

مقایسه کارایی مدل‌های رگرسیونی، شبکه عصبی مصنوعی و تلفیق آن با الگوریتم ژنتیک در بررسی فرسایش بادی

شاهین ابراهیمی^۱، علی محمدی ترکاشوند^{۲*}، مهرداد اسفندیاری^۳ و عباس احمدی^۴

(۱) دانشجوی دکتری، گروه خاکشناسی، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.

(۲) گروه علوم و مهندسی خاک، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.

(۳) گروه علوم و مهندسی خاک، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.

(۴) گروه خاکشناسی، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران.

* ایمیل نویسنده مسئول: m.torkashvand54@yahoo.com



شاپا چاپی: ۲۲۵۱-۷۴۸۰

شاپا الکترونیکی: ۲۲۵۰-۷۴۰۰

نشریه حفاظت منابع آب و خاک

چکیده:

زمینه و هدف: فرسایش بادی در بخش بزرگی از پهنه ایران وجود داد که سبب تخریب اراضی و کاهش باروری آنها به همراه اثرات زیست‌محیطی شده است. شناخت مناطق حساس به فرسایش می‌تواند در برنامه‌ریزی‌های حفاظت خاک به کمک مدیران منابع طبیعی و محیط‌زیست آید.

روش پژوهش: این تحقیق برای برآورد جزء فرسایش‌پذیر خاک در مقابل باد (EF) از روی ویژگی‌های سهل الوصول خاک در دشت الله‌آباد واقع در شرق استان قزوین انجام شد. بدین منظور جزء فرسایش‌پذیر خاک در مقابل باد با استفاده از روش‌های رگرسیون چند متغیره (MLR)، شبکه عصبی مصنوعی (ANN) و تلفیق شبکه عصبی مصنوعی با الگوریتم ژنتیک برای بهینه‌سازی اوزان (GA-ANN) با به کار بردن ویژگی‌های سهل الوصول برآورد شد. با بررسی نقشه خاک، تفاوت خاک‌ها و خصوصیات محیطی دشت الله‌آباد، ۱۰۳ نمونه خاک طبق یک الگوی تصادفی طبقه‌بندی شده از ۱۰ سانتی‌متری سطح آن‌ها، جمع‌آوری و به آزمایشگاه ارسال شد. در نمونه‌های خاک، برخی خصوصیات خاک به‌عنوان ورودی‌های مدل‌های برآورد جزء فرسایش‌پذیر خاک در مقابل باد اندازه‌گیری گردید. ورودی‌های هر مدل شامل pH، SAR، CCE، ECe و جرم مخصوص ظاهری، ذرات شن، سیلت و رس، ذرات درشت خاک با قطر کمتر از ۲ میلی‌متر و ماده آلی بودند. دقت و قابلیت اعتماد نتایج مدل‌های ایجاد شده با توجه به معیارهای ضریب تبیین، مجذور مربعات خطا، آزمون مورگان-گرنجر-نیوبلد و شاخص آکایک مورد مقایسه قرار گرفتند.

یافته‌ها: طبق یافته‌ها، بیشترین همبستگی جزء فرسایش‌پذیر خاک در مقابل باد (EF) با مقدار رس خاک دیده شد ($r = -0.789$). همچنین جزء فرسایش‌پذیر خاک با خصوصیات دیگر خاک شامل pH، هدایت الکتریکی، SAR، مقدار ماده آلی و جرم مخصوص ظاهری، همبستگی نشان داد، این همبستگی با سه خصوصیت SAR، ماده آلی و رس در سطح یک درصد همبستگی معنی‌دار بود. مدل‌های ای‌جاد شده با هر سه روش توانایی بسیار بیشتری در پیش‌بینی EF در سری داده‌های آزمون نسبت به داده‌های سری آموزش داشتند. همچنین نتایج نشان داد که مدل شبکه عصبی از دقت بیشتر و خطای تخمین کمتری در مقایسه با مدل‌های هیبرید و رگرسیون به‌دست آمده است. نتایج آنالیز حساسیت نیز نشان داد که بیشترین حساسیت مدل به متغیرهای ورودی در مدل ANN، به ترتیب مربوط به ماده آلی و SAR و در مدل GA-ANN مربوط به متغیر میزان رس خاک بود.

نتیجه‌گیری: بر طبق نتایج، تنها مدل رگرسیون در مرحله آموزش دارای R^2 بیشتر از ۵۰ درصد ($R^2=0.56$) در برآورد جزء فرسایش‌پذیر خاک بود که البته این مقدار ($R^2=0.56$) نیز قابل اعتماد نیست. با توجه به نتایج مرحله آزمون، هر سه مدل به کار رفته شامل رگرسیون، شبکه عصبی مصنوعی و تلفیق آن با الگوریتم ژنتیک در برآورد شاخص جزء فرسایش‌پذیر خاک از کارایی مناسبی برخوردار نمی‌باشند به طوری که بالاترین ضریب تبیین (R^2) در مدل شبکه عصبی در مرحله آزمون ($R^2 = 0.43$)، صحت کمتر از ۵۰ درصد در تخمین EF داشت که نمی‌تواند صحت مناسبی در پیش‌بینی جزء فرسایش‌پذیر بادی خاک باشد.

کلیدواژه‌ها: پرسپترون، رس، رگرسیون خطی چند متغیره، ریزگرد، ماده آلی

آدرس تارنما:

<https://wsrcj.srbiau.ac.ir>

پست الکترونیک:

iauwsrcj@srbiau.ac.ir

iauwsrcj@gmail.com

سال دوازدهم

شماره یک (۴۵)

پاییز ۱۴۰۱

تاریخ دریافت:

۱۴۰۰/۰۲/۲۱

تاریخ پذیرش:

۱۴۰۰/۰۸/۳۰

صفحات: ۸۶-۷۳



اندازه‌گیری SIWE به‌وسیله دستگاه تونل باد، یک روش پرهزینه و زمان‌بر می‌باشد، لذا یافتن روش‌های غیرمستقیم، ساده و کم‌هزینه در برآورد SIWE، راه حل کار است. توابع انتقالی از مهم‌ترین روش‌های غیرمستقیم به دست آوردن داده‌های دیریافت خاک از داده‌های سهل الوصول خاک است (Bouma, 1989) که دارای مزیت‌های عمده‌ای چون صرفه‌جویی در وقت و هزینه هستند (Wosten et al, 2001; Merdun et al., 2006). استفاده از روش‌های آماری کلاسیک برای پیش‌بینی خصوصیات دیریافت خاک به دلیل پیچیدگی ارتباط بین خصوصیات کمی و کیفی خاک مفید نیست (Besalatpour et al., 2014). روش‌های هوشمند شامل شبکه‌های عصبی مصنوعی و الگوریتم‌های تکاملی ابزارهای پیش‌بینی کننده قوی‌تری برای یافتن روابط پیچیده و غیرخطی بین خصوصیات خاک هستند (Li et al., 2009; Shirani et al., 2015; Sarkar and Mishra, 2018; Hojjatnooghi et al., 2019) که در دهه‌های اخیر از شبکه‌های عصبی در مطالعات زیادی در تخمین خصوصیات دیریافت خاک از روی خصوصیات زودیافت استفاده شده است (Ayoubi et al., 2011; Mokhtari et al., 2011; Peng et al., 2012; Besalatpour et al., 2013; Marashi et al., 2017; Eslami et al., 2019; Hojjatnooghi et al., 2019)

محققان تکنیک الگوریتم ژنتیک را که هدف آن دستیابی به بهترین پاسخ در میان فضای پاسخ‌های ممکن است در بسیاری از مطالعات علوم طبیعی و فنی، مورد استفاده قرار داده‌اند. از آن جمله می‌توان به استفاده از آن در تحلیل حساسیت مدل‌های تخمین هدر رفت خاک و تولید رواناب (Tung et al., 2003) و تخمین میزان ماده آلی خاک (Crowe et al., 2006) اشاره کرد. Liu و همکاران (۲۰۰۷) نیز قابلیت پیش‌بینی هدر رفت سالیانه فسفر خاک به‌وسیله الگوریتم ژنتیک را بسیار بالا توصیف نمودند. Lo و همکاران (۲۰۰۷) برای ساخت سیستم عیب‌یابی خودکار برای استفاده در سیستم گرمایش و تهویه از سیستم فازی - ژنتیک استفاده کردند و به این نتیجه رسیدند که قابلیت بهینه کردن سیستم فازی توسط الگوریتم ژنتیک باعث عملکرد بهینه سیستم فازی می‌شود.

فرسایش بادی یکی از عوامل اصلی تخریب اراضی ایران می‌باشد (Seyed Nasir et al., 2021). از دست رفتن اراضی و کاهش باروری آنها به همراه اثرات زیست‌محیطی فرسایش خاک، یک چالش جدی در استفاده پایدار از منابع تولید است (Mohammadi et al., 2008; Mohammadi et al., 2008; Torkashvand and Nikkami, 2008; Torkashvand and Haghghat, 2009; Mohammadi et al., 2008; Copping et al., 1991). مهار فرسایش بادی نیازمند اطلاعات کافی در خصوص عوامل مؤثر بر آن می‌باشد (Refahi, 2006). از پارامترهای مؤثر در فرسایش بادی خاک، عوامل اقلیمی می‌باشد (Gomez et al., 2003; Leenders et al., 2005; Mezosi et al., 2013). از میان عوامل اقلیمی، وجود باد فرساینده می‌تواند باعث افزایش فرسایش در سطوح حساس به فرسایش بادی گردد (Callot et al., 2000). رطوبت خاک نیز ارتباط زیادی به حساسیت خاک در مقابل فرسایش بادی دارد (Ravi et al., 2006). رطوبت خاک در اثر خشکسالی، کاهش می‌یابد که در نتیجه آن، مناطق بادخیز بیشتر تحت تأثیر فرسایش بادی قرار می‌گیرند (Blanka et al., 2013; Mezosi et al., 2013).

شدت فرسایش بادی تابع دو دسته عوامل فرساینده و فرسایش‌پذیری است (Stout and Zobeck, 1996; Qiang et al., 2007). فاکتور فرسایش‌پذیری ذاتی خاک یکی از ویژگی‌های خاک برای بررسی مقاومت و حساسیت ذرات آن در برابر عوامل فرسایش‌زا است. فرسایش‌پذیری خاک تحت تأثیر عوامل مختلفی به‌ویژه زبری و رطوبت خاک سطحی است و هنگامی که تأثیر عوامل زبری و رطوبت خاک سطحی بر میزان فرسایش بادی ناچیز باشد، در این صورت تنها حساسیت ذاتی خاک که به آن فرسایش‌پذیری ذاتی خاک در برابر باد^۱ (SIWE) اطلاق می‌شود، تعیین کننده میزان فرسایش بادی خواهد بود (Chandler et al., 2005).

¹ Soil inherent wind erodibility

مواد و روش‌ها

منطقه مورد مطالعه

۹۰ هزار هکتار از اراضی شرق استان قزوین در اثر بیش از دو دهه خشکسالی‌های اخیر تبدیل به بیابان شده و مستعد فرسایش بادی و تولید ریزگرد شده است. هم‌اکنون فرسایش بادی در این منطقه یک خطر جدی است. دشت الله‌آباد قزوین در اثر جریان آب‌های جاری، چاله زمین-ساختی توسط رسوبات آبرفتی کواترنری پر شده و شکل گرفته است (طرح مطالعاتی آمایش استان قزوین، قزوین، ۱۳۹۷). این دشت در جنوب غربی شهرستان آبیگ (مختصات $۲۶^{\circ}۵۰' - ۹۵^{\circ}۵۰'$ طول شرقی و $۸۹^{\circ}۳۵' - ۹۵^{\circ}۳۵'$ عرض شمالی)، در شرق استان قزوین واقع شده است.

نمونه‌برداری

جهت انجام پژوهش با بررسی نقشه خاک، تفاوت خاک‌ها و خصوصیات محیطی دشت الله‌آباد، ۱۰۳ نمونه خاک طبق یک الگوی تصادفی طبقه‌بندی شده از ۱۰ سانتی‌متری سطح آن‌ها، جمع‌آوری و به آزمایشگاه ارسال شد. پس از هوا خشک شدن بخشی از نمونه‌های خاک از الک ۲ میلی‌متری و بخش دیگر از الک ۸ میلی‌متری عبور داده شد و برخی خصوصیات فیزیکی و شیمیایی خاک‌ها اندازه‌گیری شد. در نمونه‌های خاک، علاوه بر درصد ذرات درشت (ذرات درشت‌تر از ۲ میلی‌متر)، درصد ذرات شن، سیلت و رس (Gee and Or, 2002)، pH و هدایت الکتریکی عصاره گل اشباع (Sparks and Bartels, 1996)، نسبت جذب سطحی سدیم (SAR)، میزان کربنات‌های کلسیم معادل (CCE) اندازه‌گیری شدند (Klute, 1986). مقدار کربن آلی خاک به روش و الکلی - بلک اصلاح شده (Nelson and Sommers, 1982) اندازه‌گیری گردید. همچنین از هر نقطه، با سیلندر نمونه‌برداری، یک نمونه دست نخورده برای اندازه‌گیری جرم مخصوص ظاهری (Black and Hartge, 1986) برداشته شد.

Eshtehardian و همکاران (۲۰۰۶) برای بهینه‌سازی هزینه-زمان در مدیریت پروژه از روش ترکیبی الگوریتم ژنتیک و منطق فازی در عدم قطعیت هزینه‌ها استفاده کرده و اظهار کردند استفاده از الگوریتم ژنتیک سبب بهبود مدل فازی و همگرا شدن سریع جواب‌ها می‌گردد. (Palizvanzand and Ahmadi (2016) از مدل‌های فازی و فازی-ژنتیک و رگرسیون برای برآورد ظرفیت تبادل کاتیونی خاک استفاده کردند. بیشترین دقت در برآورد CEC مربوط به مدل فازی-ژنتیک با $R^2=0.84$ و $RMSE=4.7 \text{ Cmol}_k\text{kg}^{-1}$ بود.

یکی از مناطق حساس به فرسایش بادی، دشت الله‌آباد در شرق استان قزوین و در جنوب غربی شهرستان آبیگ حد فاصل استان‌های قزوین و البرز است. باد جهت‌دار از سمت جنوب غرب به طرف شمال شرق در این دشت غالب است. خشکسالی‌های دو دهه اخیر سبب خشک شدن تالاب الله‌آباد و بیرون آمدن بستر آن شده و فرسایش بادی را در منطقه تشدید و به یک بحران تبدیل کرده است. تاکنون مطالعات جامعی در خصوص وضعیت فرسایش‌پذیری و شناخت عوامل مؤثر بر آن در این منطقه انجام نشده است که مطالعات مذکور می‌تواند اساس برنامه جامع حفاظت خاک و پایداری اراضی باشد. 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 عبارتند از:

الف) شناخت مهم‌ترین عامل مؤثر بر فرسایش‌پذیری خاک در مقابل باد در دشت الله‌آباد قزوین تخمین میزان جزء فرسایش‌پذیری خاک در برابر باد با استفاده از خصوصیات زود یافت با به‌کارگیری مدل‌های رگرسیونی؛
ب) چندمتغیره، شبکه عصبی مصنوعی و تلفیق شبکه عصبی مصنوعی با الگوریتم ژنتیک.

مستقل (متغیر تخمین‌گر) رابطه آماری خطی با استفاده از داده‌های اندازه‌گیری شده برقرار می‌نماید:

$$y_i = b_0 + b_1 x_{i1} + b_2 x_{i2} + \dots + b_k x_{ik} + e_i$$

که در آن: y_i متغیر وابسته، b_0 ضریب ثابت برابر با عرض از مبدأ خط رگرسیونی، $x_{i,k}$ متغیر مستقل، b_k ضرایب مدل رگرسیونی برای متغیرهای مستقل متناظر و e_i مقدار خطای مدل می‌باشد. در این تحقیق از نرم‌افزار STATISTICA V. 12 جهت تعیین رابطه رگرسیونی چند متغیره بین متغیر وابسته و متغیرهای مستقل استفاده به عمل آمد.

روش شبکه‌های عصبی مصنوعی

برای مدل‌سازی به روش شبکه عصبی مصنوعی از شبکه‌های عصبی مصنوعی MLP استفاده شد (Haykin, 1999) که در این ساختار، هر شبکه شامل لایه‌های ورودی، مخفی و خروجی است. در طی فرآیند آموزش، میزان یادگیری شبکه به وسیله کلیه توابع تعریف شده در نرم‌افزار (تانزانانت سیگموئید آکسون، تانزانانت هیپربولیک خطی آکسون، هیپربولیک آکسون، بایاس آکسون، سیگموئید خطی آکسون، آکسون خطی و آکسون) به شکل سعی و خطا مورد ارزیابی قرار گرفتند و شبکه‌های با بیشترین سطح عملکرد و کمترین میزان خطا مشخص شدند. برای آموزش شبکه‌های تعریف شده، از توابع آموزشی لونیبرگ-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). (Abyaneh et al. 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 با استفاده از نرم‌افزار MATLAB V.8.1 تعیین گردید.

روش ترکیبی شبکه‌های عصبی مصنوعی - الگوریتم ژنتیک (GA-ANN):

در این تحقیق از الگوریتم ژنتیک به منظور یافتن نقطه بهینه توابع پیچیده غیرخطی در ترکیب با شبکه عصبی

اندازه‌گیری جزء فرسایش‌پذیر خاک در مقابل باد

جزء فرسایش‌پذیر خاک در مقابل باد خاک، درصد خاکدانه‌های با قطر کوچک‌تر از ۰/۸۴ میلی‌متر است (Chepil, 1958 and 1960). برای اندازه‌گیری جزء فرسایش‌پذیر خاک، ابتدا نمونه‌های خاک از الک هشت میلی‌متری عبور داده شدند، سپس ۲۰۰ گرم از توده خاک وزن شده و روی یک سری از الک‌ها با قطرهای ۴/۷۵، ۲، ۱، ۰/۵ و ۰/۲۵ میلی‌متر به آرامی قرار گرفت. این سری الک‌ها به مدت ۳۰ ثانیه، با دامنه ارتعاش تقریباً ۵۰ هرتز و دامنه نوسان ۲ میلی‌متر تکان داده شد (Ahmadi et al., 2011). در ادامه مواد باقیمانده بر روی هر الک جمع‌آوری و توزین گردید. سپس از روی منحنی توزیع اندازه خاکدانه‌ها درصد خاکدانه‌های کوچک‌تر از ۰/۸۴ میلی‌متر برای هر یک از نمونه‌های خاک محاسبه گردید.

مدل‌سازی

برای مدل‌سازی ابتدا داده‌ها به صورت تصادفی به سه دسته تقسیم شدند؛ ۶۰ درصد داده‌ها برای آموزش، ۲۰ درصد برای اعتبارسنجی و ۲۰ درصد برای آزمون 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. ورودی‌های هر مدل، pH، ECe، SAR، Sand، Silt، Clay، Bd، Coarse (Bulk density)، OM (Organic Matter) و Particles (diameter more than 2 mm) بودند. در این پژوهش سه روش برای مدل‌سازی (رگرسیون چند متغیره (MLR)، شبکه عصبی مصنوعی و تلفیق شبکه عصبی مصنوعی با الگوریتم ژنتیک برای بهینه‌سازی اوزان) جهت برآورد جزء فرسایش‌پذیر خاک در مقابل باد استفاده شد؛ که در زیر به تفصیل بیان گردیده است:

روش رگرسیون خطی چندمتغیره

مدل رگرسیون چند متغیره یکی از روش‌های آماری است که بین متغیر وابسته (متغیر پاسخ) و دو یا چند متغیر

معیارهای دیگری که برای ارزیابی توانایی مدل‌ها به کار رفتند شامل؛ میانگین هندسی نسبت خطا^۱ (GMER)، میانگین خطا (ME) و انحراف استاندارد هندسی خطا^۲ (GSDER) بودند (روابط ۳، ۴ و ۵):

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

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

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

میانگین هندسی نسبت خطا^۳ (GMER) میزان انطباق بین مقادیر اندازه‌گیری شده و برآورد را نشان می‌دهد. اگر GMER برابر یک باشد، نشان دهنده انطباق کامل بین مقادیر اندازه‌گیری شده و پیش‌بینی شده است. اگر GMER بزرگ‌تر از یک باشد، نشان دهنده آن است که مقادیر پیش‌بینی شده بزرگ‌تر از مقادیر اندازه‌گیری شده است و GMER کمتر از یک نشان‌دهنده کمتر بودن مقادیر برآورد شده نسبت به مقادیر اندازه‌گیری شده است. در مواردی که مقادیر اندازه‌گیری شده و تخمین زده شده هم علامت نباشند، معیار GMER قابل محاسبه نبوده و به جای آن می‌توان از معیار ME استفاده کرد. اگر مقادیر ME منفی باشد مدل دارای کم‌تخمینی و اگر بالای صفر باشد دارای بیش‌تخمینی می‌باشد.

پخشیدگی داده‌ها با انحراف استاندارد هندسی خطا^۴ (GSDER) مشخص می‌شود که اگر هر چه اختلاف بیشتری از یک داشته باشد نشان دهنده انحراف بیشتر تخمین‌ها از داده‌های اندازه‌گیری شده است (Bayat, 2009). بر طبق معیار اطلاعات آکایک^۵ (رابطه ۶)، هر چه این معیار کوچک‌تر باشد مدل قدرت پیش‌بینی بیشتری دارد (Akaike, 1974):

مصنوعی استفاده شد و مناسب‌ترین مدل با استفاده از نرم‌افزار MATLAB V.8.1 ارائه گردید. 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 به‌طور تصادفی مقداردهی اولیه شد و میزان خطا با استفاده از داده‌های آموزش محاسبه گردید. در مرحله بعد به روز رسانی ویژگی‌های شبکه با توجه به مقادیر EF خاک و نرخ‌های جهش و آموزش 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 توابع انتقالی

برای ارزیابی دقت مدل‌ها از ضریب تبیین (R^2) و مجذور مربعات خطا (RMSE) استفاده شد (روابط ۱ و ۲)، به این ترتیب که در مرحله آموزش، هر چه R^2 مدل بیشتر و RMSE کمتر باشد، مدل ارائه شده دارای دقت و قابلیت اعتماد بیشتر است. هر چه R^2 تابع انتقالی بیشتر و RMSE کمتر باشد، مدل ارائه شده دارای قابلیت تعمیم بیشتری است.

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

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

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

¹ Geometric mean of error ratio

² Geometric standard deviation of error ratio

³ Geometric mean of error ratio

⁴ Geometric standard deviation of error ratio

⁵ Akaike information criterion

مقادیر MGN با مقادیر t جدول با درجه آزادی (۱-)
(N) مقایسه می‌شوند. اگر مقادیر MGN معنی‌دار باشد. R^2
دو مدل مورد مقایسه از لحاظ آماری دارای تفاوت
معنی‌داری می‌باشد.

نتایج و بحث

جدول ۱، برخی شاخص‌های آماری مربوط به
خصوصیات فیزیکی و شیمیایی خاک‌های مورد مطالعه را
نشان می‌دهد. حداقل EC_e ، CCE و SAR خاک‌های منطقه
مورد مطالعه به ترتیب برابر $1/10 dS/m$ ، $2/50$ درصد و
 $0.5 (mmol/l)$ و $1/23$ و حداکثر آن برابر $52/15 dS/m$ ،
 $42/10$ و $68/21 (mmol/l)^{0.5}$ می‌باشد. میزان pH خاک‌ها از
 $7/02$ تا $8/91$ متغیر بود. مقادیر بالای ضریب تغییرات
خصوصیات خاک نشان‌دهنده تغییرپذیری زیاد این
خصوصیات است و تنوع زیاد خاک‌ها را نشان می‌دهند.

طبق نتایج جدول ۲، بیشترین همبستگی جزء
فرسایش‌پذیر خاک در مقابل باد (EF) با مقدار رس خاک
دیده شد ($r = -0/789$). همچنین جزء فرسایش‌پذیر خاک
با خصوصیات دیگر خاک شامل pH، هدایت الکتریکی،
SAR، مقدار ماده آلی و جرم مخصوص ظاهری، همبستگی
نشان داد، این همبستگی با سه خصوصیت SAR، ماده آلی
و رس در سطح یک درصد همبستگی معنی‌دار بود. EF
بیانگر خاکدانه‌های خاک با قطر کمتر $0/84$ میلی‌متر است
(Chepil, 1958 and 1960) و تشکیل خاکدانه به
خصوصیات خاک ارتباط دارد (Marashi et al., 2019).

$$AIC = N \ln \left(\frac{\sum_{i=1}^N (Y_m - Y_p)^2}{N} \right) + 2n_p \quad (6)$$

که در آن:

N: تعداد نمونه‌های خاک

Y_m : مقادیر اندازه‌گیری شده متغیر خروجی

Y_p : مقادیر پیش‌بینی شده متغیر خروجی

n_p : تعداد پارامترهای مدل

در نهایت مقادیر برآورد شده متغیرهای خروجی
توسط مدل‌های ایجاد شده، توسط روش‌های رگرسیونی،
شبکه‌های عصبی مصنوعی و هیبرید شبکه عصبی
مصنوعی با الگوریتم ژنتیک با استفاده از آزمون
MorganGrangerNewbold (MGN) (Harvey, 1997) یعنی
معادله ۷ ارزیابی شدند:

$$MGN = \frac{\hat{\rho}_{XZ}}{\sqrt{\frac{1 - \hat{\rho}_{XZ}^2}{N - 1}}} \quad (7)$$

که در آن: N: تعداد مشاهدات است و $(\hat{\rho}_{XZ})$ ضریب
همبستگی بین X و Z از رابطه زیر محاسبه می‌شود:

$$\hat{\rho}_{XZ} = \frac{\sum XZ}{\sqrt{\sum X^2 \sum Z^2}} \quad (8)$$

X و Z از روابط زیر محاسبه می‌شوند:

$$X = (e_i + e_j) \quad (9)$$

$$Z = (e_i - e_j) \quad (10)$$

که در آن: e_i و e_j به ترتیب خطای تخمین مدل i و j
می‌باشند.

جدول ۱. برخی شاخص‌های آماری خصوصیات فیزیک و شیمیایی خاک‌های مورد آزمایش

	N	Minimum	Maximum	Mean	SD	CV (%)
pH	103	7.02	8.91	7.88	0.41	10.1
ECe	103	1.10	52.12	18.26	12.10	40.2
Coarse Particles*	103	0.12	32.20	3.18	4.23	88.9
SAR	103	1.23	68.21	30.82	12.65	45.6
CCE	103	2.50	42.10	17.80	10.10	33.4
OM	103	0.12	5.86	1.14	0.86	44.2
Clay	103	1.24	91.25	42.62	20.22	58.6
Silt	103	0.42	66.32	16.56	14.25	101.2
Sand	103	0.94	71.74	28.63	13.21	74.2
Bulk density	103	0.54	1.85	1.28	0.24	20.6
EF	103	30.98	89.6	58.97	4.58	37.6

* The diameter of soil particles more than 2 mm

می‌باشند. با این حال، شوری خاک معمولاً طوفان‌های گرد و غبار و فرسایش بادی را افزایش می‌دهد (Kokelj et al., 2012). مطالعات (Shahabinejad et al. (2020) در خاک‌های کرمان در ایران، SAR را مؤثرترین خصوصیت خاک بر مقدار فرسایش بادی خاک معرفی کرد. آنها نتیجه گرفتند که با افزایش SAR، EC و ذرات شن، مقدار فرسایش بادی کاهش یافت. وابستگی مقدار dust حاصل از فرسایش بادی به مقدار سیلت خاک در مطالعه (Yulevitch et al. (2020) گزارش شد. سهم ذرات Silt و Clay بر جزء فرسایش‌پذیر خاک تقریباً مشابه بود. (Shahabinejad et al. (2019) کاهش فرسایش بادی متناسب با افزایش ذرات رس خاک را گزارش کردند. آنها نتیجه گرفتند که وجود خاکدانه‌های با قطر بیشتر از ۳۰۰ میکرون و ذرات سیلت و رس به‌طور معنی‌دار سبب کاهش فرسایش بادی در مقایسه با خاک‌های شنی و خاکدانه‌های ضعیف‌تر شد. 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.

چیل (۱۹۵۸ و ۱۹۶۰) اعتقاد دارند که اندازه و پایداری خاکدانه‌ها از عوامل مؤثر بر فرسایش بادی هستند. طبق نظر مونز (۲۰۰۳) ارتباط شوری و جزء فرسایش‌پذیری خاک به‌طور غیرمستقیم به‌واسطه اثر شوری بر کاهش پوشش گیاهی است. افزایش شوری و از بین رفتن پوشش گیاهی سبب کاهش خاکدانه‌سازی و افزایش خطر فرسایش بادی می‌شود (Munson et al., 2011).


در این مطالعه نیز این احتمال وجود دارد که ارتباط خصوصیات شیمیایی خاک و EF به‌واسطه تأثیر این ویژگی‌ها بر میزان پوشش گیاهی منطقه و در نتیجه تفاوت در خاکدانه‌سازی به دلیل ترشحات ریشه گیاهان و همچنین اضافه شدن بقایای گیاهی به خاک در مناطق مختلف باشد، شواهد منطقه‌ای نیز بیانگر همین موضوع نیز می‌باشد. از طرف دیگر مطالعات نشان داده است که افزایش pH سبب کاهش پایداری خاکدانه‌ها می‌شود (احمدی، ۲۰۰۹) که با نتایج تحقیق حاضر همخوانی دارد. افزایش جزء فرسایش‌پذیر خاک در اثر افزایش SAR و EC می‌تواند به دلیل افزایش غلظت یون‌های سدیم در خاک‌های شور باشد. گرچه مطالعات Lyles and Schrandent (1971) نشان داده است که خاک‌های خیلی شور، فرسایش‌پذیری کمتری نسبت به خاک‌های غیر شور

جدول ۲. ضرایب همبستگی ساده (r) بین خصوصیات فیزیکی و شیمیایی خاک‌های مورد مطالعه


	pH	EC	CP	SAR	CCE	OM	Clay	Silt	Sand	Bd	EF
pH	1										
EC	0.112	1									
CP	0.004	0.178	1								
SAR	0.286*	0.788**	0.112	1							
CCE	0.320*	0.304*	0.084	0.208*	1						
OM	-0.362**	-0.264*	0.078	-0.412**	-0.143	1					
Clay	0.382**	0.438**	0.113	0.890**	0.184	-0.217*	1				
Silt	0.125	0.109	0.014	0.162**	0.118	-0.165	0.164	1			
Sand	-0.091	-0.298*	0.124	-0.128	0.178	-0.108	0.084	0.232*	1		
Bd	0.010	0.107	0.324*	0.074	0.321*	0.475**	0.351**	0.124	0.580**	1	
EF	0.232*	0.326*	0.148	0.438**	0.075	-0.542**	0.789**	0.187	0.067	0.245*	1

*دارای همبستگی معنی‌دار در سطح یک درصد، **دارای همبستگی معنی‌دار در سطح یک درصد

برای مدل‌های رگرسیونی، شبکه عصبی (ANN) و هیبرید (GA- ANN) به ترتیب ۱/۱۶، ۱/۱۴ و ۱/۱۳ بود.



شکل ۱. مقادیر R^2 ، GMER و GSDER برای مدل‌های رگرسیون خطی چند متغیره (MLR)، شبکه عصبی مصنوعی و هیبرید در برآورد جزء فرسایش پذیری خاک در مقابل باد در داده‌های سری آموزش



شکل ۲. مقادیر R^2 ، GMER و GSDER برای مدل‌های رگرسیون خطی چند متغیره (MLR)، شبکه عصبی مصنوعی و هیبرید در برآورد جزء فرسایش پذیر خاک در مقابل باد در داده‌های سری آموزش

با توجه به شاخص AIC، هر سه مدل توانایی بسیار بیشتری در پیش‌بینی EF در سری داده‌های آزمون نسبت به داده‌های آموزش داشتند، اما توانایی هر سه مدل در پیش‌بینی جزء فرسایش پذیری خاک، مشابه بودند. بر طبق داده‌های آزمون، مدل شبکه عصبی از R^2 بیشتر، خطای

همچنین جزء فرسایش‌پذیری خاک با مقدار ماده آلی ($r = -0.542$) همبستگی زیادی نشان داد. رس، ماده آلی و اکسیدهای آلومینیم از خصوصیات تأثیرگذار خاک بر جزء فرسایش‌پذیری خاک می‌باشد (Colazo and Buschiazzo, 2010). کاهش ماده آلی، فرسایش خاک را افزایش می‌دهد و از آن طرف، افزایش فرسایش بادی منجر به کاهش بیشتر ماده آلی می‌شود (Yan et al., 2005). زوبک و همکاران (۲۰۱۳) افزایش فرسایش بادی خاک‌ها با کاهش مقدار ماده آلی خاک را گزارش کردند. ذرات رس و پلی‌ساکاریدهای مواد آلی سبب پایداری خاکدانه‌ها و کاهش فرسایش‌پذیری خاک می‌شوند (Canasveras et al. 2010). ماده آلی همانند سیمانی ذرات خاک را به هم می‌چسباند و خاکدانه‌های پایدار در برابر فرسایش بادی می‌سازد (عظیم زاده و همکاران، ۱۳۸۱). پایداری خاکدانه‌ها یکی از عوامل مؤثر بر فرسایش‌پذیری خاک‌ها است و کاهش آن سبب افزایش تخریب خاک می‌شود (Marashi et al., 2017 and 2019; Shahabinejad et al., 2019). عنانانی و همکاران (۱۳۹۶) همبستگی بیند و شاخص فرسایش‌پذیری خاک (EFI) و فاکتور سله سطحی (SCF) را در یکی از کانون‌های فرسایش بادی در استان خوزستان مورد بررسی قرار دادند. نتایج نشان داد EF با SCF همبستگی نسبتاً خوبی داشت (R^2 برابر با ۰/۵۷).

شکل‌های ۱ و ۲، نتایج معیارهای ارزیابی سه مدل رگرسیونی، شبکه عصبی مصنوعی و هیبرید شبکه عصبی و الگوریتم ژنتیک در تخمین جزء فرسایش‌پذیری بادی در دو سری داده‌های آموزش و آزمون را نشان می‌دهند. در مدل‌های رگرسیونی و هیبرید شبکه عصبی با الگوریتم ژنتیک، R^2 مدل در داده‌های سری آزمون، کمتر از داده‌های سری آموزش بود، در حالی که در مدل شبکه عصبی، R^2 داده‌های سری آزمون بیشتر از داده‌های سری آموزش است. خطای (RMSE) داده‌های آموزش در هر سه مدل از داده‌های سری آزمون کمتر بود. در سری آزمون، هر سه مدل دارای اندکی بیش برآوردی هستند و مقدار GMER

جدول ۳. مقادیر خطا و شاخص‌های آکایک و MGN در مدل‌های رگرسیون خطی چند متغیره (MLR)، شبکه عصبی مصنوعی و هیبرید در برآورد جزء فرسایش‌پذیر خاک در داده‌های سری آموزش و آزمون

مدل	داده‌های آموزش				داده‌های آزمون			
	MGN	AIC	ME	RSME	MGN	AIC	ME	RSME
رگرسیون خطی چند متغیره	-	127.58	-8.59	15.10	-	377.79	0.00	8.42
شبکه عصبی مصنوعی	0.02 ^{ns}	125.14	-6.85	14.20	0.02 ^{ns}	432.59	-0.15	10.92
هیبرید شبکه عصبی و الگوریتم ژنتیک	1.42*	129.45	-6.79	15.82	2.56*	448.22	0.33	12.12

* در سطح پنج درصد معنی‌دار است؛ ns غیر معنی‌دار در سطح پنج درصد.


می‌دهد. بدین ترتیب که برای یک متغیر ورودی ابتدا سایر متغیرهای ورودی ثابت و برابر با میانگین آن‌ها در نظر گرفته شده و سپس میزان تغییرات خروجی با متغیر ورودی غیر ثابت در دامنه میانگین \pm انحراف استاندارد تعیین می‌گردد (NeuroSolutions, 2005). (Minasny et al. (2004) در آنالیز حساسیت، تغییرات متغیر خروجی را با تغییر هر متغیر ورودی در دامنه حداقل - حداکثر تعیین می‌کنند.

شکل‌های ۴ و ۵، آنالیز حساسیت برای پارامترهای ورودی در مدل‌های شبکه عصبی و هیبرید شبکه عصبی و الگوریتم ژنتیک را نشان می‌دهد. بیشترین تأثیر بر جزء فرسایش‌پذیری بادی خاک در مدل شبکه عصبی، به ترتیب مربوط به ماده آلی و SAR بود. بیشترین همبستگی جزء فرسایش‌پذیر خاک با ماده آلی خاک دیده شد (جدول ۲). ماده آلی با ایجاد خاکدانه‌های پایدار، مقاومت


کمتر و قدرت بیشتر پیش‌بینی در مقایسه با مدل‌های هیبرید و رگرسیون برخوردار است، اگرچه با توجه به شاخص MGN، اختلاف R^2 های دو مدل رگرسیون و شبکه عصبی، معنی‌دار نیست. (Huang et al. 2006) از شبکه عصبی مصنوعی در پیش‌بینی طوفان‌های گرد و غبار (فرسایش بادی) در شمال شرقی چین استفاده کردند و نتایج تحقیقات آنان 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).

آنالیز حساسیت توابع انتقالی

آنالیز حساسیت (Sensitivity analysis) میزان تغییرات متغیر خروجی با تغییر در کمیت هر متغیر ورودی را نشان



شکل ۴. آنالیز حساسیت برای پارامترهای ورودی در مدل شبکه عصبی مصنوعی



شکل ۵. آنالیز حساسیت برای پارامترهای ورودی در مدل هیبرید شبکه عصبی مصنوعی و الگوریتم ژنتیک

ماده آلی، اکسیدهای آلومینیم و رس به صورت لگاریتمی و یا نمایی مرتبط می‌باشند. عظیم زاده و همکاران (۱۳۸۱) نتیجه گرفتند که با افزایش SAR، فرسایش‌پذیری بادی خاک افزایش می‌یابد مگر اینکه عامل دیگری تأثیرگذار باشد. هواوی و همکاران (۲۰۲۰) نتیجه گرفتند که استفاده از رس به‌عنوان اصلاح‌کننده خاک سبب کاهش معنی‌دار فرسایش‌پذیری بادی خاک شد.

نتیجه‌گیری

طبق نتایج، جزء فرسایش‌پذیر خاک در مقابل باد (EF) دارای همبستگی معنی‌داری با pH، قابلیت هدایت الکتریکی، جرم مخصوص ظاهری، SAR، Clay و ماده آلی همبستگی معنی‌داری داشت، لذا این همبستگی در مدل‌های به کار رفته نتوانست منجر به برآورد مناسب EF شود. بر طبق نتایج، تنها مدل رگرسیون در مرحله آموزش دارای R^2 بیشتر از ۵۰ درصد ($R^2=0.56$) در برآورد جزء فرسایش‌پذیر خاک بود که البته این مقدار ($R^2=0.56$) نیز قابل اعتماد نیست. با توجه به نتایج مرحله آزمون، هر سه مدل به کار رفته شامل رگرسیون، شبکه عصبی مصنوعی و تلفیق آن با الگوریتم ژنتیک در برآورد شاخص جزء فرسایش‌پذیر خاک از کارایی مناسبی برخوردار نمی‌باشند به طوری که بالاترین ضریب تبیین (R^2) در مدل

خاک در برابر فرسایش بادی را افزایش می‌دهد (عظیم زاده و همکاران، ۱۳۸۱؛ Canasveras et al. 2010؛ Zobeck et al., 2013؛ Sirjani et al., 2019). مطالعات (Marashi et al. 2017) نیز همبستگی بالایی پایداری خاکدانه‌ها با مقدار ماده آلی را نشان داد. Zobeck et al. (2004) و Panayiotopoulos et al. (2013) افزایش حساسیت خاک‌ها به فرسایش بادی با افزایش SAR را نشان دادند.

برخلاف مدل شبکه عصبی مصنوعی، اثر ماده آلی بر مقدار جزء فرسایش‌پذیر خاک در مقایسه با اثر رس و SAR، در مدل هیبرید شبکه عصبی و الگوریتم ژنتیک پایین بود. در مدل هیبرید، بیشترین اثر بر جزء فرسایش‌پذیری خاک مربوط به ذرات رس و در وهله بعد به SAR و ذرات شن و سیلت ارتباط داشت. برخی محققین بافت خاک (عظیم زاده و همکاران، ۱۳۸۱؛ Shahabinejad et al., 2019) و رس (Naghizade Asl et al., 2019) را اصلی‌ترین عوامل در فرسایش‌پذیر خاک در مقابل باد معرفی کرده‌اند. (Buschiazzo Colazo and 2010)، مقدار جزء فرسایش‌پذیر خاک (EF) و پایداری خشک خاکدانه (DAS) را در ۲۸ خاک از منطقه نیمه‌خشک مرکزی آرژانتین با خصوصیات مختلف خاک مورد ارزیابی قرار دادند. نتایج آنان نشان داد که مقادیر EF و DAS با مقادیر

شبکه عصبی در مرحله آزمون ($R^2 = 0.43$)، صحت کمتر از ۵۰ درصد در تخمین EF داشت که نمی‌تواند صحت مناسبی در پیش‌بینی جزء فرسایش‌پذیری بادی خاک باشد. نتایج آنالیز حساسیت نشان داد که اثر خصوصیات خاک بر جزء فرسایش‌پذیری بادی خاک در مدل‌های شبکه عصبی مصنوعی و هیبرید شبکه عصبی و الگوریتم ژنتیک متفاوت بود. در حالی که بیشترین تأثیر بر جزء فرسایش‌پذیری بادی خاک در مدل شبکه عصبی، مربوط به ماده آلی بود، در مدل هیبرید شبکه عصبی و الگوریتم ژنتیک، بیشترین اثر مربوط به رس بود. با توجه به R^2 پایین هر دو مدل، می‌توان نتیجه گرفت که خصوصیات خاک به‌عنوان ورودی مدل‌ها از جامعیت کافی برای پیش‌بینی EF برخوردار نیستند و باید با تلفیق این خصوصیات با خصوصیات تأثیرگذار دیگری از خاک بر فرسایش بادی مثل آهک و یا تغییر ورودی‌های مدل، کارایی این مدل‌ها دوباره ارزیابی گردد.

Reference:

- Ahmadi A. 2011. Artificial neural networks applicability in erosion and runoff simulation using fractal dimensions. Thesis of Department of Soil Science, Agricultural College, University of Tabriz. P.197 (in Persian with English abstract).
- Akaike, H (1974). "A new look at the statistical model identification". IEEE Transactions on Automatic Control. 19(6): 716-723.
- Ananani, M., Amirian Chakan, A., Faraji, M. Yousefi Khaneghah, S.H. (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.
- Ayoubi S, Shahri AP, Karchegani PM, Sahrawat KL (2011) Application of artificial neural network (ANN) to predict soil organic matter using remote sensing data in two ecosystems (pp. 181-196). InTech Open Access.
- Azimzadeh, H.R., Ekhtesasi, M.R., Hatami, M., Qalibaf, M.A. (2002). Wind erosion: erodibility relation to soil physical and chemical properties in Iran central plain (yazd-ardakan plain - case study). Journal of Agricultural Sciences and Natural Resources, 9(1): 139-151.
- Bayat, H. 2009. Establishment of transfer functions for predicting moisture curve through artificial neural networks (ANNs) and group data management (GMDH) using fractal parameters and principal component analysis. PhD Thesis, Department of Soil Science, Faculty of Agriculture, University of Tabriz.
- 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.
- Besalatpour, A. A., S. Ayoubi, M. A. Hajabbasi, A. Yousefi Jazi, and A. Gharipour. 2014. Feature selection using parallel genetic algorithm for the prediction of geometric mean diameter of soil aggregates by machine learning methods. Arid Land Research and Management 28:383-94.
- Black, G. R., and K. H. Hartge. 1986. Bulk Density. In: Methods of Soil Analysis, Part 1. Physical and Mineralogical Methods, Agronomy Monograph no. 9 (2nd Edition). 363-375.
- Blanka, V., Mezősi, G., and Meyer, B. 2013. Projected changes in the drought hazard in Hungary due to climate change, Időjárás: Quarterly J. Hungarian Meteorol. Serv. 117: 219-237.
- Bouma J, 1989. Using soil survey data for quantitative land evaluation Advances in soil science. Springer, 177-213.
- Canasveras 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.
- Chandler D.G., K.E. Saxton and A.J. Busacca. 2005. Predicting wind erodibility of loessial soils in the Pacific Northwest by particle sizing. Arid Land Research and Management, 19(1): 13-27.
- Chepil W, 1958. Soil conditions that influence wind erosion. USDATech, Bui, No, 1185.
- Chepil W, 1960. Conservation of relative field erodibility to annual soil loss by wind. Soil Science Society of American Journal, 24(2):143-148.
- Colazo, J.C. and Buschiazzo, D.E. 2010. Soil dry aggregate stability and wind erodible fraction in a semiarid environment of Argentina. Geoderma, 159 (1-2): 228-236.
- Coppinger K D, Reiners W A, Burke I C and Olson R K, 1991. Net erosion on a sagebrush steppe landscape as determined by cesium-137 distribution. Soil Science Society of America Journal, 55: 254-258.
- Crowe A.M., McClean C.J., and Cresser M.S. 2006. An application of genetic algorithms to the robust estimation of soil organic and mineral fraction densities. Environ. Model. Software. 21: 1503-1507.
- Eshtehardian E., Afshar A., and Abbasnia R. 2006. A genetic algorithm-based optimizing approach for project time-cost trade-off with uncertain measure. 3th International Project Management Conference, Tehran, Iran. (in Persian with English abstract).
- Gee GW and Or D, 2002. Particle-size analysis. In: Warren AD (ed.) Methods of Soil Analysis. Part 4. Physical Methods. Pp.255-295, Soil Sci. Soc. Am. Inc.

- Gomez, L., J.L. Arrue, M.V. Lopez, G. Sterk, D. Richard, R. Gracia, M. Sabre, A. Gaudichet and J.P. Frangi. 2003. Wind erosion in a semiarid agricultural area of Spain the WELSONS project. *Catena*, 52: 235-256.
- Harvey, M.A.D.I., 1997. The evaluation of economic forecasts. Ph.D. Thesis, University of Nottingham. P.276.
- Haykin, S. 1999. *Neural Networks and Learning Machines*. 3rd edition, Pearson, Prentice Hall, Upper Saddle River, New Jersey 07458, United States.
- 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. *Communications in Soil Science and Plant Analysis* 50 (16), 1986-2002.
- 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.
- Huawei P, David R. Huggins, Brenton. 2020. Wind erosion of soil influenced by clay amendment in the inland Pacific Northwest, USA. *Land Degradation and Development*, 32 (1): 241-255.
- Khanbabakhani, L., Mohammadi Torkashvand, A. and Mohmoodi, M.A. 2018. Prediction of soil texture using artificial neural networks. *Soil and Water Resources Conservation*, 8(1): 1-10.
- Kim, M. and Gilley, J.E. 2018. Artificial Neural Network estimation of soil erosion and nutrient concentrations in runoff from land application areas. *Computers and Electronics in Agriculture*, 64 (2): 268-275.
- Klute, A. 1986. *Methods of Soil Analysis: Part 1. Physical and Mineralogical Methods* (Sssa Book Series No 5) 2nd Edition, American Society of Agronomy and Soil Science Society of America, Madison, WI.
- Kokelj, S. V., Lantz, T. C., Solomon, S., Pisaric, M. F. J., Keith, D., Morse, P., Thienpont, J. R., Smol, J. P., 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.
- Leenders J.K., Visser S.M., and Stroosnijder L. 2005. Farmers' perceptions of the role of scattered vegetation in wind erosion control on arable land in Burkina Faso. *Land Degradation & Development* 16(4): 327-337.
- Liu S.h., Butler D., Brazier R., Heathwaite L., and Khu S. 2007. Using genetic algorithm to calibrate a water quality model. *Sci. Total Environ.* 374: 260-272.
- Lo C.H., Chan P.T., Wong Y.K., Rad A.B., and Cheung K.L. 2007. Fuzzy-genetic algorithm for automatic fault detection in HVAC systems. *Applied Soft Computing* 7: 554–560.
- Lyles, L. and R. L. Schrandet. 1971. Wind erodibility as influence by rainfall and salinity. *Soil Science*, 114: 367-372.
- Majdi, H., Karimian Iqbal, M., Karimzadeh, H.R., Jalalian, A. (2006). The effect of different types of clay mulch on the amount of wind eroded materials. *Journal of Agricultural Science and Technology and Natural Resources*, 10(3): 137-148.
- 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 Journal of Soil Sciences*. 7(2): 89-99.
- Marashi, M., Mohammadi Torkashvand, A., Ahmadi, A., Esfandiari, M. 2019. Adaptive neuro-fuzzy inference system: estimation of soil aggregates stability. *Acta Ecologica Sinica*. 39(1): 95-101.
- Merdun, H., O. Cinar, R. Meral, and M. Apan. 2006. Comparison of artificial neural network and regression pedotransfer functions for prediction of soil water retention and saturated hydraulic conductivity. *Soil and Tillage Research* 90:108–16.
- Mezosi, G., Blanka, V., Bata1, T., Kovács, F., and Meyer, B. 2013. Estimation of regional differences in wind erosion sensitivity in Hungary. *J. Natur. Hazards Earth Syst. Sci.* 1: 4713-4750.
- Minasny, B., Hopmans, J.W., Harter, T., Eching, S.O., Tuli, A. and Denton, M.A., 2004. Neural networks predication of soil hydraulic functions for alluvial soils using multistep outflow data. *Soil Sci. Soc. Am. J.*, 68:417-429.
- Mohammadi Torkashvand, A. and Nikkami, D. 2008. Investigating some methodologies of preparing erosion features map by using RS and GIS. *International Journal of Sediment Research*, 23 (2): 124-132.
- Mohammadi Torkashvand, A., Haghghat, 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. *Research Journal of Environmental Sciences* 3 (2), 202-209.
- 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. *Geophysical Res Abs* 13: 10-75.
- Munns, R., 2003. Comparative physiology of salt and water stress. *Plant Cell Environment*, 25: 239-50.
- Munson, S. M., Belnap, J. and Okin, S. G., 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.
- Naghizade Asl F, Asgari HR, Emami H, Jafari M. 2019. Combined effect of micro silica with clay, and gypsum as mulches on shear strength and wind erosion rate of sands. *International Soil and Water Conservation Research*, 7(4): 388-394.

- Nelson D W, and Sommers L E, 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 .
- NeuroSolutions, 2005. *Getting Started Manual Version 4.* Neurodimension, Inc. 1800 N. Main Street, uite D4, Gainesville, FL 32609.
- Nosrati, H. and Eftekhari, M. (2014). A new approach for variable selection using fuzzy logic. *Computational Intelligence in Electrical Engineering*, 4, 71 -83.
- Palizvanzand H. and Ahmadi A. 2016. Comparison of linear regression, Fuzzy and Fuzzy-genetic models to predict soilcation exchange capacityHabib. *Applied Soil research*, 3(2): 86-100. In Persian.
- Panayiotopoulos KP, Barbayiannis N, Papatolios K (2004) Influence of electrolyte concentration, sodium adsorption ratio, and mechanical disturbance on dispersed clay particle size and critical flocculation concentration in Alfisols. *Commun Soil Sci Plant Anal* 35:1415–1434.
- Qiang, M., Chen, F., Zhou, A., Xiao, S., Zhang, J., & Wang, Z. (2007). Impacts of wind velocity on sand and dust deposition during dust storm as inferred from a series of observations in the northeastern Qinghai-Tibetan Plateau, China. *Powder Technology*, 175(2), 82-89.
- Refahi, H. 2006. *Soil Water Erosion and Control.* Tehran University Press, Tehran, Iran.
- Sarkar, T., Mishra, M. 2018. Soil erosion susceptibility mapping with the application of logistic regression and artificial neural network. *Journal of Geovisualization and Spatial Analysis*, 2: 1-17.
- Shahabinejad N, Mahmoodabadi M, Jalalian A, Chavoshi E. 2019. The fractionation of soil aggregates associated with primary particles influencing wind erosion rates in arid to semiarid environments. *Geoderma*, 356, Article 113936.
- Shahabinejad N, Mahmoodabadi M, Jalalian A, Chavoshi E. The Influence of Soil Properties on the Wind Erosion Rate at Different Regions of Kerman Province. *JWSS*. 2020; 24 (3) :209-222.
- Sirjani E, Sameni A, Moosavi AA, Mahmoodabadi M, Laurent B. 2019. Portable wind tunnel experiments to study soil erosion by wind and its link to soil properties in the Fars province, Iran. *Geoderma*, 333: 69-80.
- Sparks, D. and Bartels, J. 1996. *Methods of soil analysis: Part3. Chemical methods.* Soil Science Society of America Book Series. Madison, Wisconsin. USA. Pp 1390.
- Stout, J. E., & Zobeck, T. M. (1996). Establishing the threshold condition for soil movement in wind-eroding fields. Paper presented at the Proceedings of International Conference on Air Pollution from Agricultural Operations.
- Tung C., Hsu S., Liu C.M., and Li Sh.Jr. 2003. Application of the genetic algorithm for optimizing operation rules of the LiYutan reservoir in Taiwan. *J. Am. Water Resour. Assoc.* 39 (3): 649–657.
- Wösten, J.H.M., Pachepsky, Y.A., Rawls, W.J., 2001. Pedotransfer functions: bridging the gap between available basic soil data and missing soil hydraulic characteristics. *J. Hydrol.* 251(3),123-150.
- Yan H, Wang H, Wang C, Zhang G, Patel N. 2005. Losses of soil organic carbon under wind erosion in China. *Global change biology*, 11, 5: 828-840.
- Yulevitch G, Danon B, Krasovitev B, Nitzan A, Swet A, Tsesarsky M, Katra I. 2020. Evaluation of wind-induced dust-PM emission from unpaved roads varying in silt content by experimental results. *Atmospheric Pollution Research*, 11(2): 261-268.
- 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.
- Zobeck TM, Baddock M, Scott R, Pelt V, Tatarko J, Acosta-Martinez V. 2013. Soil property effects on wind erosion of organic soils. *Aeolian Research*, 10, 43-51.



Print ISSN: 2251-7480
Online ISSN: 2251-7400

Journal of
**Water and Soil
Resources Conservation
(WSRCJ)**

Web site:

<https://wsrcj.srbiau.ac.ir>

Email:

iauwsrcj@srbiau.ac.ir
iauwsrcj@gmail.com

**Vol. 12
No. 1 (45)
Autumn 2022**

Received:
2021-05-11

Accepted:
2021-11-21

Pages: 73-86

Efficiency of Regression, ANN and ANN-algorithm Genetic Hybrid Models in the Evaluation of Wind Erosion

Shahin Ebrahimi¹, Ali Mohammadi Torkashvand^{2*}, Mehrdad Esfandiari³ and Abbas Ahmadi⁴

- 1) Ph.D. Student, Department of Soil Science, Science and Research Branch, Islamic Azad University, Tehran, Iran.
 - 2) Department of Soil Science, Science and Research Branch, Islamic Azad University, Tehran, Iran.
 - 3) Department of Soil Science, Science and Research Branch, Islamic Azad University, Tehran, Iran.
 - 4) Department of Soil Science, University of Tabriz, Tabriz, Iran.
- *Corresponding author email: m.torkashvand54@yahoo.com

Abstract:

Background and Aim: Wind erosion has occurred in a large part of Iran, which has caused land degradation and reduced fertility along with environmental effects. Identifying erosion-sensitive areas can help natural resource and environmental managers in soil conservation planning.

Methods: This study is a step to estimate the erodible component of soil against the wind (EF) from soil accessibility characteristics in Allahabad plain located in the east of Qazvin province. For this purpose, the soil erodibility component, which is closely related to soil erosion versus wind, using multivariate regression (MLR), artificial neural network (ANN), and artificial neural network with genetic algorithm for weight optimization (GA-ANN) were estimated using accessible characteristics. Regarding soil map, soil differences, and environmental characteristics of Allahabad plain, 103 soil samples were collected according to a stratified random pattern of 10 cm of soil surface. In soil samples, some soil properties were measured as inputs of models for estimating erodible soil components against the wind. The inputs of each model included pH, ECe, CCE, SAR, bulk density, sand particles, silt and clay, coarse soil particles with a diameter of more than 2 mm, and organic matter. Accuracy and reliability of the results of the created models were compared with each other according to the criteria of coefficient of determination, square of error, Morgan-Granger-Newbold and Akaike information criterion.

Results: Based on data, the highest correlation between soil erodible fraction to wind erosion (EF) was observed with soil clay content ($r = -0.789$). Also, soil erodible components showed a correlation with other soil properties including pH, electrical conductivity, SAR, organic matter, and the should be omitted density. This correlation was significant with three properties of SAR, organic matter, and clay at a should be added 1% level. The models created by the three methods were much more capable of predicting EF in the test data series than the training series data. The results also showed that the neural network model had a should be omitted more accuracy and less estimation error compared to hybrid and regression models. The results of sensitivity analysis of the models also showed that the highest sensitivity of the model to input variables in the ANN model, related to organic matter and SAR, respectively, and in the model GA-ANN was related to soil clay content variable.

Conclusion: According to the results, R^2 in the regression model of training data was more than 50% in estimating EF, but this value ($R^2 = 0.56$) is not reliable. According to the test data, all three models, including regression, artificial neural network, and its combination with genetic algorithm had not been efficient enough in estimating EF, so that can be omitted the highest R^2 in the neural network model in the test data ($R^2 = 0.43$) had an accuracy of less than 50% in estimating the EF, which cannot be an appropriate accuracy in predicting EF.

Keywords: Dust, Cla, Organic Matter, MLP, Perceptron



10.30495/WSRCJ.2022.19224