

## برآورد جزء فرسایش‌پذیری بادی خاک به کمک مدل‌های شبکه عصبی مصنوعی و تلفیق شبکه عصبی مصنوعی با الگوریتم ژنتیک در بخشی از اراضی جنوب شرقی قزوین

علیرضا نوری: دانشجوی دکتری، گروه علوم خاک، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران

کامران افتخاری\*: استادیار پژوهش موسسه تحقیقات خاک و آب، تهران، ایران

مهرداد اسفندیاری: استادیار گروه علوم خاک، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران

علی محمدی ترکاشوند: دانشیار گروه علوم خاک، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران

عباس احمدی: دانشیار گروه علوم خاک، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران

نوع مقاله: پژوهشی

تاریخچه مقاله (تاریخ دریافت: ۱۴۰۰/۱/۱۸ تاریخ پذیرش: ۱۴۰۰/۶/۲۷)



20.1001.1.22517812.1401.12.1.2.7

### چکیده

یکی از مسائل اساسی ایران، فرسایش بادی در پهنه وسیعی از اراضی کشور است که یک چالش جدی در استفاده پایدار از منابع تولید است. شاخص جزء فرسایش‌پذیری بادی خاک (EF) یکی از ویژگی‌های خاک است که حساسیت ذرات خاک در برابر فرسایش بادی را نشان می‌دهد. در این تحقیق، برآورد این شاخص به کمک روش‌های شبکه عصبی مصنوعی (ANN) و تلفیق آن با الگوریتم ژنتیک (GA-ANN) بررسی می‌شود. در منطقه مورد مطالعه که بخشی از دشت الله‌آباد در استان قزوین بود، ۹۵ نمونه از ۱۰ سانتی‌متری سطح خاک، برداشت شد. در نمونه‌ها، درصد خاکدانه‌های با قطر کوچک‌تر از ۰/۸۴ میلی‌متر به عنوان شاخص جزء فرسایش‌پذیری بادی خاک و درصد رس، شن و سیلت، ظرفیت اشباع خاک، pH، EC، SAR، کربنات کلسیم معادل و ماده آلی، به عنوان ورودی مدل‌ها (خصوصیات زودیافت) اندازه‌گیری شدند. برای مدل‌سازی جزء فرسایش‌پذیری خاک در مقابل باد با استفاده از خصوصیات زودیافت از دو روش شبکه عصبی مصنوعی و تلفیق شبکه عصبی مصنوعی با الگوریتم ژنتیک برای بهینه‌سازی اوزان، استفاده شد. نتایج نشان داد که جزء فرسایش‌پذیری خاک با پنج خصوصیت خاک شامل pH، هدایت الکتریکی، SAR، رس و ماده آلی، در سطح یک درصد همبستگی معنی‌دار داشت. مدل‌های مورد استفاده از صحت مناسبی در برآورد EF در هر دو مرحله آموزش و آزمون برخوردار نبودند، طوری که بیشترین  $R^2$  در مدل شبکه عصبی مصنوعی (۰/۴۹) با داده‌های سری آزمون به دست آمد. هر دو مدل دارای اندکی بیش‌برآوردی بودند و مقدار GMER برای مدل‌های ANN و GA-ANN به ترتیب ۱/۱۵ و ۱/۰۸ بود، اما بر طبق شاخص آکایک (AIC)، هر دو مدل قدرت پیش‌بینی مشابهی داشتند. آنالیز حساسیت داده‌ها نشان داد که بیشترین تأثیر بر جزء فرسایش‌پذیری خاک در مدل ANN مربوط به ماده آلی (۴/۰۷) و در مدل GA-ANN مربوط به رس (۸/۱۴) بود.

واژگان کلیدی: الله‌آباد، آنالیز حساسیت، شوری خاک، EF، ANN، GA

## ۱- مقدمه

فرسایش بادی یک تهدید جدی در بسیاری از مناطق جهان است که دارای اثرات مستقیم و غیر مستقیم بر اکوسیستم می باشد (Jarraha et al., 2020). فرسایش بادی یکی از عوامل اصلی محدود کننده حاصلخیزی خاک (Zhao et al., 2006) و تولید ریزگرد (Shahkoui and Rahmani, 2018) در بسیاری از نقاط جهان از جمله ایران می باشد که پیامدهایی بر آب و هوا (Moradi and Aprajunqani, 2019)، کشاورزی (Sarani and Rahdari, 2019) و سلامت انسان (Chahar Azar et al., 2019) در بر دارد. فرسایش بادی خاک سبب هدر روی رس، سیلت و عناصر غذایی خاک و تغییر شرایط هیدروترمال خاک می شود که در نتیجه منجر به کاهش حاصلخیزی خاک و رشد گیاه می شود (Peng et al., 2018). مهار فرسایش بادی زمانی مؤثرتر خواهد بود که اطلاعات کافی در خصوص عوامل موثر بر آن در دسترس باشد (Refahi, 1999; Coppinger et al., 1991).

بررسی علل و مقدار فرسایش در کشورهای مختلف جهان، از اولویتهای حفاظت خاک و محیط زیست است (Wuepper et al., 2020). فاکتور فرسایش پذیری ذاتی خاک است یکی از معیارها و ویژگیهای خاک که برای بررسی مقاومت و حساسیت ذرات آن در برابر عوامل فرسایش زا مورد بررسی قرار می گیرد و در بسیاری از مدل های فرسایش و رسوب نیز در نظر گرفته شده است (Merrill et al., 1997). فرسایش پذیری خاک نیز تحت تاثیر عواملی نظیر رطوبت خاک سطحی، میکروتوپوگرافی یا زبری سطح خاک و حساسیت ذاتی خاک می باشد (Vaezi et al., 2008; Mohammadi Mohammadi Torkashvand, 2008; Mohammadi Torkashvand and Nikkami, 2008; Torkashvand and Haghighat, 2009). هنگامی که تاثیر عوامل زبری سطح خاک و رطوبت خاک سطحی بر میزان فرسایش بادی ناچیز باشد، در این صورت، تنها حساسیت ذاتی ذرات تشکیل دهنده خاک در مقابل کنده شدن و انتقال، حساسیت آن را در مقابل فرسایش کنترل می کنند، که به آن فرسایش پذیری ذاتی خاک در برابر باد (SIWE) اطلاق می شود (Chandler, 2005). اندازه گیری فرسایش پذیری ذاتی خاک در برابر باد می تواند به وسیله دستگاه تونل باد صورت بگیرد (Song et al., 2005)، که این روش عموماً پرهزینه، مشکل و زمان بر می باشد (Ostovari et al., 2016). از طرف دیگر این خصوصیت دارای تغییرات زمانی و مکانی قابل توجهی بوده و به روش اندازه گیری نیز بستگی دارد. اغلب مطالعات نشان داده است که رابطه بسیار نزدیکی بین فرسایش پذیری خاک در مقابل باد و میزان EF وجود دارد و این شاخص می تواند به عنوان معیاری از فرسایش پذیری خاک به کار رود. مطالعات (Chepil 1960 and 1958) در گاردن سیتی کانزاس در زمینه تأثیر پراکندگی اندازه خاکدانه ها بر روی فرسایش پذیری ذاتی خاک خشک نشان داد که با افزایش میزان خاکدانه های با قطر کوچکتر از ۰/۸۴ میلی متر، حساسیت خاک به فرسایش توسط باد (فرسایش پذیری ذاتی) افزایش می یابد. Lyles et al. (1969) نشان داده اند که رابطه خاکدانه های بزرگتر از ۰/۸۴ میلی متر (به عنوان شاخص فرسایش پذیری خاک) و خصوصیات زود یافت را می توان با استفاده از روش گام به گام در رگرسیون چندگانه بدست آورد.

در سال های اخیر تلاش های زیادی برای تعیین مقدار فرسایش بادی خاک در شرایط مختلف زیست محیطی و اقدامات مدیریتی متفاوت انجام شده است (Chappell and Webb, 2016; Alewell et al., 2019; Borrelli et al., 2020). یکی از راه کارها، برآورد مقدار فرسایش بادی خاک از طریق مدل سازی و شبیه سازی فرسایش بادی با توجه به عوامل مؤثر بر آن می باشد (Teng et al., 2021). در یک دهه اخیر از شبکه های عصبی در مطالعات زیادی برای ایجاد توابع انتقالی در تخمین خصوصیات دیریافت خاک از روی خصوصیات زود یافت استفاده شده است (Zhou et al., 2008; Aali et al., 2009; Parvizi et al., 2010; Mokhtari et al., 2011; Besalatpour et al., 2013; Dai et al., 2014; Marashi et al., 2017; Eslami et al., 2019; Hojjatnooghi et al., 2019).

محققین با تلفیق الگوریتم ژنتیک در شبکه‌های عصبی مصنوعی سعی در افزایش دقت برآوردها داشته‌اند (Aytek and Kisi, 2008). به الگوریتم‌های فرا ابتکاری ترکیبی، مدلسازی چندگانه نیز اطلاق می‌شود. مدلسازی چندگانه روشی برای اعمال چند مدل در توصیف نوع فرآیند حاکم، برای حصول نتیجه بهتر است (Parvaresh Rizi et al., 2006). Goldberg (1989)، علت برآوردهای بهتر الگوریتم ترکیبی شبکه عصبی مصنوعی- الگوریتم ژنتیک را در آموزش مناسب‌تر شبکه عصبی مصنوعی می‌داند.

در پژوهشی، Nasseh و همکاران (۲۰۰۹) ترکیب الگوریتم ژنتیک و شبکه عصبی مصنوعی را روشی قابل اعتماد و موفق در تخمین فشارهای به دست آمده از دستگاه ونتوری<sup>۱</sup> معرفی کردند. Prasad and Mathur (2007) با استفاده از شبکه‌های عصبی مصنوعی و تلفیق آن با الگوریتم ژنتیک (GA-ANN) به شبیه- سازی حرکت املاح آبهای زیرزمینی پرداختند. Liong et al. (2002) با مطالعه رابطه بارش - رواناب نشان دادند که استفاده از روش برنامه‌ریزی ژنتیک در پیش بینی رفتار بارش - رواناب در حوضه‌های آبریز سبب بروز خطای کمتری خواهد گردید. (Emami et al. (2018) از الگوریتم ژنتیک در تخمین پارامترهای کیفی آب زیرزمینی در منطقه بستان آباد تبریز در ایران استفاده کرد. (Matkan et al. (2014) یک مدل بهینه سازی درصد تاج پوشش مراتع با رویکرد حفاظت خاک مبتنی بر الگوریتم ژنتیک در بستر GIS طراحی کردند. (Cao et al. (2011) مدلی به نام NSGA-MOLM-II یا به عبارتی الگوریتم NSGA-II را به منظور آمایش چند منظوره سرزمین توسعه دادند. (Tanasan et al. (2013) مدلی به منظور بهینه سازی کاربری اراضی، مبتنی بر الگوریتم ژنتیک چندهدفه با رویکرد آمایش سرزمین طراحی کردند و آن را در حوضه رودبار در جنوب کرمان مورد ارزیابی قرار دادند که نتایج دلالت بر کارایی بالای الگوریتم‌های بهینه‌سازی در مسائل مدیریت منابع طبیعی داشت.

دشت الله‌آباد در جنوب غربی شهرستان آبیک در استان قزوین با داشتن باد شدید جهت دار از سمت جنوب غرب به طرف شمال شرق جزء مناطق حساس به فرسایش بادی به حساب می‌آید. خشک شدن تالاب الله‌آباد و بیرون آمدن بستر آن، فرسایش بادی را در منطقه تشدید و به یک بحران تبدیل خواهد کرد. تعیین میزان فرسایش پذیری اراضی و شناخت عوامل مؤثر بر آن (بر اساس اطلاعات واقعی و دقیق در مورد شدت و مقدار فرسایش فعلی منطقه) می‌تواند اساس برنامه جامع حفاظت خاک و پایداری اراضی و اولویت بندی مراحل اجرایی آن قرار گیرد. تحقیق حاضر به منظور استفاده از روش‌های شبکه عصبی مصنوعی و تلفیق آن با الگوریتم ژنتیک در تخمین فرسایش‌پذیری ذاتی خاک صورت گرفت. اهداف این مطالعه تخمین میزان فرسایش‌پذیری ذاتی خاک در برابر باد به کمک خصوصیات زودیافت خاک با مدل‌های شبکه عصبی مصنوعی و تلفیق آن با الگوریتم ژنتیک و شناخت مهم‌ترین خصوصیات مؤثر بر فرسایش پذیری خاک است.

## ۲- منطقه مورد مطالعه

منطقه مورد مطالعه، بخشی از دشت الله‌آباد در استان قزوین بین مختصات  $۵۰^{\circ}۱۷'$  -  $۵۰^{\circ}۲۳'$  طول شرقی و  $۳۵^{\circ}۵۴'$  -  $۵۸^{\circ}$  عرض شمالی و اقلیم نیمه خشک سرد می‌باشد (شکل ۱). تراکم رسوبات جوان آبرفتی کواترنر (دوران چهارم) که توسط آب های جاری در چاله زمین ساختی دشت قزوین رسوب نموده و به تدریج سبب تشکیل دشت شده است (طرح مطالعاتی آمایش استان قزوین، قزوین، ۱۳۹۷).

## ۳- مواد و روش

از یک و نیم میلیون هکتار اراضی استان قزوین، معادل ۳۰ درصد یا به تعبیری، به همان وسعت دشت قزوین قابلیت کشاورزی دارد. از ۹۳۵ هزار هکتار عرصه منابع طبیعی استان، ۹۰ هزار هکتار تبدیل به بیابان شده و ۲۴۰ هزار هکتار در معرض تهدید است. خشکسالی این دشت را اراضی مستعدی برای بیابان‌زایی و ریزگردها تبدیل کرده است. بعلاوه فرسایش بادی در بخش‌های جنوبی آن، از جمله در حوزه جنوبی شهرستان آبیک به وضعیت حاد رسیده است. همه این موارد نشان می‌دهد که بحران بیابان‌زایی در استان قزوین چالشی جدی است (طرح مطالعاتی آمایش استان قزوین، قزوین، ۱۳۹۷). حداقل  $EC_e$  و SAR خاک‌های منطقه مورد مطالعه به ترتیب برابر  $۰/۴۱ dS/m$  و  $۰/۳۱ (mmol/li)^{0.5}$  و حداکثر آن برابر  $۷۲/۳ dS/m$  و

<sup>1</sup> venturi scrubbers

$0.5$  (mmol/li)  $79/49$  می باشد. میزان کربن آلی در خاکهای منطقه ناچیز بوده و حداقل مقدار آن برابر  $0.06\%$  و حداکثر آن برابر  $2/86\%$  می باشد.



شکل ۱: موقعیت منطقه مورد مطالعه

با بررسی نقشه خاک دشت الله آباد، حداقل ۳۰ نوع خاک با تفاوت در بافت، ساختمان و خصوصیات شیمیایی انتخاب و از ۱۰ سانتی متری سطح آن ها، ۹۵ نمونه برداشته شد. سپس نمونه های جمع آوری شده هواخشک و از الک ۲ میلی متری عبور داده شد و برای خصوصیات فیزیکی و شیمیایی خاک نگهداری گردید. برخی خصوصیات خاک ها شامل درصد ذرات شن، سیلت و رس، pH، گل اشباع، هدایت الکتریکی ویژه عصاره گل اشباع (ECe)، ظرفیت اشباع خاک، نسبت جذب سطحی سدیم (SAR)، میزان کربنات های کلسیم معادل (CCE) اندازه گیری شدند (Klute, 1986). مقدار کربن آلی خاک به روش والکلی - بلک اصلاح شده (Nelson and Sommers, 1982) اندازه گیری گردید.

#### اندازه گیری جزء فرسایش پذیری بادی خاک

جزء فرسایش پذیری بادی خاک، درصد خاکدانه های با قطر کوچک تر از  $0.84$  میلی متر است (Chepil, 1958 and 1960). پس از عبور دادن خاک ها از الک هشت میلی متری، ۲۰۰ گرم از توده خاک توزین شده و در یک سری از الک ها با قطر  $0.475$ ، ۱، ۲، ۵ و  $0.25$  میلی متر به آرامی قرار گرفت. این سری الک ها به مدت ۳۰ ثانیه، با دامنه ارتعاش تقریباً ۵۰ هرتز و دامنه نوسان ۲ میلی متر تکان داده شد (Ahmadi et al., 2011). در ادامه مواد باقیمانده بر روی هر الک جمع آوری و توزین گردید. سپس از روی منحنی توزیع اندازه خاکدانه ها درصد خاکدانه های کوچک تر از  $0.84$  میلی متر برای هریک از نمونه های خاک محاسبه گردید.

#### مدل سازی

در این تحقیق برای مدل سازی جزء فرسایش پذیر خاک در مقابل باد با استفاده از خصوصیات زود یافت از دو روش شبکه عصبی مصنوعی و تلفیق شبکه عصبی مصنوعی با الگوریتم ژنتیک برای بهینه سازی اوزان استفاده به عمل آمد. خصوصیات خاک به عنوان ورودی در هر دو مدل شامل pH، درصد اشباع (SP)، SAR، EC، کربنات کلسیم معادل (CCE)، ماده آلی، درصد نسبی ذرات شن، سیلت و رس بود. به این منظور ابتدا داده ها به سه دسته تقسیم شدند؛ ۶۰ درصد سری داده ها به

آموزش، ۲۰ درصد به اعتبارسنجی و ۲۰ درصد به آزمودن شبکه اختصاص یافت. به این ترتیب بر اساس داده‌های آموزشی، مناسب‌ترین مدل با بیشترین تناسب بین داده‌ها انتخاب و صحت و عملکرد مدل ارائه شده در زیر مجموعه آزمایشی مورد بررسی قرار گرفت.

در این پژوهش برای مدل‌سازی شبکه عصبی مصنوعی در برآورد مقادیر جزء فرسایش‌پذیر خاک، از شبکه‌های MLP استفاده شد (Haykin, 1999) در این ساختار، هر شبکه عصبی مصنوعی شامل ورودی و لایه‌های مخفی و خروجی است. در طی فرآیند یادگیری، میزان فراگیری توسط شبکه به وسیله توابع هدف به طور مرتب مورد ارزیابی و شبکه‌های با کمترین میزان خطا مورد پذیرش قرار گرفت. برای تعیین شبکه بهینه با بیشترین سطح عملکرد از کلیه توابع محرک تعریف شده در نرم افزار (تانژانت هیپربولیک آکسون، سیگموئید آکسون، تانژانت هیپربولیک خطی آکسون، سیگموئید خطی آکسون، بایاس آکسون، آکسون خطی و آکسون) به شکل سعی و خطا تا حصول مناسب‌ترین نتیجه استفاده شد. برای آموزش شبکه‌های تعریف شده، از توابع آموزشی لونبرگ-مارکوارت استفاده شد. این الگوریتم آموزشی مناسب‌ترین روش برای آموزش شبکه‌های عصبی مصنوعی طراحی شده می‌باشد و سرعت بالاتری نسبت به دیگر الگوریتم‌های پس انتشار خطا دارد (Zare, 2010). برای تعیین بهترین تعداد نرون، از ۲ تا ۹ نرون در هر لایه در نظر گرفته شد و با روش سعی و خطا بهترین تعداد نرون برای برآورد EF تعیین گردید.

در این تحقیق از الگوریتم ژنتیک به منظور یافتن نقطه بهینه توابع پیچیده غیرخطی در ترکیب با شبکه عصبی مصنوعی (GA-ANN) استفاده شد. الگوریتم ژنتیک باعث بهینه‌سازی وزنهای شبکه عصبی مصنوعی می‌شود. در واقع تابع هدف الگوریتم ژنتیک تابعی از نتایج آماری شبکه عصبی مصنوعی است (Nosrati and Eftekhari, 2014). برای آموزش ابتدا تعداد P عدد (جمعیت هر نسل) شبکه عصبی مصنوعی به طور تصادفی مقداردهی اولیه شد و میزان خطا با استفاده از داده‌های آموزش محاسبه گردید. در مرحله بعد به روزرسانی ویژگی‌های شبکه با توجه به مقادیر EF خاک و نرخ‌های جهش و آمیزش انجام شد. الگوریتم بالا تا نبود بهبودی در ویژگی‌های شبکه با در نظر گرفتن جمعیت جدید به دست آمده تکرار گردید. در آخرین مرحله خروجی به دست آمده از اجرای شبکه با مقادیر واقعی مقایسه و در صورت حداقل شدن تفاوت بین دو مقدار بالا، اجرای مدل خاتمه یافت.

### ارزیابی مدل‌ها

کارایی روش‌های مختلف مدل‌سازی در برآورد EF با استفاده از سه آماره جذر میانگین مربعات خطا (RMSE)، میانگین خطا (ME) و ضریب تبیین ( $R^2$ ) مورد بررسی قرار گرفت:

$$R^2 = \frac{[\sum_{i=1}^N (y_i - \bar{y})(\hat{y}_i - \bar{\hat{y}})]^2}{\sum_{i=1}^N (y_i - \bar{y})^2 \sum_{i=1}^N (\hat{y}_i - \bar{\hat{y}})^2} \quad (1)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N}} \quad (2)$$

که در آن‌ها:  $y_i$ ،  $\bar{y}$  و  $\hat{y}$  به ترتیب متغیر وابسته اندازه‌گیری، میانگین آن و متغیر وابسته برآورد شده بوده و  $N$  تعداد مشاهدات است.

همچنین معیارهای دیگری که برای ارزیابی مدل‌ها به کار رفتند شامل؛ میانگین هندسی نسبت خطا<sup>۱</sup> (GMER)، میانگین خطا (ME) و انحراف استاندارد هندسی خطا<sup>۲</sup> (GSDE) بودند (روابط ۲-۷ الی ۲-۹):

$$GMER = \exp\left(\frac{1}{N} \sum_{i=1}^N \ln\left(\frac{\hat{y}_i}{y_i}\right)\right) \quad (3)$$

<sup>۱</sup> - Geometric mean of error ratio

<sup>۲</sup> - Geometric standard deviation of error ratio

$$ME = \frac{\sum_{i=1}^N (y_i - \hat{y}_i)}{N} \quad (4)$$

$$GSDER = \exp \left( \frac{1}{N-1} \sum_{i=1}^N \left[ \ln \left( \frac{\hat{y}_i}{y_i} \right) - \ln(GMER) \right]^2 \right)^{1/2} \quad (5)$$

میانگین هندسی نسبت خطا<sup>۱</sup> (GMER) نشان دهنده میزان انطباق بین مقادیر اندازه گیری شده و برآورد شده است. اگر GMER برابر یک باشد، نشان دهنده انطباق کامل بین مقادیر اندازه گیری شده و پیش بینی شده است. GMER بزرگتر و کمتر از یک نشان دهنده آن است که مقادیر پیش بینی شده به ترتیب بزرگتر و کمتر از مقادیر اندازه گیری شده است. انحراف استاندارد هندسی خطا<sup>۲</sup> (GSDER) معیاری از پخشیدگی داده ها است و هر چه نزدیک به یک باشد نشان دهنده پخشیدگی کمتر است.

معیار اطلاعات آکایک<sup>۳</sup> (رابطه ۶)، نیز یکی از معیارهای کاربردی مفید در زمینه بررسی قدرت پیش بینی توابع انتقالی ایجاد شده می باشد. هر چه این معیار کوچک تر باشد مدل قدرت پیش بینی بیش تری دارد (Akaike, 1974):

$$AIC = N \ln \left( \sum_{i=1}^N \frac{(y_i - \hat{y}_i)^2}{N} \right) + 2n_p \quad (6)$$

که در آن:

N: تعداد نمونه های خاک

$y_i$ : مقادیر اندازه گیری شده متغیر خروجی

$\hat{y}_i$ : مقادیر پیش بینی شده متغیر خروجی

$n_p$ : تعداد پارامترهای مدل

#### ۴- یافته ها (نتایج)

برخی شاخص های آماری نمونه های برداشت شده خاک در جدول ۱ مشاهده می شود. این شاخص ها نشان دهنده تفاوت زیاد در خصوصیات فیزیکی و شیمیایی نمونه های خاک می باشد. مقادیر قابلیت هدایت الکتریکی از ۰/۴۱ تا ۷۲/۳ دسی زیمنس بر متر (dS/m) متفاوت بود. مقادیر SAR هم نشان دهنده وجود خاک های شدیداً سدیمی در منطقه مورد مطالعه است. حداقل ماده آلی در خاک، ۰/۰۶ درصد و حداکثر آن، ۴/۸۶ درصد بود. تغییرپذیری زیادی در خصوصیات خاک به ویژه بافت خاک و شوری خاک دیده می شود، که نشان دهنده آن است که نمونه های انتخاب شده از تنوع خوبی برخوردار بوده و می توانند در مدل سازی کاربرد داشته باشند.

جدول ۲، همبستگی بین ویژگی های اندازه گیری شده را نشان می دهد جزء فرسایش پذیری بادی خاک (EF) با پنج خصوصیت خاک شامل pH، هدایت الکتریکی، SAR، مقدار رس و ماده آلی، در سطح یک درصد همبستگی معنی دار نشان داد. بیشترین همبستگی EF با ماده آلی دیده شد (۰/۵۷۱-) و یک همبستگی معنی دار نیز با مقدار رس مشاهده (۰/۳۹۹) شد. بیشترین همبستگی EF با ماده آلی دیده شد (۰/۵۷۱-) و یک همبستگی معنی دار نیز با مقدار رس مشاهده (۰/۳۹۹) شد.

شکل ۱ و جدول ۳، نتایج معیارهای ارزیابی مدل های ارائه شده برای تخمین EF در دو سری داده های آموزش و آزمون را نشان می دهد. در داده های سری آزمون،  $R^2$  نتایج بدست آمده از مدل شبکه عصبی مصنوعی (۰/۴۹) بیشتر از داده های نتایج بدست آمده از مدل هیبرید با الگوریتم ژنتیک بود. مقدار  $R^2$  در داده های سری آموزش تفاوت زیادی با داده های سری آزمون نشان داد. اگرچه خطای (RMSE) نتایج داده های آموزش از آزمون کمتر بود (جدول ۳). در سری آزمون، هر دو مدل دارای اندکی بیش برآوردی هستند و مقدار GMER برای مدل های شبکه عصبی (ANN) و هیبرید (GA-ANN) به ترتیب ۱/۱۵ و

1 - Geometric mean of error ratio

2 - Geometric standard deviation of error ratio

3 - Akaike information criterion


۱/۰۸ بود. بر طبق شاخص  $AIC$ ، هر دو مدل در مرحله آزمون، قدرت بسیار بیشتری در پیش‌بینی  $EF$  در مقایسه با داده‌های آموزش داشتند. اما هر دو مدل قدرت پیش‌بینی مشابهی داشتند.

جدول ۱: مقادیر، حداقل، حداکثر، میانگین، انحراف استاندارد ( $SD$ ) و ضریب تغییرات ( $CV$ ) برخی ویژگی‌های فیزیکی و شیمیایی خاک‌های مورد آزمایش

| CV (%) | SD    | Mean  | Maximum | Minimum | N  |      |
|--------|-------|-------|---------|---------|----|------|
| 4.0    | 0.32  | 7.94  | 8.72    | 6.81    | 95 | pH   |
| 27.5   | 14.43 | 52.40 | 89.13   | 24.01   | 95 | SP   |
| 121.4  | 17.60 | 14.50 | 72.3    | 0.41    | 95 | EC   |
| 92.5   | 22.53 | 24.37 | 79.49   | 0.31    | 95 | SAR  |
| 26.4   | 5.07  | 19.21 | 28.63   | 3.70    | 95 | CCE  |
| 77.4   | 1.06  | 1.37  | 2.86    | 0.06    | 95 | OM   |
| 68.4   | 0.68  | 0.99  | 3.01    | 0.05    | 95 | MWD  |
| 28.8   | 0.21  | 0.71  | 1.41    | 0.46    | 95 | GMD  |
| 89.8   | 34.22 | 38.11 | 86.04   | 0.09    | 95 | Clay |
| 95.6   | 16.64 | 17.41 | 64.08   | 0.01    | 95 | Silt |
| 167.4  | 11.66 | 6.97  | 48.58   | 0.07    | 95 | Sand |
| 20.9   | 14.62 | 69.92 | 91.25   | 33.89   | 95 | EF   |

جدول ۲: ضرایب همبستگی ساده ( $r$ ) بین برخی خصوصیات فیزیکی و شیمیایی خاک

| EF | Sand  | Silt    | Clay    | OM       | CCE     | SAR      | EC       | SP      | pH       |      |
|----|-------|---------|---------|----------|---------|----------|----------|---------|----------|------|
|    |       |         |         |          |         |          |          |         | 1        | pH   |
|    |       |         |         |          |         |          |          | 1       | 0.287**  | SP   |
|    |       |         |         |          |         |          | 1        | 0.516** | 0.059    | EC   |
|    |       |         |         |          |         | 1        | 0.874**  | 0.579** | 0.306**  | SAR  |
|    |       |         |         |          | 1       | 0.255*   | 0.214*   | 0.260*  | 0.260*   | CCE  |
|    |       |         |         | 1        | -0.250* | -0.354** | -0.311** | -0.131  | -0.469** | OM   |
|    |       |         | 1       | -0.407** | 0.352** | 0.822**  | 0.738**  | 0.677** | 0.459**  | Clay |
|    |       | 1       | 0.457** | -0.275** | 0.450** | 0.278**  | 0.194    | 0.278** | 0.185    | Silt |
|    | 1     | 0.565** | 0.009   | -0.1     | 0.269** | -0.135   | -0.17    | 0.002   | -0.006   | Sand |
| 1  | 0.067 | 0.165   | 0.399** | -0.571** | 0.075   | 0.315**  | 0.264**  | 0.169   | 0.420**  | EF   |




شکل ۲: مقادیر  $R^2$ ، GMER و GSDER در مدل‌ها و در دو مرحله آموزش و آزمون مدل‌ها



جدول ۳: مقادیر خطا و شاخص آکایک برای مدل‌های مورد استفاده در هر دو مرحله آموزش و آزمون

| مدل     | RSME      | ME    | AIC    | RSME      | ME    | AIC    |
|---------|-----------|-------|--------|-----------|-------|--------|
|         | سری آموزش |       |        | سری آزمون |       |        |
| ANN     | 10.93     | -0.59 | 432.68 | 14.18     | -8.18 | 125.08 |
| GA- ANN | 13.59     | 3.21  | 465.42 | 13.33     | -4.03 | 122.59 |

بر طبق نتایج شکل ۳ مربوط به آنالیز حساسیت توابع انتقالی، در مدل شبکه عصبی، بیشترین تأثیر بر فرسایش پذیری بادی خاک به ترتیب مربوط به ماده آلی،  $pH$  و  $EC$  بود. بر طبق نتایج جدول ۲، بیشترین همبستگی جزء فرسایش پذیری بادی خاک با ماده آلی خاک دیده شد. در مدل هیبرید شبکه عصبی و الگوریتم ژنتیک، بیشترین اثر را رس و در وهله بعد  $SAR$  و ذرات شن و سیلت داشتند.



شکل ۳: وضعیت اثرگذاری هر یک از متغیرهای ورودی (خصوصیات خاک) در مدل‌ها بر اساس آنالیز حساسیت

## ۵- بحث و نتیجه‌گیری

جزء فرسایش پذیری بادی خاک (EF) با پنج خصوصیت  $pH$ ، هدایت الکتریکی،  $SAR$ ، مقدار رس و ماده آلی خاک، همبستگی معنی‌دار داشت. (Chepil (1958 and 1960) اندازه و پایداری خاکدانه‌ها عوامل اولیه‌ای هستند که بر حساسیت خاک به فرسایش بادی تأثیر می‌گذارند. روابط بین خصوصیات خاک با EF و پایداری خاکدانه‌ها (dry aggregate stability : DAS) امکان ایجاد مدل‌های ریاضی ساده را فراهم می‌کند که می‌تواند برای کمی‌کردن مقاومت خاک در برابر فرسایش بادی مفید باشد (Colazo, 2010 and Buschiazzo, 2010). (Munns (2003) اعتقاد داشت که ارتباط شوری و EF به طور غیرمستقیم به واسطه اثر آن بر پوشش گیاهی است. شوری با افزایش فشار اسمزی محلول خاک، عدم تعادل عناصر و سمیت آنها، تأثیر معکوس بر رشد و توسعه پوشش گیاهی دارد (Munns, 2003)، بنابراین، افزایش شوری و از بین رفتن پوشش گیاهی سبب کاهش خاکدانه‌سازی و افزایش خطر فرسایش بادی افزایش می‌شود (Munson et al., 2011)، به همین دلیل شوری خاک سبب افزایش طوفان‌های گردوغبار و فرسایش بادی می‌شود (Kokelj et al., 2012). در مطالعه کنونی، این احتمال وجود دارد که ارتباط خصوصیات شیمیایی خاک و EF به واسطه اثر قبلی آنها بر پوشش گیاهی منطقه باشد، لذا شواهد منطقه‌ای نیز بیانگر همین موضوع نیز می‌باشد. گرچه مطالعات (Lyles and Schrandent (1971 نشان



داده است که خاک‌های خیلی شور، فرسایش‌پذیری کمتری نسبت به خاک‌های غیر شور می‌باشند. دلیل این امر می‌تواند تاثیر شوری بر همآوری ذرات در شوری‌های خیلی زیاد باشد.

Colazo and Buschiazzo (2010)، ماده آلی، رس و اکسیدهای آلومینیم را از خصوصیات بسیار مهم و تاثیرگذار خاک بر EF ذکر کرده است. پایداری خاکدانه‌ها یکی از عوامل موثر بر فرسایش‌پذیری خاک‌هاست و کاهش آن سبب افزایش تخریب خاک می‌شود (Marashi et al., 2017 and 2019). ذرات رس و پلی ساکاریدهای مواد آلی سبب پایداری خاکدانه‌ها و کاهش فرسایش‌پذیری خاک می‌شوند (Canasveras et al. 2010). تاثیر ماده آلی در فرسایش پذیری خاک غیرقابل انکار است. ماده آلی همانند سیمانی ذرات خاک را به هم می‌چسباند و سبب تشکیل خاکدانه‌های پایدار در برابر فرسایش بادی می‌شود (عظیم زاده و همکاران، ۱۳۸۱). عنانانی و همکاران (۱۳۹۶) همبستگی بین دو شاخص به دست آمده بر اساس خصوصیات خاک (بافت، ماده آلی و آهک) شامل شاخص فرسایش پذیری خاک (EFI) و فاکتور سله سطحی (SCF) با EF در یکی از کانون‌های فرسایش بادی در استان خوزستان مورد بررسی قرار دادند. نتایج نشان داد EF با EFI و SCF همبستگی نسبتاً خوبی داشت (مقادیر  $R^2$  به ترتیب برابر با ۰/۶۰ و ۰/۵۷). بنابراین در مناطقی که داده‌های فرسایش پذیری موجود نیست و انجام مطالعات دقیق با محدودیت‌های مالی و زمانی مواجه است، می‌توان از EFI و SCF که داده‌های لازم برای محاسبه آنها معمولاً در دسترس است، برای برآورد EF استفاده نمود. EF بیانگر خاکدانه‌های خاک با قطر کمتر ۰/۸۴ میلی‌متر است (Chepil, 1958 and 1960) و تشکیل خاکدانه به خصوصیات خاک ارتباط دارد (Marashi et al., 2019).

مدل‌های شبکه عصبی مصنوعی در مطالعات مختلف به عنوان مدل مناسب در برآورد فرسایش (Huang et al., 2006; Dai et al., 2014; Sarkar and Mishra, 2018; Alexakis et al., 2019; Aslan et al., 2019; Eslami et al., 2019)، شاخص‌های پایداری خاکدانه‌ها (Paz Lagos-Avid and Bonilla, 2017; Wu et al., 2018) معرفی شده‌اند. Huang et al. (2006) از شبکه عصبی مصنوعی در پیش‌بینی طوفان‌های گرد و غبار (فرسایش بادی) در شمال شرقی چین استفاده کرد و نشان داد که ضریب همبستگی بین مقادیر پیش‌بینی شده و مقادیر اندازه‌گیری شده در مدل شبکه عصبی بیشتر از مدل حاصل از رگرسیون بود. در برخی مطالعات نیز در استفاده از مدل‌های شبکه عصبی مصنوعی پاسخ مناسبی برای پیش‌بینی خصوصیات خاک دریافت نشد (Khanbabakhani et al., 2020; Kim et al., 2018). در این مطالعه نیز با توجه به مقادیر شاخص‌های آماری شکل ۲ به ویژه  $R^2$  هر دو مدل شبکه عصبی و هیبرید آن با الگوریتم ژنتیک حکایت از دقت کم آنها در برآورد EF دارد.

آنالیز حساسیت می‌تواند برای شناخت چگونگی کار مدل‌های "جعبه سیاه" به کار رود. این آنالیز قوانین صریحی به دست نمی‌دهد، ولی می‌تواند اهمیت نسبی ورودی‌ها بر جواب ANN را مشخص سازد. به عبارت دیگر این تکنیک میزان حساسیت خروجی شبکه به تغییرات هر ورودی را مشخص می‌کند. آنالیز حساسیت برای پارامترهای ورودی در مدل‌های شبکه عصبی مصنوعی و هیبرید شبکه عصبی مصنوعی با الگوریتم ژنتیک را نشان می‌دهد. بر طبق نتایج شکل ۳، در مدل شبکه عصبی، بیشترین تأثیر بر فرسایش‌پذیری بادی خاک به ترتیب مربوط به ماده آلی، pH و EC بود. بر طبق نتایج جدول ۲، بیشترین همبستگی جزء فرسایش‌پذیری بادی خاک با ماده آلی خاک دیده شد. نتایج (Marashi (2017) نیز مؤید بیشترین همبستگی پایداری خاکدانه‌ها با مقدار ماده آلی بود. اثر pH و شوری بر EF می‌تواند به دلیل اثر آنها بر پوشش گیاهی و متعاقب آن اثر پوشش گیاهی بر خاکدانه‌ها باشد. مجدی و همکاران (۱۳۸۵) در بررسی اثر مالچ رسی بر تثبیت خاک در برابر فرسایش بادی نتیجه گرفتند که افزایش شوری مالچ به کار رفته سبب کاهش فرسایش بادی می‌شود زیرا با افزایش شوری، تأثیر سدیم در پراکندگی ذرات خاک کاهش می‌یابد.

در مدل هیبرید شبکه عصبی و الگوریتم ژنتیک، بیشترین اثر را رس و در وهله بعد SAR و ذرات شن و سیلت داشتند. دانشمندان در اغلب موارد، بافت خاک را اصلی‌ترین عامل در فرسایش پذیری خاک معرفی کرده‌اند (عظیم زاده و همکاران، ۱۳۸۱). Colazo and Buschiazzo (2010)، مقدار جزء فرسایش پذیری خاک (EF) و پایداری خشک خاکدانه (DAS) را در ۲۸ خاک کشت شده و کشت نشده از منطقه نیمه‌خشک مرکزی آرژانتین با مقادیر متفاوت رس، ماده آلی، آهک و

اکسیدهای آهن و آلومینیم مورد ارزیابی قرار دادند. نتایج آنان نشان داد که مقادیر EF و DAS با مقادیر ماده آلی، اکسیدهای آلومینیم و رس به صورت لگاریتمی و یا نمایی مرتبط می‌باشند. این روابط می‌تواند مقادیر بحرانی ماده آلی، اکسیدهای آلومینیم و رس برای مقاومت خاک در برابر فرسایش بادی را مشخص نماید. آنان نشان دادند که کشت و کار می‌تواند سبب افزایش EF و کاهش DAS شود. آهک و اکسیدهای آهن بر EF و DAS اثر ندارد. عظیم زاده و همکاران (۱۳۸۱) نتیجه گرفتند که با افزایش SAR، فرسایش پذیری بادی افزایش می‌یابد مگر این که عامل دیگری تاثیرگذار باشد. فاکتور فرسایش پذیری ذاتی خاک یکی از ویژگی‌های خاک برای بررسی مقاومت و حساسیت ذرات آن در برابر عوامل فرسایش زا است که ارتباط زیادی با جزء فرسایش پذیری خاک دارد. این تحقیق از توابع انتقالی به عنوان یک روش غیر مستقیم پیش-بینی جزء فرسایش پذیری بادی خاک از داده‌های زودپافت خاک استفاده نمود. برای این منظور، از مدل‌های شبکه عصبی مصنوعی و تلفیق آن با الگوریتم ژنتیک در پیش‌بینی جزء فرسایش پذیری خاک استفاده شد. نتایج نشان داد که جزء فرسایش پذیری بادی خاک (EF) دارای همبستگی معنی‌داری با پنج خصوصیت فیزیکی و شیمیایی  $pH$ ،  $EC$ ،  $SAR$ ،  $Clay$  و  $OM$  خاک می‌باشد. طبق نتایج آنالیز حساسیت، در مدل شبکه عصبی، بیشترین تأثیر بر فرسایش پذیری بادی خاک به ترتیب مربوط به ماده آلی،  $pH$  و  $EC$  بود. در مدل هیبرید شبکه عصبی و الگوریتم ژنتیک، بیشترین اثر را رس و در وهله بعد  $SAR$  و ذرات شن و سیلت داشتند. اما موضوعی که در تحقیق مهم بود این است که مدل‌های به کار رفته یعنی شبکه عصبی مصنوعی و تلفیق آن با الگوریتم ژنتیک در برآورد شاخص جزء فرسایش پذیری بادی خاک از کارایی مناسبی برخوردار نمی‌باشند به طوری که بالاترین ضریب تبیین ( $R^2$ ) در مدل شبکه عصبی در مرحله آزمون ( $R^2 = 0.49$ )، صحت کمتر از ۵۰ درصد در تخمین EF داشت.

#### فهرست منابع

1. Aali KA, Parsinejad M, Rahmani B (2009) Estimation of saturation percentage of soil using multiple regression, ANN, and ANFIS techniques. *Computer Inform Sci* 2(3), 127-136.
2. Ahmadi A, Neyshabouri MR, Rouhipour H, Asadi H (2011) Fractal dimension of soil aggregates as an index of soil erodibility. *J Hydrol* 400 (3-4), 305-311.
3. Akaike H (1974) A new look at the statistical model identification. *IEEE Transactions on Automatic Control*. 19(6): 716-723.
4. Alewell C, Borrelli P, Meusburger K, Panagos P (2019) Using the USLE: chances, challenges and limitations of soil erosion modelling. *Int. Soil Water Conserv Res* 7: 203-225. Doi: 10.1016/j.iswcr.2019.05.004.
5. Alexakis DD, Tapoglou E, Vozinaki AEK, Tsanis LK (2019) Integrated Use of Satellite Remote Sensing, Artificial Neural Networks, Field Spectroscopy, and GIS in Estimating Crucial Soil Parameters in Terms of Soil Erosion. *Rem Sens* 11(9): 1-21.
6. Ananani M, Amirian Chakan A, Faraji M, Yousefi Khaneghah SH (2018) Use of erodibility indices and surface ridges in the study of soil sensitivity to wind erosion. 15th Iranian Soil Science Congress, Isfahan University of Technology, Isfahan, Iran.
7. Aslan Z, Erdemir G, Feoli E, Giorgi F, Okou D (2019) Effects of Climate Change on Soil Erosion Risk Assessed by Clustering and Artificial Neural Network. *Pure Appl Geophys* 176 (2): 937-949.
8. Aytak A, Kisi O (2008). A genetic programming approach to suspended sediment modeling. *Journal of Hydrology*, 351: 288-298.
9. Azimzadeh HR, Ekhtesasi MR, Hatami M, Qalibaf MA (2002). Wind erosion: erodibility relation to soil physical and chemical properties in iran central plain (yazd-ardakan plain - case study). *J Agr Sci Nat Resour*, 9(1): 139-151.
10. Besalatpour AA, Ayoubi S, Hajabbasi MA, Mosaddeghi MR, Schulin R (2013). Estimating wet soil aggregate stability from easily available properties in a highly mountainous watershed. *Catena*, 111: 72-79.
11. Borrelli P, Robinson DA, Panagos P, Lugato E, Yang JE, Alewell C, Wuepper D, Montanarella L, Ballabio C (2020) Land use and climate change impacts on global soil erosion by water (2015-2070). *Proc Natl Acad Sci USA* 117: 21994-22001, 10.1073/pnas.2001403117.
12. Cañasveras JC, Barrón V, Del Campillo MC, Torrent J, Gómez JA (2010). Estimation of aggregate stability indices in Mediterranean soils by diffuse reflectance spectroscopy. *Geoderma*. 158(1):78-84.
13. Cao K, Batty M, Huang B, Liu Y, Yu L, Chen J (2011). Spatial multi-objective land use optimization: extensions to the non-dominated sorting genetic algorithm-II. *Int J Geographic Inform Sci*, 25(12), 1949-1969.

14. Chahar Azar F, Chahar Azar Y, Javad Amiri M (2019) The Role of aerosol on Human Health and the Environment, International Dust Conference on Southwest Asia, 23-25 April 2019, University of Zabol, Zabol, Iran. In Persian.
15. Chandler DG (2005). Predicting wind erodibility of loessial soils in the Pacific Northwest by particle sizing. *Arid Land Res Manag* 19: 13-27.
16. Chappell A, Webb NP (2016) Using albedo to reform wind erosion modelling, mapping and monitoring Aeolian Res 23: 63-78, 10.1016/j.aeolia.2016.09.006.
17. Chepil W (1958). Soil conditions that influence wind erosion. *USDA Tech, Bui, No*, 1185.
18. Chepil W, 1960. Conservation of relative field erodibility to annual soil loss by wind. *Soil Sci Soc Am J* 24(2):143-148.
19. Colazo JC, Buschiazzi DE (2010) Soil dry aggregate stability and wind erodible fraction in a semiarid environment of Argentina. *Geoderma*, 159 (1-2): 228-236.
20. Coppinger KD, Reiners WA, Burke IC and Olson RK (1991). Net erosion on a sagebrush steppe landscape as determined by cesium-137 distribution. *Soil Sci Soc Am J* 55: 254-258.
21. Dai F, Zhou Q, Lv Z, Wang X, Liu G (2014) Spatial prediction of soil organic matter content integrating artificial neural network and ordinary kriging in Tibetan Plateau. *Ecol Indicators*, 45: 184-194.
22. Emami S, Hemmati M, Arvanaghi H (2018)). Performance evaluation of imperialist competitive and genetic algorithm for estimating groundwater quality parameters (case study: Bostanabad plain). *Hydrogeology*, 2(2): 44-54.
23. Eslami M, Shadfar S, Mohammadi Torkashvand A, Pazira E (2019). Assessment of density area and LNRF models in landslide hazard zonation (case study: Alamout watershed, Qazvin province, Iran. *Acta Ecol Sinica*. 3 (2): 173-180.
24. Goldberg DE (1989). Genetic algorithm in search, optimization and machine learning. Addison Wesley, Reading, MA, 412p.
25. Haykin S (1999) *Neural Networks and Learning Machines*. 3<sup>rd</sup> edition, Pearson, Prentice Hall, Upper Saddle River, New Jersey 07458, United States.
26. Hojjatnooghi F, Shirani H, Pazira E, Besalatpour A (2019). Identification of Soil Properties Influencing Some Soil Physical Quality Indicators Using Hybrid PSO-ICA-SVR Algorithm in Some Agricultural Land Uses of Kerman Province, Iran. *Commun Soil Sci Plant Anal* 50 (16), 1986-2002.
27. Huang M, Peng G, Zhang J, Zhang S (2006). Application of artificial neural networks to the prediction of dust storms in Northwest China. *Global and Planetary Change*, 52 (1-4): 216-224.
28. Jarraha M, Mayela S, Tatarkob J, Funkc R, Kukaa K (2020) A review of wind erosion models: Data requirements, processes, and validity. *Catena*, 187, 104388, <https://doi.org/10.1016/j.catena.2019.104388>.
29. Khanbabakhani E, mohammadi Torkashvand A, Mahmoodi MA (2020). The possibility of preparing soil texture class map by artificial neural networks, inverse distance weighting, and geostatistical methods in Gavoshan dam basin, Kurdistan. *Arabian J Geosci* 13 (5), 1-14
30. Khanbabakhani L, Mohammadi Torkashvand A, Mohmoodi MA (2018). Prediction of soil texture using artificial neural networks. *Soil Water Resour Conserv* 8(1): 1-10.
31. Kim M, Gilley JE (2008). Artificial Neural Network estimation of soil erosion and nutrient concentrations in runoff from land application areas. *Comput Electronics Agr* 64 (2): 268-275.
32. Klute A (1986). *Methods of Soil Analysis: Part 1. Physical and Mineralogical Methods* (Sssa Book Series No 5) 2nd Edition, Am Soc Agron Soil Sci Soc Am, Madison, WI.
33. Kokelj SV, Lantz TC, Solomon S, Pisaric MFJ, Keith D, Morse P, Thienpont JR, Smol JP, Esagok D (2012). Using multiple sources of knowledge to investigate northern environmental change: regional ecological impacts of a storm surge in the outer Mackenzie delta, N.W.T. Arctic, 65(3): 257 – 272.
34. Liong SY, Gautam TR, Khu ST, Babovic V, Muttill N (2002). Genetic Programming: A New Paradigm in Rainfall- Runoff Modelling. *J Am Water Resour Assoc* 38(3), 705-718.
35. Lyles L, Disrud L A and Woodruff NP (1969). Effects of soil physical properties, rainfall characteristics, and wind velocity on clod disintegration by simulated rainfall. *SSSA Proc*, 33(2): 302-306.
36. Lyles L, Schrandet RL (1971). Wind erodibility as influence by rainfall and salinity. *Soil Sci* 114: 367-372.
37. Majdi H, Karimian Iqbal M, Karimzadeh HR, Jalalian A (2006). The effect of different types of clay mulch on the amount of wind eroded materials. *J Agr Sci Technol Nat Resour* 10(3): 137-148.
38. Marashi M, Mohammadi Torkashvand A, Ahmadi A, Esfandiari M (2017). Estimation of soil aggregate stability indices using artificial neural network and multiple linear regression models. *Spanish J Soil Sci* 7(2): 89-99.
39. Marashi M, Mohammadi Torkashvand A, Ahmadi A, Esfandiari M (2019). Adaptive neuro-fuzzy inference system: estimation of soil aggregates stability. *Acta Ecol Sinica*. 39(1):95-101.
40. Matkan A, Tanasan M, Shakiba A, Mirbagheri B, Akbari K, Shaygan M (2014). Designing a multi-objective optimization model of management canopy, based on genetic algorithms approach to soil conservation - Case study: Kerman- Roodbar watershed. *Environ Erosion Res* 4 (3): 33-46. (In Persian).

41. Merrill SD, Black AL, Halvorson A (1997). Soil-inherent wind erodibility: Progress and prospects; Paper presented at the Proceedings Wind Erosion: An International Symposium/Workshop.
42. Mohammadi Torkashvand A (2008). Geographic information system and remote sensing: proposing a model for providing erosion features map in Iran at the national scale. *J Appl Sci* 8 (4): 594-600.
43. Mohammadi Torkashvand A, Haghighat N (2009). Investigation of some models derived from data layers integration in geographic information system with slope layer for providing water-soil erosion types maps. *Res J Environ Sci* 3 (2), 202-209.
44. Mohammadi Torkashvand A, Nikkami D (2008). Investigating some methodologies of preparing erosion features map by using RS and GIS. *Int J Sediment Res* 23 (2): 124-132.
45. Mokhtari P, Ayoubi SH, Honarju N, Jalalian A (2011). Predicting soil organic matter by artificial neural network in landscape scale using remotely sensed data and topographic attributes. *Geophys Res Abs* 13: 10-75.
46. Moradi Gh, Aprajunqani A (2019) Investigating the Origin of aerosol and their Impacts on Air Pollution, International Dust Conference on Southwest Asia, 23-25 April 2019, University of Zabol, Zabol, Iran. In Persian.
47. Munns R (2003). Comparative physiology of salt and water stress. *Plant Cell Environ* 25: 239-50.
48. Munson SM, Belnap J, Okin SG (2011). Responses of wind erosion to climate-induced vegetation changes on the Colorado Plateau. *Proceedings of the National Academy of Sciences of the United States of America*, 108(10): 3854-3859.
49. Nasseh S, Mohebbi A, Sarrafi A, Taheri M (2009). Estimation of pressure drop in venturi scrubbers based on annular two-phase flow model, artificial neural networks and genetic algorithm. *J Chem Engin* 150: 1. 131-138.
50. Nelson DW, Sommers LE (1982). Total carbon, organic carbon, and organic matter: 539-579, In: Page AL (ed.) *Methods of Soil Analysis. Part 2. 2nd ed. American Society of Agronomy, Madison, WI*.
51. Nosrati H, Eftekhari M (2014). A new approach for variable selection using fuzzy logic. *Computational Intelligence in Electrical Engineering*, 4, 71 -83.
52. Ostovari Y, Ghorbani-Dashtaki S, Bahrami HA, Naderi M, Dematte JAM, Kerry R (2016). Modification of the USLE K factor for soil erodibility assessment on calcareous soils in Iran. *Geomorphology*, 273, 385-395.
53. Palizvanzand H, Ahmadi A (2016). Comparison of linear regression, Fuzzy and Fuzzy-genetic models to predict soilcation exchange capacity. *Appl Soil Res* 3(2): 86-100. In Persian.
54. Parvaresh Rizi A, Koochak Zadeh S, Omid M (2006). Estimating moving hydraulic jump parameters by means of ANN and the integration of ANN and GA. *Agricultural Sci* 37: 1. 187-196. (In Persian)
55. Parvizi Y, Omid M, Mahdian MH, Amini M (2010) Determination of Soil Organic Carbon Variability of Rainfed Crop Land in Semi-arid Region (Neural Network Approach). *Modern Appl Sci* 4(7): 25-33.
56. Paz Lagos-Avid M, Bonilla CA (2017) Predicting the particle size distribution of eroded sediment using artificial neural networks. *Science of The Total Environment*, 581-582: 833-839.
57. Peng F, Xue X, You Q, Huang C, Dong S, Liao J, Duan H, Tsunekawa A, Wang T (2018) Changes of soil properties regulate the soil organic carbon loss with grassland degradation on the Qinghai-Tibet Plateau. *Ecol Ind* 93: 572-580, 10.1016/j.ecolind.2018.05.047.
58. Prasad R, Mathur S (2007). Groundwater Flow and Contaminant Transport Simulation with Imprecise Parameters. *Irrigation Drain Engin* 133(1): 61-70.
59. Qazvin province planning study plan (2018). Management and Planning Organization, Qazvin, Iran.
60. Refahi H (1999). Wind erosion and conservation. Tehran University Press, 320 p.
61. Sarani A, Rahdari S (2019) Aerosol on Agricultural Performance and Extension Activities. International Dust Conference on Southwest Asia, 23-25 April 2019, University of Zabol, Zabol, Iran. In Persian.
62. Sarkar T, Mishra M (2018). Soil erosion susceptibility mapping with the application of logistic regression and artificial neural network. *J Geovisual Spatial Anal* 2: 1-17.
63. Shahkoui A, Rahmani T (2018) Climatic Survey of aerosol at Northwest of Iran, Second National Meteorological Conference of Iran, 9th May 2018, Ferdowsi University of Mashhad, Mashhad, Iran. In Persian.
64. Song Y, Liu L, Yan P, Cao T (2005). A review of soil erodibility in water and wind erosion research. *J Geograph Sci* 15, 167-176.
65. Tanasan M (2013). Designing spatial optimization land use model using multi-objective genetic algorithm whit land use planning approach, MSc Thesis, Department of Remote Sensing and GIS, Shahid Beheshti University, In Persian.
66. Teng Y, Zhan J, Liu W, Sun Y, Boappeah Agyemang F, Liang L, Li Z (2021) Spatiotemporal dynamics and drivers of wind erosion on the Qinghai-Tibet Plateau, China. *Ecol Ind* 123: 107340. doi.org/10.1016/j.ecolind.2021.107340.
67. Vaezi AR, Sadeghi SH, Bahrami HA, Mahdian M (2008). Modeling the USLE K-factor for calcareous soils in northwestern Iran. *Geomorphology* 97, 414-423.
68. Wu W, Dili A, He HX, Ma R, Liu HB, LV JK (2018). A comparison of support vector machines, artificial neural network and classification tree for identifying soil texture classes in southwest China. *Computers and Electronics in Agriculture*, 144: 86-93.

69. Wuepper D, Borrelli P, Finger R (2020) Countries and the global rate of soil erosion. *Nat Sustain* 3: 51-55, 10.1038/s41893-019-0438-4.
70. Zare Abyaneh H., Bayat Varkeshi M. Marofi S. Ildromi A.R. (2010). Simulation of Malayer Plain Groundwater Level Based on Weather Data Using Artificial Neural Network. *Natural Geographic Research Journal*, 78, 17-38.
71. Zhao HL, Yi XY, Zhou RL, Zhao XY, Zhang TH, Drake S (2006). Wind erosion and sand accumulation effects on soil properties in Horqin Sandy Farmland, Inner Mongolia. *Catena*, 65: 71-79.
72. Zhou T, Shi PJ, Luo JY (2008). Estimation of soil organic carbon based on remote sensing and process model. *J Rem Sens* 11(1): 127-136.



# Estimation of soil erodible fraction using artificial neural network models and integration of artificial neural network with genetic algorithm in the part of Qazvin province

**Alireza Noori:** Ph.D. Student, Department of Soil Science, Science and Research Branch, Islamic Azad University, Tehran, Iran

**Kamran Eftekhari**<sup>1</sup>: Research Assistant Professor, Soil and Water Research Institute, Tehran, Iran

**Mehrdad Esfandiari:** Department of Soil Science, Science and Research Branch, Islamic Azad University, Tehran, Iran

**Ali Mohammadi Torkashvand:** Assistant Professor, Department of Soil Science, Science and Research Branch, Islamic Azad University, Tehran, Iran

**Abbas Ahmadi:** Associate Professor, Department of Soil Science, University of Tabriz, Tabriz, Iran

Article History (Received: 2021/04/7

Accepted: 2021/09/18)

## Extended abstract

### 1- Introduction

Erosion is one of the main factors restricting the soil fertility and dust production, in several parts of the world, including Iran, has effects on climate agriculture, and human health. Controlling wind erosion would be more effective once sufficient information concerning the effective factors is available. Soil Erodible Fraction (EF) is one of the soil properties that shows the sensitivity of soil particles to wind erosion. The current research aimed to utilize ANN methods and integrating it with GA in order to estimate the soil erodible fraction to wind erosion. Allahabad plain in the southwest of Abiek city in Qazvin province is considered as one of the areas sensitive to wind erosion with strong wind direction from southwest to northeast. The drying up of Allahabad wetland will intensify wind erosion in the region and turn it into a crisis. Determining the extent of land erodibility and identifying its factors affecting can be the basis of a comprehensive plan for soil protection and land sustainability and prioritizing its implementation steps. The present study was conducted to use artificial neural network methods and combine it with genetic algorithm to estimate the soil erodible factor.

### 2- Methodology

In the study area, which was part of the Allahabad plain in Qazvin province, between the coordinates of 50°15' - 50°57' east longitude and 35°53' - 35°57' north latitude, 95 samples were taken from 10 cm of soil surface. In the samples, the percentage of aggregates with a diameter of less than 0.84 mm as an indicator of EF and percentage of clay, sand and silt, soil saturation capacity, pH, EC, SAR, equivalent calcium carbonate (CCE) and organic matter were measured as input to the models. In this paper, to model the EF using early available characteristics, two methods of artificial neural network (ANN) and its integration with genetic algorithm (GA-ANN) were employed in order to optimize the weights. In this regard, the data were primarily divided into three categories as follows: 60% of the data series was allocated to training, 20% to validation, and 20% to network testing. In this study, MLP networks were used to model the artificial neural network in estimating the values of soil erodible Fraction. In this structure, each artificial neural network includes inputs and hidden and output layers. During the learning process, the degree of network learning by the objective functions was regularly evaluated and networks with the lowest error rate were accepted. To determine the optimal network with the highest level of performance of all stimulus functions defined in the software (axon hyperbolic tangent, axon sigmoid, axon linear hyperbolic tangent, axon linear sigmoid, axon bias, linear axon and axon) by trial and error The most results were used. Levenberg-Marquardt training functions were used to teach defined networks. In this study, genetic algorithm was used to find the optimal point of complex nonlinear functions in combination with artificial neural network (GA-

<sup>1</sup> Corresponding Author: [kamran\\_eftekhari@hotmail.com](mailto:kamran_eftekhari@hotmail.com)

ANN). The genetic algorithm optimizes the weights of the artificial neural network. In fact, the objective function of the genetic algorithm is a function of the statistical results of the artificial neural network.

### 3- Results

The results showed that the erodible fraction of soil with five soil properties including pH, electrical conductivity, SAR, clay and organic matter, had a significant correlation at the level of one percent. The models used did not have an appropriate accuracy in estimating EF in both training and testing stages, so that the highest  $R^2$  was obtained in the artificial neural network model (0.49) with test series data. Both models were slightly overestimated and the GMER values for the ANN and GA-ANN models were 1.15 and 1.08, respectively, but according to the AIC index, both models had similar predictive power. Sensitivity analysis of the data showed that the greatest effect on EF in the ANN model was related to organic matter (4.07) and in the GA-ANN model was related to clay (8.14).

### 4- Discussion & Conclusions

In the current research, the relationship between soil chemical characteristics and EF might be attributed to their previous effects on vegetation in the region. Additionally, regional evidence indicates the same finding. The highest correlation was observed between EF and soil organic matter. Based on the sensitivity analysis, in the neural network model, the greatest effect on erodible fraction was related to organic matter, pH, and EC, respectively. The effect of pH and salinity on EF could be interpreted due to their effects on vegetation and consequently, the effect of vegetation on aggregates. An important issue in the research was that the proposed models, which were ANN and its integration with GA for estimating the soil erodible fraction, were not efficient enough for obtaining the highest coefficient of determination ( $R^2$ ) in the model in the neural network in the test phase ( $R^2 = 0.49$ ), which has an accuracy of less than 50% for estimating EF.

**Key Words:** Allahabad, ANN, EF, GA, Sensitivity analysis, Soil salinity.