

## Evaluating Efficiency of Some Artificial Intelligence Techniques for Modeling Soil Wind Erodibility in Part of Eastern Land of Urmia Lake

BIJAN RAEI<sup>1\*</sup> ABBAS AHMADI<sup>1</sup>, MOHAMMAD RZA NEYSHABURI<sup>1</sup>, MOHAMMAD ALI GHORBANI<sup>2</sup>, FAROKH ASADZADEH<sup>3</sup>

1. Department of Soil Science, faculty of agriculture, University of Tabriz, Tabriz, Iran.
  2. Department of Water Engineering, faculty of agriculture, University of Tabriz, Tabriz, Iran.
  3. Department of Soil Science, faculty of agriculture, Urmia University, Urmia, Iran
- (Received: June. 30, 2019- Revised: Aug. 12, 2019- Accepted: Aug. 24, 2019)

### ABSTRACT

Prediction of soil wind erodibility through soil characteristics is an important aspect for modeling soil wind erosion. This study was conducted to compare the efficiency of multiple linear regression (MLR), artificial neural network (MLP), artificial neural network based on genetic algorithm (MLP-GA) and artificial neural network based on whale optimization algorithm (MLP-WOA) for prediction of soil wind erodibility in part of eastern land of Urmia Lake. In this research, 96 soil samples were collected based on a stratified random sampling method and their physicochemical properties were measured. Additionally, the wind erodibility of soil samples was measured using a wind tunnel. Among the 32 measured soil properties, four properties including the percentages of fine sand, size classes of 1.7-2.0, and 0.1-0.25 mm (secondary particles) and organic carbon were selected as the model inputs by stepwise regression. Result showed that the MLP-WOA was the most effective method for predicting soil wind erodibility in the study area regarding to the lowest RMSE (2.9) and ME (-0.11), and the highest  $R^2$  (0.87) and NSE (0.87) values; followed by MLP-GA, MLP, and MLR. Considering the high efficiency of MLP-WOA, This method can be used as a promising method for determination of soil wind erodibility in the study area.

**Keywords:** Artificial Neural Network, Genetic Algorithm, Whale Optimization Algorithm, Wind Erosion, Wind Tunnel.

## ارزیابی کارایی برخی روش‌های هوش مصنوعی در مدل‌سازی فرسایش‌پذیری بادی خاک در بخشی از اراضی شرق دریاچه ارومیه

بیژن راعی<sup>۱\*</sup>، عباس احمدی<sup>۱</sup>، محمدرضا نیشابوری<sup>۱</sup>، محمدعلی قربانی<sup>۲</sup>، فرخ اسدزاده<sup>۳</sup>

۱. گروه علوم و مهندسی خاک، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران

۲. گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران

۳. گروه علوم و مهندسی خاک، دانشکده کشاورزی، دانشگاه ارومیه، ایران

(تاریخ دریافت: ۱۳۹۸/۴/۹ - تاریخ بازنگری: ۱۳۹۸/۵/۲۱ - تاریخ تصویب: ۱۳۹۸/۶/۲)

### چکیده

پیش‌بینی فرسایش‌پذیری بادی از طریق ویژگی‌های خاک به عنوان گامی اساسی در مدل‌سازی فرسایش بادی محسوب می‌شود. این پژوهش با هدف مقایسه کارایی چهار روش مختلف شامل رگرسیون خطی چندمتغیره، شبکه عصبی مصنوعی، شبکه عصبی مصنوعی هیبرید شده با الگوریتم ژنتیک و شبکه عصبی هیبرید شده با الگوریتم بهینه‌سازی وال در مدل‌سازی فرسایش‌پذیری بادی در بخشی از اراضی پیرامون شرقی دریاچه ارومیه انجام شد. برای این منظور، ۹۶ نمونه خاک به روش تصادفی نظارت شده جمع‌آوری و ۳۲ ویژگی مختلف فیزیکی و شیمیایی آن‌ها در آزمایشگاه تعیین شدند. همچنین فرسایش‌پذیری بادی نمونه‌ها نیز با استفاده از تونل باد تعیین گردید. از میان ویژگی‌های خاک، چهار ویژگی شامل فراوانی ذرات ثانویه ۰/۱ تا ۰/۲۵ میلی‌متری، فراوانی ذرات ثانویه ۱/۷ تا ۲ میلی‌متری، فراوانی ذرات شن ریز و محتوای کربن آلی از طریق رگرسیون گام به گام به عنوان ورودی مدل‌های پیش‌بینی فرسایش‌پذیری، انتخاب شدند. نتایج نشان داد که مدل شبکه عصبی هیبرید شده با الگوریتم بهینه‌سازی وال با توجه به کمترین مقادیر میانگین خطا (۰/۱۱-) و جذر میانگین مربعات خطا (۲/۹) و بیشترین مقادیر ضریب تبیین (۰/۸۷) و ضریب کارایی نش-ساتکلیف (۰/۸۷) از کارایی مطلوب‌تری در پیش‌بینی فرسایش‌پذیری بادی خاک‌های منطقه برخوردار است و پس از آن روش‌های شبکه عصبی مصنوعی هیبرید شده با الگوریتم ژنتیک، شبکه عصبی مصنوعی و رگرسیون خطی چندمتغیره به ترتیب در رتبه‌های بعدی قرار داشتند. در مجموع با توجه به کارایی قابل قبول مدل شبکه عصبی هیبرید شده با الگوریتم بهینه‌سازی وال در پیش‌بینی فرسایش‌پذیری بادی، استفاده از این روش برای تعیین سریع و دقیق فرسایش‌پذیری خاک‌های منطقه توصیه می‌شود.

**واژه‌های کلیدی:** شبکه عصبی مصنوعی، الگوریتم ژنتیک، الگوریتم بهینه‌سازی وال، فرسایش بادی، تونل باد.

### مقدمه

بنابراین، پیش‌بینی آن با استفاده از توابع انتقالی می‌تواند موجب صرفه‌جویی در هزینه و زمان شود (Ostovari et al., 2016). از طرفی با توجه به این که فرسایش‌پذیری (بادی و آبی) تحت تأثیر فاکتورهای مختلفی قرار می‌گیرد، در نظر گرفتن تمامی این فاکتورها و اثرات متقابل آن‌ها امر دشواری می‌باشد. همچنین از آنجا که فرآیند اثرگذاری این فاکتورها هنوز به طور کامل درک نشده است، مدل‌سازی فرسایش‌پذیری بادی خاک امر بسیار پیچیده و دشوار می‌باشد (Vaezi et al., 2008).

در مباحث پیچیده‌ای از قبیل فرسایش‌پذیری بادی که فیزیک آن‌ها هنوز به طور کامل درک نشده است، مشکلات موجود در زمینه مدل‌سازی و پیش‌بینی را می‌توان با استفاده از روش‌های هوش مصنوعی به میزان زیادی کاهش داد (Fallah-Mehdipour

فرسایش‌پذیری بادی خاک یکی از فاکتورهای اساسی در مدل‌سازی فرسایش بادی است که منعکس‌کننده شدت آسیب‌پذیری خاک در مقابل نیروی فرساینده باد است (Webb and McGowan, 2009). فرسایش‌پذیری یک مفهوم پیچیده می‌باشد که تحت تأثیر عوامل مختلفی از قبیل ویژگی‌های خاک، موقعیت توپوگرافی، شیب زمین، مدیریت خاک و فعالیت‌های انسانی قرار دارد (Liu et al., 2007). در مطالعات مربوط به فرسایش بادی، فرسایش‌پذیری از طرق مختلفی مانند استفاده از توابع انتقالی و همچنین آزمایشات تونل باد در آزمایشگاه و مزرعه اندازه‌گیری و ارزیابی می‌شود (Song et al., 2005). اندازه‌گیری فرسایش‌پذیری خاک در مزرعه خسته‌کننده، وقت‌گیر و پرهزینه می‌باشد،

این الگوریتم در بسیاری از مسائل بهینه‌سازی استفاده نمایند (Kaveh and Ghazaan, 2017; Ladumor *et al.*, 2016; Mafarja and Mirjalili, 2018; Touma, 2016). با توجه به مزیت‌های یاد شده، استفاده از الگوریتم بهینه‌سازی وال در آموزش شبکه عصبی مصنوعی می‌تواند موجب بهبود کارایی شبکه‌های عصبی در شبیه‌سازی و مدل‌سازی رخدادهای طبیعی شود (Thoma, 2016; Mafarja and Mirjalili, 2018; Raj and Bhattacharyya, 2018; Reddy *et al.*, 2017; Mafarja and Mirjalili, 2017).

دریاچه ارومیه با وسعتی در حدود ۲۳۸۸ کیلومتر مربع، بزرگترین آب‌گیر فلات ایران می‌باشد که در حال حاضر گستره و ارتفاع آب در آن به پائین‌ترین حد خود رسیده است به گونه‌ای که در مقایسه با سال ۱۳۸۱ حدود ۴ متر کاهش یافته است (Dastranj *et al.*, 2018). در طول دو دهه اخیر، بحران خشک شدن دریاچه ارومیه سبب بروز مشکلات زیست محیطی متعددی شده است که این مشکلات با تشدید خشک شدن دریاچه در سال‌های اخیر بسیار چشمگیر شده و موجب بروز خسارات زیست محیطی جبران ناپذیری در اطراف آن گردیده است. یکی از مهمترین این مشکلات، بیرون آمدن بستر دریاچه از زیر آب می‌باشد به گونه‌ای که مساحت آبی دریاچه از ۵۳۶۶ کیلومتر مربع در سال ۱۳۵۵ به ۲۳۸۸ کیلومتر مربع در سال ۱۳۹۶ رسیده است (Dastranj *et al.*, 2018)، که با توجه به مستعد بودن بسیاری از نقاط بستر خشک شده‌ی دریاچه به فرسایش بادی، شناسایی این نقاط و مطالعات علمی در بررسی و کنترل فرسایش بادی ضروری به نظر می‌رسد. با توجه به این که اندازه‌گیری فرسایش‌پذیری بادی خاک با استفاده از تونل بادی زمان‌بر و پرهزینه می‌باشد، بنابراین این مطالعه با هدف بررسی کارایی برخی روش‌های هوش مصنوعی از قبیل شبکه عصبی مصنوعی، شبکه عصبی مصنوعی هیبرید شده با الگوریتم ژنتیک و شبکه عصبی مصنوعی هیبرید شده با الگوریتم بهینه‌سازی وال و مقایسه آن‌ها با رگرسیون خطی چندمتغیره در مدل‌سازی فرسایش‌پذیری بادی در اراضی شرقی دریاچه ارومیه انجام گرفت و هدف از آن تعیین بهترین روش در ارزیابی فرسایش‌پذیری بادی خاک بوده است.

## مواد و روش‌ها

### منطقه مورد مطالعه و نمونه‌برداری

منطقه مورد مطالعه در این پژوهش در بخش شرقی پیرامون دریاچه ارومیه و در محدوده‌ی جغرافیایی  $46^{\circ} 15'$  و  $45^{\circ} 30'$

(*et al.*, 2013). شبکه‌های عصبی مصنوعی یکی از روش‌های پرکاربرد هوش مصنوعی بوده که بر اساس سیستم عصبی انسان طراحی شده و توانایی بالایی در یادگیری، شناسایی و مدل‌سازی روابط پیچیده غیرخطی بین ورودی‌ها و خروجی‌های یک سیستم را دارا هستند (Kaunda, 2015). علی‌رغم مزیت‌های مذکور، شبکه عصبی دارای محدودیت‌هایی است که مهم‌ترین آن‌ها توقف فرآیند بهینه‌سازی در نقاط محلی می‌باشد (Hamm *et al.*, 2007). برای رفع این مشکل و به دست آوردن راه حل بهینه، شبکه عصبی مصنوعی می‌تواند به وسیله الگوریتم‌های جستجوی جهانی از قبیل الگوریتم ژنتیک آموزش داده شود (Garcia and Arguello, 2005). الگوریتم ژنتیک یکی از روش‌های بهینه‌سازی می‌باشد که در آن فرآیندهای محاسباتی از تئوری تکامل و از اصول انتخاب طبیعی داروین تقلید می‌کنند (Holland, 1992). از آنجا که در این روش برخلاف روش‌های تک‌مسیری فضای جواب به طور همه جانبه جستجو می‌شود، احتمال کمتری برای توقف در یک نقطه بهینه محلی وجود خواهد داشت (Kantardzic, 2011). بنابراین استفاده از الگوریتم ژنتیک در آموزش شبکه عصبی مصنوعی در اکثر موارد نتایج بهتری نسبت به الگوریتم متداول و پرکاربرد پس انتشار خطا (BP) به همراه داشته است (Nazghelichi *et al.*, 2011).

علی‌رغم این که تاکنون تعداد زیادی از الگوریتم‌های جستجوی جهانی گسترش یافته است و در بسیاری از مطالعات برای آموزش شبکه عصبی مورد بحث و بررسی قرار گرفته‌اند، همچنان مشکلاتی از قبیل توقف در نقاط بهینه محلی پابرجا می‌باشد (Aljarah *et al.*, 2016). یکی از جدیدترین الگوریتم‌های جستجوی جهانی که به منظور برطرف نمودن ضعف‌های آموزش شبکه عصبی مصنوعی گسترش یافته است الگوریتم بهینه‌سازی وال<sup>۳</sup> می‌باشد (Mirjalili and Lewis, 2016). این الگوریتم بر اساس روش جالب و منحصر به فرد تغذیه نهنگ کوهان‌دار شبیه‌سازی شده است.

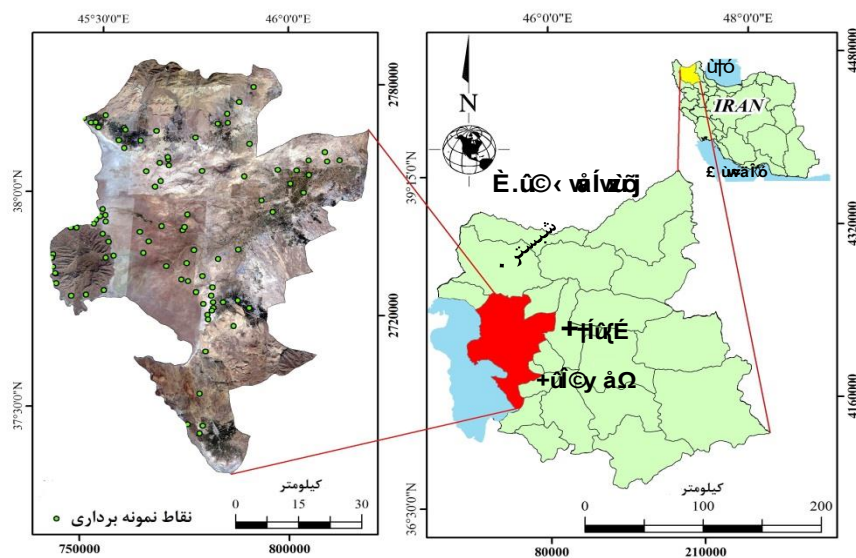
الگوریتم بهینه‌سازی وال در مقایسه با دیگر الگوریتم‌های جستجوی جهانی دارای مزیت‌هایی می‌باشد که این مزیت‌ها شامل تعداد پارامترهای داخلی اصلی کمتر، اجرای آسان و انعطاف‌پذیری بالای آن می‌باشد (Mafarja and Mirjalili, 2017 & 2018). سادگی اجرای الگوریتم وال و وابستگی کمتر این الگوریتم به پارامترها و همچنین توانایی پوشش مناطق مرزی فضای جستجو با استفاده از تابع لگاریتمی که حرکت مارپیچی حلزونی شکل را شبیه‌سازی می‌کند، محققان را بر آن داشته تا از

اولیه با استفاده از روش هیدرومتری (درصد ذرات شن، سیلت، رس، شن خیلی ریز، شن ریز، شن متوسط، شن درشت و شن خیلی درشت که به ترتیب دارای اندازه ۰/۰۵ تا ۲، ۰/۰۰۲ تا ۰/۰۵، ۰/۰۵ تا ۰/۲۵، ۰/۲۵ تا ۰/۱، ۰/۱ تا ۰/۰۵۳، ۰/۰۰۲ تا ۰/۰۵۳، ۰/۱ تا ۱، ۱ تا ۲ میلی متری می باشند) (Gee and Or, 2002)، جزء فرسایش پذیر خاک EF<sup>۲</sup> که عبارت است از درصد خاکدانه های کوچکتر از ۰/۸۵ میلی متر در خاک در حالت هواخشک (Lopez et al., 2007)، توزیع اندازه ذرات ثانویه به روش الک خشک توسط سری الک های ۰ تا ۰/۰۵۳، ۰/۰۵۳ تا ۰/۱، ۰/۱ تا ۰/۲۵، ۰/۲۵ تا ۰/۵، ۰/۵ تا ۰/۸۵، ۰/۸۵ تا ۱، ۱ تا ۱/۷، ۱/۷ تا ۲، ۲ تا ۴/۷۵ و ۴/۷۵ تا ۸ میلی متری (Kemper and Rosenau, 1986)، کربن آلی با استفاده از روش والکلی-بلاک (Nelson and Sommers, 1982)، کربنات کلسیم معادل (Nelson, 1982)، هدایت الکتریکی (Sparks and Bartels, 1996)، میانگین وزنی قطر ذرات در حالت خشک (MWD) (Nimmo and Perkins, 2002) و نسبت جذب سدیم (SAR) (Sparks, 2003) تعیین شدند.

در این پژوهش به منظور تعیین بهترین ترکیب از متغیرهای مستقل به عنوان ورودی های مدل از رگرسیون خطی چندمتغیره به روش گام به گام و نرم افزار SAS استفاده گردید. به منظور مدل سازی فرسایش پذیری بادی با استفاده از روش های هوش مصنوعی مدنظر در این پژوهش نیز از نرم افزار MATLAB R2014b استفاده شد.

شرقی و ۳۸° 17' و ۳۷° 56' شمالی واقع شده است (شکل ۱). این منطقه بر اساس میانگین دمای ۱۲/۸ درجه سانتی گراد و میانگین بارندگی ۲۳۰/۷ میلی متر در سال دارای آب و هوای سرد و خشک بوده و یکی از مناطق مستعد فرسایش بادی به شمار می رود (Barzegar et al., 2015). منطقه مورد مطالعه مساحتی برابر با ۴۱۴۰۰۰ هکتار را در بر می گیرد که شامل کاربری های اراضی مختلفی از قبیل اراضی زراعی، اراضی باغی، اراضی مرتعی و همچنین بستر خشک شده دریاچه ارومیه می باشد. به منظور تعیین فرسایش پذیری بادی خاک های منطقه، ۹۶ نمونه خاک در محدوده ی مورد بررسی جمع آوری شد. الگوی پراکندگی نقاط نمونه برداری بر مبنای روش تصادفی نظارت شده<sup>۱</sup> تعیین شد (شکل ۱). نمونه برداری از منطقه در خرداد ماه ۱۳۹۶ انجام و نمونه های خاک با مراجعه به محل جغرافیایی نقاط تعیین شده، با استفاده از یک بیل چهارگوش از سطح خاک تا عمق پنج سانتی متری خاک جمع آوری شدند (Lopez et al., 2007). نمونه های جمع آوری شده از منطقه پس از انتقال به آزمایشگاه، هواخشک شده و از الک هشت میلی متری عبور داده شدند. برای هر نقطه حدود ۲۰ کیلوگرم از نمونه خاک برای اندازه گیری فرسایش پذیری بادی در تونل باد جداسازی گردید.

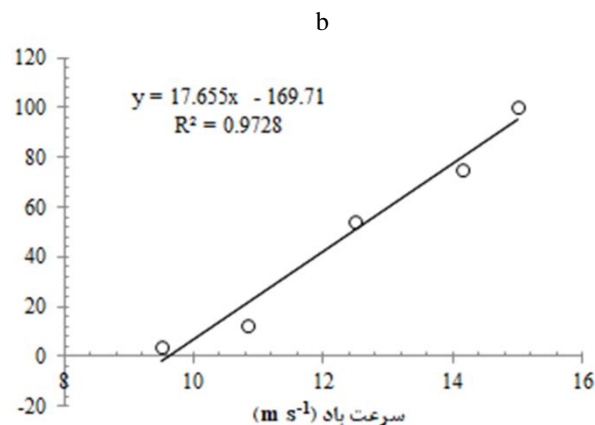
بخشی از نمونه های خاک، از الک دو میلی متری عبور داده شد و ویژگی های فیزیکی و شیمیایی آنها اندازه گیری شد. ویژگی های فیزیکی و شیمیایی خاک ها از قبیل توزیع اندازه ذرات



شکل ۱- محدوده ی منطقه مورد مطالعه و نقاط نمونه برداری

سرعت باد در تونل با استفاده از دستگاه سرعت سنج -HOT WIRE-1341 در ارتفاع ۲۰ سانتی متری از سطح خاک اندازه گیری شد. به منظور اندازه گیری فرسایش پذیری بادی در تونل باد، هر نمونه در هر تکرار به مدت ۱۰ دقیقه در معرض یکی از سرعت های ۹/۵، ۱۱، ۱۲/۵، ۱۴/۱ و ۱۵ متر بر ثانیه قرار داده شده (این سرعت ها بر اساس سرعت آستانه نمونه ها و حداکثر توان تونل باد در ایجاد سرعت باد انتخاب شدند) و شدت فرسایش خاک ( $gr\ m^{-2}\ min^{-1}$ ) تحت هر یک از سرعت های باد محاسبه گردید. در نهایت فرسایش پذیری بادی هر نمونه از طریق محاسبه شیب خط نمودار شدت فرسایش در مقابل سرعت باد تعیین شد (شکل ۲) (Zamani and Mahmoodabadi, 2013). در مجموع برای اندازه گیری فرسایش پذیری تمامی نمونه های خاک، ۴۸۰ آزمایش در تونل بادی انجام شد.

تعیین فرسایش پذیری بادی خاک در تونل باد آزمایش های مربوط به تعیین فرسایش پذیری بادی نمونه های خاک با استفاده از دستگاه تونل بادی گروه علوم و مهندسی خاک دانشگاه تبریز صورت گرفت (شکل ۲). این تونل متشکل از سه قسمت شامل بخش مولد باد که توانایی تولید حداکثر سرعتی معادل ۱۵ متر بر ثانیه در ارتفاع ۲۰ سانتی متری از سطح را دارد (شامل موتور، پروانه های ایجاد باد، بخش تنظیم کننده سرعت باد)، دیفیوژر یا پخش کننده سرعت باد که در فاصله ۱۶۰ سانتی متری از قسمت مولد باد قرار گرفته و باعث ایجاد باد یکنواخت و پایدار می شود و در نهایت محفظه آزمایش است. محفظه آزمایش در این تونل شامل یک تونل با عرض ۵۰، ارتفاع ۷۰ و طول ۳۷۰ سانتی متر است که سینی های آزمایش با ابعاد  $3 \times 40 \times 30$  سانتی - متر در این قسمت جای گذاری می گردند.



شکل ۲- (a) تونل باد، (b) اندازه گیری فرسایش پذیری بادی به عنوان شیب خط رابطه بین شدت فرسایش بادی و سرعت باد

شبکه عصبی مصنوعی در پیش بینی فرآیندهایی که روند غیرخطی داشته و شناخت کاملی از چگونگی رخداد آنها وجود ندارد مناسب می باشد (Jamalizadeh Tajabadi, 2010). در یک شبکه عصبی مصنوعی، نرون ها به عنوان کوچک ترین واحد پردازشگر داده ها، اساس عملکرد شبکه های عصبی را تشکیل می دهند. یک شبکه عصبی مصنوعی مجموعه ای از نرون ها است که با قرار گرفتن در لایه های مختلف، معماری خاصی را بر مبنای ارتباطات بین نرون ها در لایه های مختلف تشکیل می دهند. یک نرون با استفاده از یک تابع واکنش، مقدار خروجی خاصی را به ازای ورودی های مختلف تولید می کند (Menhaj, 2018). اجرای شبکه عصبی مصنوعی شامل سه بخش است. اولین بخش تعیین تعداد لایه های ورودی و خروجی است که تعداد این عوامل ورودی و خروجی با توجه به شرایط حاکم بر مسئله، بانک اطلاعاتی موجود و عوامل موثر تعیین می شوند. دومین بخش آن تعیین

## الگوریتم های هوش مصنوعی


### شبکه عصبی مصنوعی

شبکه های عصبی مصنوعی الگویی برای پردازش اطلاعات می باشند که با تقلید از شبکه بیولوژیکی مغز انسان ساخته شده اند (Kaunda, 2015; Ryan et al., 2013). توانایی این شبکه ها در کشف روابط غیرخطی میان داده های ورودی و همچنین استخراج مدل دینامیک غیرخطی حاکم بر داده ها قابل ملاحظه می باشد و در مقایسه با مدل های مرسوم به ورودی های کمتر و تلاش محاسباتی کمتری نیاز دارند (Hashimoto, 1997). در این روش نیازی به اطلاعات قبلی و یا فرضیات وجود ندارد و این شبکه ها قادر به یادگیری از طریق داده های آزمایشگاهی (حتی در صورت وجود نقص یا بی نظمی) می باشند. شبکه های عصبی انعطاف پذیر و سازگار می باشند و بنابراین می توانند در مدل سازی مسائل محیطی مفید واقع گردند (Keshavarzi and Sarmadian, 2010).

فضای جواب به طور همه جانبه جستجو می‌شود، احتمال کمتری برای هم‌گرایی به یک نقطه بهینه محلی وجود خواهد داشت (Kantardzic, 2011; Galletly, 1992).

### الگوریتم بهینه‌سازی وال

الگوریتم بهینه‌سازی وال (WOA) یکی از جدیدترین الگوریتم‌های متاهیوریستیک می‌باشد که توسط Mirjalili and Lewis (2016) معرفی شده است. این الگوریتم بر اساس شبیه‌سازی روش جالب و منحصر به فرد تغذیه نهنگ کوهان‌دار کدنویسی شده است. این نهنگ‌ها از روش منحصر به فردی برای شکار و تغذیه استفاده می‌کنند که به روش تغذیه‌ای شبکه حباب<sup>۱</sup> معروف می‌باشد (شکل ۳). در این روش نهنگ‌های کوهان‌دار به دور دسته‌ی ماهی‌ها و یا کریل‌های چرخند و شبکه‌ای از حباب ایجاد می‌کنند که این حباب‌ها همانند یک قفس عمل می‌نمایند. این عمل در یک شکل دورانی انقباضی<sup>۲</sup> و یک مسیر حلزونی شکل<sup>۴</sup> انجام می‌شود (شکل ۳). الگوریتم بهینه‌سازی وال از این روش شکار نهنگ کوهان‌دار اقتباس شده و شامل دو فاز می‌باشد: ۱- فاز بهره‌وری<sup>۵</sup> (جستجوی همسایگی) که شامل چرخیدن به دور طعمه یا شکار و ایجاد یک شبکه حباب به دور آن در یک مسیر دایره‌ای انقباضی و حلزونی شکل می‌باشد، ۲- فاز اکتشاف<sup>۶</sup> (جستجوی تصادفی) که شامل جستجوی تصادفی برای طعمه یا شکار می‌باشد (Mirjalili and Lewis, 2016).



شکل ۳- روش شکار نهنگ کوهان‌دار با استفاده از ایجاد شبکه حباب به دور شکار

نهنگ کوهان‌دار هم‌زمان در یک مسیر دورانی انقباضی و یک مسیر حلزونی شکل به دور شکار می‌چرخد. در این الگوریتم به منظور مدل‌سازی این دو مکانیسم در فاز بهره‌وری، در طول پروسه بهینه‌سازی یک احتمال ۵۰ درصدی برای انتخاب میان این دو مکانیسم در نظر گرفته می‌شود:

(رابطه ۱)

$$\vec{X}(t+1) = \begin{cases} \vec{X}^*(t) - \vec{A} \cdot \vec{D} & \text{Shrinking Encircling if } (p < 0.5) \\ D^i \cdot e^{bt} \cdot \cos(2\pi t) + \vec{X}^*(t) & \text{spiral-shaped path if } (p \geq 0.5) \end{cases}$$

تعداد لایه‌های پنهان است، لایه پنهان نقش عمده‌ای در قدرت شبکه دارد و سومین بخش شبکه عصبی آموزش و آزمایش شبکه است. منظور از آموزش در شبکه عصبی مصنوعی تنظیم وزن پارامترهای ورودی شبکه است. ارتباط بین هر کدام از نرون‌ها از طریق مقدار وزن می‌باشد. در فرآیند آموزش ورودی‌های مربوط به بخشی از بانک اطلاعاتی به شبکه ارائه می‌شود، مقادیر خروجی محاسبه شده و با مقادیر هدف مقایسه شده و با توجه به مقدار خطا وزن‌ها اصلاح می‌شوند. پس از پایان این مرحله مقادیر وزن‌ها ذخیره شده و شبکه برای بخش دیگری از داده‌ها که در مرحله آموزش استفاده نشده‌اند آزمایش می‌شوند (Cook et al., 2000; Ryan et al., 2013). شبکه عصبی مصنوعی آموزش‌یافته بیش‌ترین وزن را به متغیری خواهد داد که بیشترین تاثیر را در خروجی داشته باشد (Menhaj, 2018).

### الگوریتم ژنتیک

الگوریتم ژنتیک یکی از روش‌های بهینه‌سازی و جستجو می‌باشد که بر اساس نحوه تکامل ژنتیکی موجودات زنده به حل مسائل مختلف می‌پردازد. طی دهه اخیر الگوریتم‌های ژنتیک به طور گسترده‌ای در حوزه وسیعی از مسایل علوم و مهندسی به عنوان ابزارهای جستجو و بهینه‌سازی بکار گرفته شده‌اند. الگوریتم‌های ژنتیک یکی از اعضای خانواده مدل‌های محاسباتی می‌باشد که الهام گرفته از روند تکامل می‌باشند (Sexton and Gupta, 2000). این الگوریتم‌ها راه‌حل‌های بالقوه یک مسأله را در قالب کروموزوم-های ساده‌ای کدگذاری می‌کنند و سپس عملگرهای ترکیبی (آمیزش و جهش) را بر روی این ساختارها اعمال می‌کنند. الگوریتم‌های ژنتیک اغلب به عنوان روشی برای بهینه‌سازی توابع شناخته می‌شوند که البته دامنه استفاده از این روش‌ها بسیار گسترده‌تر از این می‌باشد (Kantardzic, 2011). در الگوریتم ژنتیک هیچ محدودیتی برای تابع بهینه شونده مانند مشتق‌پذیری وجود ندارد و در روند جستجوی خود تنها به تعیین مقدار تابع هدف در نقاط مختلف نیاز دارد و از اطلاعات کمکی دیگری مثل مشتق تابع استفاده نمی‌کند. بنابراین می‌تواند در مسائل مختلف اعم از خطی، پیوسته یا گسسته استفاده گردد و به سهولت با مسائل مختلف قابل تطبیق می‌باشد (Kantardzic, 2011). الگوریتم ژنتیک به عنوان یک الگوریتم محاسباتی بهینه‌سازی با در نظر گرفتن مجموعه‌ای از نقاط فضای جواب در هر تکرار محاسباتی به نحو مؤثری نواحی مختلف فضای جواب را جستجو می‌کند. از آنجایی که در این روش برخلاف روش‌های تک مسیری

4- Spiral-Shape Path  
5- Exploitation  
6- Exploration

1- Bubble-net Feeding Method  
2- Kill  
3- Shrinkage Circle

مشخص در ابتدا با ایجاد یک مجموعه از راه حل های تصادفی (که جمعیت نامیده می شود) آغاز می گردد، در این الگوریتم هر راه حل یا عامل جستجو در واقع نماینده موقعیت یک نهنگ کوهان دار می باشد. هر یک از راه حل ها با استفاده از یک تابع برازش ارزیابی می گردد و بهترین راه حل در جمعیت با نام  $X^*$  (شکار) مشخص می شود. در هر تکرار موقعیت راه حل ها بر اساس انتخاب تصادفی یک عامل جستجو یا بهترین راه حل به دست آمده تاکنون به روزرسانی می شود. در اینجا به منظور فراهم کردن فاز اکتشاف و فاز بهره وری، پارامتر  $a$  از ۲ تا ۰ کاهش می یابد و برای به روزرسانی موقعیت راه حل ها وقتی که  $|\vec{A}| < 1$  باشد بهترین راه حل انتخاب می شود و از طرفی وقتی که  $|\vec{A}| > 1$  باشد یک راه حل به صورت تصادفی انتخاب می گردد. الگوریتم بهینه سازی وال با توجه به مقدار  $p$  بین حرکت دایره ای و حلزونی ارتباط برقرار می کند. در نهایت الگوریتم بهینه سازی وال با دستیابی به یک مقدار مناسب از معیار خاتمه که از پیش تعریف شده است، پایان می یابد. به طور نظری از آنجایی که الگوریتم بهینه سازی وال توانایی انجام هر دو عمل بهره وری و اکتشاف را دارا است، می توان آن را به عنوان یک بهینه ساز جهانی در نظر گرفت (Aljarah et al., 2016; Mirjalili and Lewis, 2016).

#### معیارهای ارزیابی

کارایی روش های مختلف مدل سازی و پیش بینی فرسایش پذیری بادی منطقه مورد مطالعه با استفاده از چهار آماره صحت سنجی شامل ضریب تبیین  $R^2$ ، میانگین خطا  $ME$ ، جذر میانگین مربعات خطا  $RMSE$  و ضریب کارایی نش-ساتکلیف  $NSE$  مورد بررسی قرار گرفت:

$$NSE = 1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (\text{رابطه ۶})$$

$$RMSE = \sqrt{\frac{\sum (O_i - P_i)^2}{n}} \quad (\text{رابطه ۷})$$

$$ME = \frac{\sum (O_i - P_i)}{n} \quad (\text{رابطه ۸})$$

$$R^2 = \frac{[\sum_{i=1}^n (O_i - \bar{O})(P_i - \bar{P})]^2}{\sum_{i=1}^n (O_i - \bar{O})^2 \sum_{i=1}^n (P_i - \bar{P})^2} \quad (\text{رابطه ۹})$$

در این روابط  $O_i$  فرسایش پذیری اندازه گیری شده در تونل بادی،  $\bar{O}$  میانگین فرسایش پذیری بادی اندازه گیری شده،  $P_i$  فرسایش پذیری پیش بینی شده توسط مدل مورد نظر،  $n$  تعداد نمونه می باشد. آماره های گوناگون بر خطاهای رفتاری متفاوت تاکید دارند (Abbasi et al., 2011). در شکل (۴) مراحل انجام پژوهش حاضر به طور خلاصه ارائه شده است.

در اینجا،  $t$  شماره تکرار،  $\vec{A}$  ضریب بردار،  $X^*$  موقعیت بردار بهترین راه حلی که تاکنون به دست آمده،  $\vec{X}$  موقعیت بردار،  $p$  یک عدد تصادفی در محدوده  $[0, 1]$ ،  $b$  یک ضریب ثابت برای تعریف شکل مارپیچ لگاریتمی و  $l$  عددی تصادفی است که در فاصله  $[1, -1]$  انتخاب می گردد. در معادله مربوط به حرکت دایره شکل انقباضی،  $\vec{D}$  با استفاده از رابطه  $\vec{D} = |\vec{C} \cdot \vec{X}^*(t) - \vec{X}(t)|$  به دست می آید که در اینجا  $C$  ضریب بردار می باشد. همچنین در رابطه (۱)، فاصله بین موقعیت نامین راه حل با بهترین راه حلی که تا کنون به دست آمده می باشد که این فاصله با استفاده از رابطه  $D' = |\vec{X}^*(t) - \vec{X}(t)|$  محاسبه می شود. ضرایب  $A$  و  $C$  نیز با استفاده از روابط زیر محاسبه می شوند:

$$\vec{A} = 2\vec{a} \cdot \vec{r} - \vec{a} \quad (\text{رابطه ۲})$$

$$\vec{C} = 2 \cdot \vec{r} \quad (\text{رابطه ۳})$$

در اینجا مقدار  $a$  در طول تکرارها به صورت خطی از دو تا صفر کاهش می یابد (در هر دو فاز) و  $r$  یک بردار تصادفی می باشد که در فاصله  $[0, 1]$  ایجاد شده است (Mirjalili and Lewis, 2016).

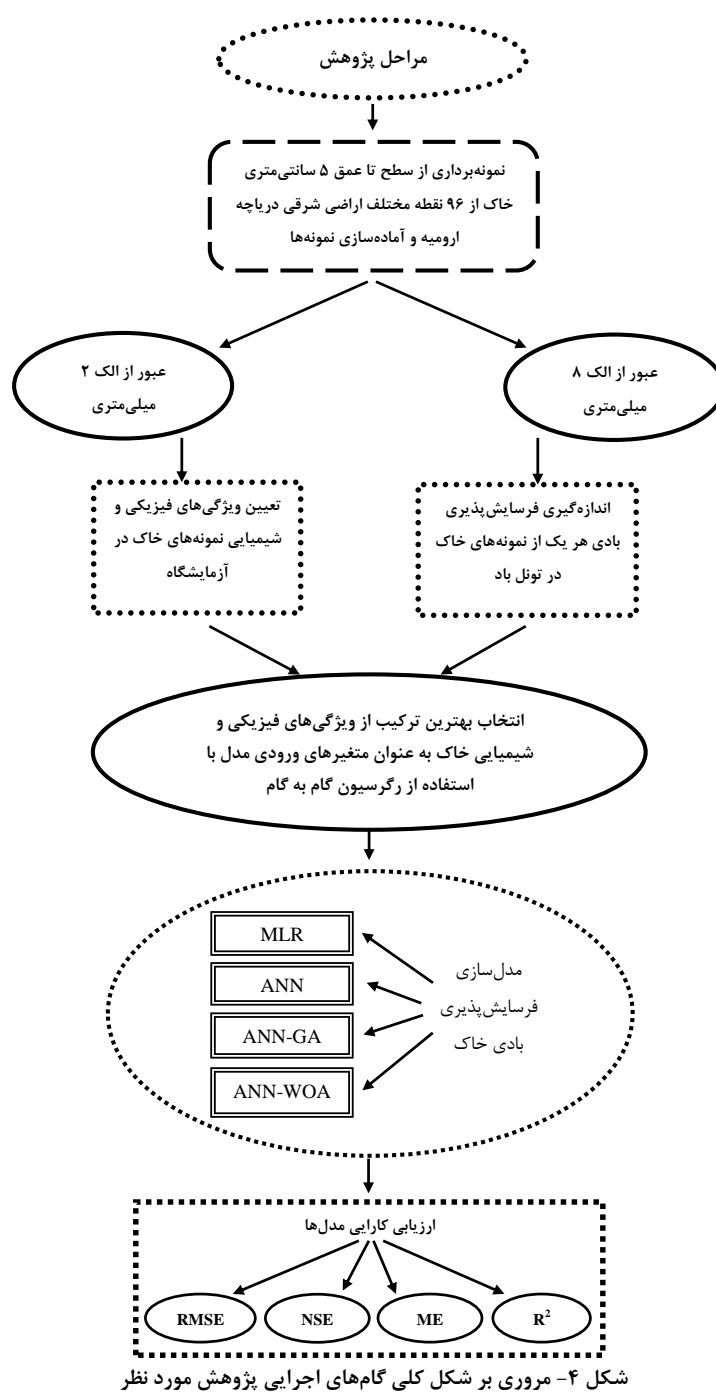
از آنجایی که نهنگ های کوهان دار جستجوی تصادفی را بر اساس موقعیت یکدیگر انجام می دهند؛ به منظور تقویت فاز اکتشاف، در الگوریتم بهینه سازی وال به روزرسانی موقعیت هر راه حل بر اساس انتخاب تصادفی عامل جستجو انجام می شود (و نه بر اساس بهترین راه حل به دست آمده که در فاز بهره وری استفاده می شود). به منظور حرکت راه حل ها به مناطق دورتر از بهترین راه حلی که تا کنون شناخته شده، در فاز جستجو از یک بردار  $A$  با مقادیر تصادفی بزرگتر از ۱ و کوچکتر از -۱ استفاده می شود. در این فاز، به روز رسانی موقعیت راه حل ها بر اساس انتخاب تصادفی و همچنین استفاده از بردار  $|\vec{A}| > 1$  منجر به تقویت جستجوی بهینه می شود و این دو مکانیسم تضمین کننده اجرای یک جستجوی بهینه جهانی در الگوریتم بهینه سازی وال می باشند. این مکانیسم ها می توانند به صورت معادله زیر نمایش داده شوند:

$$\vec{D} = |\vec{C} \cdot \vec{X}_{rand} - \vec{X}| \quad (\text{رابطه ۴})$$

$$\vec{X}(t+1) = \vec{X}_{rand} - \vec{A} \cdot \vec{D} \quad (\text{رابطه ۵})$$

در اینجا  $\vec{X}_{rand}$  یک راه حل انتخاب شده از جمعیت جاری می باشد که به طور تصادفی انتخاب شده است (یک بردار موقعیت تصادفی) (Mirjalili and Lewis, 2016).

به طور خلاصه، در الگوریتم وال، بهینه سازی یک مسئله



## نتایج و بحث

### انتخاب متغیرهای ورودی مدل

توصیف آماری ویژگی های خاک در جدول (۱) ارائه شده است. همان طور که مشاهده می شود اکثر ویژگی های مورد نظر از تغییرات بالایی در منطقه مورد مطالعه برخوردار بوده و این امر می تواند تضمین کننده انعکاس اثر تغییرات این ویژگی های خاک بر فرسایش پذیری بادی باشد. خاک های منطقه از لحاظ بافت، کاربری اراضی و درجه شوری از تنوع بالایی برخوردار بود. در این منطقه تنوع بافتی از قبیل خاک رسی، لومی رسی، شنی لومی،

شنی، لوم رسی شنی، لوم شنی، لوم سیلتی، رسی سیلتی، لومی رسی سیلتی مشاهده شد و از لحاظ کاربری اراضی نیز این منطقه به اراضی زراعی، مرتعی، باغات و بستر خشک شده دریاچه ارومیه تقسیم می شود. همچنین به لحاظ تغییرات شوری خاک، نسبت جذب سدیم و اسیدیته نیز دارای تنوع مناسبی بود به گونه ای که حدود نیمی از نمونه ها در رده خاک های شور و یا خاک های شور و سدیمی قرار می گرفت. فرسایش پذیری بادی خاک در این منطقه از تغییرات و تنوع مناسبی برخوردار بود به گونه ای که میانگین، حداکثر و حداقل مقدار فرسایش پذیری بادی در منطقه



مذکور با استفاده از سری داده‌های آزمون مورد ارزیابی قرار گرفت که نتایج معیارهای ارزیابی  $R^2$ ، NSE، RMSE و ME برای داده‌های آزمون به ترتیب برابر ۰/۷، ۰/۶۶، ۴/۷ و ۰/۳۵ بود.

#### شبکه عصبی مصنوعی

با توجه به توانایی شبکه عصبی مصنوعی در کاهش مشکلات موجود در زمینه مدل‌سازی و پیش‌بینی مباحث پیچیده‌ای از قبیل فرسایش‌پذیری بادی، در این بخش به بررسی کارایی این روش در مدل‌سازی و پیش‌بینی فرسایش‌پذیری خاک در منطقه مورد مطالعه پرداخته شد. از آنجایی که داده‌های ورودی و خروجی مدل شامل ویژگی‌های مختلف با معانی فیزیکی، دامنه و واحدهای متفاوت می‌باشند، در ابتدا به منظور یکسان‌سازی مقیاس داده‌ها، از داده‌های استاندارد شده به عنوان ورودی‌های شبکه عصبی استفاده گردید. در این پژوهش از یک ساختار محبوب شبکه عصبی به نام پرسپترون چندلایه<sup>۴</sup> (MLP) استفاده شد که این شبکه به همراه الگوریتم آموزشی پس انتشار خطا<sup>۵</sup> (BP) به کار گرفته شد. پارامترهای شبکه عصبی به منظور دست‌یابی به بهترین ساختار از طریق سعی و خطا و با در نظر گرفتن عملکرد و کارایی آن‌ها مورد ارزیابی قرار گرفتند. در نهایت با استفاده از روش سعی و خطا و در نظر گرفتن ترکیبات مختلف از پارامترهای مذکور بهترین کارایی شبکه عصبی مصنوعی به منظور پیش‌بینی فرسایش‌پذیری بادی با استفاده از تابع آموزشی TRAINLM، تابع آموزشی تطبیقی LEARNGDM و تابع عملکرد MSE حاصل شد. معماری شبکه عصبی مصنوعی مورد استفاده شامل یک لایه میانی و یک لایه خروجی بوده است. تعداد نرون‌های لایه میانی نیز با سعی و خطا و در نظر گرفتن تعداد مختلفی مشخص شده است که پس از بررسی و مقایسه نتایج، شبکه عصبی مصنوعی با تعداد نرون لایه میانی برابر با پنج بهترین نتیجه را ارائه داد. تابع انتقال یا محرک برای لایه میانی TANSIG و برای لایه خروجی PURELIN انتخاب گردید. در نهایت معماری شبکه عصبی مصنوعی مطابق با شکل (۵) صورت گرفت.

پس از تعیین مشخصات شبکه عصبی مصنوعی، این شبکه با استفاده از ۷۰ درصد داده‌ها آموزش داده شد که تغییرات میانگین مربعات خطا در شکل (۶) ارائه شده است. پس از آموزش شبکه، به منظور شبیه‌سازی، از ۳۰ درصد داده‌هایی که به منظور آزمون انتخاب شده بود استفاده گردید. بر اساس نتایج، شبکه عصبی توانایی تبیین ۷۸ درصد از تغییرات فرسایش‌پذیری منطقه

برابر ۱۰/۳۲، ۴۹/۹۸ و ۰/۷۶۳  $((\text{gr m}^{-2} \text{ min}^{-1})/(\text{m s}^{-1}))$  بوده است.

با توجه به این که مهم‌ترین اصل در مدل‌سازی، ارائه مدلی ساده با تعداد متغیرهای ورودی کم و با کارایی بالا می‌باشد، بنابراین در ابتدای کار می‌بایست بهترین ترکیب از ویژگی‌های فیزیکی و شیمیایی خاک به عنوان متغیرهای ورودی مدل انتخاب شود. به منظور دستیابی به این هدف از رگرسیون گام به گام<sup>۱</sup> (ترکیبی از دو روش پیش‌خور<sup>۲</sup> و پس‌خور<sup>۳</sup>) استفاده شد که بر اساس آن از بین ۳۲ ویژگی خاک تنها چهار ویژگی به عنوان بهترین ترکیب از متغیرهای مستقل به عنوان ورودی مدل انتخاب شد. این چهار متغیر عبارتند از: درصد ذرات ثانویه ۰/۱ تا ۰/۲۵ میلی‌متری ( $\text{SPS}_8$ )، درصد ذرات اولیه شن ریز ( $\text{FS}$ )، درصد ذرات ثانویه ۱/۷ تا ۲ میلی‌متری ( $\text{SPS}_3$ ) و درصد کربن آلی خاک ( $\text{OC}$ ). همچنین شرط نرمال بودن باقیمانده داده‌ها نیز مورد بررسی قرار گرفت که از این لحاظ باقیمانده داده‌ها نرمال بود. مراحل انجام رگرسیون گام به گام در جدول (۲) ارائه شده است. با توجه به جدول (۲) اولین ویژگی خاک که به عنوان متغیر ورودی مدل در نظر گرفته شده است، درصد کلاس اندازه‌ای ذرات ثانویه ۰/۱ تا ۰/۲۵ میلی‌متری می‌باشد که توانایی تبیین ۶۵ درصد از تغییرات فرسایش‌پذیری بادی خاک منطقه مورد مطالعه را دارا است. در مقایسه با دیگر ویژگی‌های خاک که وارد مدل شده‌اند، کلاس اندازه‌ای مذکور از تأثیرگذاری بالایی در مدل برخوردار می‌باشد که نشان‌دهنده اهمیت بالای این ویژگی خاک در تعیین فرسایش‌پذیری بادی در خاک‌های اراضی شرقی دریاچه ارومیه می‌باشد.

پس از تعیین متغیرهای ورودی مدل، نمونه‌های خاک به گونه‌ای به دو قسمت تقسیم شدند که ۷۰ درصد از داده‌ها (۶۷ نمونه) برای قسمت آموزش (واسنجی) و ۳۰ درصد از داده‌ها (۲۹ نمونه) برای آزمون (اعتبارسنجی) مدل در نظر گرفته شدند. در نهایت با استفاده از داده‌های قسمت آموزش و با در نظر گرفتن متغیرهای ورودی، مدل رگرسیونی خطی چند متغیره (MLR) زیر بسط و گسترش داده شد:

(رابطه ۱۰)

$$E = 5.43 - 0.34 \text{ FS} - 2.07 \text{ SPS}_3 + 1.14 \text{ SPS}_8 + 2.54 \text{ OC}$$

در اینجا، WE فرسایش‌پذیری بادی خاک  $(\text{gr m}^{-2} \text{ min}^{-1})$

می‌باشد. پس از بسط و گسترش مدل رگرسیونی خطی چند متغیره با استفاده از داده‌های آموزشی، کارایی مدل

مقدار کمتر RMSE (۳/۷۸)، مقدار بیشتر NSE (۰/۷۷) و مقدار ME نزدیکتر به صفر (۰/۱۵) مدل MLP، این مدل توانایی بهتری در شناسایی و مدل‌سازی روابط پیچیده غیرخطی بین ورودی‌های مدل و فرسایش‌پذیری بادی داشته است.


مورد نظر را داشته است که این نشان‌دهنده توانایی مناسب آن در مدل‌سازی و پیش‌بینی فرسایش‌پذیری بادی خاک است. با توجه به این که ضریب تبیین در مدل MLP یک افزایش ۱۱ درصدی در مقایسه با مدل MLR داشته و همچنین با توجه به

جدول ۱- ویژگی‌های آماری ویژگی‌های فیزیکی و شیمیایی نمونه‌های خاک

ویژگی خاک	علامت اختصاری	بیشینه	کمینه	میانگین	انحراف معیار	ضریب تغییرات (%)
فرسایش‌پذیری بادی ((gr m <sup>-2</sup> min <sup>-1</sup> )/(m s <sup>-1</sup> ))	WE	۴۹/۹۸	۰/۷۶	۱۰/۲۳	۹/۷	۹۵
رس	CL	۶۴	۱/۶۶	۲۶/۷۸	۱۴/۶۸	۵۵
سیلت	SI	۸۱	۲/۶	۳۹/۶۷	۱۵/۳۹	۳۹
شن	SA	۹۱/۶۱	۲	۳۳/۵۳	۲۴/۷۸	۷۴
شن خیلی ریز	VFS	۳۹/۵	۰/۲۱	۱۰/۳۹	۶/۷۴	۶۵
شن ریز	FS	۳۵/۵	۰/۱۸	۹/۰۱	۸/۹۶	۹۹
شن متوسط	MS	۲۷/۶۸	۰/۱۲	۶/۳۱	۷/۱۵	۱۱۳
شن درشت	CS	۲۴/۲۲	۰	۳/۹۳	۵/۱۲	۱۳۰
شن خیلی درشت	VCS	۱۴/۶	۰	۲/۰۴	۳/۰۸	۱۵۱
جزء فرسایش‌پذیر (%)	EF	۹۰/۹۳	۱۶/۴۱	۵۳/۵۳	۱۷/۰۳	۳۲
۴/۷۵ تا ۸ میلی‌متر	SPS <sub>1</sub>	۲۶/۷۴	۱	۸/۶۱	۵/۴۶	۶۳
۲ تا ۴/۷۵ میلی‌متر	SPS <sub>2</sub>	۴۰/۹	۲/۸۲	۱۸/۶۱	۸/۸۸	۴۸
۱/۷ تا ۲ میلی‌متر	SPS <sub>3</sub>	۹/۲۶	۰/۷۸	۴	۱/۶	۴۰
۱ تا ۱/۷ میلی‌متر	SPS <sub>4</sub>	۲۵/۱۵	۲/۷۸	۱۳/۴۱	۴/۳۴	۳۲
۰/۸۵ تا ۱ میلی‌متر	SPS <sub>5</sub>	۳/۴	۰/۳۴	۱/۸	۰/۶۳	۳۵
۰/۵ تا ۰/۸۵ میلی‌متر	SPS <sub>6</sub>	۳۳/۳۹	۵/۵۵	۱۶/۱۳	۵/۶۹	۳۵
۰/۲۵ تا ۰/۵ میلی‌متر	SPS <sub>7</sub>	۳۳/۵۹	۴/۳۵	۱۵/۱۴	۶/۶۷	۴۴
۰/۱ تا ۰/۲۵ میلی‌متر	SPS <sub>8</sub>	۳۷/۱۲	۱/۷۶	۱۱/۹	۷/۵۳	۶۳
۰/۰۵۳ تا ۰/۱ میلی‌متر	SPS <sub>9</sub>	۲۳/۸۵	۰/۵۹	۶/۹۳	۴/۸۹	۷۱
۰ تا ۰/۰۵۳ میلی‌متر	SPS <sub>10</sub>	۱۲/۵۸	۰/۴	۳/۳۸	۲/۶۲	۷۸
کربن آلی (%)	OC	۴/۳۸	۰/۰۹۷	۰/۹۷	۰/۷۳	۷۵
کربنات کلسیم معادل (%)	ECC	۴۹	۷/۶	۲۳/۵۴	۷/۴۹	۳۲
هدایت الکتریکی عصاره اشباع (ms m <sup>-1</sup> )	EC <sub>sa</sub>	۲۰۰	۰/۶۲	۴۲/۳۹	۵۷/۴۶	۱۳۶
هدایت الکتریکی عصاره ۱:۵ (ms m <sup>-1</sup> )	EC <sub>1:5</sub>	۵۳/۸	۰/۰۹	۶/۹۷	۱۰/۷۴	۱۵۴
pH	pH	۹/۱۱	۷/۰۱	۸/۲۸	۰/۴۹	۶
رطوبت هواخشک (%)	SM	۷/۳	۰/۵۹	۲/۷۳	۱/۶۶	۶۱
Ca <sup>2+</sup> (mmol l <sup>-1</sup> )	Ca	۲۰۳	0.87	۳۰/۸۸	۴۰/۴۴	۱۳۱
Mg <sup>2+</sup> (mmol l <sup>-1</sup> )	Mg	۲۴۵/۸۳	۰/۸۷	۴۲/۹۴	۶۱/۷۶	۱۴۴
Na <sup>+</sup> (mmol l <sup>-1</sup> )	Na	۳۳۹۶/۵	۱/۶۹	۴۷۳/۸۸	۷۴۳/۸۵	۱۵۷
نسبت جذب سدیم	SAR	۶۳۱/۶۲	۰/۴۲	۴۳/۳	۷۷/۸۶	۱۸۰
چگالی ظاهری خاک (gr cm <sup>-3</sup> )	Bd	۱/۷۴	۰/۸۵	۱/۳۳	۰/۱۷	۱۳
میانگین وزنی قطر (mm)	MWD	۲/۲۷	۰/۴۱	۱/۲۳	۰/۴	۳۲

جدول ۲- مراحل انجام رگرسیون گام به گام

مرحله	متغیر وارد شده در مدل	متغیر خارج شده از مدل	تعداد متغیر وارد شده در مدل	R <sup>2</sup> جزئی	R <sup>2</sup> مدل	C(p)	F Value	Pr>f
۱	SPS <sub>8</sub>	-	۱	۰/۶۵	۰/۶۵	۵۱/۵۸	۱۷۹/۴۸	> ۰/۰۰۰۱
۲	FS	-	۲	۰/۴۹	۰/۷	۳۳/۰۳	۱۵/۵۳	> ۰/۰۰۰۲
۳	SPS <sub>3</sub>	-	۳	۰/۲۱	۰/۷۲۷	۲۵/۸۶	۷/۴۱	> ۰/۰۰۷۸
۴	OC	-	۴	۰/۱۴	۰/۷۴۱	۲۱/۸۴	۵/۰۹	> ۰/۰۲۶۵




شکل ۵- ساختار شبکه عصبی مصنوعی با چهار متغیر ورودی، یک خروجی و دو لایه میانی

شبکه عصبی مصنوعی استفاده شد. به منظور بررسی کارایی الگوریتم ژنتیک در آموزش شبکه عصبی مصنوعی، ابتدا شبکه عصبی با استفاده از داده‌های قسمت آموزش و به وسیله الگوریتم ژنتیک تشکیل گردید. در این پژوهش تعداد جمعیت اولیه برابر ۱۰۰، حداکثر نسل برابر ۴۰۰ و تعداد گردش برابر با ۱۰۰۰ در نظر گرفته شد. پس از آموزش و ایجاد شبکه عصبی توسط الگوریتم ژنتیک، در نهایت عملکرد MLP-GA در پیش‌بینی فرسایش‌پذیری بادی خاک با استفاده از داده‌های قسمت آزمون بررسی شد. در مجموع با توجه به افزایش پنج درصدی ضریب تبیین (۰/۸۲)، کاهش ۱۱ درصدی مقدار RMSE (۳/۴۴)، افزایش شش درصدی NSE (۰/۸۲) و همچنین بهبود ۱۳ درصدی مقدار ME (-۰/۱۳) در مدل MLP-GA، این مدل در مقایسه با MLP از کارایی بهتری در مدل‌سازی و پیش‌بینی فرسایش‌پذیری بادی خاک در منطقه برخوردار بود.

علی‌رغم مطالعات مختلفی که تاکنون در زمینه بررسی کارایی الگوریتم ژنتیک در آموزش شبکه عصبی مصنوعی در علوم مختلف صورت گرفته است، مطالعه‌ای که در آن کارایی MLP-GA در زمینه فرسایش‌پذیری بادی مورد بررسی قرار گیرد، مشاهده نشده است. از طرفی مطالعات انجام شده در زمینه مدل‌سازی رواناب-بارش حاکی از کارایی مناسب الگوریتم ژنتیک در آموزش شبکه عصبی مصنوعی است (Jain and Srinivasulu, 2004). Taghizade Mehrjerdi et al. (2013) در مطالعه‌ای به پیش‌بینی شوری خاک با استفاده از روش‌های نروفازی، الگوریتم ژنتیک، شبکه عصبی و رگرسیون چند متغیره پرداختند. در این پژوهش روش نروفازی در پیش‌بینی شوری خاک دقت بالاتری نسبت به بقیه روش‌ها از خود نشان داد و شبکه عصبی هیبرید شده با الگوریتم ژنتیک نسبت به شبکه عصبی بدون بهینه‌سازی دقت بالاتری داشت. (Haghverdi et al., 2011) در مطالعه‌ای به مدل‌سازی منحنی مشخصه رطوبتی خاک با استفاده از مدل‌های مختلف هوش مصنوعی پرداختند. نتایج این مطالعه نشان داد که

مرور منابع نشان می‌دهد که تاکنون گزارشی در زمینه بررسی کارایی شبکه عصبی مصنوعی در پیش‌بینی فرسایش‌پذیری بادی خاک منتشر نشده است، اما مطالعات متعددی در زمینه بررسی کارایی شبکه عصبی در زمینه فرسایش خاک (آبی و بادی) و انتقال رسوب انجام گرفته است که حاکی از کارایی مناسب شبکه عصبی مصنوعی در مدل‌سازی و حل مسائل مختلف بوده است (Chebud et al., 2012; De-Gennaro et al., 2012; Kim et al., 2012). بر اساس نتایج (Jamalizadeh, 2009) Tajabadi et al. شبکه عصبی مصنوعی و ماشین‌بردار پشتیبان از کارایی خوبی در پیش‌بینی طوفان‌های گرد و خاک شهر زابل برخوردار بودند. نتایج (Ostovari et al., 2016) نیز نشان داد که شبکه عصبی مصنوعی در مقایسه با مدل‌های رگرسیونی و منطق فازی از کارایی مناسب‌تری در پیش‌بینی فرسایش‌پذیری خاک (در فرسایش آبی) برخوردار بود.



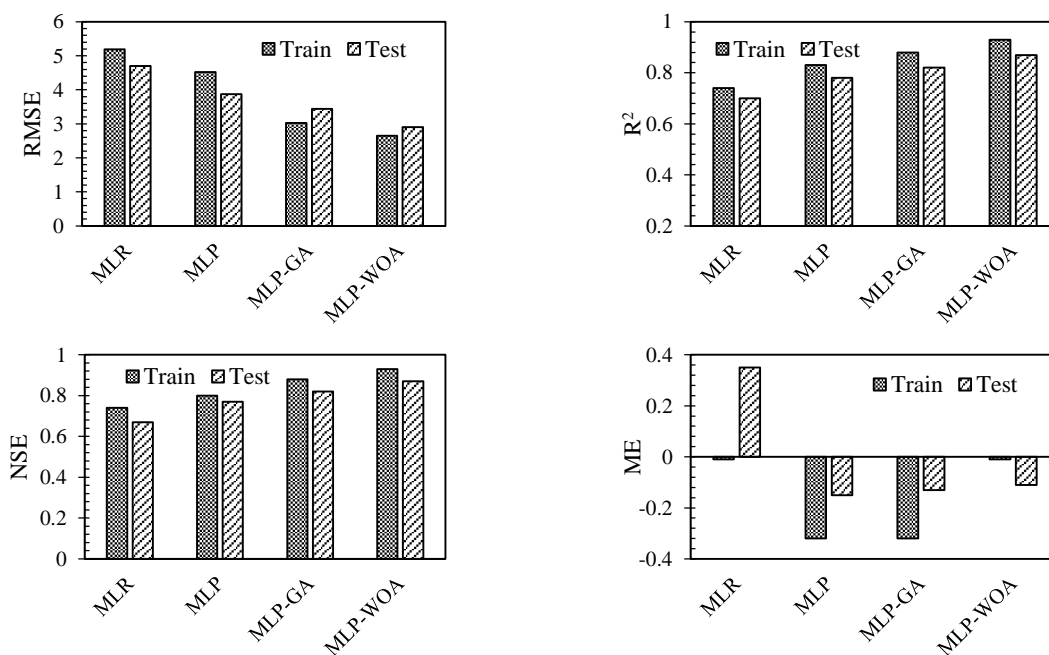
شکل ۶- تغییرات میانگین مربعات خطا در مرحله آموزش شبکه عصبی

شبکه عصبی مصنوعی هیبرید شده با الگوریتم ژنتیک با توجه به محدودیت‌های الگوریتم BP در آموزش شبکه عصبی که مهم‌ترین آن توقف در نقاط بهینه محلی و عدم دستیابی به راه‌حل بهینه جهانی است، برای برطرف نمودن این محدودیت و بدست آوردن راه‌حل بهینه جهانی از الگوریتم ژنتیک برای آموزش

پس از ایجاد شبکه و آموزش آن با الگوریتم وال، کارایی آن در پیش‌بینی فرسایش‌پذیری خاک با استفاده از داده‌های آزمون بررسی شد. مدل MLP-WOA توانایی تبیین ۸۷ درصد از تغییرات فرسایش‌پذیری بادی در منطقه را داشته که مقدار آن در مقایسه با مدل MLP افزایش ۱۲ درصدی داشته است که این افزایش نشان‌دهنده برتری الگوریتم بهینه‌سازی وال در آموزش شبکه عصبی در مقایسه با الگوریتم BP بوده است. همچنین مقدار RMSE مدل MLP-WOA (۲/۹) در مقایسه با مدل‌های MLP (۳/۸۷)، MLP-GA (۳/۴۴) و MLR (۴/۷) دارای مقدار کمتری بود. RMSE نشان‌دهنده اختلاف بین مقادیر اندازه‌گیری شده و مقادیر پیش‌بینی شده فرسایش‌پذیری خاک می‌باشد، و مقدار کمتر RMSE در مدل MLP-WOA نشان‌دهنده کارایی بهتر این مدل نسبت به دیگر روش‌های مدل‌سازی در پیش‌بینی و ارزیابی فرسایش‌پذیری می‌باشد. معیارهای ارزیابی کارایی مدل هیبریدی MLP-WOA به همراه سایر مدل‌ها در شکل (۷) ارائه شده است. به طور کلی با توجه به مقادیر معیارهای ارزیابی می‌توان عنوان نمود که مدل MLP-WOA بهترین کارایی را در پیش‌بینی فرسایش‌پذیری بادی در منطقه مورد مطالعه داشته است و پس از آن مدل‌های MLP-GA، MLP و MLR به ترتیب در رتبه دوم، سوم و چهارم قرار داشتند. مقادیر فرسایش‌پذیری اندازه‌گیری شده در تونل باد و پیش‌بینی شده توسط مدل‌های مختلف در هر دو مرحله آموزش و آزمون مدل‌ها در شکل (۸) نشان داده شده است.

استفاده از شبکه‌های عصبی-فازی منجر به بهبودی نتایج حاصل از شبکه‌های پرسپترون نمی‌شود ولی استفاده از الگوریتم ژنتیک در ساختار شبکه عصبی مصنوعی می‌تواند به بهبود نتایج منجر شود.

**مدل هیبریدی شبکه عصبی مصنوعی-الگوریتم بهینه‌سازی وال**  
به منظور مقایسه توانایی WOA در آموزش شبکه عصبی در مقایسه با الگوریتم BP و GA، در این قسمت از WOA برای آموزش شبکه عصبی مصنوعی استفاده شد. یکی از مهمترین مراحل آموزش شبکه عصبی توسط این الگوریتم آموزشی تعیین ضرایب A و C می‌باشد که این دو ضریب توسط تعیین مقادیر a و r مشخص می‌گردند. در الگوریتم وال پارامتر a در طول تکرار به صورت خطی از دو تا صفر کاهش یافت و همچنین r به عنوان یک بردار تصادفی در فاصله [0, 1] در نظر گرفته شد. مقادیر ضریب P به صورت تصادفی در فاصله صفر و یک تعیین گردید و همچنین مقادیر ضریب l به صورت تصادفی در فاصله بین -1 و 1 در نظر گرفته شد. در این پژوهش مقادیر ضرایب P و l به ترتیب برابر 0/۳۷ و 0/۶۵ به دست آمد (به منظور کسب اطلاعات جامع در زمینه معادلات و روابط مربوط به الگوریتم بهینه‌سازی وال به مقاله (Mirjalili and Lewis (2016) مراجعه نمایید). همچنین اندازه جمعیت و تعداد تکرارها به ترتیب برابر ۵۰۰ و ۳۰ انتخاب گردید. شبکه عصبی مصنوعی هیبرید شده با الگوریتم وال با تعداد نرون هشت در لایه مخفی بهترین کارایی را از خود نشان داد.



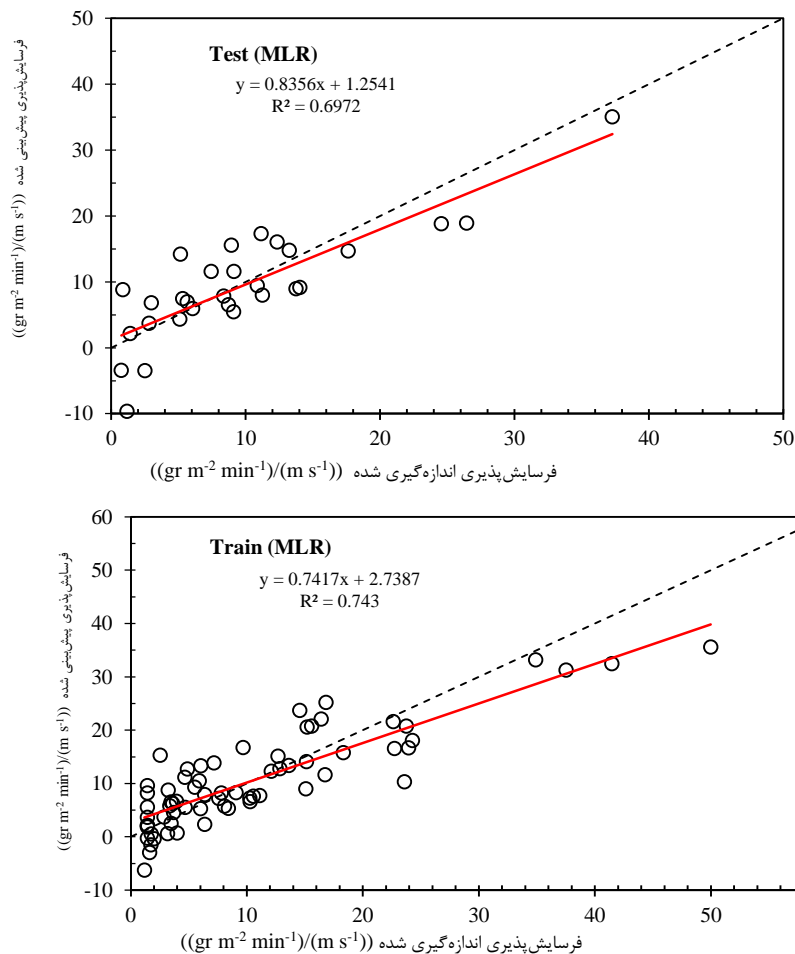
شکل ۷- مقایسه کارایی و عملکرد مدل‌های مختلف در پیش‌بینی فرسایش‌پذیری باد

در مقایسه با GA در آموزش شبکه عصبی موجب افزایش ۶ درصدی ضریب تبیین و NSE، کاهش ۱۶ درصدی RMSE و بهبود ۱۵ درصدی آماره ME شده بود، سرعت بالای WOA در پیدا کردن نقطه بهینه جهانی در مدل MLP-WOA نیز نشان دهنده برتری چشمگیر الگوریتم WOA در آموزش شبکه عصبی بود.

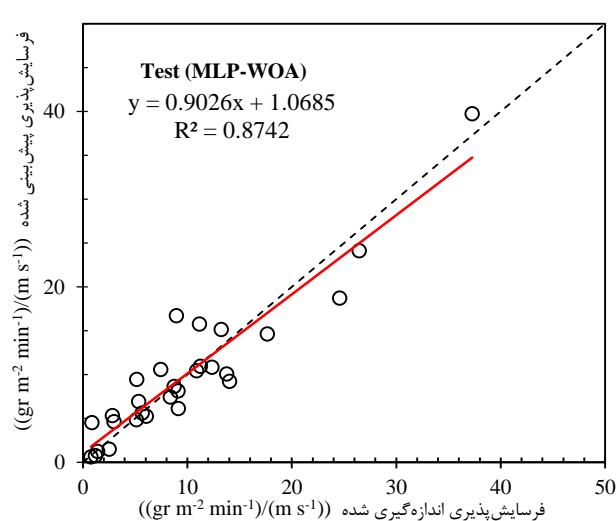
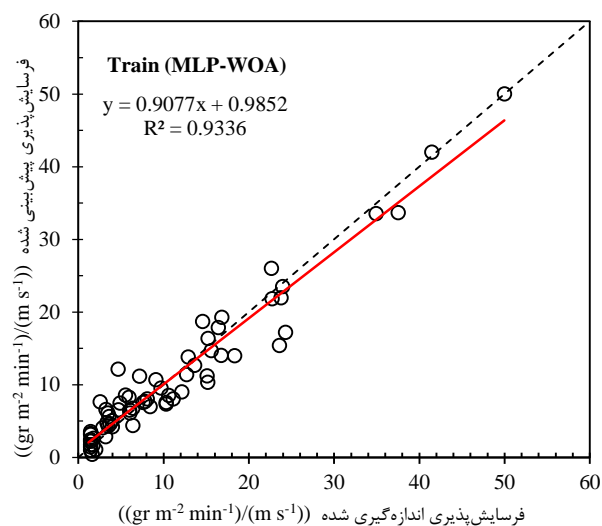
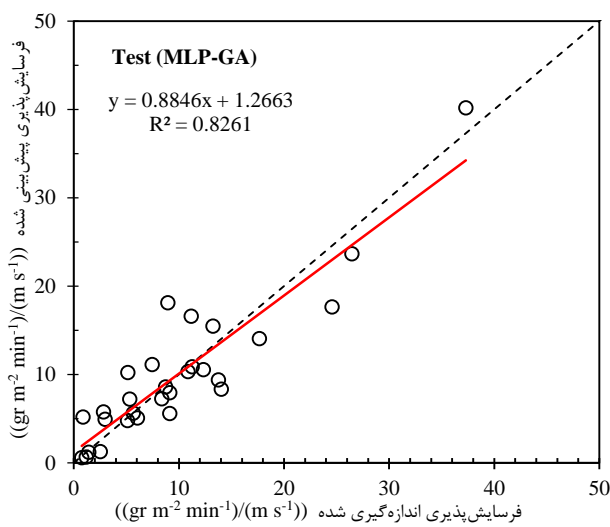


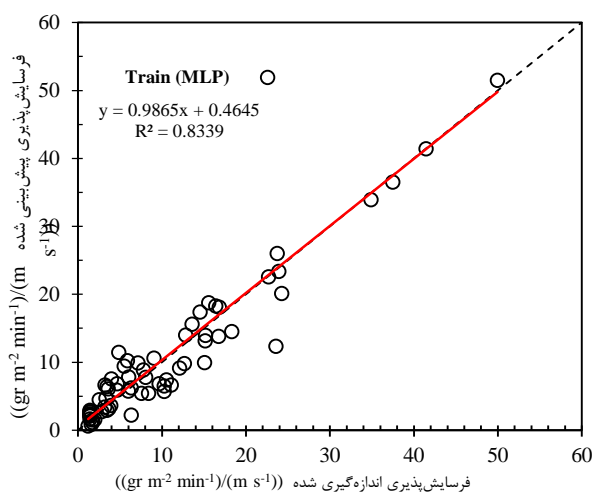
Aljarah *et al.* (2016) و Mirjalili and Lewis (2016) نیز به توانایی و قابلیت بالای WOA در پیدا کردن نقاط بهینه جهانی اشاره نموده‌اند. دلیل اصلی دوری از گیر کردن در نقاط بهینه محلی در این الگوریتم وجود روش جستجوی قدرتمند می‌باشد. مکانیسم اصلی که باعث می‌شود این الگوریتم از نقاط بهینه محلی دوری نماید انتخاب تصادفی راه حل‌ها در حین آموزش شبکه عصبی می‌باشد. نتایج این مطالعه در بررسی کارایی الگوریتم بهینه‌سازی مشابه نتایج Aljarah *et al.* (2016) می‌باشد و الگوریتم وال نه تنها دارای دقت بالایی در پیدا کردن نقاط بهینه جهانی می‌باشد، بلکه سرعت بالایی نیز در پیدا کردن نقاط بهینه جهانی در مقایسه با بقیه روش‌های بهینه‌سازی تکاملی (متهایوریستیک) دارد.

مقدار NSE برای مدل MLP-WOA در مقایسه با MLR (۰/۶۷)، MLP (۰/۷۷) و MLP-GA (۰/۸۲) نزدیکتر به عدد یک می‌باشد (۰/۸۷) که این حاکی از کارایی بهتر مدل MLP-WOA و مطابقت بهتر مقادیر فرسایش‌پذیری بادی اندازه‌گیری شده و پیش‌بینی شده می‌باشد. معیار دیگری که به منظور بررسی کارایی مدل‌ها استفاده شد ME می‌باشد که مقدار آن برای مدل MLP-WOA (-۰/۱۱) در مقایسه با MLP (-۰/۱۵)، MLP-GA (-۰/۱۳) و MLR (۰/۳۵) نزدیکتر به صفر می‌باشد. به طور کلی روش‌های هوش مصنوعی از قابلیت و توانایی بالاتری در مدل نمودن روابط پیچیده بین ورودی‌ها و فرسایش‌پذیری باد در مقایسه با مدل رگرسیونی برخوردار بودند.

علاوه بر این مقادیر بالای  $R^2$  و NSE، مقدار پایین RMSE و مقدار نزدیک به صفر آماره ME مدل MLP-WOA گواه این امر می‌باشد که الگوریتم بهینه‌سازی وال به طور قابل قبولی از همگرایی محلی و توقف در نقاط بهینه محلی دوری می‌کند و در مقایسه با الگوریتم‌های آموزشی BP و GA قدرت بالاتری در پیدا نمودن نقاط بهینه جهانی دارد. علاوه بر اینکه استفاده از WOA



شکل ۸- مقایسه مقادیر فرسایش‌پذیری اندازه‌گیری شده در تونل باد و مقادیر فرسایش‌پذیری پیش‌بینی شده توسط مدل‌ها برای دو بخش آموزش و



ادامه شکل ۸- مقایسه مقادیر فرسایش پذیری اندازه گیری شده در تونل باد و مقادیر فرسایش پذیری پیش بینی شده توسط مدل‌ها برای دو بخش آموزش و آزمون

### نتیجه گیری

اساس نتایج پژوهش حاضر و با توجه به مقادیر کمتر ME و RMSE و مقادیر بالاتر  $R^2$  و NSE مدل MLP-WOA کارایی بسیار مناسبی برای پیش بینی فرسایش پذیری بادی خاک ارائه داد. از آنجایی که بسیاری از نقاط اراضی شرقی دریاچه ارومیه

این پژوهش به منظور مقایسه کارایی روش‌های MLP، MLR، MLP-GA و MLP-WOA در شبیه سازی و پیش بینی فرسایش - پذیری بادی خاک در اراضی شرقی دریاچه ارومیه انجام شد. بر

بادی و همچنین صرف وقت و هزینه کمتر در این روش در مقایسه با اندازه گیری فرسایش پذیری در مزرعه و یا تونل باد، این روش می تواند روشی جایگزین و مناسب برای ارزیابی فرسایش پذیری بادی خاک و تعیین نقاط حساس به فرسایش بادی در منطقه مورد مطالعه معرفی گردد.

## REFERENCES

- Abbasi, Y., Ghanbarian-Alavijeh, B., Liaghat, A. and Shorafa, M. (2011). Evaluation of pedotransfer functions for estimating soil water retention curve of saline and saline-alkali soils of Iran. *Pedosphere* 21 (2), 230–237.
- Aljarah, I., Faris, H. and Mirjalili, S. (2016). Optimizing connection weights in neural networks using the whale optimization algorithm. *Soft Computing*, 22 (1), 1-15.
- Barzegar, R., Asghari Moghadam, A. and baghban, H. (2015). A supervised committee machine artificial intelligent for improving DRASTIC method to assess groundwater contamination risk: a case study from tabriz plain aquifer, iran. *Stoch Environ Res Risk Assess*, 30(3), 883–899.
- Chebud, Y., Naja, G.M., Rivero, R.G. and Melesse, A.M. (2012). Water quality monitoring using remote sensing and artificial neural network. *Water Air Soil Pollut*, 223, 4875–4887.
- Cook, D.F., Ragsdale, C.T. and Major, R.L. (2000). Combining a neural network with a genetic algorithm for process parameter optimization. *Engineering Applications of Artificial Intelligence* 13: 391-396.
- Dastranj, H., Tavakoli, F. and Soltanpour, A. (2018). Investigating the water level and volume variations of Lake Urmia using satellite images and satellite altimetry. *Scientific - Research Quarterly of Geographical Data* 27(107), 149-163. (In Farsi).
- De-Gennaro, G., Trizio, L., DiGilio, A., Pey, J., Pérez, N., Cusack, M., Alastuey, A. and Querol, X. (2013). Neural network model for the prediction of PM10 daily concentrations in two sites in the Western Mediterranean. *Science of the Total Environment*, 463–464, 875–883.
- Fallah-Mehdipour, E., Bozorg Haddad, O. and Marino, M.A. (2013). Prediction and simulation of monthly groundwater levels by genetic programming. *Journal of Hydro-environment Research*, 7, 253-260.
- Galletly, J.E. (1992). An overview of genetic algorithms. *Kybernetes* 21(6): 26-30.
- Garcia, M. and Arguello, C. (2005). A hybrid approach based on neural networks and genetic algorithms to study the profitability in the Spanish stock market. *Applied Economics Letters*, 12, 303–308.
- Gee, G.W. and Or, D. (2002). Particle size analysis. In: Dane J.H., G.C.Topp, editors. *Methods of soil analysis. Part 4. Physical methods*. Soil Science Society of America. Madison (WI), p. 255–293.
- Haghverdi A., Ghahraman, B., Joleini, M., Khoshnud A., Yazdi, A. and Arabi, Z. (2011). Comparison of different Artificial Intelligence methods in modeling water retention curve (Case study: North and Northeast of Iran). *J. of Water and Soil Conservation*, 18(2), 65-84. In Farsi
- Hamm, L., Brorsen, B.W. and Hagan, M.T. (2007). Comparison of stochastic global optimization methods to estimate neural network weights. *Neural Process Lett*, 26, 145–58.
- Hashimoto, Y. (1997). Applications of artificial neural networks and genetic algorithms to agricultural system. *Computers and Electronics in Agriculture* 18:71- 72.
- Holland, J.H. (1992). *Genetic Algorithms*. Scientific American, 267(1), 66-72.
- Jain, A. and Srinivasulu, S. (2004). Development of effective and efficient rainfall-runoff models using integration of deterministic, real-coded genetic algorithms and artificial neural network techniques. *Water and resource research*, 40(4), W04302.
- Jamalizadeh Tajabadi, M.R., Moghadam Nia, A.R., Piri, J. and Ekhtesasi, M.R. (2010). Application of artificial neural networks in dust storm prediction (case study: Zabol city). *Iranian Journal of Rangeland and Desert Research* 17 (2): 205-220. (In Farsi)
- Kantardzic, M. (2011). *Data Mining: concepts, models, methods, and algorithms*. John Wiley & Sons. Alberta, Canada. pp 529.
- Kaunda, R.B. (2015). A neural network assessment tool for estimating the potential for backward erosion in internal erosion studies. *Computers and Geotechnics*, 69, 1–6.
- Kaveh, A., Ghazaan, M.I. (2017). Enhanced whale optimization algorithm for sizing optimization of skeletal structures, *Mech. Based Des. Struct. Mach*, 45(3), 345–362.
- Kemper, W.D. and Rosenau, R.C. (1986). Aggregate stability and size distribution. In: Klute A, editor, *Methods of Soil Analysis*. ASA and SSSA, Madison (WI), p. 425–442.
- Keshavarzi, A. and Sarmadian, F. (2010). Comparison of artificial neural network and multivariate regression methods in prediction of soil cation exchange capacity. *Int. J. Environ. Chem. Ecol. Geo Eng*. 4(12): 644–649.
- Kim, R.J., Loucks, D.P. and Stedinger, J.R. (2012). Artificial neural network models of watershed nutrient loading. *Water Resour. Manage*, 26, 2781–2797.
- Ladumor, D.P., Jangir, p., Trivedi, P.N. and Kumar, A. (2016). A whale optimization algorithm approach

- for unit commitment problem solution, in: Proceeding of the 2016 National Conference on Advancements in Electrical and Power Electronics Engineering (AEPEE-2016), Morbi.
- Liu, L.Y., Li, X.L., Shi, P.J., Gao, S.Y., Wang, J.H., Ta, W.Q., Song, Y., Liu, M.X., Wang, Z. and Xiao, B.L. (2007). Wind erodibility of major soils in the farming-pastoral ecotone of China. *Journal of Arid Environments*, 68, 611-623.
- Lopez, M.V., de Dios Herrero, J.M., Hevia, G.G., Gracia, R. and Buschiazzo, D.E. (2007). Determination of the wind-erodible fraction of soils using different methodologies. *Geoderma*, 139, 407-411.
- Mafarja, M. and Mirjalili, S. (2017). Hybrid Whale Optimization Algorithm with simulated annealing for feature selection. *Neurocomputing*, 260, 302-312.
- Mafarja, M. and Mirjalili, S. (2018). whale optimization approaches for wrapper feature selection. *Applied Soft Computing*, 62, 441-453.
- Menhaj, M.B. (2018). *Fundamental of neural network (Computational intelligence)*. Amirkabir University of Technology Press, Tehran, Iran. pp 716. (In Farsi)
- Mirjalili, S. and Lewis, A. (2016) The whale optimization algorithm. *Adv Eng Softw* 95:51-67.
- Nazghelichi, T., Aghbashlo, M. and Kianmehr, M.H. (2011). Optimization of an artificial neural network topology using coupled response surface methodology and genetic algorithm for fluidized bed drying. *Computers and Electronics in Agriculture*, 75, 84-91.
- Nelson, D.W. and Sommers, L.E. (1982). Total carbon, organic carbon, and organic matter. Pp. 539-579. In: Page AL, Miller RH and Keeney DR (eds). *Methods of Soil Analysis, part 2*. ASA and SSSA, Medison, Wisconsin.
- Nelson, R.E. (1982). Carbonate and Gypsum. P. 181-197. In Page, A. L. (ed.). *Methods of Soil Analysis. Part 2*. (2nd ed.). Agron. Mongor. 9. ASA and SSSA, Madison, WI.
- Nimmo, J.R. and Perkins, K.S. (2002). Aggregate stability and size distribution. In: Dane, J.H., Topp, G.C. (Eds.), *Methods of Soil Analysis. Part 4. Physical Methods*. Soil Science Society of America, Inc., Madison, WI, pp. 317-328.
- Ostovari, Y., Ghorbani-Dashtaki, S., Bahrami, H.A., Naderi, M., Dematte, J.A.M. and Kerry, R. (2016). Modification of the USLE K factor for soil erodibility assessment on calcareous soils in Iran. *Geomorphology*, 273, 385-395.
- Raj, S. and Bhattacharyya, B. (2018). Optimal placement of TCSC and SVC for reactive power planning using Whale optimization algorithm. *Swarm and Evolutionary Computation*, 40, 131-143.
- Reddy, P.D.P., Reddy, V.C.V. and Manohar, T.G. (2017). Whale optimization algorithm for optimal sizing of renewable resources for loss reduction in distribution systems. *Renewables: Wind, Water, and Solar*, 4, 3.
- Ryan, D., G.A. Hamill and Johnston, H.T. (2013). Determining propeller induced erosion alongside quay walls in harbours using Artificial Neural Networks. *Ocean Engineering* 59: 142-151.
- Sexton, R.S. and Gupta, N.D.J. (2000). Comparative evaluation of genetic algorithm and backpropagation for training neural networks. *Information Sciences*, 129: 45-59.
- Song, Y., Liu, L., Yan, P. and Cao, T. (2005). A review of soil erodibility in water and wind erosion research. *Journal of Geographical Sciences*, 15, 167-176.
- Sparks, D.L., (2003). *Environmental Soil Chemistry*. Academic Press, London, UK.
- Sparks, D. and Bartels, J. (1996). *Methods of soil analysis: Part 3. Chemical methods*. Soil Science Society of America Book Series. Madison, Wisconsin. USA. pp1390.
- Taghizade-Mehrjerdi, R., Sarmadian, F., savaghebi, G.H., Omid, M., Tomanian, N., Rosta, M.J. and Rahimian, M.H. (2013). Comparison of Neuro-Fuzzy, Genetic Algorithm, Artificial Neural Network and Multivariate Regression for Prediction of Soil Salinity (Case study: Ardakan City). *Journal of Range and Watershed Management*, 66 (2), 207-222. (In Farsi)
- Touma, H.J. (2016). Study of the economic dispatch problem on IEEE 30-bus system using whale optimization algorithm, *Int. J. Eng. Technol. Sci.*, 5(1), 11-18.
- Vaezi, A.R., Sadeghi, S.H., Bahrami, H.A. and Mahdian, M. (2008). Modeling the USLE K-factor for calcareous soils in northwestern Iran. *Geomorphology*, 97, 414-423.
- Webb, N.P. and McGowan, H.A. (2009). Approaches to modelling land erodibility by wind. *Progress in Physical Geography*, 33(5), 587-613.
- Zamani, S. and Mahmoodabadi, M. (2013). Effect of particle-size distribution on wind erosion rate and soil erodibility. *Archives of Agronomy and Soil Science*, 59 (12), 1743-1753.