0.853	0.932

نتایج برازش داده‌های حاصل از نمونه‌برداری در روش زمین‌آمار نشان داد که به صورت کلی داده‌ها با مدل کروی تطابق داشتند که بر این اساس با اطمینان می‌توان استنباط نمود که پراکندگی *O. erosus* به صورت تجمعی است (جدول ۴). با توجه به مقادیر بالای *R*² و درجه وابستگی مکانی، می‌توان به این نتایج اطمینان کافی داشت.

جدول ۴- ویژگی‌های زمین‌آمار درختان کاج آلوده شده توسط *Orthotomicus erosus* در شهر کرمانشاه

Table 4. Geostatistical characteristics of the infected pines by *Orthotomicus erosus* in Kermanshah

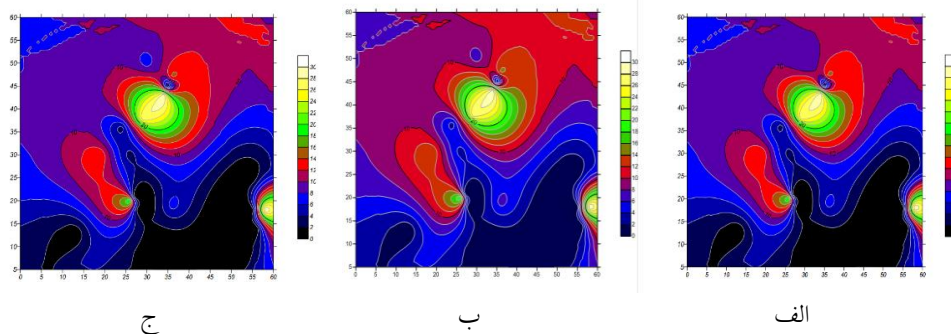
Nugget	Range of spatial dependence	Degree of spatial dependence	RSS	<i>R</i> ²	Model
120.05	1215.12	0.790	2.43	0.801	Spherical

مقایسه مقادیر ضریب تبیین در شبکه‌های عصبی با روش زمین‌آمار نشان داد که شبکه عصبی MLP و شبکه عصبی MLP ترکیب شده با الگوریتم ژنتیک و شبکه عصبی MLP ترکیب شده با الگوریتم رقابت استعماری با دقت بیشتری توزیع سوسک پوست‌خوار را برآورد کرده است که نشان دهنده برتری شبکه‌های عصبی مصنوعی نسبت به روش زمین‌آمار در تخمین توزیع این آفت می‌باشد.

مطالعه Young et al. (2000) بیانگر کارایی بالای شبکه عصبی مصنوعی MLP در پیش‌بینی پویایی جمعیت مگس گالزا، *Thecodiplosis japonensis* Uchida & Inouye (Diptera: Cecidomyiida) در جنگل‌های سوزنی-برگ آمریکا بود. در پژوهشی که به منظور تعیین الگوهای پراکنش حشرات در یک مرتع به وسیله شبکه عصبی انجام شد، بیان شد که شبکه عصبی MLP، شبکه عصبی بردار چندی‌ساز یادگیر (LVQ = Learning Vector Quantization) و شبکه عصبی خطی می‌توانند به خوبی الگوهای توزیع حشرات را تشخیص دهند. اما در بین شبکه‌های مذکور شبکه عصبی MLP قوی‌ترین الگوریتم‌ها را در تشخیص الگوهای پراکنش دارا بود (Zhang et al., 2008). در بررسی‌های انجام شده توسط Shabaninejad et al. (2017) روی *Tetranychus urticae* Koch (Acari: Tetranychidae) در مزارع خیار شهر رامهرمز، شبکه عصبی MLP ترکیب شده با الگوریتم ژنتیک قابلیت بالایی در تشخیص پراکنندگی این کنه نشان داد.

نقشه‌های توزیع مکانی *O. erosus*:

نقشه پراکنندگی مکانی سوسک پوست‌خوار کاج توسط شبکه عصبی پرسپترون چندلایه، شبکه عصبی MLP ترکیب شده با الگوریتم ژنتیک و شبکه عصبی MLP ترکیب شده با الگوریتم رقابت استعماری ترسیم و در شکل ۱ نشان داده شده است. در نقشه‌های ترسیم شده توسط هر سه روش مناطقی که در محدوده رنگ‌های زرد تا سفید قرار دارند آلوده‌ترین مناطق در شهر کرمانشاه بوده که بیشترین تراکم سوسک پوست‌خوار را دارا می‌باشند. هر سه نقشه ترسیم شده توزیع تجمعی *O. erosus* را نشان می‌دهد. با توجه به نقشه‌های پراکنندگی ترسیم شده می‌توان پی برد که تراکم سوسک پوست‌خوار کاج در شهر کرمانشاه پایین می‌باشد. واضح است که مناطق دارای آفت در مدیریت متناسب با مکان، مورد کنترل قرار می‌گیرند و سایر مناطق نیاز به اقدامات مدیریتی و کنترل ندارند.



شکل ۱- نقشه پراکنندگی *Orthotomicus erosus* در شهر کرمانشاه (الف) شبکه عصبی پرسپترون چند لایه، (ب) شبکه عصبی MLP ترکیب شده با الگوریتم ژنتیک (ج) شبکه عصبی MLP ترکیب شده با الگوریتم رقابت استعماری

Fig. 1. Distribution map of *Orthotomicus erosus* in Kermanshah (A) Multilayer perceptron neural network (B) MLP neural network combined with genetic algorithm (C) MLP neural network combined with Imperialist competitive algorithm

شبکه عصبی مصنوعی به عنوان یک مدل تجربی، به علت عدم استفاده از فرمول‌های پیچیده دیفرانسیلی و ایجاد رابطه دقیق بین داده‌های ورودی و خروجی، می‌تواند پویایی حاکم بر سیستم را استخراج نموده و خروجی مدل را پیش‌بینی کند. بر این اساس در هر زمان با داشتن اطلاعاتی از قبیل طول و عرض جغرافیایی و قرار دادن آن‌ها در مدل شبکه عصبی می‌توان تراکم جمعیت آفت را پیش‌بینی و اقدامات مدیریتی لازم را انجام داد. در این مطالعه شبکه عصبی پرسپترون چند لایه، شبکه عصبی MLP ترکیب شده با الگوریتم ژنتیک و شبکه عصبی MLP ترکیب

شده با الگوریتم رقابت استعماری توانستند با دقت مناسبی الگوی توزیع سوسک‌های پوست‌خوار را پیش‌بینی کنند. همچنین شبکه‌های عصبی مصنوعی قادر بودند علاوه بر پیش‌بینی، نقشه پراکنش *O. erosus* را ترسیم نمایند. نقشه‌های حاصله بیان‌کننده پراکنش تجمعی این آفت است. نقشه‌های تهیه شده به وسیله شبکه عصبی چنانچه دقت بالایی داشته باشند، در جهت اعمال روش‌های کنترل کمک شایانی می‌کنند. از آن جایی که سوسک پوست‌خوار آفت مهمی برای درختان کاج به شمار می‌آید، اطلاع از مکان‌های پراکنش این آفت به مدیریت تلفیقی آن کمک می‌کند. با توجه به مناسب بودن پارامترهای آماری می‌توان با اطمینان به نقشه‌های ترسیم شده توسط شبکه عصبی، محل‌های مناسب برای سم‌پاشی را انتخاب نموده و تنها با سم‌پاشی محل‌هایی با تراکم بالا به مدیریت مناسب و کاهش مصرف سموم و کاهش آلودگی فضای سبز دست یافت. همچنین با توجه به این که تهیه فرمون جنسی و نصب تله‌های فرمونی هزینه‌های فراوانی را به دنبال دارد، با استفاده از نقشه‌های تهیه شده توسط شبکه عصبی می‌توان تله‌های فرمونی را در مکان‌هایی که آفت وجود دارد نصب کرد و یا استفاده از عوامل کنترل طبیعی را در نقاط آلوده، متمرکز ساخت.

سپاس‌گزاری

این تحقیق بخشی از رساله دکتری نویسنده اول است که با حمایت مالی دانشگاه رازی انجام شده است. همین‌طور از همکاری صمیمانه آقای مهندس علیرضا شعبانی نژاد تشکر و قدردانی می‌شود.

References

- Amani, M.** (2004) Urban trees and around the urban. *Magazine of Greenspace of parks organization and Greenspace of Tehran* 6, 20-27 (in Persian).
- Asakereh, H.** (2008) Application of Kriging method for rainfall interpolation, case study, rainfall interpolation 17.3.1998 in Iran. *Geography and Development Magazine* 42, 12-25 (in Persian).
- Atashpaz-Gargari, E.** (2009) Imperialist Competitive Algorithm development and its applications, M.S. Thesis, University of Tehran (in Persian).
- Azadeh, A., Ghaderi, S. F. & Sohrabkhani, S.** (2006) Forecasting electrical consumption by integration of Neural Network, time series and ANOVA. *Applied Mathematics and Computation* 186, 1753-1761.
- Bevan, D.** (1984) *Orthotomicus erosus* (Wollaston) in Usutu pine plantations, Swaziland. Forest Research Report No. 64. Usutu Pulp Company Limited, Bhunya, Swaziland.
- Castera, I. & Boyd, M.** (1996) Designing an Artificial Neural Network for forecasting financial and economic time series. *Neurocomputing* 12(5), 13-19.
- Choudhury, S. K. & Bartarya, G.** (2003) Role of temperature and surface finish in predicting tool wear using neural network and design of experiments. *International Journal of Machine Tools & Manufacture* 10(2), 747-753.
- Dayhoff, J. E.** (1990) *Neural network principles*. Prentice-Hall International, USA.
- Eglitis, A.** (2000) *Exotic forest pest information system for north america: Orthotomicus erosus*. North American Forest Commission.
- Enayatifar, R., Sadaei, H. J., Abdullah, A. H. & Gangi, A.** (2013) Imperialist competitive algorithm combined with refined high-order weighted fuzzy time series (RHWFTS-ICA) for short term load forecasting. *Energy Conversion and Management* 76(3), 1104-1116.
- Freeman, J. & Sakura, D.** (2005) *Neural networks: Algorithms, applications, and programming techniques*. Addison-Wesley, Berlin.
- Gevery, M. & Worner, S. P.** (2006) Prediction of global distribution of insect pest species in relation to climate by using an ecological informatics method. *Journal of economic entomology* 99(3), 979-986.

- Gonzalez, R., Grégoire, J. C., Drumont, A. & De Windt, N.** (1996) A sampling technique to estimate within-tree populations of pre-emergent *Ips typographus* (Col., Scolytidae). *Journal of Applied Entomology* 120, 569-576.
- Goovaets, P.** (1997) *Geostatistics for natural resources evaluation*. 1th ed. 512 pp. Oxford University Press.
- Gotway, C. A., Ferguson, R. B., Hergert, G. W. & Peterson, T. A.** (1996) Comparison of kriging and inverse distance methods for mapping soil parameters. *Soil Science Society America Journal* 60(13), 1237-1247.
- Gressie, N.** (1993) *Statistics for spatial data*. 1th ed. 550 pp. John Wiley, New York.
- Haack, R. A.** (2004) *Orthotomicus erosus*: A new pine-infesting bark beetle in the United States. *Newsletter of the Michigan Entomological Society* 49, 3-4.
- Habashi, H., Hosseini, M., Mohammadi, J. & Rahmani, R.** (2007) Geostatistic applied in forest soil studying process. *Journal of Agricultural Science and natural Resources* 14, 1-10. [In Persian with English summary]
- Hassani Pak, A.** (2007) *Geostatistics*. 3th ed. 538 pp. University of Tehran Press. [In Persian]
- Heykin, S.** (1999) *Neural networks; A comprehensive foundation*. 2th ed. pp 14-29.
- Journel, A. G. & Huijbregts, C. J.** (1978) *Mining geostatistics*. 1th ed. 599 pp. Academic Press.
- Katherine, A. R.** (2001) *Geostatistic using SAS software*. Owen analytic inc. Deep River, CT., 6 pp.
- Kaul, M., Hill, R. L. & Walthall, C.** (2005) Artificial neural networks for corn and soybean yield prediction. *Agriculture system* 85, 1-18.
- Krige, D. G. & Magri, E. J.** (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.
- Lee, J. C., Smith, S. L. & Seybold, S. J.** (2005) *Mediterranean pine engraver*. USDA-APHIS Pest Alert R5-PR-016. 4 pp.
- Mahhou, A. & Dennis, F. G.** (1992) The almond trees in Morocco. *HortTechnology* 2, 488-492.
- MATLAB 8.0 AND Statistics Toolbox 8.1.** (2013) The MathWorks, Inc., Natick, Massachusetts, United States.
- Mouton, M., Wingfield, M. J., Van Wyk, P. S. & Van Wyk, P. W. J.** (1994) *Graphium pseudormiticum* sp. nov.: a new hyphomycete with unusual conidiogenesis. *Mycological Research* 98, 1272-1276.
- Sarmadian, F., Keshavarzi, A., Odagiu, A., Zahedi, Gh. & Javadikia, H.** (2014) Mapping of spatial variability of soil organic carbon based on radial basis functions method. *ProEnvironment* 7, 3-9.
- Shabaninejad, A., Tafaghodinia, B. & Zandi Sohani, N.** (2017) Hybrid neural network with genetic algorithms for predicting distribution pattern of *Tetranychus urticae* (Acari: Tetranychidae) in cucumbers field of Ramhormoz, Iran. *Persian Journal of Acarology* 6(1), 53-62.
- Shoji, T. & Kitaura, H.** (2006) Statistical and geostatistical analysis of rainfall in central Japan. *Computers and Geosciences* 32, 1007-1024.
- Shu-Heng, C.** (2002) *Genetic Algorithm and Genetic Programming in Computational Finance*. Springer Kluwer Academic Publications, New York, USA.
- SPSS.** (2014) *SPSS base 16.0 user's guide*. SPSS Incorporation, Chicago, IL.
- Tonnang, Z. E. H., Nedorezov, L. V., Ochanda, H., Owino, J. O. & Lohr, B.** (2010) Assessing the impact of biological control of *Plutella xylostella* through the application of Lotka-Volterra model. *Ecological Modeling* 220, 60-70.
- Torrecilla, J. S., Otero, L. & Sanz, P. D.** (2004) A neural network approach for thermal/pressure food processing. *Food Engineer* 62, 89-95.
- Vakil-Baghmisheh, M. T. & Pavešić, N.** (2003) Premature clustering phenomenon and new training algorithms for LVQ. *Pattern recognition* 36(5), 1901-1921.
- Vellido, A., Liboa, P. J. G. & Vaughan, J.** (2010) Neural networks in business: a survey of applications. *Expert Systems with Application* 19(3), 12-24.

- Wang, Y. M. & Elhag, T. M. S.** (2007) A comparison of neural network, evidential reasoning and multiple regression analysis in modeling bridge risks. *Expert Systems with Applications* 32, 336-348.
- Yang, L. N., Peng, L., Zhang, L. M., Zhang, L. L. & Yang, S. S.** (2009) A prediction model for population occurrence of paddy stem borer (*Scirpophaga incertulas*), based on Back Propagation Artificial Neural Network and Principal Components Analysis. *Computers and Electronics in Agriculture* 200-206.
- Young-S, P., Ja-Myung, K., Buom-Young, L., Yeong, J. & YooShin, K.** (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., Mulla, D. J. & Pierre, C. R.** (2006) Identifying important factors influencing corn yield and grain quality variability using artificial neural networks. *Precision Agriculture* 7(2), 117-135.
- Zhang, W. J., Zhong, X. Q. & Liu, G. H.** (2008) Recognizing spatial distribution patterns of grassland insects: neural network approaches. *Stochastic Environmental. Research and Risk Assessment* 22, 207-216.
- Zhang, Y. F. & Fuh, J. Y. H.** (1998) A neural network approach for early cost estimation of packaging products. *Computers & Industrial Engineering* 34(2), 433-50.
- Zhou, X. D., de Beer, Z. W., Wingfield, B. D. & Wingfield, M. J.** (2001) Ophiostomatoid fungi associated with three pine-infesting bark beetles in South Africa. *Sydowia* 53, 290-300.