



تحقیقات آب و خاک ایران | دوره ۵۲ | شماره ۱۲ | اسفند ۱۴۰۰ (ص ۳۰۱۸-۳۰۰۱)

<https://dx.doi.org/10.22059/ijswr.2022.333856.669130>

(مقاله علمی - پژوهشی)

The Use of Spectral Indices to Estimate Soil Surface Moisture using Machine Learning Algorithms

AZADEH SEDAGHAT¹, MAHMOUD SHABANPOUR SHAHRESTANI^{1*}, ALI AKBAR NOROOZI², ALIREZA FALLAH NOSRATABAD³, HOSSEIN BAYAT⁴

1. Department of Soil Science, Faculty of Agriculture Sciences, University of Guilan, Rasht, Iran.

2. Soil Conservation and Watershed Management Research Institute (SCWMRI), Agricultural Research, Education and Extension Organization (AREEO), Tehran, Iran.

3. Soil and Water Research Institute, Agricultural Research, Education and Extension Organization (AREEO), Karaj, Iran.

4. Department of Soil Science, Faculty of Agriculture, Bu-Ali Sina University, Hamedan, Iran

(Received: Nov. 12, 2021- Revised: Jan. 2, 2022- Accepted: Jan. 4, 2022)

ABSTRACT

Detailed information about soil moisture and its spatial and temporal distribution provides opportunity for optimized land resources utilization. Our study aimed to estimate soil surface moisture through readily available soil parameters and spectral index obtained from Sentinel-2 sensors using two methods, artificial neural networks (ANN) and support vector regression (SVM). There were 124 soil samples collected from three regions of Iran (Tehran, Garmsar, and Lorestan). After normalizing the data, the significance of the correlation between input variables (spectral indices and basic soil properties) and output variables (surface moisture) was evaluated statistically. In the next step, the mentioned methods were used to perform a modeling process, and the results were evaluated. The results showed that the ANN method outperformed the SVM method. Based on ANN technique, the Root Mean Square Error (RMSE), Akaike Information Criterion (AIC), coefficient of determination (R^2) and Relative Improvement (RI) in the training step were 0.033, -538, 0.71, 21.25, and in the testing step they were 0.410, -266, 0.69, and 16.06, respectively. Also, RMSE, AIC, R^2 , and RI in the SVM method in training step were respectively 0.035, -474, 0.71, and 35.16 and in testing step were respectively 0.046, 252, 0.63, and 20.21. Using the ANN method, soil color index (CI) has been shown to estimate soil moisture more accurately than other spectral indices. Therefore, the ANN method constructs a nonlinear relationship between soil surface moisture and input parameters, which enables soil moisture to be estimated with acceptable accuracy in the study area.

Keywords: Transfer Functions, Soil Color Index, Salinity Index, Soil Temperature Index, Soil Surface Moisture.

استفاده از شاخص‌های طیفی در برآورد رطوبت سطحی خاک بر اساس الگوریتم یادگیری ماشین

آزاده صداقت^۱، محمود شعبانپور شهرستانی^{۱*}، علی اکبر نوروزی^۲، علیرضا فلاح نصرت‌آباد^۳، حسین بیات^۴

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

۲. پژوهشکده حفاظت خاک و آبخیزداری، سازمان تحقیقات، آموزش و ترویج کشاورزی، تهران، ایران.

۳. موسسه تحقیقات خاک و آب، سازمان تحقیقات، آموزش و ترویج کشاورزی، کرج، ایران.

۴. گروه علوم و مهندسی خاک، دانشکده کشاورزی دانشگاه بوعلی سینا، همدان، ایران.

(تاریخ دریافت: ۱۴۰۰/۸/۲۱ - تاریخ بازنگری: ۱۴۰۰/۱۰/۱۲ - تاریخ تصویب: ۱۴۰۰/۱۰/۱۴)

چکیده

اطلاع دقیق از میزان رطوبت سطح خاک و توزیع مکانی و زمانی آن می‌تواند منجر به بهره‌برداری بهینه از امکانات زمین گردد. هدف از پژوهش حاضر برآورد رطوبت سطحی خاک به‌وسیله پارامترهای زودیافت خاک و شاخص‌های طیفی حاصل از سنجنده سنتینل ۱-۲ با دو روش شبکه عصبی مصنوعی (ANN) و رگرسیون بردار پشتیبان (SVM) است. به تعداد ۱۲۴ نمونه خاک از سه منطقه ایران (تهران، گرمسار و لرستان) برداشته شد. پس از نرمال‌سازی داده‌های موردنظر، معنی‌داری همبستگی متغیرهای ورودی (شاخص‌های طیفی و خصوصیات پایه‌ای خاک) با خروجی (رطوبت سطحی) از نظر آماری بررسی گردید. سپس، مدل‌سازی با روش‌های مذکور انجام و نتایج مورد ارزیابی قرار گرفت. نتایج نشان داد که روش ANN کارایی بهتری نسبت به روش SVM دارد. در روش ANN، میانگین مقادیر، ریشه میانگین مربعات خطا (RMSE)، آکاتیک (AIC)، ضریب تعیین (R^2)، و ضریب بهبود نسبی (RI) به ترتیب در مرحله آموزش ۰/۰۳۳، ۰/۷۱، ۰/۲۵ و ۲۱/۲۵ در مرحله آزمون ۰/۴۱۰، ۲۶۶، ۰/۶۹ و ۱۶/۰۶ به دست آمدند. همچنین مقادیر میانگین RMSE، AIC، R^2 و RI در روش SVM به ترتیب در مرحله آموزش ۰/۰۳۵، ۴۷۴، ۰/۷۱ و ۳۵/۱۶ و در مرحله آزمون ۰/۰۴۶، ۲۵۲، ۰/۶۳ و ۲۰/۲۱ به دست آمدند. در این پژوهش شاخص رنگ خاک (CI) نسبت به سایر شاخص‌های طیفی با روش ANN با دقت بالاتری رطوبت خاک را برآورد کرده است؛ بنابراین روش شبکه عصبی مصنوعی با ایجاد ارتباط غیرخطی بین رطوبت سطح خاک و پارامترهای ورودی قادر به برآورد رطوبت خاک با دقت قابل قبول در منطقه مورد مطالعه است.

واژه‌های کلیدی: توابع انتقالی، شاخص رنگ خاک، شاخص شوری، شاخص حرارتی خاک، رطوبت سطحی خاک.

مقدمه

رطوبت خاک به سه دسته کلی تقسیم می‌شوند: دسته اول اندازه-گیری رطوبت خاک در مزرعه به صورت مستقیم یا غیرمستقیم است. دسته دوم روش‌های مبتنی بر سنجش‌ازدور است. دسته سوم استفاده از مدل‌های ریاضی در شبیه‌سازی رطوبت خاک است. دسته اول و دوم محدودیت‌هایی دارند که بسط این اندازه-گیری‌ها به مقیاس‌های بزرگ کار مشکلی می‌باشد (Zhao et al., 2010). برای غلبه بر چنین محدودیت‌هایی، تلفیق داده‌های سنجش‌ازدور و مدل‌سازی رطوبت خاک استفاده شده است. سنجش از دور بر مبنای ارتباط قوی بین خواص دی-الکترونیک آب و خاک عمل می‌کند و به دلیل دید جامع و یکنواخت از نواحی مختلف زمین، تصویربرداری مکرر از مناطق وسیع و غیرقابل دسترس، به دست آوردن اطلاعات با فواصل زمانی منظم و

بررسی توزیع مکانی رطوبت خاک پیش‌نیاز پژوهش و مدیریت کشاورزی و محیط‌زیست می‌باشد. استخراج اطلاعات رطوبت سطحی خاک در مناطق ناهموار چالش بزرگی است (Luo et al., 2019). رطوبت خاک، به شدت وابسته به زمان و مکان بوده و مقدار آن در هر منطقه نسبت به زمان و مکان تغییر می‌کند (Rosenbaum et al., 2012). اگر ارتباطی بین داده‌های ماهواره‌ای و رطوبت خاک برقرار شود، تصاویر ماهواره‌ای قادر خواهد بود، تخمین رطوبت خاک در سطح حوضه را تسهیل و دسترسی به نقاط دور یا خارج از دسترس را فراهم سازد (Soleimani et al., 2008). به‌طورکلی روش‌های اندازه‌گیری

* نویسنده مسئول: shabanpour@guilan.ac.ir

تفاضلی نرمال شده پوشش گیاهی حاصل از سنجنده AVHRR با روش SVM رطوبت سطحی خاک را تخمین زدند و گزارش کردند که این روش در تخمین رطوبت سطحی عملکرد بالایی دارد. (Moreira and Pedrollo, 2015) با استفاده از روش‌های رگرسیون خطی چند متغیره و شبکه عصبی مصنوعی نشان دادند که ارتباط رطوبت سطح خاک با مؤلفه‌های اصلی یک ارتباط غیرخطی است که توسط مدل رگرسیون به‌خوبی قابل برازش و توضیح نیست و این متغیر با توابع غیرخطی مدل شده توسط شبکه‌های عصبی قابل پیش‌بینی است.

ماهواره سنتینل-۲ در اواسط سال ۲۰۱۵ ساخته شده و مدت‌زمان مطالعه با این ماهواره به میزان محدود بوده است (Sadeghi et al., 2017). اما پژوهش‌هایی مبنی بر استفاده از شاخص‌های طیفی مختلف حاصل از داده‌های سنتینل-۲ برای مدل‌سازی رطوبت سطحی خاک بسیار کم انجام شده است. (Tietje and Hennings, 1996) نشان دادند که انحرافات قابل توجهی بین مقادیر اندازه‌گیری و پیش‌بینی شده در همه PTFها که خواص هیدرولیکی خاک را تخمین می‌زنند وجود دارد؛ بنابراین، استفاده از روش‌هایی برای کاهش انحراف بین نتایج اندازه‌گیری و پیش‌بینی شده با استفاده از PTF مهم است. یک رویکرد برای دستیابی به این هدف، یافتن پیش‌بینی‌کننده‌های جدیدتر و مؤثرتر و روش‌های به‌روز و قابل‌اعتمادتر در توسعه PTF می‌باشد؛ بنابراین هدف از این مطالعه ایجاد مدل با روش‌های جدید و قابل‌اعتماد، برای کاهش انحراف بین نتایج اندازه‌گیری و پیش‌بینی شده رطوبت سطحی خاک در منطقه‌ای با اقلیم نیمه‌خشک با استفاده از شاخص‌های طیفی جدید (شاخص‌های رنگ خاک، شوری و حرارتی) که از ترکیب باندهای ماهواره سنتینل-۲ است، می‌باشد.

مواد و روش

مشخصات مورد مطالعه و برداشت نقاط نمونه

در پژوهش حاضر، ۱۲۴ نمونه خاک سطحی (۰ تا ۱۰ سانتی‌متر) از سه استان‌های تهران (تلو) (N ۳۵° ۴۷' - ۳۵° ۴۸' و E ۳۹° ۵۱' - ۳۷° ۳۷'، ۳۰ نمونه)، سمنان (ایوانکی) (N ۳۴° ۳۴' - ۳۵° ۲۸' و E ۳۷° ۵۱' - ۵۲° ۰۰'، ۴۰ نمونه) و لرستان (بروجرد) (N ۳۳° ۵۵' - ۳۳° ۴۵' و E ۳۳° ۱۲' - ۳۳° ۱۲'، ۵۴ نمونه) به‌صورت تصادفی با توزیع مناسب به‌طوری که نمایانگر خصوصیات عمومی منطقه باشد، نمونه‌برداری شده است. نمونه‌برداری بروجرد در ۲۰، ۲۱ و

کاهش اثر طرح‌های شناسایی میدانی بر محیط‌زیست بسیار مفید بوده است (Escorihuela and Quintana-Seguí., 2016).

توابع انتقالی (PTF) با استفاده از خصوصیات زود یافت خاک مانند بافت خاک، چگالی ظاهری، میانگین هندسی قطر ذرات، مقدار ماده آلی و انحراف استاندارد هندسی ذرات خاک ایجاد می‌شوند (Bouma, 1989). این امر به‌ویژه برای پارامترهایی که اندازه‌گیری آن‌ها سخت و زمان‌بر است مانند پلاستیسیته خاک (Al Masmoudi et al., 2021)، ماده آلی خاک (Keskin et al., 2019)، هدایت هیدرولیکی (Sedaghat et al., 2016)، جرم مخصوص ظاهری (Souza et al., 2016) و مقدار آب خاک (Santra et al., 2018) اهمیت زیادی دارد. مشکلات و پیچیدگی‌هایی که در تخمین رطوبت خاک که در بالا بیان شده است، منجر به استفاده از ابزارهای مدل‌سازی مبتنی بر داده، مانند شبکه‌های عصبی مصنوعی (ANN)، ماشین‌های بردار پشتیبانی (SVM)، و جنگل تصادفی (RF) برای پیش‌بینی رطوبت خاک شده است. داده‌کاوی^۱ یک تکنیک محبوب برای پیش‌بینی رطوبت خاک، ارائه تخمین‌هایی با وضوح‌های بالا با داده‌های سنجش‌ازدور می‌باشد که به طور مؤثر برای تخمین رطوبت خاک با استفاده از داده‌های سنجش‌ازدور در مناطق نیمه‌خشک استفاده شده است. (Bousbih et al., 2018)

(Sadeghi et al., 2017) با مدل حرارتی - بصری (OPTRAM) با استفاده از داده‌های حاصل از ماهواره سنتینل-۲ و لندست-۸ با استفاده از شاخص‌های دمای سطح زمین - پوشش گیاهی^۲ (LST-VI) رطوبت سطح خاک را برآورد نمودند. این محققان نشان دادند که این مدل برای هر مکان خاص نیاز به پارامتر واحدی دارد که می‌تواند راه پیشرفت قابل توجهی را در برآورد رطوبت خاک از طریق سنجش‌ازدور فراهم نماید. (Xia et al., 2019) از دو روش برای برآورد رطوبت سطحی خاک استفاده نمودند. این دو روش شامل استفاده از شاخص دما، پوشش گیاهی و خشکی (TVDI)^۴ (ترکیب شاخص‌های NDVI/LSD) و استفاده از مدل مثلثی (استفاده از معادله چندجمله‌ای درجه دوم) بود. آنها گزارش کردند هر دوی این روش‌ها به‌خوبی توانستند رطوبت سطحی خاک را برآورد نمایند. (Adab et al., 2020) از ماشین یادگیری برای تخمین رطوبت سطح خاک با استفاده از داده‌های لندست استفاده کرد و مقادیر اندازه‌گیری با مقادیر تخمینی حاصل از روش RF، SVM و ANN مطابقت داشت. (Ahmad et al., 2010) با استفاده از شاخص

۴. Temperature and Drought of Vegetation Index

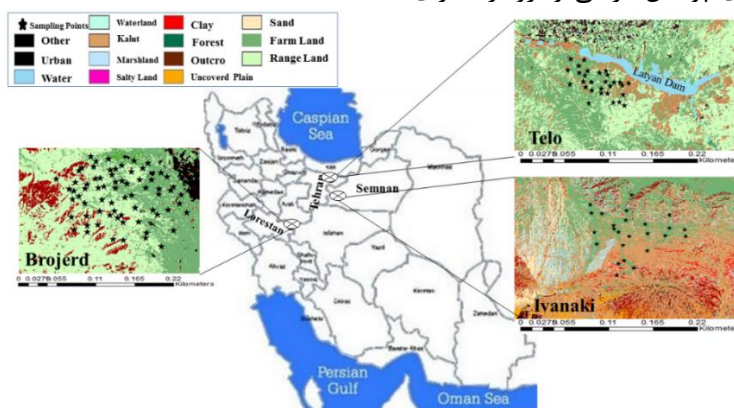
۱. Data mining

۲. Optical TRapezoid Model

۳. Land Surface Temperature- Vegetation Index

پوشش دیم گندم و جو است. شکل ۱ نقشه پوشش زمین این سه منطقه را نشان می‌دهد. نقشه پوشش زمین با پردازش تصاویر سنتینل ۲- در پلت فرم Google Earth Engine ایجاد شد. برای این منظور، تصاویر سنتینل ۲- با روش طبقه‌بندی جنگل تصادفی شیء‌گرا (RF) طبقه‌بندی شده‌اند. همان‌طور که در شکل ۱ مشاهده می‌شود، نمونه‌ها از زمین‌های زراعی و مرتعی با پوشش گیاهی (قسمت‌های سبز نقشه) گرفته شده است.


۲۲ اردیبهشت، در جنگل تلو در تاریخ ۳۱ اردیبهشت و ۵ خرداد، و در ایوانکی در ۲۰ خرداد سال ۱۳۹۸ انجام شده است. افق‌های مشخصه سطحی و تحت‌الارضی سه منطقه مشابه بودند به طوری که افق سطحی هر سه منطقه Ochric و افق تحت‌الارضی آن‌ها Cambic و Calcic شناسایی شد. بر اساس طبقه‌بندی تاکسونومیکی به روش Key to Soil Takonomy, (2006) که با طبقه‌بندی FAO (1989) مطابقت دارد، خاک‌های این مطالعه به دو گروه Entisols و Inceptisols تقسیم شدند. پوشش گیاهی منطقه تلو جنگلی و مرتعی، ایوانکی دارای پوشش مرتعی و بروجرد دارای



شکل ۱- نقشه پوشش گیاهی مناطق مورد مطالعه

برای اندازه‌گیری جرم مخصوص ظاهری خاک از روش سیلندر (Grossman & Reinsch., 2002) استفاده شد (جدول ۱). وضعیت توزیع اندازه ذرات نمونه خاک، بر اساس مثلث بافت خاک USDA انجام شد (شکل ۲)، بر اساس این مثلث، نمونه‌های خاک این پژوهش از ۱۲ کلاس بافتی که وجود دارد شامل ده کلاس بافتی است و دو کلاس بافتی شنی و سیلت را ندارد.

اندازه‌گیری‌های آزمایشگاهی بعد از انتقال نمونه‌های خاک به آزمایشگاه بلافاصله اقدام به اندازه‌گیری رطوبت خاک به صورت وزنی شد و سپس به رطوبت حجمی تبدیل گردید (Gardner, 1986). بعد از انجام عملیات آماده‌سازی نمونه‌های خاک، برای اندازه‌گیری بافت خاک (درصد رس، سیلت و شن) از روش هیدرومتر (Gee and Or, 2002) و



شکل ۲- توزیع اندازه ذرات خاک بر اساس مثلث بافت خاک USDA

طول موج الکترومغناطیسی، باندهای تصویر سنتینل ۲-، به طور مجزا به عنوان ویژگی استخراجی از تصویر انتخاب شدند و کارکرد آن‌ها در تخمین رطوبت سطحی خاک مورد بررسی قرار گرفت.

داده‌های ماهواره‌ای

تجزیه و تحلیل داده‌های سنتینل ۲- در این پژوهش برای بررسی بازتاب طیفی سطح خاک در گستره

تا ۳، نمایش داده شده است.

$$L_{\lambda} = M_L \times Q_{cal} + A_L - O_i \quad (\text{رابطه ۱})$$

$$BT = \frac{K_2}{\ln[(K_1/L_{\lambda}) + 1]} - 273.15 \quad (\text{رابطه ۲})$$

$$T_s = \frac{BT}{\left\{1 + \left[(\lambda BT / \rho) \ln \varepsilon_{\lambda} \right] \right\}} \quad (\text{رابطه ۳})$$

در این رابطه L_{λ} رادیانس طیفی بالای اتمسفر، M_L ضریب کسب باند مربوطه، Q_{cal} عدد رقومی باند ۱۰ تصویر لندست-۸، A_L ضریب بایاس باند ۱۰ و O_i ضریب تصحیح برای باند ۱۰ تصویر می‌باشد. این اطلاعات در فایل هدر^۳ تصویر موجود است. همچنین BT ضرایب ثابت، $\rho \approx 1.438 \times 10^{-2} \text{mk}$ و ε_{λ} ضریب گسیل است.

شاخص‌های طیفی با استفاده از نرم‌افزار SNAP8 محاسبه شدند (جدول ۱) و در نرم‌افزار ArcMap 10.7 برای خروجی داده‌ها استفاده شدند.

گام‌های ساخت توابع انتقالی

فرضیه‌های پیش‌پردازش و رگرسیون داده‌ها، از جمله تشخیص داده‌های پرت‌ها^۴، آزمون نرمال کردن داده‌ها، بررسی چند خطی بودن برای همه متغیرها اعمال شد (Berry, 1993). برخی اوقات در میان داده‌های پژوهشی، اعداد غیرمنتظره بسیار بزرگ یا کوچک وجود دارد که داده پرت نامیده می‌شوند که ممکن است ناشی از خطاهای اندازه‌گیری یا نقص ابزارها باشد. بنابراین پژوهشگران در مطالعات خود باید وجود داده‌های پرت را در نظر بگیرند و آن‌ها را اصلاح یا توجیه نمایند. برای جلوگیری از تأثیرپذیری فاصله بین داده‌ها (فاصله بین بزرگ‌ترین و کوچک‌ترین داده) می‌توان از روش "دامنه میان چارکی (IQR)"^۵ (Seo, 2006) استفاده کرد. چارک داده‌ها را به چهار قسمت مساوی تقسیم می‌کند؛ هر بخش شامل ۲۵ درصد داده‌ها است. روش IQR بیان‌کننده فاصله بین چارک اول و چارک سوم است. برای محاسبه چارک اول یا مقادیر آستانه پایین از فرمول (انحراف استاندارد $2 \times$ - میانگین)، و چارک سوم یا مقادیر آستانه بالا از فرمول (انحراف استاندارد $2 \times$ + میانگین) استفاده می‌شود (Seo, 2006)؛ بنابراین مقادیر کوچک‌تر از آستانه پایین و مقادیر بزرگ‌تر از آستانه بالا به‌عنوان داده‌های پرت شناخته می‌شوند و باید حذف شوند. آزمون نرمال بودن متغیرها با روش کلمگوروف-اسمیرنوف با نرم‌افزار Minitab انجام شد. جدول ۳، وضعیت نرمال

ماهواره سنتینل ۲- دارای وضوح مکانی بالا (۱۰ تا ۶۰ متر) و زمانی (۵ روز)، و دارای ۱۳ باند طیفی که حوزه‌های فرکانس الکترومغناطیسی VIS، NIR و SWIR را شامل می‌شود، و عرض باندها حدود ۲۹۰ کیلومتری می‌باشد (ESA, 2017). سنتینل ۲- دارای ۴ باند ده متری (B2, B3, B4 و B8)، شش باند بیست متری (B5, B6, B7, B8a, B11 و B12) و سه باند ۶۰ متری (B1, B9 و B10) می‌باشد. همچنین شاخص‌های شوری و رنگ خاک متنوعی که بر اساس نتایج مطالعات پیشین عملکرد مطلوبی در تخمین خصوصیات خاک داشتند انتخاب و محاسبه شدند. در این پژوهش از آژانس فضایی اروپا (<https://scihub.copernicus.eu/>) برای دستیابی به تصاویر ماهواره سنتینل ۲-، محصولی با درجه پردازش L2A (محصول Level-2A را نیز می‌توان مستقیماً از ESA از دسامبر ۲۰۱۸ دریافت کرد) که تصویر قائمی می‌باشد و تصحیح اتمسفری بر روی آن انجام شده و نمایانگر بازتابش پایین اتمسفر^۱ می‌باشد، استفاده شده است. برداشت این تصاویر عمدتاً با زمان نمونه‌برداری مطابقت دارد و تصاویری که درصد پوشش ابر کم باشد انتخاب شده است. برای تصاویر level-2A یک ضریب مقیاس ساده ۰/۰۰۱ اعمال شد (Sadeghi et al., 2017). سپس تمام باندها با روش نزدیک‌ترین همسایه^۲ با استفاده از نرم‌افزار SNAP به ۲۰ متر تبدیل شده‌اند (Chen et al., 2020). بدیهی است که در مقایسه با اندازه‌گیری‌های زمینی، تصاویر ۲۰ متری سنجش‌ازدور جزئیات مکانی بیشتری را در تخمین رطوبت سطحی و شناسایی الگوهای مکانی ارائه می‌کنند (Adab et al., 2020). با در نظر گرفتن زمان‌های نمونه‌برداری، از سه تصویر درصد ابری کم استفاده شده است.

تجزیه و تحلیل داده‌ها و تصاویر لندست-۸

ماهواره سنتینل ۲-، فاقد باند حرارتی می‌باشد. در این پژوهش برای به‌دست‌آوردن شاخص حرارتی (LST) از تصاویر حاصل از ماهواره لندست ۸- مطابق زمان‌های نمونه‌برداری استفاده شده است. پیش‌پردازش تصویر ماهواره لندست ۸- نیز برای باند حرارتی با اعمال تصحیحات رادیومتریکی و اتمسفری با تبدیل عدد رقومی تصویر به تابندگی سطح و سپس تبدیل تابندگی سطح به دمای ظاهری مطابق با روش (Avdan and Jovanovska, 2016) با پلت فرم Google Earth Engine انجام شده است. چگونگی محاسبه دمای سطح خاک از باند حرارتی لندست ۸- در روابط ۱

۴. Outlier data

۵. InterQuartile Range

۱. Bottom Of Atmosphere (BOA)

۲. Nearest neighbor

در فایل‌های گرافیکی یا همان تصاویر، هدر شامل اطلاعاتی مانند Header file: ۳. اندازه تصویر، تعداد رنگ‌ها، وضوح و غیره می‌باشد.



در این رابطه منظور از R^2_i ضریب تعیین مدل (R Square) مدل رگرسیونی روی متغیر توصیفی i ام به عنوان متغیر پاسخ با متغیرهای توصیفی دیگر به عنوان متغیرهای مستقل است. در این پژوهش ۶۵ درصد داده‌ها برای مرحله آموزش و ۳۵ درصد از داده‌ها برای مرحله آزمون انتخاب شده است. ورودی هر مدل را بر اساس ماهیت شاخص‌ها، در دسترس بودن داده‌ها و همبستگی ورودی‌های با خروجی مدل انتخاب شد. مدل‌سازی رطوبت در این پژوهش بر اساس شاخص‌های طیفی رنگ خاک، شوری، دما و خصوصیات پایه-ای خاک به چهار گروه تقسیم شده است (جدول ۲).

بودن پارامترهای به کار برده شده در این پژوهش را نشان می‌دهد. فرض صحت رگرسیون خطی، بررسی هم‌راستایی بین متغیرهای مستقل است. در این پژوهش برای این که مشکل هم‌راستایی ایجاد نشود از نسبت سیلت به شن بهره‌گیری شد. همچنین در تمام توابع ایجاد شده این مسئله از طریق آماره فاکتور تورم واریانس (VIF) بررسی شد. متغیرهایی که VIF آن‌ها کمتر از ۱۰ باشد مشکل هم‌راستایی نخواهند داشت (Hocking 2013). که در این پژوهش VIF تمام ورودی‌ها با SPSS.26 بررسی شد (نتایج نشان داده نشده است). VIF از فرمول زیر محاسبه می‌شود:

$$VIF = \frac{1}{1 - R_i^2} \quad (\text{رابطه ۴})$$

جدول ۱- علائم اختصاری پارامترها و روش اندازه‌گیری آن‌ها

ردیف	علائم اختصاری	شاخص طیفی	نسبت طیفی	رفرنس
۱	BI	شاخص درخشندگی	$BI = \sqrt{(Red^2 + NIR^2)}$	Mandal, 2016
۲	CI	شاخص رنگ	$CI = \frac{Red - Green}{Red + Green}$	Mandal, 2016
۳	SI1	شاخص شوری ۱	$SI1 = \frac{Red \times NIR}{Green}$	Abbas and Khan, 2007
۴	SI2	شاخص شوری ۲	$SI2 = \frac{Red \times Blue}{Green}$	Abbas and Khan, 2007
۵	SI3	شاخص شوری ۳	$SI3 = \frac{Blue - Red}{Blue + Red}$	Abbas and Khan, 2007
۶	SI4	شاخص شوری ۴	$SI4 = \sqrt{(Red^2 + Green^2)}$	Douaoui et al., 2006
۷	SI6	شاخص شوری ۶	$SI6 = \sqrt{Red \times Blue}$	Abbas and Khan, 2007
۸	SI7	شاخص شوری ۷	$SI7 = \frac{Blue}{Red}$	Abbas and Khan, 2007
۹	NDSI	شاخص تفاضلی نرمال شده شوری	$NDSI = \frac{Red - NIR}{NIR + Red}$	and Kumar, 2013 Allbed
۱۰	LST	دمای سطح	-	Avdan and Jovanovska, 2016
۱۱	SM	رطوبت خاک	-	Gardner, 1986
۱۲	Si/Sa	نسبت سیلت به شن	-	Gee and Or, 2002
۱۳	C	درصد رس	-	Gee and Or, 2002
۱۴	BD	جرم مخصوص ظاهری	-	Grossman and Reinsch, 2002
۱۵	OM	ماده آلی	-	Nelson and Sommers, 1983
۱۶	CaCO ₃	کربنات کلسیم	-	Sims, 1996
۱۷	EC	قابلیت هدایت الکتریکی	-	Rhoades, 1996
۱۸	pH	پهاش خاک	-	McLean, 1983

جدول ۲- پارامترهای ورودی در ایجاد توابع انتقالی

توابع	گروه	شاخص‌های	ورودی‌ها*
PTF ₁	گروه اول	خصوصیات پایه‌ای خاک	C+Si/Sa
PTF ₂			C+Si/Sa+ BD
PTF ₃	گروه دوم	شاخص‌های طیفی خاک	C+Si/Sa+ BD+CI
PTF ₄			C+Si/Sa+ BD+BI

C+Si/Sa+ BD+BI+CI			PTF ₅
C+Si/Sa+ BD+SI2+SI4+SI6			PTF ₆
C+Si/Sa+ BD+SI1+SI3+SI7+NDSI	شاخص‌های طیفی شوری	گروه سوم	PTF ₇
C+Si/Sa+ BD+LST	شاخص طیفی حرارتی	گروه چهارم	PTF ₈

* SM: رطوبت سطحی خاک؛ BD: جرم مخصوص ظاهری خاک؛ Si/Sa: نسبت سیلت به شن؛ C: درصد رس؛ BI: شاخص درخشندگی؛ CI: شاخص رنگ؛ SI2, SI1, SI3, SI4, SI6, SI7 و SI8: شاخص‌های طیفی شوری؛ NDSI: شاخص تفاضلی نرمال شده شوری؛ و LST: شاخص طیفی دمای سطحی.

کرنل خطی، چندجمله‌ای، شعاعی و حلقوی است. در این پژوهش، روش SVM با نرم‌افزار STATISTICA12 انجام و برازش در ۱۰۰۰ تکرار تنظیم شده است. رگرسیون بردار پشتیبان دارای پارامترهای تنظیم‌کننده شامل C و nu هسته است. در این پژوهش نوع کرنل، از هسته تابع پایه شعاعی (RBF) استفاده شده که شامل پارامتر گاما (γ) است. در روش SVM پارامترها و هسته مورد استفاده بایستی بهینه شود در غیر این صورت دقت مطلوب حاصل نمی‌گردد. اگر پارامتر C مقدار بزرگی باشد، دقت در مرحله آموزش بالاست درحالی‌که معمولاً در مرحله آزمون دقت پایین می‌آید. اگر پارامتر C مقدار کوچک باشد، دقت نامطلوب است و مدل را بی‌اعتبار می‌کند. پارامتر هسته گاما (γ) معمولاً تأثیر بیشتری نسبت به پارامتر C، بر نتیجه مدل‌سازی دارد. اگر مقدار پارامتر C بزرگ انتخاب شود منجر به بیش‌برازشی می‌شود، درحالی‌که مقدار کوچک آن منجر به کم‌برازشی می‌شود. هرچه مقدار پارامتر nu بیشتر باشد تعداد بردارهای پشتیبان کمتر و دقت تخمین کمتر می‌شود (Vapnik, 2000).

آماره‌های ارزیابی توابع انتقالی

در پایان برتری و صحت هر یک از مدل‌ها بر پایه آماره‌های ضریب تعیین R^2 ، مجذور میانگین خطا ($RMSE^4$)، معیار اطلاعات آکائیک، ضریب بهبود نسبی (RI^5) و میانگین خطای اریب (MBE^6) ارزیابی شد:

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N}} \quad (\text{رابطه ۵})$$

$$AIC = \ln N \left[\sum_{i=1}^N \frac{(y_i - \hat{y}_i)^2}{N} \right] + 2n_p \quad (\text{رابطه ۶})$$

$$RI = \frac{RMSE_1 - RMSE_i}{RMSE_1} \times 100 \quad (\text{رابطه ۷})$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (\hat{y}_i - \bar{y}_i)^2} \quad (\text{رابطه ۸})$$

شبکه عصبی مصنوعی (ANN)

مدل‌سازی رطوبت سطحی خاک با دو نوع شبکه عصبی مصنوعی شامل پرسپترون چندلایه (MLP)^۱ و تابع پایه شعاعی (RBF)^۲، انجام شد. در این پژوهش روش ANN با استفاده از نرم‌افزار STATISTICA12 انجام شده است. شبکه نوع MLP به طور معمول در مدل‌سازی زیست‌محیطی و علوم خاک استفاده می‌شود (Agyare et al., 2007) و اساس نوع RBF توسط Picton (2000) و Hagan et al., (1996) توضیح داده شده است. این پژوهشگران گزارش کردند، ورودی شبکه عصبی از نوع RBF نسبت به نوع MLP متفاوت است. برای کاهش خطا در مدل‌سازی، شبکه عصبی در ۱۰۰ تکرار تنظیم شده است. میانگین ۵۰ خروجی از ۱۰۰ تکرار که خطای کمتری دارند، به‌عنوان خروجی نهایی شبکه عصبی مرکب (استفاده از هر دو نوع شبکه)، برای تخمین رطوبت سطحی خاک انتخاب شد.

رگرسیون بردار پشتیبان (SVM)

رگرسیون بردار پشتیبان، روش بسیار کارا و مفید برای حل مسائل داده مبنای است که میان داده‌های ورودی و خروجی رابطه برقرار می‌کند (Gill et al., 2007). این روش همچنین یک روش طبقه‌بندی دودویی^۳ است که با تعیین یک صفحه تفکیک‌کننده بهینه در فضای داده‌های آموزشی، کلاس‌های مختلف را با حداکثر جدایی بین آن‌ها، تفکیک می‌کند. فرا صفحه‌ای که حداکثر حاشیه را بین دو کلاس فراهم می‌نماید، فرا صفحه بهینه و داده‌های نزدیک‌تر به فرا صفحه، بردارهای پشتیبان نامیده می‌شوند (Petropoulos et al., 2010). از جمله قابلیت‌های ماشین بردار پشتیبان، توانایی غلبه بر مشکل توزیع غیرخطی داده‌های آموزشی است. در این حالت با استفاده از توابع کرنل، داده‌ها به فضایی با بعد بزرگ‌تر انتقال می‌یابند که در آن تفکیک‌پذیری بهتر انجام می‌شود (Shanani Hoveyze and Heidar., 2015). جذابیت ماشین‌های بردار پشتیبان در قابلیت آن‌ها در حداقل کردن ریسک ساختاری یا خطای طبقه‌بندی هنگام حل مسئله طبقه‌بندی است (Aslami et al., 2015). این روش دارای چهار نوع کرنل شامل

۴ Root mean square error

۵ Relative improvement

۶ Mean Bias Error

1. Multilayer perceptron's

2. Radial basis function

3. Binary

۵۶- ۰/۶ است. هنگامی که تغییرات پارامترهای ورودی و خروجی زیاد باشد، نشان‌دهنده این است که قابلیت تعمیم‌پذیری مدل افزایش و هنگامی که تغییرپذیری کم است، قابلیت تعمیم‌پذیری آن نیز کاهش می‌یابد. به‌منظور نشان‌دادن پراکندگی نسبی داده‌ها به میانگین، از ضریب تغییرات (CV) استفاده می‌شود. ضریب تغییرات (CV) برای رطوبت خاک حدود ۴۹-۵۱ درصد می‌باشد، که نشان می‌دهد رطوبت خاک در مجموعه داده‌ها، پراکندگی متوسطی در اطراف مقادیر میانگین دارد؛ بنابراین نقاط نمونه‌برداری به‌طور نسبی مقادیر مختلف رطوبت خاک (از مقادیر کم تا زیاد) را پوشش می‌دهد (Adab et al., 2020).

بهره‌گیری از توابع انتقالی در محدوده داده‌های به‌کارگرفته‌شده برای آموزش بادقت بیشتری همراه خواهد بود (Ungaro et al., 2005). چون انتخاب داده‌ها برای آموزش و آزمون به‌صورت تصادفی انجام شد، محدوده تغییرات و میانگین متغیرها برای داده‌های آموزش و آزمون مشابه است.

بررسی همبستگی بین کلیه پارامترهای بهره‌گیری شده در این مطالعه

عموماً متداول‌ترین نمایه برای بیان همبستگی بین متغیرهای دارای اندازه‌های مقیاس فاصله‌ای و نسبی استفاده از ضریب همبستگی پیرسون^۲ است که در این پژوهش از آن استفاده شده است. ضریب همبستگی پیرسون بین متغیرهای به‌کاررفته در PTFها برای داده‌های آموزش و آزمون بررسی شد (جدول ۴). همبستگی بین ویژگی‌های خاک نشانه‌ای از ارتباط بین آن‌ها می‌باشد که برای ایجاد PTFها ضروری است. رطوبت سطحی خاک همبستگی منفی و معنی‌داری ($P < 0.01$) با درصد رس و جرم مخصوص ظاهری، و رابطه مثبت و معنی‌دار ($P < 0.01$) با نسبت Si/Sa دارد (جدول ۴). محققانی مانند (Rastgu et al., 2020) نتایج معکوس را گزارش کردند. این‌گونه به نظر می‌رسد که علت متفاوت بودن نتایج این پژوهش با نتایج سایر محققان، تفاوت در نحوهٔ نرمال کردن درصد رس خاک باشد. به‌عنوان مثال، در پژوهش (Rastgu et al., 2020) مقدار رس با لگاریتم نرمال شده است ولی در این پژوهش با فرمول $(\sqrt{10} * (65.5 - C))$ نرمال شده است. در تحقیق حاضر همبستگی بین رطوبت خاک با داده‌های خام رس نیز بررسی شده است (نتایج آورده نشده

$$MBE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i) \quad (\text{رابطه ۹})$$

در رابطه‌های ۹-۵، n تعداد داده‌ها، y_i : میانگین داده‌های اندازه‌گیری شده، \hat{y}_i : میانگین داده‌های تخمین زده شده توسط مدل و \bar{y} : میانگین رطوبت سطحی خاک می‌باشد. دقت تخمین وقتی بالاتر است که مقدار RMSE پایین‌تر باشد. اختلاف بین مقادیر اندازه‌گیری و تخمینی با آماره RMSE مشخص می‌شود (Adab et al., 2020). هرچه AIC کوچکتر باشد کیفیت برازش بالاتر است (Akaike, 1974). اگر انطباق کامل مقادیر مشاهده‌ای و برآوردی رخ دهد AIC به سمت منفی بی نهایت میل خواهد کرد. روش مقایسه با بهره‌گیری از آماره AIC به این گونه می‌باشد که نخست یکی از مدل‌ها به‌عنوان مدل پایه گزینش می‌شود و مدل‌های دیگر نسبت به آن سنجیده می‌شوند. اندازه AIC برای مدل پایه و مدل‌های دیگر تعیین می‌شود. اگر اندازه آماره آکائیک مدل مقایسه شونده با مدل پایه از ۹۵٪ اندازه آکائیک به‌دست آمده برای مدل پایه کمتر باشد، به این معنی است که مدل مقایسه شونده با اطمینان ۹۵ درصد بهتر از مدل پایه است و در غیر این صورت مدل پایه ترجیح داده می‌شود (Hwang et al., 2002). در فرمول ضریب بهبود نسبی، RMSE1: مجذور مربعات خطای مدل پایه، RMSEi: مجذور میانگین خطای مدل مورد نظر است. MBE عمدتاً برای نشان دادن اریب در مدل مورد استفاده قرار می‌گیرد و مقدار مثبت آن نشان دهنده بیش‌برآوردی و مقدار منفی آن کم‌برآوردی را در تخمین رطوبت خاک را نشان می‌دهد (Gopinathan, 1988).

نتایج و بحث

توصیف آماری

توصیف آماری ویژگی‌های فیزیکی و شیمیایی خاک و شاخص‌های طیفی برای مجموعه داده‌های به کار برده شده در این پژوهش در جدول ۳ آورده شده است. در این پژوهش تخمین رطوبت خاک با داده‌های نرمال انجام شده است. این جدول شامل تمام متغیرهایی است که مستقیماً اندازه‌گیری شده و یا از باندهای ماهواره سنتینل ۲ و لندست ۸ محاسبه گردیدند. کلیه ویژگی‌های خاک که در ارتباط با بافت و ساختمان خاک هستند دارای دامنه تغییرات بالایی می‌باشند. به‌عنوان مثال دامنهٔ داده‌های خام درصد سیلت، شن و رس به ترتیب برابر با ۵۸-۱۱/۲۳، ۱۷/۸۸-۴ و

Zhang et al., 2013). باتوجه به پژوهش‌های (Zhang et al., 2013) باندهای جذب آب در محدوده طول موج VIS نسبت به طول موج‌های دیگر حساسیت شدیدتری به تغییرات رطوبت دارد، اما در محدوده طول موج NIR حساسیت ضعیف‌تر دارد. از این رو، استفاده از ترکیب باندهای VIS و NIR می‌تواند به طور مؤثر اثرات پراکندگی تک باندها را کاهش داده و تغییرات رطوبت برگ‌های گیاهان را راحت‌تر نشان می‌دهد.

است)، نتایج نشان داد که بین رطوبت خاک و داده‌های خام رس همبستگی مثبت و معنی‌داری (۰/۷۴) وجود دارد. باتوجه به جدول ۴، رطوبت سطحی خاک بیشترین همبستگی منفی و معنی‌دار (۰/۷۳-) را با درصد رس خاک دارد. رطوبت خاک رابطه معنی‌دار و قوی ($P < 0.01$) با همه شاخص‌های طیفی دارد (جدول ۴). همان‌طور که در جدول ۱ نشان داده شده است، این شاخص‌های طیفی ترکیبی از طیف طول موج‌های VIS و NIR هستند (Zhang

جدول ۳- ویژگی‌های آماری خصوصیات فیزیکی و شیمیایی خاک و شاخص‌های طیفی برای ۱۲۴ نقطه نمونه برداری

بیشینه	کمینه	CV (%)	انحراف استاندارد	میانگین	سازی فرمول نرمال	پارامترها ^a
۰/۲۵	۰/۰۲	۵۳	۰/۰۶	۰/۱۲	-	SM ($\text{cm}^3\text{cm}^{-3}$)
۵۸	۱۱/۲۳	۲۶	۱۰/۱۵	۳۹/۶۱	-	Si (%)
۲۲/۰۸	۴/۴۷	۲۵	۳/۵۳	۱۳/۸۴	Sqrt ($10 * (60 - \text{Si})$)	Si* (%)
۵۶	۰/۶	۴۶	۱۳/۶۹	۲۹/۶۳	-	C (%)
۲۵/۴۸	۹/۷۵	۲۰	۳/۷۱	۱۸/۵۸	Sqrt ($10 * (65.5 - C)$)	C* (%)
۸۸/۱۷	۴	۶۸	۲۱/۰۷	۳۰/۷۷	-	Sa (%)
۴/۴۹	۱/۵۹	۲۳	۰/۷۴	۳/۲۱	Log (Sa + 0.9)	Sa* (%)
۷/۰۹	۲/۳۲	۲۰	۰/۸۹	۴/۳۸	-	Si/Sa
۰/۶۲	۰/۵۱	۴	۰/۰۲	۰/۵۷	-	BD (gr cm^{-3})
۵/۶۰	۰/۱۵	۸۲	۰/۹۹	۱/۲۰	-	EC (mS cm^{-1})
۱/۷۲	-۱/۹۲	-۶۹۶	۰/۷۹	-۰/۱۱	Log (EC)	EC* (mS cm^{-1})
۸/۹۲	۷/۳۹	۵	۰/۴۰	۸/۰۶	-	pH
۴/۲۹	۰/۲۵	۵۸	۰/۸۶	۱/۴۸	-	OM (%)
۱/۴۶	-۱/۳۸	۲۰۳	۰/۵۲	۰/۲۶	Log (OM)	OM* (%)
۴۴/۵۰	۰/۶۰	۴۰	۸/۹۱	۲۲/۵۵	-	CaCO ₃ (%)
۴۶/۵۸	۱/۱۳	۴۳	۱۱/۸۲	۲۷/۴۷	-	LST
۰/۱۷	-۰/۲۳	۳۸۹	۰/۰۹	۰/۰۲	-	CI
۰/۲۸	۰/۰۶	۳۶	۰/۰۵	۰/۱۴	-	BI
۰/۵۳	۰/۲۵	۱۸	۰/۰۷	۰/۳۷	Sqrt (BI)	BI*
۰/۴۵	۰/۲۴	۱۳	۰/۰۴	۰/۳۴	-	SI1
۰/۲۸	۰/۰۲	۴۸	۰/۰۵	۰/۱۱	-	SI2
-۰/۰۸	-۰/۳۶	-۲۳	۰/۰۵	-۰/۲۴	-	SI3
۰/۴۰	۰/۰۸	۳۶	۰/۰۷	۰/۲۰	-	SI4
۰/۶۳	۰/۲۹	۱۸	۰/۰۸	۰/۴۴	Sqrt (SI4)	SI4*
۰/۲۰	-۱/۰۸	-۲۳۱۴	۰/۲۶	-۰/۰۱	-	SI6
۰/۸۵	۰/۴۷	۱۱	۰/۰۷	۰/۶۲	-	SI7
-۱/۳۹	-۲۰/۱۱	-۵۱	۳/۶۴	-۷/۰۶	-	NDSI

EC: قابلیت هدایت الکتریکی؛ OM: درصد ماده آلی؛ CaCO₃: کربنات کلسیم؛ pH: پ‌هاش خاک؛ SM: رطوبت سطحی خاک؛ BD: جرم مخصوص ظاهری خاک؛ Si/Sa: نسبت سیلت به شن؛ C: درصد رس؛ BI: شاخص درخشندگی؛ CI: شاخص رنگ؛ SI1, SI2, SI3, SI4, SI6 و SI7: شاخص‌های طیفی شوری؛ NDSI: شاخص تفاضلی نرمال شده شوری؛ و LST: شاخص طیفی دمای سطحی.

*نشان دهنده فرم نرمال پارامترها است (ستاره نشان دهنده این است که داده خام آن پارامتر نرمال نبوده است و با روش‌های نرمال‌سازی نرمال شده است).

(2015) گزارش کردند مقدار رس، شن و سیلت خاک به طور معنی داری ($p < 0.01$) با مقادیر بازتاب طیفی در طول موج‌های مربوط به مقادیر محتوای آب ارتباط داشتند.

سه پارامتر درصد رس، نسبت سیلت به شن و جرم مخصوص ظاهری تقریباً با اکثر شاخص‌های طیفی (به جز SI3 و SI7) همبستگی معنی‌داری دارند (جدول ۴). (Babaeian et al.,

جدول ۴- ضرایب همبستگی ساده بین خصوصیات ورودی مدل با رطوبت سطحی خاک

NDSI	SI7	SI6	SI4	SI3	SI2	SI1	BI	CI	LST	BD	Si/Sa	C	SM*
۰/۲۶**	۰/۲۴**	۰/۵۵**	-۰/۶۰**	۰/۲۴**	-۰/۵۱**	-۰/۳۶**	-۰/۶۴**	-۰/۶۴**	-۰/۴۹**	-۰/۳۷**	۰/۳۰**	-۰/۷۳**	۱
-۰/۲۵**	-۰/۱۱	-۰/۴۰**	۰/۵۴**	-۰/۰۹	۰/۵۰**	۰/۳۱**	۰/۵۵**	۰/۴۶**	۰/۶۳**	۰/۳۰**	-۰/۵۷**	۱	-۰/۷۲**
۰/۱۵	۰/۱۴	۰/۱۴	-۰/۳۰**	۰/۱۴	-۰/۳۳**	-۰/۲۳**	-۰/۳۵**	-۰/۲۶**	-۰/۴۲**	-۰/۱۱	۱	-۰/۵۷**	۰/۳۰**
-۰/۲۸**	-۰/۰۵	-۰/۶۵**	۰/۳۹**	-۰/۰۴	۰/۴۵**	۰/۲۴**	۰/۴۵**	۰/۲۴**	۰/۴۱**	۱	-۰/۱۱	۰/۳۰**	-۰/۳۷**

SM*: رطوبت سطحی خاک؛ BD: جرم مخصوص ظاهری خاک؛ Si/Sa: نسبت سیلت به شن؛ C: درصد رس؛ BI: شاخص درخشندگی؛ CI: شاخص رنگ؛ SI2, SI1, SI3, SI4, SI6 و SI7: شاخص‌های طیفی شوری؛ NDSI: شاخص تفاضلی نرمال شده شوری؛ و LST: شاخص طیفی دمای سطحی.

می‌باشد. باتوجه به پژوهش‌هایی که انجام شده است (Bayat et al., 2021; Twarakavi et al., 2009)، مقادیر پارامترهای روش SVM در محدوده مناسب قرار دارد، که احتمالاً در تخمین رطوبت سطحی خاک خطای قابل توجهی ایجاد نکرده و در اکثر توابع انتقالی ایجاد شده در این پژوهش، رطوبت سطحی خاک را به طور معنی‌داری برآورد کرده است.

جدول ۶ و ۷ نتایج مدل‌سازی رطوبت سطحی خاک با استفاده از روش‌های ANN و SVM را نشان می‌دهند. ردیف‌های آخر جدول ۶ و ۷ حداقل، حداکثر و میانگین هر ۱۲ مرحله برای دو روش بکار رفته در این پژوهش نشان داده است. مشاهده می‌شود در هر دو مرحله آموزش و آزمون میانگین RMSE و AIC روش ANN نسبت به روش SVM کمتر است.

باتوجه به جدول ۶ و ۷، مشاهده می‌شود که در روش ANN، در مرحله آموزش ۱۰۰٪ و در مرحله آزمون ۸۸٪ توابع نسبت به سطح اول، رطوبت سطحی خاک را به صورت معنی‌دار تخمین زده‌اند (جدول ۶). همچنین در روش SVM، در مرحله آموزش ۸۸٪ و در مرحله آزمون ۶۳٪ توابع نسبت به سطح اول (جدول ۷)، رطوبت سطحی خاک را به صورت معنی‌دار تخمین زده‌اند؛ بنابراین نتیجه می‌گیریم در این پژوهش نتایج روش ANN نسبت به روش SVM بهتر بوده است. پژوهش‌های بسیاری عملکرد روش ANN و SVM را ارزیابی و گزارش کردند که عملکرد روش SVM بهتر از سایر روش‌ها است (Holtgrave et al., 2018; Noroozi Angnaei et al., 2017). Adab (2015) از عوامل حرارتی، توازن انرژی و پوشش گیاهی جهت تخمین رطوبت سطحی خاک استفاده کردند. نتایج این پژوهش نشان داد که متوسط درصد خطای مطلق برای روش رگرسیون خطی چند متغیره و شبکه عصبی به ترتیب ۴۰ درصد و ۳۰ درصد خطا بود که نشان‌دهنده کارایی مناسب مدل پیشنهادی روش شبکه عصبی است. از طرفی محققانی مانند Lafdani et al., (2013) عملکرد بالای دو روش ANN و SVM را گزارش کردند. در این پژوهش هر دو روش ANN و SVM توانستند رطوبت خاک به طور معنی‌داری تخمین بزنند ولی دقت

در جدول ۴ مشاهده می‌شود رطوبت سطحی خاک با دمای سطح خاک همبستگی منفی و معنی‌داری (-۰/۴۹) دارد. دمای سطح خاک یک عامل موثر در رطوبت سطحی خاک است. Adab (۲۰۱۵) در پژوهش خود نشان داد که با افزایش دما، آب نگهداری شده در داخل منافذ ذرات سطح خاک به طور معنی‌داری کاهش (ضریب همبستگی -۰/۶۵) می‌یابد. همچنین تابش خورشیدی خالص و انرژی در دسترس، زمانی که خاک مرطوب است، تمایل به افزایش دارد. در پژوهش حاضر همبستگی بین رطوبت سطح خاک و دمای سطح خاک برابر با -۰/۴۹- می‌باشد که نشان می‌دهد با افزایش دما رطوبت در سطح خاک کاهش می‌یابد. یافته‌های این پژوهش منطبق با نتایج پژوهش‌های Small and Kurc (2001) می‌باشد.

بهره‌گیری از توابع انتقالی برای برآورد رطوبت سطحی خاک با روش‌های مختلف

در عبارت‌هایی که به صورت PTFx نوشته می‌شود، PTF به معنی تابع ایجاد شده و x اعدادی است که نشان‌دهنده مراحل ایجاد توابع انتقالی از ۱ تا ۸ هستند (جدول ۲). در این پژوهش از دو روش ANN و SVM استفاده شده است. شبکه عصبی بکار رفته در این پژوهش دارای سه لایه ورودی، میانی و خروجی بودند. از توابع فعال‌سازی Sine، Tanh، Exponential، Gaussian، Logistic، Identity در لایه‌های میانی و خروجی استفاده شد (جدول ۵). در جدول ۵ مشاهده می‌شود که PTF₃ که به طور نسبی بهترین نتایج را داشته است از ۵۰ مدل خروجی روش ANN، دارای ۲۱ پرسپترون چندلایه (MLP) و ۲۹ توابع پایه شعاعی (RBF) می‌باشد، و دامنه سلول‌های پنهان ۲-۳۰، و بیشترین نوع تابع خروجی و پنهان این سطح به ترتیب Identity و Gaussian می‌باشد.

مشخصات روش SVM که در این مطالعه استفاده شده است در جدول ۵ آمده است. مقادیر C و nu و نتیجه تخمین را کنترل می‌کنند. در این پژوهش محدوده مقادیر پارامتر nu بین ۰/۵ - ۰/۰۰۱، پارامتر C بین ۵۰ - ۱ و پارامتر gamma بین ۰/۳۵ - ۰/۱۳

و اعتبار روش ANN در این پژوهش بیشتر از روش SVM می‌باشد؛ بنابراین در این مطالعه برای جلوگیری از طولانی شدن متن تنها به بررسی نتایج روش ANN می‌پردازیم.

جدول ۵- ویژگی‌های روش‌های ANN و SVM بکار رفته در این پژوهش

توابع انتقالی*	ANN												SVM						
	نوع شبکه	تعداد سلول‌های پنهان	نوع تابع لایه خروجی					نوع تابع لایه پنهان							Cross-validation error				
			Tanh	Sine	Exponential	Logistic	Identity	Gaussian	Identity	Sine	Exponential	Tanh	Logistic	gamma		nu	C	Number of SVs	
PTF ₁	۲۳	۲۷	۳-۱۸	۴	۳۴	۵	۰	۷	۲۶	۵	۲	۶	۴	۷	۰/۳۵	۰/۳	۵۰	۲۳	۰/۰۰۲
PTF ₂	۲۵	۲۵	۱-۱۵	۷	۲۸	۶	۱	۸	۲۴	۳	۷	۷	۵	۴	۰/۲۰	۰/۵	۹	۳۷	۰/۰۰۲
PTF ₃	۲۱	۲۹	۲-۲۰	۵	۳۳	۶	۲	۴	۲۹	۴	۲	۷	۶	۲	۰/۲۴	۰/۵	۱۰	۴۹	۰/۰۰۲
PTF ₄	۳۱	۱۹	۱-۲۰	۷	۲۵	۷	۳	۸	۱۹	۹	۵	۵	۹	۳	۰/۲۹	۰/۱	۸	۲۶	۰/۰۰۲
PTF ₅	۲۱	۲۹	۵-۲۰	۳	۳۳	۶	۳	۵	۲۹	۳	۴	۷	۶	۱	۰/۲۱	۰/۵	۱۰	۵۴	۰/۰۰۲
PTF ₆	۲۶	۲۴	۵-۲۰	۷	۲۷	۹	۳	۴	۲۴	۸	۵	۳	۳	۷	۰/۱۷	۰/۲	۹	۲۸	۰/۰۰۲
PTF ₇	۲۸	۲۲	۱-۲۰	۵	۲۶	۱۰	۳	۶	۲۲	۳	۶	۳	۶	۱۰	۰/۱۴	۰/۴	۲	۴۹	۰/۰۰۲
PTF ₈	۱۷	۳۳	۲-۲۵	۴	۳۸	۴	۱	۳	۳۳	۶	۱	۱	۴	۵	۰/۲۹	۰/۰۰۱	۳۴	۴۱	۰/۰۰۳

* توابع انتقالی‌ها و پارامترهای ورودی در جدول ۲ معرفی شده است.

جدول ۶- آماره‌های برآورد رطوبت سطحی خاک به روش ANN

RI	MBE	R ²	AIC	RMSE	RI	MBE	R ²	AIC	RMSE	ورودی‌ها	توابع انتقالی	گروه
آزمون					آموزش							
	۰/۰۰۰۴	۰/۵۲	-۲۵۵	۰/۰۴۸		۰/۰۰۳۹	۰/۵۶	-۵۰۶	۰/۰۴۱	Si/Sa+C	PTF ₁	۱
۸/۸	-۰/۰۱۴۶	۰/۶۴	-۲۶۹*	۰/۰۴۴	۱۸/۳	-۰/۰۰۱۶	۰/۷۰	-۵۳۸*	۰/۰۳۳	Si/Sa+ BD+C	PTF ₂	
۲۵/۷	-۰/۰۰۹۲	۰/۷۹	-۲۸۵*	۰/۰۳۶	۲۳/۶	-۰/۰۰۰۴	۰/۷۵	-۵۴۷*	۰/۰۳۱	Si/Sa+ BD+CI+C	PTF ₃	
۱۱/۱	-۰/۰۱۷۵	۰/۷۰	-۲۶۹*	۰/۰۴۳	۲۲/۹	-۰/۰۰۳۴	۰/۷۵	-۵۴۵*	۰/۰۳۱	Si/Sa+ BD+BI+C	PTF ₄	۲
۲۲/۱	-۰/۰۱۳۳	۰/۷۸	-۲۷۹*	۰/۰۳۸	۲۶/۳	-۰/۰۰۱۲	۰/۷۶	-۵۵۱*	۰/۰۳۰	C+Si/Sa+ BD+BI+CI	PTF ₅	
۱۸/۸	-۰/۰۱۰۱	۰/۷۲	-۲۷۳*	۰/۰۳۹	۲۲/۱	-۰/۰۰۱۰	۰/۷۳	-۵۴۰*	۰/۰۳۲	Si/Sa+ BD+SI2+SI4+SI6+C	PTF ₆	
۱۷/۹	-۰/۰۱۰۸	۰/۷۲	-۲۷۰*	۰/۰۴۰	۲۱/۱	-۰/۰۰۰۴	۰/۷۲	-۵۳۶*	۰/۰۳۲	Si/Sa+BD+SI1+SI3+SI7++C	PTF ₇	۳
										NDSI		
۱۲/۲	-۰/۰۰۸۵	۰/۶۶	-۲۷۰*	۰/۰۴۲	۲۰/۵	-۰/۰۰۱۸	۰/۷۳	-۵۴۰*	۰/۰۳۲	Si/Sa+ BD+LST+C	PTF ₈	۴
۸/۸	-۰/۰۱۷۵	۰/۵۲	-۲۷۰	۰/۰۳۶	۱۵/۲	-۰/۰۰۳۴	۰/۵۶	-۵۵۱	۰/۰۳۰	حداقل کل توابع		
۲۵/۷	-۰/۰۰۰۴	۰/۷۹	-۲۵۵	۰/۰۴۸	۲۶/۳	-۰/۰۰۳۹	۰/۷۶	-۵۰۶	۰/۰۴۱	حداکثر کل توابع		
۱۶/۱	-۰/۰۱۰۴	۰/۶۹	-۲۶۶	۰/۰۴۱	۲۱/۲	-۰/۰۰۰۶	۰/۷۱	-۵۳۸	۰/۰۳۳	میانگین کل توابع		

گروه اول

می‌شود. علت اینکه این سطح به عنوان سطح پایه در نظر گرفته شده است این می‌باشد که از اجزای بافت خاک از خصوصیات سهل‌الوصول می‌باشد و هم تاثیر قابل توجهی بر رطوبت خاک دارند (Ghanbarian-Alavijeh and Millán., 2010). نتایج حاصل از این سطح ضعیف‌تر از نتایج سایر تابع‌ها می‌باشد (جدول

در گروه اول دو تابع وجود دارد (PTF₁ و PTF₂)، در PTF₁ از درصد مقدار رس و نسبت سیلت به شن برای برآورد رطوبت خاک استفاده شده است (جدول ۲). این سطح به عنوان سطح پایه معرفی می‌شود و سایر تابع‌های ایجاد شده با این سطح مقایسه



مقادیر $RMSE$ ، AIC ، R^2 و RI به ترتیب برای آموزش $0.033 / (cm^3 cm^{-3})$ ، -538 ، $18/35$ و 0.70 و برای آزمون $0.044 / (cm^3 cm^{-3})$ ، -269 ، $8/79$ و 0.64 می باشد (جدول ۶).

محققان زیادی دریافته اند که افزودن BD به همراه بافت خاک به عنوان پارامترهای مؤثر در توابع انتقالی باعث افزایش عملکرد مدل در تخمین رطوبت خاک می شوند (Rastgou et al., 2020; Bayat et al., 2015). با توجه به مزیت های بافت و ساختمان خاک (Ghanbarian-Alavijeh and Millán., 2010)، جهت افزایش دقت مدل ها، ورودی های این گروه به طور ثابت در همه سطوح آماده است.

در این سطح، مقادیر $RMSE$ ، AIC و R^2 به ترتیب برای آموزش $0.041 / (cm^3 cm^{-3})$ ، -506 و 0.56 و برای آزمون $0.048 / (cm^3 cm^{-3})$ ، -255 و 0.52 می باشد (جدول ۶).

در سطح دوم، PTF_2 ، علاوه بر خصوصیات سطح اول از جرم مخصوص ظاهری (BD) هم به عنوان ورودی استفاده شده است. با افزایش BD در سطح دوم، در هر دو مرحله آموزش و آزمون R^2 افزایش، $RMSE$ و AIC کاهش و برآورد رطوبت در هر دو مرحله آموزش و آزمون بهبود پیدا کرده است، اما در روش SVM بهبود معنی داری در تخمین رطوبت وجود نداشت. BD شاخصی از ساختمان خاک می باشد (Nunes et al., 2020) و همبستگی منفی و معنی داری با رطوبت خاک دارد (جدول ۴). PTF_2 ،

جدول ۷- آماره های برآورد رطوبت سطحی خاک به روش SVM

RI	MBE	R ²	AIC	RMSE	RI	MBE	R ²	AIC	RMSE	ورودی ها	توابع انتقالی	گروه
آموزش					آزمون							
	-0.10	0.38	-249	0.056		0.08	0.36	-471	0.051	Si/Sa+C	PTF ₁	۱
7/8	-0.08	0.55	-254	0.051	4/1	-0.05	0.59	-476	0.049	Si/Sa+ BD+C	PTF ₂	
21/6	-0.18	0.67	-267*	0.044	37/6	-0.06	0.74	-543*	0.032	Si/Sa+ BD+CI+C	PTF ₃	۲
18/3	-0.16	0.64	-263*	0.046	32/7	0.004	0.71	-531*	0.034	Si/Sa+ BD+BI+C	PTF ₄	
14/4	-0.21	0.63	-257	0.048	38/5	-0.02	0.76	-543*	0.032	C+Si/Sa+ BD+BI+CI	PTF ₅	
8/5	-0.21	0.64	-249	0.052	25/6	-0.005	0.72	-511*	0.038	Si/Sa+ BD+SI2+SI4+SI6+C	PTF ₆	۳
38/1	-0.004	0.75	-281*	0.035	54	-0.01	0.85	-586*	0.024	Si/Sa+BD+SI1+SI3+SI7++C	PTF ₇	
										NDSI		
20/3	-0.02	0.66	-265*	0.045	45/4	0.005	0.87	-564*	0.028	Si/Sa+ BD+LST+C	PTF ₈	۴
8/8	-0.21	0.52	-270	0.052	4/1	-0.06	0.36	-476	0.036	حداقل کل توابع		
25/7	-0.004	0.79	-255	0.079	54	0.08	0.87	0.471	0.087	حداکثر کل توابع		
16/1	-0.12	0.69	-266	0.069	35/2	-0.001	0.71	-474	0.071	میانگین کل توابع		

بازتاب از سطح خاک است و شاخص CI بیانگر نسبت هماتیت به مجموع هماتیت و ژئوتیت، و مشخصه رنگ خاک می باشد (Mandal, 2016). در بیشتر موارد، شاخص طیفی CI اطلاعات تکمیلی شاخص های BI و $NDVI$ را ارائه می کند. Zhang et al., (2013) گزارش کردند که بازتاب های طیفی با افزایش رطوبت خاک و کاهش آلبيدو کاهش می یابد، اما با افزایش رطوبت خاک بازتاب طیفی با سرعت ملایم تری کاهش می یابد. دلیل این امر احتمالاً به این خاطر است که در رطوبت بالای خاک، رنگ خاک کاملاً تیره است و رطوبت اضافی تأثیر نسبتاً کمی بر بازتاب از خاک دارد. در مناطقی که تراکم گیاه کم است، بازتاب از سایبان گیاه به شدت تحت تأثیر بازتاب از سطح خاک می باشد. بازتاب از سطح خاک علاوه بر رطوبت خاک، تحت تأثیر عوامل دیگری مانند مواد معدنی، مواد آلی و بافت خاک می باشد (Asner, 1998). این ویژگی های خاک با خواص هیدرولیکی خاک ارتباط

گروه دوم

در گروه دوم از سه تابع (PTF_{3-5}) تشکیل شده است. در این گروه از شاخص های رنگ خاک (CI و BI) به عنوان ورودی مدل برای تخمین رطوبت خاک استفاده شده است (جدول ۲). با توجه به نتایج (جدول ۶)، ورودی های همه سطح های این گروه، در هر دو مرحله آموزش و آزمون رطوبت خاک را به طور معنی داری بهبود داده اند. در این گروه PTF_3 به طور نسبی عملکرد بهتری نسبت به دو سطح دیگر در این گروه نشان داده است. در PTF_3 مقادیر AIC ، $RMSE$ ، R^2 و RI به ترتیب در مرحله آموزش برابر -543 ، 0.032 ، 0.74 و $37/62$ و در مرحله آزمون برابر با -267 ، 0.044 ، 0.67 و $21/65$ می باشد.

شاخص روشنایی (BI) و شاخص رنگ (CI) جزء شاخص های طیفی رنگ خاک می باشند. شاخص BI بیانگر میانگین مقدار

تنگانگی دارند (Szabó et al., 2019).

باتوجه به این که خاک‌های این مطالعه از مناطق مرتعی برداشت شده است، دارای مقدار بالای ماده آلی حدود ۱/۵ درصد (جدول ۳) می‌باشد که وضعیت مطلوبی در مقایسه با بخش عمده-ای از خاک‌های کشور دارد و نظر به همبستگی مثبت میان درصد کربن آلی خاک با ظرفیت نگهداشت رطوبت در خاک این فرضیه قوت می‌گیرد با افزایش ماده آلی مقدار رطوبت خاک افزایش یافته و رنگ تیره به خاک القاء می‌کند (Mousavi et al., 2022) و باعث کاهش بازتاب از سطح خاک می‌شود. باتوجه به جدول ۴، شاخص‌های طیفی CI و BI همبستگی منفی و معنی‌دار (-۰/۶۴) با رطوبت خاک دارد. در نتیجه می‌توان گفت استفاده از شاخص‌های طیفی رنگ خاک می‌تواند رطوبت خاک با درجه اطمینان قابل توجهی برآورد کنند.

گروه سوم

در گروه سوم از سه تابع (PTF₆₋₇) تشکیل شده است. در این گروه از شاخص‌های شوری به‌عنوان ورودی مدل برای تخمین رطوبت خاک استفاده شده است (جدول ۲). باتوجه به نتایج جدول ۶، ورودی‌های هر دو سطح‌های این گروه، در هر دو مرحله آموزش و آزمون تخمین رطوبت خاک را به طور معنی‌داری بهبود داده‌اند. در این گروه ورودی‌های PTF₆ (شاخص‌های SI₂، SI₄ و SI₆) توانسته است رطوبت را در هر دو مرحله آموزش و آزمون با دقت بالاتری برآورد کند. در PTF₆ مقادیر AIC، RMSE، R² و RI به ترتیب در مرحله آموزش برابر ۰/۳۲، ۰/۷۳ و ۲۲/۰۴ و در مرحله آزمون برابر با ۰/۳۹، ۰/۷۲ و ۱۸/۸۱ می‌باشد. شوری خاک به‌عنوان تجمع نمک محلول در خاک شناخته شده است. شوری بر رشد گیاه، تولید محصول و کیفیت خاک تأثیر منفی می‌گذارد و در نهایت باعث تخریب و فرسایش خاک می‌شود (Allbed and Kumar., 2013). شوری خاک می‌تواند باعث تغییر میزان ضریب دی‌الکتریک خاک شود و در نتیجه باعث تخمین بیش از حد رطوبت خاک شود. همچنین در خاک‌های خیلی شور به دلیل خاصیت نگهداری رطوبت و حالت هیگروسکوپی املاح، با افزایش میزان آب، بازتاب کمتری نشان می‌دهند (Alavi Panah, 2007). با توجه به توزیع بافت خاک این پژوهش، خاک‌های این پژوهش بافت متوسطی دارند، و میانگین مقدار قابلیت هدایت الکتریکی خاک‌های این پژوهش برابر ۱/۲۰ میلی‌زیمنس می‌باشد (جدول ۳). در نتیجه خاک این پژوهش شور نمی‌باشد (Sun et al., 2000).

به‌طور معمول خاک‌های شور مناطق خشک به‌ویژه زمانی که پوسته نمکی در سطح خاک تشکیل می‌شود، بازتاب طیفی

بالایی را نشان می‌دهد؛ از سوی دیگر، به‌وسیله شاخص‌های پوشش گیاهی نیز می‌توان به‌طور غیرمستقیم مناطق شور را مشخص کرد، زیرا در مناطقی که پوشش گیاهی ندارند، احتمال شوری خاک و تنش آبی زیاد است (Allbed et al., 2018). طبیعتاً در شرایط تنش آبی، گیاه با کاهش تعداد و کوچک کردن برگ، سطح فتوسنتز کننده خود را کاهش می‌دهد و به دنبال کاهش سطح برگ، ظرفیت فتوسنتزی گیاه کاهش می‌یابد (Basirat and Mousavi, 2022; Basirat et al., 2022; Basirat et al., 2019). باتوجه به جدول ۴، شاخص‌های شوری ورودی PTF₆ (SI₂، SI₄ و SI₆) همبستگی قوی و معنی‌داری با رطوبت خاک نسبت به دیگر شاخص‌های طیفی شوری دارد، و همچنین شاخص‌های طیفی شوری ورودی PTF₆ همبستگی (مثبت و منفی) معنی‌داری با بافت و ساختمان خاک دارند؛ بنابراین، احتمالاً باتوجه به مطالب بالا و همبستگی‌هایی که بین ورودی‌های این سطح با رطوبت خاک، بافت و ساختمان خاک وجود دارد، باعث شده این سطح نتایج بهتری نسبت به سایر سطح‌های این گروه نشان دهد.

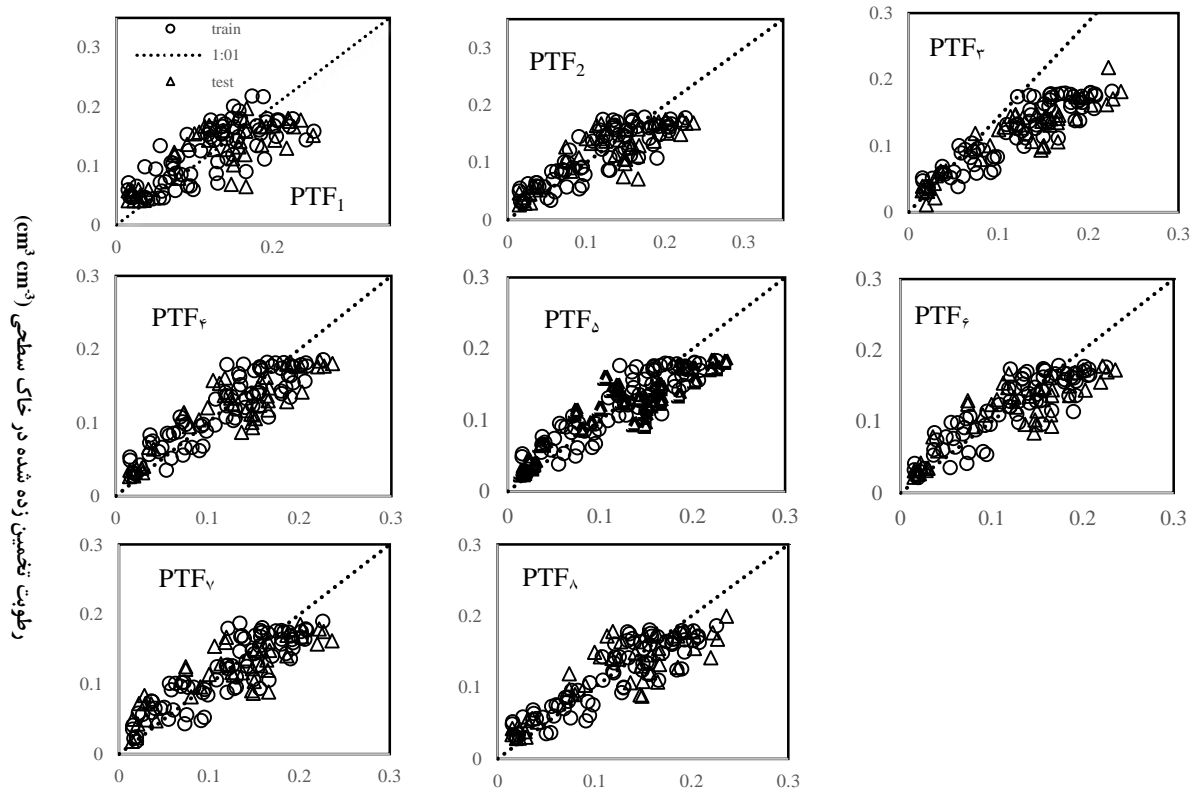
گروه چهارم

در گروه چهارم از شاخص طیفی دمای سطحی (LST) به همراه خصوصیات پایه‌ای (PTF₈) به‌عنوان ورودی مدل استفاده شده است. ورودی‌های این سطح، در هر دو مرحله آموزش و آزمون رطوبت خاک را به طور معنی‌داری نسبت به سطح اول (PTF_i) بهبود داده‌اند (جدول ۶). در PTF₈ مقادیر AIC، RMSE، R² و RI به ترتیب در مرحله آموزش برابر ۰/۳۲، ۰/۷۳ و ۲۰/۴۹ و در مرحله آزمون برابر با ۰/۴۲، ۰/۶۶ و ۱۲/۲۰ می‌باشد.

دمای سطح زمین و تابش خالص به‌عنوان عامل حرارتی و عامل تراز انرژی یکی از مهم‌ترین عوامل مؤثر در میزان رطوبت سطح خاک مطرح است. همبستگی منفی دمای خاک با رطوبت خاک نشان‌دهنده تأثیر منفی دمای سطح زمین بر رطوبت خاک می‌باشد. به‌طوری که با افزایش دما تبخیر و تعرق افزایش و رطوبت خاک کاهش می‌یابد، و لذا بر فعالیت‌های زیستی و متابولیکی گیاه اثرگذار خواهد بود که به‌تبع آن تولید محصول نیز تحت تأثیر قرار می‌گیرد. در همین راستا (Sayão et al., 2018) پژوهشی به این نتیجه رسیدند که تغییرات ویژگی‌های حرارتی خاک، تأثیرات زیادی بر رطوبت خاک دارد که با افزایش LST، مقدار رطوبت خاک کاهش می‌یابد. (Babaeian et al., 2018) نشان داده‌اند که LST مهم‌ترین پارامتر مؤثر بر تغییرپذیری مکانی رطوبت خاک است. پوشش گیاهی می‌تواند رطوبت را با سایه انداختن در سطح خاک و کاهش LST از طریق افزایش تبخیر و

به صورت معنی داری برآورد کرده است. با ارزیابی نتایج این چهار گروه (جدول ۶)، سطح سوم از گروه دوم که از شاخص رنگ خاک (CI) استفاده شده است نسبت به سایر سطح‌ها AIC و RMSE کمتری دارد در نتیجه رطوبت خاک را با دقت بالاتری تخمین زده است.

تعرق گیاه، حفظ کند (Holtgrave et al., 2018). باتوجه به جدول ۴، شاخص دمایی همبستگی منفی و معنی داری (-۰/۴۹) با رطوبت خاک دارد، احتمالاً به علت وجود این همبستگی و تأثیرات متقابل بین رطوبت سطحی خاک و دما (Sayão et al., 2018)، شاخص دمایی، رطوبت خاک را در هر دو مرحله آموزش و آزمون



شکل ۲- مقادیر رطوبت اندازه گیری شده در مقابل مقادیر تخمین زده شده

کوچک و منفی می باشد. اما باتوجه به کم بودن مقادیر آماره MBE، نمی توان گفت مدل کم برآوردی یا بیش برآوردی مشهود داشته است و در نتیجه می توان از آن چشم پوشی کرد (Singh et al., 2020).

نتیجه گیری

رویکرد توابع انتقالی طیفی، از اطلاعات طیفی خاک برای ارائه سریع و دقیق ویژگی های اولیه خاک استفاده می کند و هزینه های مربوط به ضبط داده های ورودی PTF ها را کاهش می دهد. اطلاعات طیفی در PTF های کلاسیک، راه را برای استفاده از داده های سنجنش از دور در برآورد خواص هیدرولیکی خاک باز می کند. در این پژوهش، روش های ANN (RBF و MLP) و SVM برای

همان طور که در شکل ۲، مشاهده می شود مقادیر اندازه گیری شده و تخمینی همبستگی خوبی دارند که فقط بخش کوچکی از داده ها در زیر خط منحنی قرار گرفتند. منحنی ۱:۱ نشان می دهد داده های اندازه گیری شده و برآورد شده در اطراف خط پراکنده شده اند در صورتی که داده ها در زیر خط ۱:۱ قرار بگیرند بدین معنی است که مدل برآوردی کمتر از مقادیر اندازه گیری شده داشته و اگر در بالای آن خط قرار گیرند یعنی مدل برآوردی بیشتر داشته است. همان طور که در شکل ۲ مشاهده می شود بیشترین نزدیکی بین مقادیر اندازه گیری و تخمینی و نزدیکی به خط ۱:۱، در گراف PTF_۳، که بهترین نتیجه را در این پژوهش داشته است، دیده می شود. باتوجه به جدول ۶ و ۷، مقادیر آماره MBE در هر دو مرحله آموزش و آزمون، اغلب مقادیر

پژوهش همبستگی مناسبی با رطوبت خاک داشتند، که نشان‌دهنده موفقیت انتخاب پارامترها در ایجاد توابع است. شاخص حرارتی به‌طور نسبی نسبت به سایر شاخص‌ها در تخمین رطوبت خاک عملکرد ضعیفی داشته است که گویای این مسئله است که به‌غیر از دمای سطحی خاک، عوامل مختلف دیگری از قبیل بافت و رنگ خاک، شوری و پوشش گیاهی، بر رطوبت سطحی خاک اثرگذار است. پژوهش حاضر در مناطق مرتعی انجام شده است؛ لذا لازم است صحت روش‌های ارائه شده در مناطقی با پوشش گیاهی بیشتر و مناطق جنگلی یا مناطقی با پوشش کمتر بیابانی مورد آزمون قرار گیرد تا یک مدل بادقت بالاتری و با اطمینان‌تر ارائه شود.

"هیچ‌گونه تعارض منافع توسط نویسندگان وجود ندارد"

REFERENCES

- Abbas, A. and Khan, S. (2007). Using remote sensing techniques for appraisal of irrigated soil salinity. *Int. Congr. Model. Simul.(MODSIM), Model. Simul. Soc. Aust. New Zealand, Bright*, (January), (pp. 2632-2638).
- Adab, H. (2015). Estimation of the Instantaneous Soil Surface Moisture Content in Cold Seasons by using Optical and Thermal Remote Sensing Data under Clear Sky. *Water and Soil Science*. 21 (2):175-191 (In Farsi).
- Adab, H., Morbidelli, R., Saltalippi, C., Moradian, M. and Ghalhari, G. A. F. (2020). Machine learning to estimate surface soil moisture from remote sensing data. *Water*, 12(11), 3223.
- Akaike, H. (1974). A new look at the statistical model identification. *IEEE transactions on automatic control*. 19, 716-723.
- Ahmad, S., Kalra, A. and Stephen, H. (2010). Estimating soil moisture using remote sensing data: A machine learning approach. *Advances in water resources*. 33(1): 69-80.
- Agyare, W. A., Park, S. J. and Vlek, P. L. G. (2007). Artificial neural network estimation of saturated hydraulic conductivity. *Vadose Zone Journal*. 6(2): 423-431.
- Alavi Panah, K. (2007) Thermal remote sensing and its application in earth sciences. *University of Tehran Press*. (In Farsi).
- Al Masmoudi, Y., Bouslihim, Y., Doumali, K., El Aissaoui, A. and Namr, K. I. (2021). Application of the random forest model to predict the plasticity state of vertisols. *Journal of Ecological Engineering*, 22(2)
- Allbed, A., Kumar, L. and Sinha, P. (2018). Soil salinity and vegetation cover change detection from multi-temporal remotely sensed imagery in Al Hassa Oasis in Saudi Arabia. *Geocarto International*, 33 (8), 830-846.
- Allbed, A. and Kumar, L. (2013). Soil salinity mapping and monitoring in arid and semi-arid regions using remote sensing technology: a review. *Advances in remote sensing*, 2(4): 373.
- Aslami, F., Ghorbani, A., Sobhani, B. and Panahandeh, M. (2015). Comparing artificial neural network, support vector machine and object-based methods in preparation land use/cover maps using landsat-8 images. *RS & GIS techniques in natural resources*, 6:1-14 (In Farsi).
- Asner, G.P. (1998). Biophysical and biochemical sources of variability in canopy reflectance. *Remote sensing of environment*. 64(3), 234-253
- Avdan, U. and Jovanovska, G. (2016). Algorithm for Automated Mapping of Land Surface Temperature Using LANDSAT 8 Satellite Data. *Journal of Sensors*, 2016, 1-8.
- Babaeian, E., Homae, M., Montzka, C., Vereecken, H. and Norouzi, A. A. (2015). Towards retrieving soil hydraulic properties by hyperspectral remote sensing. *Vadose Zone Journal*, 14(3), vzj2014-07.
- Babaeian, E., Sadeghi, M., Franz, T.E., Jones, S. and Tuller, M. (2018). Mapping soilmoisturewith the Optical TRapezoid Model (OPTRAM) based on long-term MODIS observations. *Remote Sens. Environ.* 211, 425-440.
- Basirat, M, and Mousavi, S. M. (2022). Effect of Foliar Application of Silicon and Salicylic Acid on Regulation of Yield and Nutritional Responses of Greenhouse Cucumber Under High Temperature. *Journal of Plant Growth Regulation*, 1-11
- Basirat, M., Mousavi, S. M. and Abbaspour, M. (2022). Evaluation of the Interaction of Potassium Salicylate and Potassium Silicate on Yield, Nutritional Status, and Quality of Greenhouse



- Cucumber under Cold Stress Condition. Iranian Journal of Soil Research, 35(3): 287-301.
- Basirat, M., Mousavi, S. M., Abbaszadeh, S., Ebrahimi, M., and Zarebanadkouki, M. (2019). The rhizosheath: a potential root trait helping plants to tolerate drought stress. *Plant and Soil*, 445(1), 565-575.
- Bayat, H., Ebrahimzadeh, G. and Mohanty, B. P. (2021). Investigating the capability of estimating soil thermal conductivity using topographical attributes for the Southern Great Plains, USA. *Soil and Tillage Research*, 206, 104811.
- Bayat, H., Sedaghat, A., Sinigani, A. A. S. and Gregory, A. S. (2015). Investigating the relationship between unsaturated hydraulic conductivity curve and confined compression curve. *Journal of Hydrology*, 522, 353-368.
- Berry, W.D. (1993) Understanding Regression Assumptions. *Sage Publications*, London.
- Bouma J. (1989). Using soil survey data for qualitative land evaluation, *Advances in Soil Science*, 9: 177-213.
- Bousbih, S., Zribi, M., El Hajj, M., Baghdadi, N., Lili-Chabaane, Z., Gao, Q. and Fanise, P. (2018). Soil moisture and irrigation mapping in a semi-arid region, based on the synergetic use of Sentinel-1 and Sentinel-2 data. *Remote Sensing* 10, 1953.
- Douaoui E. K., Nicolasb H. and Walter, C. (2006). Detecting Salinity Hazards within a Semiarid Context by Means of Combining Soil and Remote-Sensing Data, *Geoderma*, Vol. 134, No. 1-2, pp. 217-230.
- Escorihuela, M. J. and Quintana-Seguí, P. (2016). Comparison of remote sensing and simulated soil moisture datasets in Mediterranean landscapes. *Remote sensing of environment*, 180, 99-114.
- Gardner, W. H. (1986). Water content. *Methods of Soil Analysis: Part 1 Physical and Mineralogical Methods*, 5, 493-544.
- Ghanbarian-Alavijeh, B. and Millán, H.A. (2010). Point pedotransfer functions for estimating soil water retention curve. *International Agrophysics*. 24(3), 243-251.
- Gee, G. W. and Or, D. (2002) 2.4 Particle-size analysis. *Methods of soil analysis*. Part, 4(598), 255-293.
- Gill, M., Kemblowski, M.W. and McKee, M. (2007). Soil moisture data assimilation using support vector machines and ensemble Kalman filter 1. *JAWRA Journal of the American Water Resources Association*. 43, 1004-1015.
- Gopinathan, K.K. (1988). A general formula for computing the coefficients of the correlation connecting global solar radiation to sunshine duration. *Solar energy*. 41, 499-502.
- Grossman, R. B. and Reinsch, T. G. (2002). 2.1 Bulk density and linear extensibility. *Methods of soil analysis: Part 4 physical methods*, 5, 201-228.
- Hagan, M.T.; Demuth, H.B. and Beale, M.H. (1996). Neural Network. *Design PWS Publishing Co.*
- Holtgrave, A.K., Förster, M., Greifeneder, F., Notarnicola, C. and Kleinschmit, B. (2018). Estimation of soil moisture in vegetation-covered floodplains with Sentinel-1 SAR data using support vector regression. *PFG-Journal of Photogrammetry, Remote Sensing and Geoinformation Science* 86, 85-101.
- Hocking, R.R. (2013). Methods and Applications of Linear Models: Regression and the Analysis Of Variance. *John Wiley & Sons*.
- Hwang, SII., Kwang, PL., Dong, SL. and Susan, EP. (2002). Models for estimating soil particle-size distributions. *Soil Science Society of America Journal*. 66:1143-1150.
- Keskin, H., Grunwald, S. and Harris, W. G. (2019). Digital mapping of soil carbon fractions with machine learning. *Geoderma* 339, 40-58.
- Lafdani, E. K., Nia, A. M. and Ahmadi, A. (2013). Daily suspended sediment load prediction using artificial neural networks and support vector machines. *Journal of Hydrology*, 478, 50-62.
- Luo, W., Xu, X., Liu, W., Liu, M., Li, Z., Peng, T., Xu, Ch., Zhang, Y. and Zhang, R. (2019). UAV based soil moisture remote sensing in a karst mountainous catchment. *Catena*, 174, 478-489.
- Mandal, U.K. (2016). SPECTRAL COLOR INDICES BASED GEOSPATIAL MODELING OF SOIL ORGANIC MATTER IN CHITWAN DISTRICT, NEPAL. *International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences*, 41.
- McLean, E. (1983). Soil pH and lime requirement. *Methods of soil analysis: Part 2 Chemical and microbiological properties*. 9:199-224.
- Moreira de Melo, T. and Pedrollo, O. C. (2015). Artificial Neural Networks for Estimating Soil Water Retention Curve Using Fitted and Measured Data. *Applied and Environmental Soil Science*. 1-16.
- Mousavi, S. M., Srivastava, A. K. and Cheraghi, M. (2022). Soil health and crop response of biochar: an updated analysis. *Archives of Agronomy and Soil Science*, 1-26
- Nelson, D., and Sommers, L.E. (1983). Total carbon, organic carbon, and organic matter. *Methods of soil analysis: Part 2 chemical and microbiological properties*. 9:539-579.
- Noroozi Angnaei, A., Khalafi Khatbasra, M.J. and

- Karimi Sorand, M. (2017). Investigation the performance of data-based methods in estimating the important moisture points in Shahroud region. *Journal of Irrigation Sciences and Engineering*, 29-44. (In Farsi)
- Picton, P. (2000) *Neural Networks*, 2nd edn. Palgrave, New York.
- Rhoades, J. (1996). Salinity: Electrical conductivity and total dissolved solids. *Methods of soil analysis: Part 3 Chemical methods*. 5:417-435
- Rastgou, M., Bayat, H., Mansoorizadeh, M., Gregory, A. S. and Agriculture, E. i. (2020). Estimating the soil water retention curve: Comparison of multiple nonlinear regression approach and random forest data mining technique. *Computers and Electronics in Agriculture*, 174, 105502.
- Rosenbaum, U., Bogena, H.R., Herbst, M., Huisman, J.A., Peterson, T.J., Weuthen, A., Western, A. W. and vereecken, H. (2012). Seasonal and event dynamics of spatial soil moisture patterns at the small catchment scale, *water Resources Research*, Vol. 48, W10544: 1-22.
- Sadeghi, M., Babaeian, E., Tuller, M. and Jones, S. B. (2017). The optical trapezoid model: A novel approach to remote sensing of soil moisture applied to Sentinel-2 and Landsat-8 observations. *Remote sensing of environment*, 198, 52-68.
- Santra, P., Kumar, M., Kumawat, R. N., Painuli, D. K., Hati, K. M., Heuvelink, G. B. M. and Batjes, N. H. (2018). Pedotransfer functions to estimate soil water content at field capacity and permanent wilting point in hot Arid Western India. *Journal of Earth System Science*, 127(3), 1-16.
- Sayão, V.M., Demattê, J.A., Bedin, L.G., Nanni, M.R. and Rizzo, R. (2018). Satellite land surface temperature and reflectance related with soil attributes. *Geoderma* 325, 125-140.
- Sedaghat, A., Bayat, H., and Sinegani, A. S. (2016). Estimation of soil saturated hydraulic conductivity by artificial neural networks ensemble in smectitic soils. *Eurasian Soil Science*. 49, 347-357.
- Seo, S. (2006) A review and comparison of methods for detecting outliers in univariate data sets, Thesis for Master of Science in Field of Public Health University of Pittsburgh, (pp. 1-59).
- Sims, D. A., and Gamon, J. A. (2003). Estimation of Vegetation Water Content and Photosynthetic Tissue Area from Spectral Reflectance: A Comparison of Indices Based on Liquid Water and Chlorophyll Absorption Features. *Remote Sensing of Environment* 84: 526-537.
- Singh, A., Haghverdi, A., Öztürk, H.S. and Durner, W. (2020). Developing Pseudo Continuous Pedotransfer Functions for International Soils Measured with the Evaporation Method and the HYPROP System: I. The Soil Water Retention Curve. *Water*, 12(12), 3425.
- Shanani Hoveyzeh, S.M., and Heidar, Z. (2015). Investigation of Land Use Changes During the Past Two Last Decades (Case Study: Abolabas Basin), *Journal of Watershed Management Research*, 7: 237-234, (In Farsi).
- Small, E.E. and Kurc, S. (2001). The influence of soil moisture on the surface energy balance in semiarid environments (pp. 318): New Mexico Water Resources Research Institute, New Mexico State University.
- Soleimani, M., Kafi, M., Ziaei, M., Shabahang, J. and Davari, K. (2008). The influence of drought stress on the quantitative and qualitative properties of seeds of two native halofit plants of kochia under irrigation with saline water. *Journal of Agricultural Sciences and Natural Resources*. 15 (5), (In Farsi).
- Souza, E. d., Fernandes, E. I., Schaefer, C. E. G. R., Batjes, N. H., Santos, G. R. d. and Pontes, L. M. (2016). Pedotransfer functions to estimate bulk density from soil properties and environmental covariates: *Rio Doce basin*. 73, 525-534.
- Petropoulos, G.P., Knorr, W., Scholze, M., Boschetti, L., and Karantounias, G. (2010). Combining ASTER multispectral imagery analysis and support vector machines for rapid and cost-effective postfire assessment: a case study from the Greek wild land fires of 2007. *Natural hazards and earth system sciences*, 10: 305-317.
- Sun, ZJ., Young, G.D., McFarlane, R. and Chambers, B.M. (2000). The effect of soil electrical conductivity on moisture determination using time domain- reflectometry in sandy soil. *Canadian Journal of Soil Science* 80(1): 13-22.
- Szabó, B., Szatmári, G., Takács, K., Laborczi, A., Makó, A., Rajkai, K. and Pásztor, L. (2019). Mapping soil hydraulic properties using random-forest-based pedotransfer functions and geostatistics. *Hydrology and Earth System Sciences*, 23(6), 2615-2635.
- Tietje, O. and Hennings, V. (1996). Accuracy of the saturated hydraulic conductivity prediction by pedo-transfer functions compared to the variability within FAO textural classes. *Geoderma* 69, 71-84.
- Twarakavi, N.K., Simunek, J. and Schaap, M. (2009). Development of pedotransfer functions for estimation of soil hydraulic parameters using support vector machines. *Soil Science Society of America Journal*. 73, 1443-1452.
- Ungaro, F., Calzolari, C. and Busoni, E. (2005). Development of pedotransfer functions using a group method of data handling for the soil of the Pianura Padano-Veneta region of North Italy: water retention properties. *Geoderma* 124, 293-317.



- Vapnik, V.N. (2000) The nature of statistical learning theory, ser. Statistics for engineering and information science, vol 21. *Springer*, New York, (pp 1003–1008).
- Xia, L., Song, X., Leng, P., Wang, Y., Hao, Y. and Wang, Y. (2019). A comparison of two methods for estimating surface soil moisture based on the triangle model using optical/thermal infrared remote sensing over the source area of the Yellow River. *International Journal of Remote Sensing*, 40(5-6), 2120-2137.
- Zhang, N., Hong, Y., Qin, Q. and Liu, L. (2013). VSDI: a visible and shortwave infrared drought index for monitoring soil and vegetation moisture based on optical remote sensing *International journal of remote sensing*. 34 (13), 4585–4609.
- Zhao, Y., Peth, S., Wang, X. Y., Lin, H. and Horn, R. (2010). Controls of surface soil moisture spatial patterns and their temporal stability in a semi-arid steppe. *Hydrological Processes*, 24(18), 2507-2519.