

## مدل سازی پایداری خاکدانه ها با استفاده از ماشین های بردار پشتیبان و رگرسیون خطی چند متغیره

علی اصغر بسالت پور<sup>۱\*</sup>- حسین شیرانی<sup>۲</sup>- عیسی اسفندیارپور بروجنی<sup>۳</sup>

تاریخ دریافت: ۱۳۹۲/۰۳/۱۹

تاریخ پذیرش: ۱۳۹۴/۰۱/۱۶

### چکیده

ماشین های بردار پشتیبان، ابزاری امیدبخش برای روش های مبتنی بر آموزش می باشند که برای مسایل تشخیص الکو بر اساس کمینه کردن احتمال بروز اشتباه، ایجاد شده اند. در این پژوهش، کارآیی روش ماشین های بردار پشتیبان در مدل سازی برآورد پایداری خاکدانه ها (از طریق محاسبه میانگین هندسی قطر خاکدانه ها، GMD) با رگرسیون خطی چند متغیره مقایسه شد. برای این منظور از داده های زودیافت مؤثر بر پایداری خاکدانه ها شامل برخی ویژگی های توپوگرافیکی، پوشش گیاهی و خاک استفاده گردید. برای بررسی کارآیی مدل ها نیز از برخی شاخص های آماری نظریه ضریب همبستگی (r)، میانگین مربعات خطأ (MSE) و درصد خطأ (ERROR%) (Bragg et al., 2005) بین مقادیر اندازه گیری شده و برآورد شده استفاده شد. نتایج نشان داد که کارآیی مدل های مبتنی بر ماشین های بردار پشتیبان در تخمین پایداری خاکدانه ها، بسیار بیشتر از روش رگرسیون خطی چند متغیره مرسوم بود. مقادیر MSE و ۲ مدل ماشین های بردار پشتیبان طراحی شده برای برآورد پایداری خاکدانه ها به ترتیب، برابر ۰/۰۰۵ و ۰/۰۶ بودند. درصد خطأ برای تخمین پایداری خاکدانه ها با استفاده از مدل ماشین های بردار پشتیبان برابر ۱۰/۷ درصد بود درحالی که مقدار درصد خطأ برای مدل رگرسیونی برازش داده شده، حدود ۱۵/۷ درصد بود. بنابراین به توان از ماشین های بردار پشتیبان برای برآورد برخی ویژگی های فیزیکی خاک (نظریه میانگین هندسی قطر خاکدانه ها) در منطقه هی مورد بررسی استفاده نمود.

**واژه های کلیدی:** ساختمان خاک، ماشین های بردار پشتیبان، میانگین هندسی قطر خاکدانه ها، ویژگی های فیزیکی خاک

### مقدمه

خاکدانه ها<sup>۴</sup>، میانگین هندسی قطر خاکدانه ها<sup>۵</sup>، رس قابل پراکنش<sup>۶</sup> و مقاومت کششی خاکدانه ها<sup>۷</sup> اشاره نمود (۵ و ۹). با این وجود، سیاری از این روش ها و اندازه گیری پایداری خاکدانه ها نسبتاً پیچیده و عمده تا وقت گیر و پرهزینه می باشند و استفاده از آن ها در مقیاس های بزرگ (نظریه حوزه های آبخیز)، با محدودیت های فراوان مواجه است. به همین سبب، امروزه از روش های غیر مستقیم (مانند توابع انتقالی خاک<sup>۸</sup> و توابع تخمین مکانی خاک<sup>۹</sup>) به منظور برآورد این ویژگی ها استفاده می گردد. در این توابع با استفاده از داده های زودیافت مانند توزیع اندازه ی ذرات خاک، ماده ای آلی، کربنات کلسیم معادل، ویژگی های توپوگرافیکی (مانند درصد شیب، جهت شیب، ارتفاع) و

ساختمان خاک از جمله ویژگی های فیزیکی مهم خاک می باشد که از طریق اثر بر چرخه کربن آلی و سایر عناصر غذایی، دریافت، ذخیره و انتقال آب در خاک، مقاومت در برابر فرسایش، هدایت هیدرولیکی، تهווیه، گرمای خاک و نیز از راه تاثیر بر مقاومت مکانیکی خاک و انتشار عناصر غذایی، بر رشد گیاه و تولید محصول اثر می گذارد. یکی از شاخص های رایج برای مطالعه و بیان وضعیت ساختمان خاک، پایداری خاکدانه ها می باشد (۱). روش های گوناگونی برای اندازه گیری پایداری خاکدانه ها وجود دارند. همچین از شاخص های گوناگونی برای بیان پایداری خاکدانه ها استفاده می شود که از آن جمله می توان به شاخص میانگین وزنی قطر

- 4- Mean Weight Diameter, MWD  
5- Geometric Mean Diameter, GMD  
6- Water Dispersible Clay, WDC  
7- Tensile strength  
8- Pedotransfer Functions, PTFs  
9- Soil Spatial Prediction Functions, SSPFs

همکاران (۱۳) نیز امکان استفاده از SVMs برای تخمین هدایت هیدرولیکی خاک با استفاده از داده‌های زودیافت را مورد بررسی قرار دادند و دقت بالای این روش برای برآورد هدایت هیدرولیکی خاک را گزارش کردند.

با این وجود، تاکنون پژوهش‌های اندکی با هدف استفاده از SVMs در علوم خاک (به ویژه برآورد پایداری خاکدانه‌ها) انجام شده است اگرچه با توجه به ماهیت ذاتی ویژگی‌های خاک، یعنی تغیرپذیری زمانی و مکانی زیاد و دیریافت بودن بسیاری از این ویژگی‌ها، به نظر می‌رسد که ماشین‌های بردار پشتیبان دارای توانایی بالایی برای مدل‌سازی این ویژگی‌ها باشند. در همین راستا، پژوهش حاضر با هدف اصلی بررسی امکان استفاده از این روش برای تخمین پایداری خاکدانه‌ها با استفاده از ویژگی‌های زودیافت خاک در یک حوزه آبخیز کوهستانی با توبوگرافی شدید و قابلیت دسترسی محدود که شدیداً در معرض خطر فرسایش قرارداد (حوزه آبخیز بازفت، غرب استان چهارمحال و بختیاری) بررسی شد. همچنین قابلیت استفاده از ماشین‌های بردار پشتیبان در برآورد پایداری خاکدانه‌ها با روش مرسوم رگرسیون خطی چند متغیره<sup>۴</sup> مقایسه شد.

## مواد و روش‌ها

### منطقه‌ی مورد مطالعه

منطقه‌ی مورد بررسی، بخشی از حوزه آبخیز کارون شمالی واقع در غرب استان چهارمحال و بختیاری می‌باشد که در موقعیت جغرافیایی  $34^{\circ} 33' 33''$  تا  $39^{\circ} 32' 50''$  طول شرقی و  $31^{\circ} 37' 32''$  تا  $32^{\circ} 39' 33''$  عرض شمالی قرار گرفته است (شکل ۱). بخش اعظم منطقه مورد مطالعه (حدود  $50$  درصد) کوهستانی بوده که مرتفع‌ترین نقطه آن، زردکوه با ارتفاع  $4221$  متر می‌باشد. ارتفاع متوسط منطقه، حدود  $2200$  متر است. شبیه منطقه متغیر می‌باشد و بیشترین آن مربوط به کلاس شبیه  $40$  تا  $70$  درصد است (معادل  $46$  درصد از وسعت کل حوزه). حدود  $56$  درصد از وسعت کل منطقه، دارای پوشش مرتعی (به طور عمده، دافنه و گون) و بقیه دارای پوشش جنگلی (به طور عمده، بلوط ایرانی) یا عاری از پوشش می‌باشد. دامنه تغییرات بارش و درجه حرارت سالیانه در منطقه، به ترتیب،  $500$  تا  $1400$  میلی‌متر و  $8$  تا  $20$  درجه سلسیوس می‌باشند. منطقه مورد بررسی در زون شکسته‌ی زاگرس قرار دارد و قدیمی‌ترین رخنمون‌های منطقه مربوط به دوران پالئوزوئیک زیرین (پرکامبرین) تا دوره‌های فرسایشی و نهشتشی کواترنر در قلمروی زاگرس می‌باشند. واحدهای فیزیوگرافی غالب در منطقه بر اساس مطالعات صحرایی و خصوصیات ظاهری خاک‌ها شامل کوه، تپه، فلات و تراس‌های بالایی، دشت دامنه‌ای، دشت آبرفتی و اراضی مخلوط و متفرقه می‌باشند (۴).

پوشش گیاهی (نظیر درصد پوشش گیاهی و شاخص‌های مرتبط با آن)، برخی خصوصیات دیریافت مانند ویژگی‌های فیزیکی و مکانیکی خاک تخمین زده می‌شوند (۳)، از جمله روش‌های نوین برای ایجاد توابع انتقالی و توابع تخمین مکانی خاک، ماشین‌های بردار پشتیبان<sup>۱</sup> (SVMs) می‌باشند.

ماشین‌های بردار پشتیبان، جزء الگوریتم‌های طبقه‌بندی ناظارت‌شونده<sup>۲</sup> هستند که قادر به پیش‌بینی تعلق یک نمونه به یک کلاس یا گروه هستند. این الگوریتم برای تفکیک دو کلاس از هم، از یک صفحه استفاده می‌کند به گونه‌ای که این صفحه از هر طرف بیشترین فاصله را با هر کلاس داشته باشد. نزدیک‌ترین نمونه‌های آموزشی به این صفحه، «بردارهای پشتیبان» نام دارند (۲۴) و (۲۶). در واقع، SVMs نخستین بار برای مسائل طبقه‌بندی پیشنهاد شدند اما با اصلاحاتی که در معادله‌ها و توابع آن‌ها انجام گرفت، امروزه برای برآوردهای رگرسیونی غیرخطی نیز کابرد دارند. در واقع، ماشین‌های بردار پشتیبان ساخته شده با تابع کرنلی برخلاف روش‌های رگرسیون خطی مرسوم که تنها قادر به شیوه‌سازی روابط خطی هستند، دارای قابلیت بالایی در تشخیص روابط غیرخطی و پیچیده‌ی بین متغیر(های) وابسته و متغیر هدف می‌باشند. همچنین این روش‌های مبتنی بر هوش مصنوعی می‌توانند الگوهای موجود بین پارامترهای ورودی و خروجی را بهتر استخراج نموده و تشخیص بهتری از روند تغییرات پارامترها داشته باشند چرا که توانایی قابل

توجهی در استخراج پاسخ هدف از داده‌های پیچیده دارند (۴). تاکنون از ماشین‌های بردار پشتیبان در پژوهش‌ها و زمینه‌های گوناگونی برای مدل‌سازی استفاده شده است. برای مثال لیو و همکاران (۱۶) قابلیت استفاده از شبکه‌های عصبی مصنوعی<sup>۳</sup> (ANNs)، رگرسیون چند متغیره گام به گام و برای برآورد ظرفیت تبادل کاتیونی خاک را مورد بررسی قرار دادند و بیان کردند که روش SVMs بسیار قوی‌تر از دیگر روش‌های مورد مطالعه بود. لامورسکی و همکاران (۱۴) ضمن بررسی قابلیت شیوه‌سازی تغییرات رطوبت خاک نسبت به زمان با استفاده از دو مدل HYDRUS-1D و HYDRUS-2D SVMs گزارش کردند که مدل SVMs نسبت به مدل HYDRUS-1D دارای ضریب خطای کمتری بود. ونگ و همکاران (۲۷) برای شبیه‌سازی روان‌آب ماهیانه از SVMs استفاده نمودند و به قابلیت بالای این روش در مقایسه با سایر روش‌های مورد بررسی خود اشاره کردند. تواراکاوی و همکاران (۲۲) ضمن مقایسه روش SVMs با ANNs برای برآورد پارامترهای هدایت هیدرولیکی خاک، دریافتند که ماشین‌های بردار پشتیبان دارای توانایی بالاتری در تعیین مقادیر بهینه پارامترهای هدایت هیدرولیکی خاک هستند. لامورسکی و

1- Support Vector Machines, SVMs

2- Supervised Learning Algorithms

3- Artificial Neural Networks; ANNs



شکل ۱- موقعیت جغرافیایی منطقه مورد بررسی در حوزه‌ی آبخیز کارون شمالی  
Figure 1- Location of the study area in the Northern Karun basin

(میانگین قطر سوراخ‌های الک بالایی و پایینی)،  $n$  تعداد الک‌ها و  $w_i$  نسبت وزن خاکدانه‌های روی هر الک به وزن کل خاک استفاده شده پس از کسر وزن ذرات شن و سنگریزه می‌باشد که به صورت زیر محاسبه می‌شود:

$$w_i = \frac{W_i - W_{i(s)}}{W_t - \sum_{i=1}^n W_{i(s)}} \quad (2)$$

که در آن،  $W_i$  وزن ذرات باقی‌مانده در دامنه  $i$ ،  $W_{i(s)}$  وزن ذرات شن و سنگریزه در دامنه  $i$  و  $W_t$  وزن خشک خاک می‌باشند.

**تعیین ویژگی‌های توپوگرافیکی و پوشش گیاهی**  
برخی خصوصیات توپوگرافیکی نقاط نمونه‌برداری شده، نظری درصد شیب، جهت شیب و ارتفاع با استفاده از نقشه مدل رقومی ارتفاع با اندازه ابعاد سلولی ۲۰ متر در محیط نرم‌افزار ایلویس<sup>۴</sup> تعیین شدند. شاخص نرمال شده تفاوت پوشش گیاهی<sup>۵</sup> نیز به عنوان معیاری از وضعیت پوشش گیاهی نقاط مورد مطالعه استفاده شد. این شاخص از تصویر ماهواره‌ای IRS ۲۰۰۸ با وضوح ۲۴ متر در ۲۴ متر و در محیط نرم‌افزار ایلویس استخراج گردید.

### تجزیه و تحلیل آماری داده‌ها

پس از اندازه‌گیری و تعیین ویژگی‌های خاک، توپوگرافی و پوشش

### نمونه‌برداری و اندازه‌گیری ویژگی‌های خاک

منطقه مورد مطالعه ابتدا بر اساس ویژگی‌های توپوگرافیکی، زمین‌شناسی و پوشش گیاهی به واحدهای کاری همسان تقسیم شد. سپس، نمونه‌برداری خاک از عمق سطحی (صفرا تا ۵ سانتی‌متر) به صورت تصادفی نظارت شده<sup>۱</sup> انجام شد و در مجموع، ۱۶۰ نمونه با در نظر گرفتن سطح هر واحد کاری برداشت گردید. نمونه‌های خاک به آرامی در ظروف پلاستیکی قرار گرفتند تا کمترین آسیب به خاکدانه‌ها وارد شود. نمونه‌های خاک پس از انتقال به آزمایشگاه هواشک شدند و برای انجام آزمایش‌های فیزیکی و شیمیابی لازم از الک دو میلی‌متری عبور داده شدند. ماده آلی خاک به روش والکی و بلاک<sup>۲</sup>، کربنات کلسیم معادل خاک به روش تیتراسیون برگشتی<sup>۳</sup>، بافت خاک به روش پیپت (۱۰) و درصد ذرات شن ریز و شن خلی ریز با عبور سوسیانسیون آب و خاک به ترتیب از الک‌های ۱۸۰ و ۲۷۰ میلی‌متری تعیین شدند. برای اندازه‌گیری پایداری خاکدانه‌ها نیز ابتدا خاک هواشک شده (بدون کوبیدن) از الک ۸ میلی‌متری عبور داده شد و سپس از روش ون باول (۲۳) اصلاح شده توسط کمپر و روزنو<sup>۶</sup> استفاده گردید و میانگین هندسی قطر خاکدانه‌ها (GMD) به عنوان شاخصی از پایداری خاکدانه‌ها با استفاده از رابطه ۱ تعیین شد.

$$GMD = \exp\left(\sum_{i=1}^n w_i \log \bar{x}_i\right) \quad (1)$$

که در آن،  $\bar{x}_i$  میانگین قطر خاکدانه‌های باقی‌مانده بر روی هر الک  $i$

3- Digital Elevation Model, DEM

4- Integrated Land and Water Information System, ILWIS

5- Normalized Difference Vegetation Index, NDVI

1- Supervised random soil sampling

2- Mesh

به منظور مفهوم سازی چگونگی عملکرد ماشین های بردار پشتیبان، نقاط آموزشی به صورت رابطه ۵ در نظر گرفته شدند:

$$D = \{(x_i, y_i)\}_{i=1}^n \quad (5)$$

که در این رابطه،  $x_i$  بردار ورودی بوده که  $x_i \in X$  و  $y_i$  مقدار مطلوب می باشد که  $y_i \in R$  است و  $n$  تعداد کل الگوهای داده ای می باشد. اگر داده ها به صورت خطی قابل تفکیک باشند؛ آن گاه قواعد تصمیم گیری که توسط یک صفحه هی بهینه که طبقات تصمیم گیری بازنی را تفکیک می کند به صورت معادله زیر خواهد بود:

$$y = sign\left(\sum_{i=1}^n y_i a_i (X \cdot X_i) + b\right) \quad (6)$$

که در آن،  $y$  خروجی معادله،  $y_i$  ارزش طبقه ای نمونه آموزشی، بردار  $x_i = (x_1, x_2, \dots, x_n)$  نشان دهنده یک داده ای ورودی و بردارهای  $X_i$  ( $i = 1, \dots, N$ )، بردارهای پشتیبان هستند. در این معادله، پارامترهای  $b$  و  $a_i$  تعیین کننده ابر صفحه هستند.

اگر داده ها به صورت خطی قابل تفکیک نباشند، معادله ای ۶ به معادله زیر تغییر می یابد:

$$y = sign\left(\sum_{i=1}^n y_i a_i K(X, X_i) + b\right) \quad (7)$$

کهتابع  $K(X, X_i)$  تابع کرنلی<sup>۳</sup> است که برای ایجاد ماشین هایی با انواع مختلفی از سطوح تصمیم گیری غیرخطی در فضای داده ها، ضربه های داخلی تولید می کند (۲۴ و ۲۵). به عنوان مثال، سه نوع تابع کرنل که در مدل SVM به کار می روند، عبارتند از:

الف) ماشین چند جمله ای با تابع کرنل

$$K(X, X_i) = (X \cdot X_i + 1)^d \quad (8)$$

که در آن،  $d$  درجه کرنل چند جمله ای است.

ب) ماشین تابع پایه ای شعاعی با تابع کرنل

$$K(X, X_i) = exp(-1/\theta^2 (X - X_i)^2) \quad (9)$$

که در آن،  $\theta$  پهنه ای باند کرنل تابع پایه شعاعی است.

پ) ماشین دو لایه با تابع کرنل

$$K(X, X_i) = S[(X \cdot X_i)] = 1/[1 + exp\{v(X \cdot X_i) - c\}] \quad (10)$$

که در آن،  $c$  و  $v$  پارامترهای تابع زیگمویدی  $[S((X \cdot X_i))]$  هستند، به گونه ای که نامعادله که  $c \geq v$  برقرار باشد (۲۶). شکل ۲ فرآیند مدل SVM را نشان می دهد. مدل سازی با ماشین های بردار پشتیبان در این پژوهش در محیط نرم افزار کلمتاین<sup>۳</sup> انجام شد.

گیاهی نقاط مورد مطالعه، برخی خصوصیات آماری داده ها نظیر بیشینه، کمینه، میانگین، واریانس و انحراف معیار با استفاده از نرم افزار SPSS تعیین شدند. سپس به منظور یکسان نمودن ارزش داده ها پیش از استفاده در آزمون گاما و مدل سازی با شبکه های عصبی، داده ها با استفاده از رابطه ۳ استاندارد شدند:

$$X_n = \left[ \frac{X_i - \bar{X}}{X_{max} - X_{min}} \right] + 0.5 \quad (3)$$

که در این رابطه،  $X_n$  داده های استاندارد شده،  $X_i$  داده های مشاهده ای،  $\bar{X}$  میانگین داده های مشاهده ای می باشند. این رابطه، داده ها را در بازه ۰ و ۱ تبدیل می کند.

### مدل سازی با رگرسیون خطی چند متغیره (MLR)

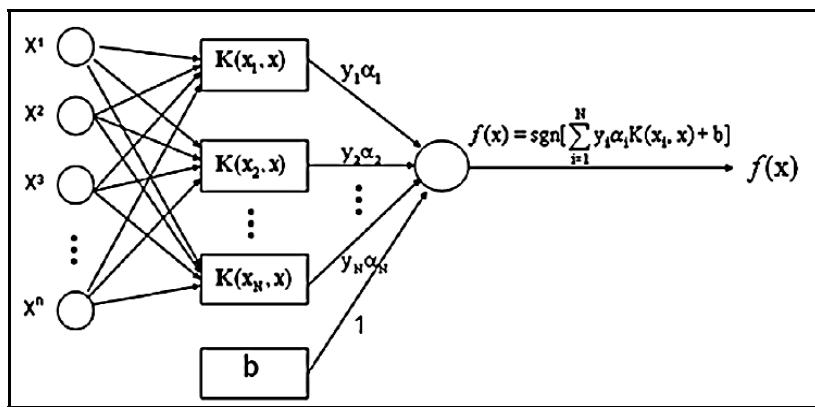
رگرسیون های خطی از جمله روش های ساده ای مدل سازی می باشند که از آن ها می توان برای پیش بینی یک یا چند متغیر پاسخ (وابسته) از مجموعه ای از مقادیر متغیرهای پیش بینی کننده (مستقل) استفاده نمود. رگرسیون های خطی به صورت دو متغیره و چند متغیره می باشند که در رگرسیون دو متغیره، یک متغیر مستقل و یک متغیر وابسته وجود دارد. در رگرسیون چند متغیره نیز، یک متغیر وابسته و دو یا چند متغیر مستقل وجود دارد. معادله کلی یک رگرسیون خطی چند متغیره به صورت رابطه ۴ می باشد:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \dots + \beta_n X_n \quad (4)$$

که در آن،  $Y$  متغیر وابسته،  $X$  متغیر مستقل و  $\beta_1, \dots, \beta_n$  ضرایب رگرسیونی می باشند. مدل سازی رگرسیونی در محیط نرم افزار SPSS انجام شد.

### مدل سازی با ماشین های بردار پشتیبان (SVMs)

ماشین های بردار پشتیبان (SVMs) از جمله روش های یادگیری ناظارت شونده<sup>۱</sup> می باشند که از آن ها برای طبقه بندی و رگرسیون استفاده می شود (۲۴ و ۲۵). الگوریتم SVM نوع خاصی از مدل های خطی را می یابد که حاشیه ای ابر صفحه بیشینه شود. بیشینه کردن حاشیه ای ابر صفحه، منجر به حداقل شدن تفکیک بین طبقات می شود. در واقع، نزدیک ترین نقاط آموزشی به حداقل حاشیه ای ابر صفحه را بردارهای پشتیبان می نامند که از آن ها برای مشخص کردن مرز بین طبقات استفاده می شود. اگر داده ها به صورت خطی قابل جداسازی باشند، از ماشین های خطی برای تولید یک سطح بهینه که داده ها را بدون خطأ و با حداقل فاصله میان صفحه و نزدیک ترین نقاط آموزشی (بردارهای پشتیبان) تفکیک می نماید، استفاده می شود.



شکل ۲- فرآیند مدل SVM ( $X=[x^1, x^2, \dots, x^n]$ : بردار ورودی،  $b$ : بیاس،  $[y_1\alpha_1, y_2\alpha_2, \dots, y_n\alpha_n]$ : معادله تصمیم‌گیری)  
Figure 2- The SVM model schematic ( $[X=[x^1, x^2, \dots, x^n]$ : input vector;  $b$ : bias;  $[y_1\alpha_1, y_2\alpha_2, \dots, y_n\alpha_n]$ : weights vector; and  $f(x)$ : decision equation])

کلسیم معادل خاک در منطقه مورد مطالعه به دلیل وجود مواد مادری مارن غنی از کج و آهک و وجود افق کلسیک می‌باشد (۱۷).  
شاخص NDVI در نقاط نمونه‌برداری از  $۰/۳۱$ - $۰/۳۷$  تا  $۰/۰۸$  متغیر بود و دارای میانگین و انحراف معیار به ترتیب،  $۰/۱۳$  و  $۰/۰۸$  بود. شاخص NDVI بیان کنندهٔ سبزینهٔ گیاهی است که در ارتباط با درصد تابش‌های جذب شدهٔ فتوسنتزی می‌باشد و نمایان‌گر فعالیت کلروفیل در گیاهان است. این شاخص بین  $-۱$  تا  $۱$  متغیر بوده که افزایش میزان عددی آن، بیان‌گر افزایش درصد پوشش گیاهی سبز سالمند می‌باشد و بنابراین سطوح بدون پوشش گیاهی، دارای مقادیر منفی NDVI هستند (۱۲). درصد شیب در نقاط نمونه‌برداری بین  $۰/۱۰$  تا  $۰/۶۱$  درصد با میانگین  $۰/۲۸$  درصد متفاوت بود که نمایان‌گر وجود توپوگرافی شدید در منطقهٔ مورد مطالعه است. جهت شیب، دارای میانگین  $۰/۸۲$  رادیان و ارتفاع نقاط نمونه‌برداری به ترتیب دارای مقادیر کمینه، بیشینه و میانگین  $۰/۰۰۷۰$ ،  $۰/۰۲۶۹$  و  $۰/۵۳۱۷$  متر بود.

در بسیاری از مطالعات، برخی از ویژگی‌های خاک (مانند توزیع اندازه‌ی ذرات خاک، ماده‌ی آلی و کربنات کلسیم معادل) و نیز برخی از خصوصیات توپوگرافیکی و پوشش گیاهی (مانند درصد و جهت شیب، ارتفاع و درصد پوشش گیاهی) به عنوان پارامترهای اثرباز بر پایداری خاکدانه‌ها نام برده شده‌اند (۱)، (۲)، (۱۹)، (۲۱) و (۲۲). برای مثال، سیکس و همکاران (۱۹) و آندرسون و همکاران (۲) بیان کردند که کمبود و کاهش ماده‌ی آلی سبب کاهش اندازه‌ی خاکدانه‌ها، تخریب آن‌ها و در نتیجه، حساسیت خاک به فرسایش می‌شود. در واقع، ماده‌ی آلی از دو راه افزایش ویژگی آب‌گریزی و افزایش چسبندگی بین ذرات خاک، سبب افزایش مقاومت خاکدانه‌ها در برابر خیس شدن و پایداری ساختمان خاک می‌گردد (۸). تیسداال و اوذ (۲۱) رس، اکسیدهای آهن و آلومینیوم و کربنات‌ها را بر پایداری ساختمان خاک مؤثر دانستند.

### شاخص‌های ارزیابی مدل‌ها

به منظور بررسی کارایی و دقیقی مدل طراحی شده برای برآورد پایداری خاکدانه‌ها در این پژوهش، از برخی شاخص‌های آماری نظریه ضریب همبستگی ( $r$ )، میانگین مربعات خطای  $(MSE)$  و درصد خطای  $(ERROR\%)$  استفاده شد که معادله‌ی دو شاخص آخر به صورت زیر می‌باشد:

$$MSE = \frac{1}{n} \sum_{i=1}^n [y_k - \hat{y}_k]^2 \quad (11)$$

$$ERROR\% = \frac{\sum_{k=1}^n |y_k - \hat{y}_k|}{\sum_{k=1}^n y_k} \times 100 \quad (12)$$

که در این روابط،  $y_k$  و  $\hat{y}_k$  به ترتیب، مقادیر مشاهده‌ای و برآورد شده و  $n$  تعداد کل مشاهدات می‌باشند.

### نتایج و بحث

#### ویژگی‌های خاک، توپوگرافی و پوشش گیاهی

جدول ۱ توصیف آماری ویژگی‌های خاک، توپوگرافی و پوشش گیاهی نقاط مطالعه استفاده شده برای برآورد پایداری خاکدانه‌ها را نشان می‌دهد. بر اساس توزیع اندازه‌ی ذرات خاک، بافت غالب خاک در منطقه شامل لوم رس سیلتی، لوم رس سیلتی، لوم و رس سیلتی بود. ماده‌ی آلی خاک بین  $۰/۰۰۶$ - $۰/۳۳$  درصد و کربنات کلسیم معادل خاک، به ترتیب دارای مقادیر کمینه، بیشینه، میانگین و انحراف میانگین  $۰/۰۰۸۰$ ،  $۰/۰۲۵$  و  $۰/۱۲$  درصد بود. مقادیر زیاد کربنات

1 -Mean Square Error, MSE

جدول ۱- خلاصه آماری پارامترهای مورد استفاده برای مدل‌سازی پایداری خاکدانه‌ها

Table 1- Description statistics of the parameters used for modelling of aggregate stability

پارامتر Parameter	Descriptive statistics شاخص آماری					
	Min کمینه	Max بیشینه	میانگین Mean	واریانس Variance	انحراف معیار Standard deviation	
(Clay %) رس (%)	8.00	53.60	31.08	70.96	8.42	
(Silt %) سیلت (%)	21.60	81.60	48.40	86.19	9.28	
(Sand %) شن (%)	3.20	65.60	20.53	164.09	12.81	
(Very fine sand %) شن خیلی ریز (%)	0.70	28.04	6.65	29.66	5.45	
(Fine sand %) شن ریز (%)	0.18	16.02	4.13	11.43	3.38	
(Organic matter %) ماده‌ای آلی (%)	0.22	6.33	2.58	1.67	1.29	
Calcium کربنات کلسیم معادل (carbonate equivalent %)	1.00	80.65	25.32	445.90	21.12	
شاخص پوشش گیاهی (NDVI)	-0.31	0.47	0.13	0.006	0.08	
(Slope %) درصد شیب (%)	3.10	80.61	28.31	273.88	15.42	
(Aspect, radian) جهت شیب (ج) (Aspect, radian)	8.87	365.85	171.82	10162.00	100.81	
(Elevation, m) ارتفاع (Elevation, m)	907.00	2639.00	1714.00	88484.00	297.64	

(شکل ۴) و نیز بر اساس مقادیر شاخص‌های آماری ارزیابی مدل مورد استفاده به نظر می‌رسد که مدل رگرسیونی خطی چند متغیره، فاقد دقت قابل قبول برای برآورد و مدل‌سازی پایداری خاکدانه‌ها در منطقه‌ی مورد مطالعه است. در واقع مدل‌های رگرسیون خطی تنها قادر به تشخیص روابط خطی بین متغیرهای مستقل و وابسته هستند و چنان‌چه روابط غیرخطی بین این متغیرها وجود داشته باشد، کارایی این مدل‌ها به حد قبل ملاحظه‌ای کاوش می‌یابد (۲۰ و ۲۸). بنابراین، به نظر می‌رسد که دلیل اصلی عملکرد ضعیف مدل رگرسیون خطی در برآورد ویژگی مورد مطالعه در این پژوهش، روابط غیرخطی بین این ویژگی و ورودی‌های مورد استفاده در مدل‌سازی باشد.

**مدل ماشین‌های بردار پشتیبان (SVMs)** مقادیر  $MSE$  و  $ERROR\%$  برای مدل SVM طراحی شده برای برآورد GMD به ترتیب برابر  $0.086$  و  $0.005$  و  $0.06$  درصد بودند (جدول ۲). همچنین، ضریب تبیین نسبتاً مناسبی ( $R^2 = 0.74$ ) بین مقادیر مشاهده‌ای و شبیه‌سازی شده برای داده‌های تست مدل SVM حاصل شد (شکل ۵)؛ اگرچه در بسیاری از نقاط، بیش برآورده از GMD وجود داشت (شکل ۶).

به علاوه، آزمکتا (۱) اظهار می‌دارد که آهک به سبب اثرات سیمان‌کننده‌ی خود می‌تواند از تخریب خاکدانه‌ها جلوگیری کند. کانتون و همکاران (۷) بیان کردند که ویژگی‌های توپوگرافیکی می‌توانند به صورت غیرمستقیم و از طریق اثر بر کائی‌شناسی خاک، رطوبت خاک، کربن آلی، بافت خاک و استقرار پوشش گیاهی بر ساختمان خاک و پایداری خاکدانه‌ها اثرگذار باشند.

#### مدل رگرسیون خطی چند متغیره (MLR)

مقادیر شاخص‌های آماری مورد استفاده برای ارزیابی کارایی مدل رگرسیونی طراحی شده برای برآورد GMD در جدول ۲ آورده شده‌اند. مقادیر  $MSE$  و  $ERROR\%$  برای مدل رگرسیونی طراحی شده برای برآورد GMD به ترتیب برابر  $0.012$  و  $0.015$  درصد و  $0.032$  و  $0.071$  بودند. مقادیر مشاهده‌ای و شبیه‌سازی شده GMD برای داده‌های تست مدل نیز در شکل ۳ مقایسه شده‌اند. با توجه به این شکل، مشخص است که در برخی از نقاط به صورت غیریکنواخت، بیش برآورده از GMD صورت گرفته است و در برخی دیگر از نقاط، GMD کمتر از مقادیر مشاهده‌ای آن‌ها تخمین زده است. با توجه به ضریب تبیین پایین ( $R^2 = 0.10$ ) بین مقادیر مشاهده‌ای و شبیه‌سازی شده برای داده‌های تست مدل رگرسیونی طراحی شده در این پژوهش

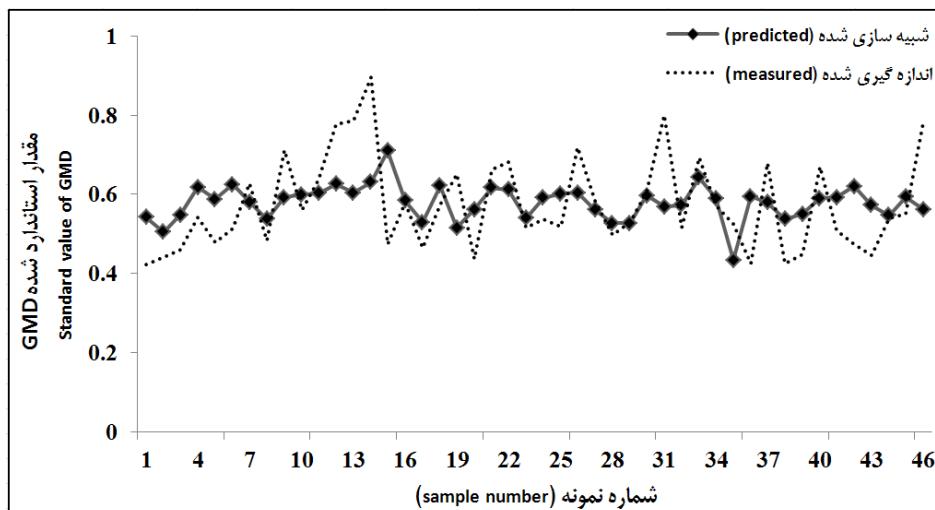
جدول ۲- شاخص‌های آماری مورد استفاده برای ارزیابی کارایی مدل‌های رگرسیون خطی چند متغیره (MLR) و ماشین‌های بردار پشتیبان (SVMs) در برآورد GMD

Table 2- Statistical criteria used to evaluate the performance of the MLR and SVM models for the prediction of GMD  
(Evaluation Criterion) (Statistical criterion)

نوع مدل (Model type)	ERROR%	MSE	r
MLR	15.70	0.012	0.32
SVMs	10.60	0.005	0.86

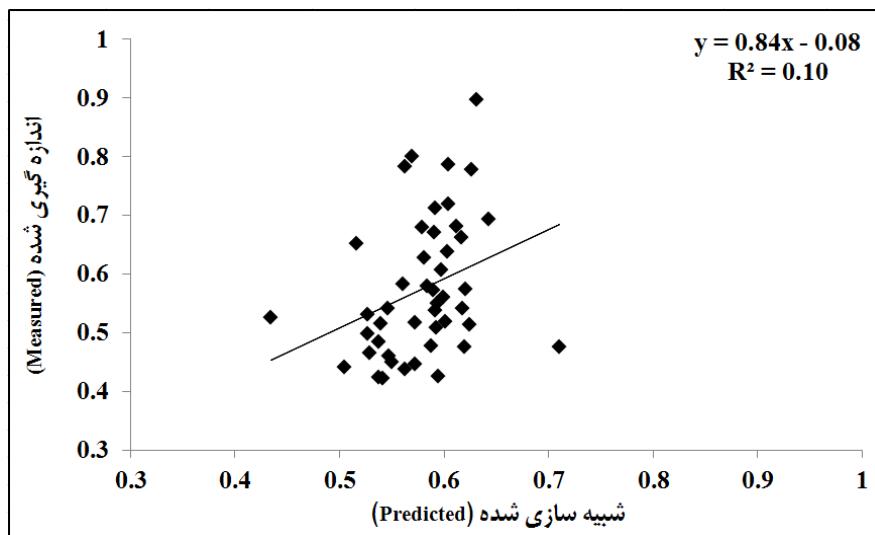
٪ ضریب همبستگی، MSE: میانگین مربعات خطأ و ERROR%: درصد خطأ

r: correlation coefficient; MSE: mean square error; and ERROR%: error percentage



شکل ۳- مقایسه مقادیر مشاهده‌ای و شبیه‌سازی شده‌ی GMD برای داده‌های تست مدل رگرسیونی

Figure 3- Comparison of the observed and predicted GMD values for the test data of the regression model



شکل ۴- همبستگی بین مقادیر مشاهده‌ای و شبیه‌سازی شده‌ی GMD برای داده‌های تست مدل رگرسیونی

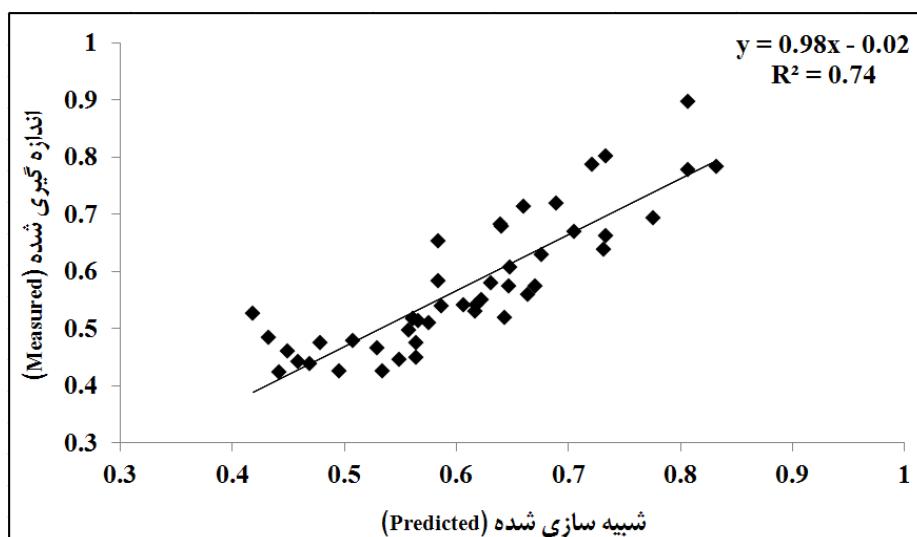
Figure 4- Correlation between the observed and predicted GMD values for the test data of the regression model

بیشتری نسبت به مدل رگرسیونی در برآورد و مدل‌سازی GMD در منطقه‌ی مورد مطالعه داشته باشند. در واقع، ماشین‌های بردار پشتیبان

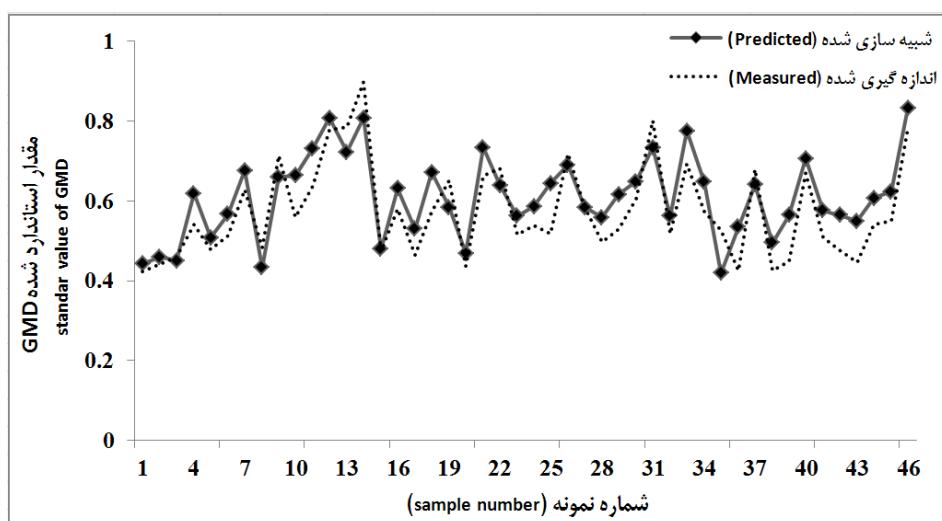
بنابراین به نظر می‌رسد که بر اساس مقادیر نسبتاً قابل قبول شاخص‌های آماری ارزیابی مدل، ماشین‌های بردار پشتیبان دقیق

از دیگر عوامل مؤثر بر قابلیت مدل ها در برآورد و مدل سازی GMD در این پژوهش می باشدند که به نظر می رسد مدل ماشین های بردار پشتیبان در مقایسه با مدل رگرسیون خطی دارای انعطاف پذیری بیشتری بوده است. بنابراین به نظر می رسد که در مناطقی که پیچیدگی های محیطی زیاد و بین داده های ورودی و خروجی، روابط غیرخطی پیچیده وجود داشته و در عین حال تعداد داده های قابل دسترس کم می باشد، روش های هوش مصنوعی مانند ماشین های بردار پشتیبان نسبت به روش های مرسوم مدل سازی مانند رگرسیون های خطی برتری دارند.

ساخته شده با تابع کرنلی، دارای انعطاف پذیری زیاد و قابلیت بالای در تشخیص روابط غیرخطی و پیچیده ای بین داده های ورودی و خروجی می باشدند (۱۵). از سوی دیگر، روش های مبتنی بر آموزش در مقایسه با مدل های رگرسیون خطی از توانایی بیشتری در تشخیص روابط بین ورودی ها و خروجی برخوردار می باشند. همچنین روش های هوش مصنوعی مانند ماشین های بردار پشتیبان در مقایسه با روش های قدیمی و مرسوم مدل سازی مانند رگرسیون های خطی دارای قابلیت بالای در تشخیص روابط پیچیده ای بین داده های ورودی و خروجی با تعداد نمونه ای کم هستند. پراکنش نمونه ها، تعییرات مکانی نقاط نمونه بردای و مقیاس منطقه ای مورد بررسی نیز



شکل ۵- همبستگی بین مقادیر مشاهده ای و شبیه سازی شده GMD برای داده های تست مدل SVM  
Figure 5- Correlation between the observed and predicted GMD values for the test data of the SVM model



شکل ۶- مقایسه مقادیر مشاهده ای و شبیه سازی شده GMD برای داده های تست مدل SVM  
Figure 6- Comparison of the observed and predicted GMD values for the test data of the SVM model

بردار پشتیبان دقت و قابلیت بیشتری نسبت به مدل‌های رگرسیونی مرسوم در برآورده و مدل‌سازی این ویژگی دارند. از سوی دیگر، با توجه به همیستگی نسبتاً مناسب بین مقادیر مشاهده‌ای و شبیه‌سازی شده‌ی GMD برای داده‌های تست مدل SVM طراحی شده به نظر می‌رسد که بتوان از ویژگی‌های زودیافت مورد استفاده در این پژوهش به عنوان ورودی SVM در مدل‌سازی و تخمین پایداری خاکدانه‌ها در منطقه‌ی مورد بررسی بهره جست. لذا این احتمال وجود خواهد داشت که بتوان از ماشین‌های بردار پشتیبان به عنوان روشی نوین برای برآورده ویژگی‌های فیزیکی و مکانیکی خاک برای رسیدن به بیشترین دقت با صرف کمترین هزینه و زمان استفاده نمود. با این وجود، بررسی امکان استفاده از تکنیک‌های انتخاب ورودی‌های بهینه نظریه‌الگوریتم‌های تکاملی<sup>۱</sup> (همچون الگوریتم ژنتیک<sup>۲</sup>) و نیز استفاده از دیگر ابزارهای مدل‌سازی در برآورده پایداری خاکدانه‌ها (مانند شبکه‌های عصبی مصنوعی و سیستم‌های استنتاج نروفازی انطباقی<sup>۳</sup>) در پژوهش‌های آینده پیشنهاد می‌گردد.

لامورسکی و همکاران (۱۳) از ماشین‌های بردار پشتیبان برای برآورده هدایت هیدرولیکی خاک استفاده نمودند و به قابلیت بالای ماشین‌های بردار پشتیبان در مدل‌سازی ویژگی‌های خاک اشاره کردند. ونگ و همکاران (۲۷) امکان استفاده از روش‌های گوناگون برآورده روان آب ماهیانه را بررسی و مقایسه نمودند و دریافتند که ماشین‌های بردار پشتیبان تخمین بهتری از روان آب ماهیانه (چه در مرحله‌ی آموزش و چه در مرحله‌ی اعتبارسنجی) در دسترس قرار دادند. تواراکاوی و همکاران (۲۲) نیز به توانایی بالاتر مدل‌های توسعه داده شده بر اساس ماشین‌های بردار پشتیبان برای برآورده پارامترهای هدایت هیدرولیکی در مقایسه با مدل‌های توسعه داده شده بر اساس شبکه‌های عصبی مصنوعی اشاره نمودند.

### نتیجه‌گیری کلی

نتایج این پژوهش، نمایانگر آن بود که مدل رگرسیون خطی چند متغیره، قادر دقت قابل قبول برای برآورده و مدل‌سازی GMD در حوزه آبخیز کارون شمالی می‌باشد. این در حالی است که ماشین‌های

### منابع

- 1- Amezketa E. 1999. Soil aggregate stability: A review. *Journal of Sustainable Agriculter*, 14: 83-151.
- 2- Andesodun J.K., Mbagwu J.S.C., and Oti N. 2005. Distribution of carbon, nitrogen and phosphorus in water-stable aggregates of an organic waste amended Ultisol in southern Nigeria. *Bioresoure Technology*, 96: 509-516.
- 3- Besalatpour A., Hajabbasi M.A., Ayoubi S., Afyuni M., Jalalian A., and Schulin R. 2012. Soil shear strength prediction using intelligent systems: artificial neural networks and adaptive neuro-fuzzy inference system. *Journal of Soil Science and Plant Nutrition*, 58: 149-160.
- 4- Besalatpour A.A., Ayoubi S., Hajabbasi M.A., Gharipour A., and Yousefian Jazi A. 2014. Feature selection using parallel genetic algorithm for the prediction of geometric mean diameter of soil aggregates by machine learning methods. *Arid Land Researche and Management*, 28:383-394.
- 5- Calero N., Barron V., and Torrent J. 2008. Water dispersible clay in calcareous soils of southwestern Spain. *Catena*, 74: 22-30.
- 6- Canasveras J.C., Barron V., Del Campillo M.C., Torrent J., and Gomez J.A. 2010. Estimation of aggregate stability indices in Mediterranean soils by diffuse reflectance spectroscopy. *Geoderma*, 158: 78-84.
- 7- Canton Y., Sole-Benet A., Asensio C., Chamizo S., and Puigdefabregas J. 2009. Aggregate stability in range sandy loam soils: relationships with runoff and erosion. *Catena*, 77: 192-199.
- 8- Chenu C., Le Bissonnais Y., and Arrouays D. 2000. Organic matter influence on clay wettability and soil aggregate stability. *Soil Science Society of American Journal*, 64:1479-1486.
- 9- Dexter A.R., and Kroesbergen B. 1985. Methodology for determination of tensile strength of soil aggregates. *Journal of Agricultural Engineering Research*, 31: 139-147.
- 10- Gee G.W., and Bauder J.W. 1986. Particle size analysis. In: Klute, A. (Ed.), *Methods of Soil Analysis: Part 1, Agronomy Handbook No 9.*, American Society of Agronomy and Soil Science Society of America, Madison, WI, pp. 383-411.
- 11- Kemper W.D., and Rosenau K. 1986. Size distribution of aggregates. In: Klute, A. (Ed.), *Methods of Soil Analysis: Part 1: Physical and Mineralogical Methods*, American Society of Agronomy, Madison, WI, pp. 425-442.
- 12- Khalilmoghadam B., Afyuni M., Abbaspour K.C., Jalalian A., Dehghani A.A., and Schulin R. 2009. Estimation of

1- Evolutionary algorithms

2- Genetic algorithm

3- Adaptive Neuro-Fuzzy Inference Systems, ANFIS

- surface shear strength in Zagros region of Iran-A comparison of artificial neural networks and multiple-linear regression models. *Geoderma*, 153: 29-36.
- 13- Lamorski K., Pachepsky Y., Slawinski C., and Walczak R.T. 2008. Using support vector machines to develop pedotransfer functions for water retention of soils in Poland. *Soil Science Society of American Journal*, 72: 1243-1247.
- 14- Lamorski K., Pastuszka T., Krzyszczak J., Slawinski C., and Witkowska-Walczak B. 2013. Soil water dynamic modeling using the physical and support vector machine methods. *Vadose Zone Journal*, 12 (4):
- 15- Li H., Liang Y., and Xu Q. 2009. Support vector machines and its applications in chemistry. *Chemometrics Intelligent Laboratory Systems*, 95: 188-198.
- 16- Liao K., Xu S., Wu J., Zhu Q., and An L. 2014. Using support vector machines to predict cation exchange capacity of different soil horizons in Qingdao City, China. *Journal of Plant Nutrition and Soil Science*, 177 (5): 775-782.
- 17- Nelson D.W. and Sommers L.E. 1982. Total carbon, organic carbon, and organic matter. In: Page, A. L. (Ed.), *Methods of Soil Analysis*, American Society of Agronomy, Madison, Wis, pp. 539-579.
- 18- Nelson R.E. 1982. Carbonate and gypsum. In: Page, A.L. (Ed.), *Methods of Soil Analysis: Part I: Agronomy Handbook No 9*, American Society of Agronomy and Soil Science Society of America, Madison, WI, pp. 181-197.
- 19- Six J., Paputian K., Elliot E.T., and Combrink C. 2001. Soil structure and organic matter. I. Distribution of aggregate-size classes and aggregate-associated carbon. *Soil Science Society of American Journal*, 64: 681-689.
- 20- Sobhani J., Najimi M., Pourkhoshidi A.R., and Parhizkar T. 2010. Prediction of the compressive strength of no-slump concrete: A comparative study of regression, neural network and ANFIS models. *Journal of Construction and Building Materials*, 24: 709-718.
- 21- Tisdall J. M., and Oades J.M. 1982. Organic matter and water-stable aggregates in soils, *Soil Sci.*, 33: 141-163.
- 22- Twarakavi N.K.C., Simunek J., and Schaap M.G. 2009. Development of pedotransfer functions for estimation of soil hydraulic parameters using support vector machines. *Soil Science Society of American Journal*, 73: 1443-1452.
- 23- Van Bavel C.H.M. 1950. Mean-weight diameter of soil aggregates as a statistical index of aggregation. *Proceeding of Soil Science Society of American*, 14: 20-23.
- 24- Vapnik V. 1995. *The Nature of Statistical Learning Theory*, Springer-Verlag, New York.
- 25- Vapnik V. 1998. *Statistical Learning Theory*, Wiley, New York.
- 26- Wang L. 2005. *Support Vector Machines: Theory and Applications*. Springer-Verlag, New York.
- 27- Wang W.C., Chau K.W., Cheng C.T., and Qiu L. 2009. A comparison of performance of several artificial intelligence methods for forecasting monthly discharge time series. *Journal of Hydrology*, 374: 294-306.
- 28- Yilmaz I., and Yuksek G. 2009. Prediction of the strength and elasticity modulus of gypsum using multiple regression, ANN, and ANFIS models. *International Journal of Rock Mechanics and Mining Sciences*, 46: 803-810.



## Modeling of Soil Aggregate Stability using Support Vector Machines and Multiple Linear Regression

A.A. Besalatpour<sup>1\*</sup> - H. Shirani<sup>2</sup> - I. Esfandiarpoor Borujeni<sup>3</sup>

Received: 09-06-2013

Accepted: 05-04-2015

**Introduction:** Soil aggregate stability is a key factor in soil resistivity to mechanical stresses, including the impacts of rainfall and surface runoff, and thus to water erosion (Canasveras et al., 2010). Various indicators have been proposed to characterize and quantify soil aggregate stability, for example percentage of water-stable aggregates (WSA), mean weight diameter (MWD), geometric mean diameter (GMD) of aggregates, and water-dispersible clay (WDC) content (Calero et al., 2008). Unfortunately, the experimental methods available to determine these indicators are laborious, time-consuming and difficult to standardize (Canasveras et al., 2010). Therefore, it would be advantageous if aggregate stability could be predicted indirectly from more easily available data (Besalatpour et al., 2014). The main objective of this study is to investigate the potential use of support vector machines (SVMs) method for estimating soil aggregate stability (as quantified by GMD) as compared to multiple linear regression approach.

**Materials and Methods:** The study area was part of the Bazoft watershed ( $31^{\circ} 37'$  to  $32^{\circ} 39'$  N and  $49^{\circ} 34'$  to  $50^{\circ} 32'$  E), which is located in the Northern part of the Karun river basin in central Iran. A total of 160 soil samples were collected from the top 5 cm of soil surface. Some easily available characteristics including topographic, vegetation, and soil properties were used as inputs. Soil organic matter (SOM) content was determined by the Walkley-Black method (Nelson & Sommers, 1986). Particle size distribution in the soil samples (clay, silt, sand, fine sand, and very fine sand) were measured using the procedure described by Gee & Bauder (1986) and calcium carbonate equivalent (CCE) content was determined by the back-titration method (Nelson, 1982). The modified Kemper & Rosenau (1986) method was used to determine wet-aggregate stability (GMD). The topographic attributes of elevation, slope, and aspect were characterized using a 20-m by 20-m digital elevation model (DEM). The data set was divided into two subsets of training and testing. The training subset was randomly chosen from 70% of the total set of the data and the remaining samples (30% of the data) were used as the testing set. The correlation coefficient ( $r$ ), mean square error (MSE), and error percentage (ERROR%) between the measured and the predicted GMD values were used to evaluate the performance of the models.

**Results and Discussion:** The description statistics showed that there was little variability in the sample distributions of the variables used in this study to develop the GMD prediction models, indicating that their values were all normally distributed. The constructed SVM model had better performance in predicting GMD compared to the traditional multiple linear regression model. The obtained MSE and  $r$  values for the developed SVM model for soil aggregate stability prediction were 0.005 and 0.86, respectively. The obtained ERROR% value for soil aggregate stability prediction using the SVM model was 10.7% while it was 15.7% for the regression model. The scatter plot figures also showed that the SVM model was more accurate in GMD estimation than the MLR model, since the predicted GMD values were closer in agreement with the measured values for most of the samples. The worse performance of the MLR model might be due to the larger amount of data that is required for developing a sustainable regression model compared to intelligent systems. Furthermore, only the linear effects of the predictors on the dependent variable can be extracted by linear models while in many cases the effects may not be linear in nature. Meanwhile, the SVM model is suitable for modelling nonlinear relationships and its major advantage is that the method can be developed without knowing the exact form of the analytical function on which the model should be built. All these indicate that the SVM approach would be a better choice for predicting soil aggregate stability.

**Conclusion:** The pixel-scale soil aggregate stability predicted that using the developed SVM and MLR models demonstrates the usefulness of incorporating topographic and vegetation information along with the soil properties as predictors. However, the SVM model achieved more accuracy in predicting soil aggregate stability compared to the MLR model. Therefore, it appears that support vector machines can be used for prediction of

1, 2, 3- Assistant Professor, Associate Professor and Assistant Professor, Department of Soil Science, Collage of Agriculture, Vali-e-Asr University of Rafsanjan, Respectively

(\*-Corresponding Author Email: a.besalatpour@vru.ac.ir)

some soil physical properties such as geometric mean diameter of soil aggregates in the study area. Furthermore, despite the high predictive accuracy of the SVM method compared to the MLR technique which was confirmed by the obtained results in the current study, the advantages of the SVM method such as its intrinsic effectiveness with respect to traditional prediction methods, less effort in setting up the control parameters for architecture design, the possibility of solving the learning problem according to constrained quadratic programming methods, etc., should motivate soil scientists to work on it further in the future.

**Keywords:** Geometric mean diameter (GMD), Soil structure, Support vector machines (SVMs), Soil physical properties