

تخمین شاخص کیفیت فیزیکی خاک و عدم قطعیت با به‌کارگیری شبکه عصبی مصنوعی بوت‌استرپ (BANNs)

معصومه صبری^{1*}، محمدرضا نیشابوری²، محمد علی قربانی³، فرزین شهبازی⁴، خلیل ولیزاده⁵

تاریخ دریافت: 94/02/22 تاریخ پذیرش: 94/10/21

¹ دانشجوی دکتری، گروه علوم خاک، دانشکده کشاورزی دانشگاه تبریز

² استاد گروه خاکشناسی، دانشکده کشاورزی، دانشگاه تبریز

³ دانشیار گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز

⁴ دانشیار گروه خاکشناسی، دانشکده کشاورزی، دانشگاه تبریز

⁵ استادیار گروه جغرافیای طبیعی، دانشکده جغرافیا و برنامه‌ریزی، دانشگاه تبریز

*مسئول مکاتبات، پست الکترونیکی: azadeh.sabri@gmail.com

چکیده

در این پژوهش شیب منحنی رطوبتی در نقطه عطف آن (Si) به‌عنوان شاخص کیفیت فیزیکی خاک در نظر گرفته شده و همبستگی آن با ویژگی‌های زودیاقت خاک و اطلاعات به‌دست‌آمده از تصاویر ماهواره‌ای (SAVI) و اطلاعات رقومی ارتفاع (DEM) بررسی شده است. بدین منظور 176 نمونه دست‌خورده و به همان تعداد نمونه دست‌نخورده که از لحاظ ارتفاع، نوع پوشش گیاهی، کاربری اراضی و الگوی توزیع خاک دارای تنوع لازم بودند، از خاک‌های استان‌های آذربایجان شرقی و گیلان تهیه گردید. توزیع اندازه ذرات، جرم مخصوص ظاهری، میانگین هندسی قطر خاکدانه‌ها، تخلخل کل، ماده آلی، درصد آهک، EC، pH، میانگین هندسی و انحراف استاندارد هندسی قطر خاکدانه‌ها، رطوبت ظرفیت مزرعه‌ای و SAVI، DEM به‌عنوان ورودی توابع انتقالی مورد استفاده قرار گرفتند. با توجه به اینکه قابلیت اطمینان پیش-بینی‌های هیدرولیکی در مدیریت و طراحی و برنامه‌ریزی فعالیت‌های علوم خاک حائز اهمیت است. لذا در این تحقیق سعی شد عدم قطعیت در S_i تخمینی، کمی شود. بدین‌منظور از روش شبکه عصبی مصنوعی ادغام‌شده با روش بوت‌استرپ- (BANNs) استفاده شد. مدل‌های ایجاد شده با استفاده از آزمون مرگان-گرنجر-نیوبلد (MGN) و ریشه میانگین مربعات خطا (RMSE) برای داده‌های آموزش و صحت‌سنجی ارزیابی شدند. با وجود تغییرپذیری موجود در روش بوت‌استرپ، نتایج مؤثر بودن SAVI حاصل از تصاویر ماهواره‌ای و DEM را در توسعه و بهبود توابع انتقال هنگامی که به خصوصیات پایه خاک افزوده می‌شوند در مقایسه با زمانی که تنها از خصوصیات پایه خاک به‌عنوان ورودی استفاده می‌شود، تأیید می‌کند.

واژه‌های کلیدی: بوت‌استرپ، دور سنجی، شاخص S_i ، شبکه عصبی مصنوعی، عدم قطعیت

Estimation of soil quality indices and its uncertainty using Bootstrap-based Artificial Neural Networks (BANNs)

M sabri^{1*}, MR Neyishabouri², MA Ghorbani³, F Shahbazi⁴, K Valizadeh⁵

Received: 12 May 2015 Accepted: 11 January 2016

¹PhD Student, Dept. of Soil Science, Faculty of Agric., Tabriz Univ., Tabriz, Iran

²Prof., Dept. of Soil Science, Faculty of Agric., Tabriz Univ., Tabriz, Iran

³Associated Prof., Dept. of Water Resource Eng., Faculty of Agric., Tabriz Univ., Tabriz, Iran

⁴Associated Prof., Dept. of Soil Science, Faculty of Agric., Tabriz Univ., Tabriz, Iran

⁵Assistant Prof., Dept. of Geography, Faculty of Geography and Planning, Tabriz Univ., Tabriz, Iran

* Corresponding Author, Email: azadeh.sabri@gmail.com

Abstract

In this study the slope of soil water retention curve at its inflection point (S_i) as a soil physical quality index and its correlation with soil convenient properties and with information on vegetation cover from satellite images (SAVI) and digital elevation model (DEM) were studied. For this purpose, 176 disturbed and undisturbed soil samples were collected from East Azarbaijan and Gilan provinces. The test sites were chosen as such to provide wide variety in terrain, land use characteristics, vegetation, soil types and soil distribution patterns. Particle size distribution, total porosity, bulk density, organic matter, EC, pH, CCE, mean weight diameter (MWD), geometric mean and standard deviation of particle diameter, water content at -30 kPa, DEM and SAVI were used as pedotransfer function (PTFs) inputs. Since reliable hydrologic prediction is essential for planning, developing and rational management of the soils, therefore, in this study the uncertainty involved in S_i prediction using artificial neural network (ANN) models was quantified. The uncertainty associated with S_i was investigated using the bootstrap based artificial neural networks (BANNs). The performance of PTFs was evaluated using the root mean square error (RMSE) between the observed and the predicted values and the Morgan-granger-newbold test (MGN). Although variability exists within bootstrapped replications, improvements were achieved with certain input combinations of basic soil properties, topography and vegetation information compared with using only the basic soil properties as inputs.

Keywords: Artificial neural networks, Bootstrap based ANN, S_i Index, Remote sensing, Uncertainty

این عدم قطعیت‌ها برای تصمیمات کاربردی مهم است. تعیین عدم قطعیت ورودی‌ها اغلب مشکل است زیرا بزرگی خطای ورودی‌ها نامعلوم است. در عمل نیاز است عدم قطعیت همراه با نتایج تولید شده توسط شبکه عصبی به منظور استفاده مطمئن و قابل اطمینان کمی شود. یکی از روش‌های پارامتریک کمی کردن عدم قطعیت استفاده از روش شبکه عصبی تلفیق یافته با

مقدمه

قابلیت اعتماد مدل‌های تخمین‌گر خصوصیات خاک به وسیله سه منبع اصلی عدم قطعیت (باتزو تونلی 1988) تحت تأثیر قرار می‌گیرد: 1- عدم قطعیت ورودی‌ها (کیفیت داده‌ها)، 2- عدم قطعیت در ساختار مدل (توانایی مدل برای توصیف پدیده) و 3- عدم قطعیت پارامترها (مقادیر کافی از پارامترهای مدل). کمی کردن

پتانسیلی از منحنی رطوبتی مناطق مورد مطالعه، ارائه می‌دهد. پاچپسکی و همکاران (2001)، لی جی و همکاران (2004) نیز با افزودن توزیع توپوگرافی به پارامترهای فیزیکی سعی در توسعه توابع انتقال داشتند. نتیجه مطالعات آن‌ها در مرلند آمریکا و باسیلیکاتا در ایتالیا بهبود در پیش‌بینی‌های انجام شده توسط توابع انتقالی را نشان داد. ذوالفقاری و همکاران (2015) در توسعه توابع انتقال مربوط به حدود آتربرگ و شاخص پلاستیکی، سه دسته از خواص را به‌عنوان ورودی استفاده کردند. اولین مدل تنها شامل خصوصیات پایه خاک، مدل دوم شامل ویژگی‌های توپوگرافی و NDVI و سوم ترکیبی از ویژگی‌های خاک، توپوگرافی و NDVI بود. نتایج آن‌ها نشان داد بهترین نتیجه مربوط به مدل سوم و ضعیف‌ترین اجرا به مدل اول مربوط می‌شود. تفاوت معنی‌دار بین مدل‌های دوم و سوم مشاهده نشد. بنابراین، داده مربوط به مدل دوم (داده‌های توزیع توپوگرافی) به دلیل سهل‌الوصول بودن در پیش‌بینی حدود آتربرگ و شاخص پلاستیکی در مقیاس منطقه‌ای توسط این محققان پیشنهاد شدند. از کیفیت خاک برای ارزیابی میزان تخریب اراضی یا اصلاح و تعیین نوع فعالیت‌های مدیریتی مناسب جهت کاربری پایدار استفاده می‌شود. از دهه 1950 ویژگی‌های مختلفی از خاک به‌عنوان شاخصی از کیفیت فیزیکی مورد استفاده قرار گرفته است (گوپریف و همکاران 2001). دکستر (2004) با توجه به تأثیرپذیری عمیق منحنی رطوبتی از اندازه و آرایش منافذ خاک طی تحقیقاتی نشان داد که شیب منحنی رطوبتی در نقطه عطف آن S_i می‌تواند منعکس‌کننده جنبه‌های مختلف کیفیت خاک از قبیل نفوذ، سخت‌شدگی و فشردگی باشد. وی شیب منحنی رطوبتی در نقطه عطف را شاخص کیفیت فیزیکی خاک (S_i) نامید. با توجه به اینکه اندازه‌گیری شاخص S_i زمان‌بر و پرهزینه و از طرفی با گذشت زمان دست‌خوش تغییر می‌شود، لذا استفاده از روش‌های غیرمستقیم معمولاً ترجیح داده می‌شود.

بوت‌استرپ است. روش بوت‌استرپ¹ (بازنمونه‌گیری) از نمونه‌گیری مجدد در یک مجموعه داده به‌منظور کاهش عدم قطعیت استفاده می‌کند. این روش با تولید نمونه‌های ساختگی مشابه با نمونه اصلی و در مرحله بعد با برآورد مقدار اریب و ارائه برآوردگر اریب-اصلاح شده و تولید بازه‌های اطمینان به ارزیابی عدم قطعیت مقدار کارآیی به‌دست‌آمده از نمونه اصلی می‌پردازد (تومی و اسمیت 1998). به‌علاوه این روش نیاز به محاسبات پیچیده مشتق، ماتریس وارونه هسین² و حل مونت کارلوی انتگرال که در روش شبکه عصبی بی‌زین (یکی از روش‌های کمی کردن عدم قطعیت) اتفاق می‌افتد، نیاز ندارد. روش بوت‌استرپ به‌طور موفقیت‌آمیزی در مدل‌سازی‌های مربوط به خصوصیات هیدرولیکی خاک استفاده شده است. شارما و همکاران (2006) عدم قطعیت هشت نقطه پتانسیلی مربوط به منحنی رطوبتی را با روش شبکه عصبی بوت‌استرپ شده³ محاسبه کردند. تحقیق دیگری که در آن از شبکه عصبی بوت‌استرپ در زمینه علوم خاک استفاده شده باشد، مشاهده نشده است. در چند دهه اخیر با افزایش دسترسی به داده‌های دورسنجی، برخی محققان سعی کردند شاخص‌های مختلف پوشش گیاهی مانند LAI^4 ، $SAVI^5$ ، $NDVI^6$ را جهت بهبود توابع انتقالی بکار برند. این شاخص‌ها یک ترکیب ریاضی از باندهای متعدد تصاویر رقومی ماهواره‌ای هستند که از اختلاف معنی‌دار بازتابش پوشش گیاهی در طول موج‌های آبی، قرمز، سبز و مادون‌قرمز نزدیک استفاده می‌کنند. شارما و همکاران (2006) مدل‌های ترکیبی متفاوتی (بر اساس شبکه عصبی) از NDVI، توزیع توپوگرافی (درجه و جهت شیب، ارتفاع، شکل شیب) ارائه و نشان دادند مدل حاوی NDVI و ارتفاع بهترین پیش‌بینی را در هشت نقطه

¹ Bootstrapping method² Hessian³ Bootstrapped artificial neural networks (BANNs)⁴ Leaf area index⁵ Soil-adjusted vegetation index⁶ Normalized difference vegetation index

کلسیم معادل به روش تیتراسیون (نلسون 1982) اندازه‌گیری شد. میانگین وزنی قطر خاکدانه‌ها (MWD) به روش یودر (1936) اندازه‌گیری شد. منحنی رطوبتی خاک با استفاده از ستون آب آویزان (رومانو و همکاران 2002)، دستگاه صفحات فشاری (دن و همکاران 2002) با اعمال فشار 1، 3، 4، 10، 20، 30، 100، 500، 1000، 1500 کیلوپاسکال به دست آمد. اندازه‌گیری‌های فوق تا مکش 200 کیلوپاسکال بر روی نمونه‌های دست‌نخورده و بالاتر از آن بر روی نمونه‌های دست‌خورده انجام شد. مدل ون‌گنوختن، بروکس و کوری (به ترتیب معادلات 1، 2) با استفاده از نرم‌افزار RETC (ون گنوختن و همکاران 1991) بر داده‌های رطوبت-مکش برازش گردید و مقادیر α ، n ، θ_r به دست آمد.

$$s_e = \frac{\theta_h - \theta_r}{\theta_{sat} - \theta_r} \quad [1]$$

$$s_e = \frac{1}{1 + (\alpha h)^n} \quad [2]$$

مقدار S_i برای هر نمونه خاک با استفاده از رابطه دکستر (2004) (معادلات 3 و 4) محاسبه شد.

$$s_i = -n(\theta_{sat} - \theta_{res}) \frac{\theta_h - \theta_r}{\theta_{sat} - \theta_r} + \frac{1}{m} \frac{\theta_h - \theta_r}{\theta_{sat} - \theta_r} \quad [3]$$

با قرار دادن $m = 1 - \frac{1}{n}$ (دکستر 2004) در معادله فوق مقدار S_i به شکل زیر بر حسب n قابل محاسبه است.

$$s_i = -n(\theta_{sat} - \theta_{res}) \frac{\theta_h - \theta_r}{\theta_{sat} - \theta_r} \frac{2n-1}{n-1} \quad [4]$$

در معادلات فوق θ_{sat} و θ_{res} به ترتیب رطوبت اشباع و باقی‌مانده ($g\ g^{-1}$)، h مکش (cm) و n و m پارامترهای بدون بعد و تجربی هستند. h_e پتانسیل ماتریک در نقطه ورود هوا (cm)، s_e اشباع مؤثر و λ پارامتر برازش است که نشان‌دهنده توزیع اندازه منافذ خاک و α (cm^{-1}) تقریباً معادل عکس فشار در نقطه ورود هوا است.

مقالاتی در مورد استفاده از روش‌های آماری متعارف به منظور توسعه معادلات تجربی برای پیش‌بینی شاخص S_i وجود دارد. به عنوان نمونه امامی و همکاران (1387) نشان دادند با استفاده از ویژگی‌های زود یافت خاک می‌توان شاخص S_i را به راحتی تعیین نمود. با توجه به تأثیر ارتفاع بر دما و بارندگی و تأثیر این دو بر تنوع پوشش گیاهی و خاک، به نظر می‌رسد به نقش عامل توپوگرافی بر شاخص کیفیت فیزیکی خاک توجه جدی نشده است. هدف این تحقیق بهبود تابع انتقالی (PTF) تخمین‌گر شاخص S_i با افزودن اطلاعات مربوط به توپوگرافی (رقومی ارتفاع) و اطلاعات پوشش گیاهی با استفاده از شاخص SAVI است. انعکاس عدم قطعیت در خروجی‌ها (یکی از مهم‌ترین چالش‌ها در تخمین‌های توابع انتقال) هدف دیگر این تحقیق است. در این مطالعه عدم قطعیت در شبکه عصبی و فاصله اطمینان ناشی از عدم قطعیت پارامتریک مورد بررسی قرار گرفته و تلاش شده است عدم قطعیت در پیش‌بینی کمی شود و در نهایت شبکه عصبی بوت-استرپ با شبکه عصبی متداول مقایسه شده است.

مواد و روش‌ها

منطقه مورد مطالعه

مناطق مورد مطالعه بخش‌هایی از اراضی استان آذربایجان شرقی (دشت تبریز، میانه، خواجه) و استان گیلان را شامل می‌شوند. 176 نمونه (دست‌نخورده و دست‌خورده) به طور تصادفی از عمق 0-10 سانتی-متری خاک تهیه شد. در هر یک از این نمونه‌ها برخی ویژگی‌های زود یافت از جمله فراوانی نسبی ذرات به-روش هیدرومتری چهار قرائت (گی و بادر 1986)، جرم ویژه ظاهری به روش سیلندر (بلک و هارتج 2002)، ماده آلی به روش والکلی و بلک (1934)، میانگین هندسی و انحراف معیار قطر ذرات به روش شیرازی و بورسما (1984) و اکنش عصاره گل اشباع با pH متر، قابلیت هدایت الکتریکی عصاره گل اشباع با EC متر، کربنات

دریافت و آماده‌سازی تصاویر ماهواره‌ای

تهیه اطلاعات و داده‌های پوشش گیاهی با استفاده از تصاویر ماهواره لندست 8 با قدرت تفکیک مکانی 30 متر در باندهای مرئی و مادون قرمز انعکاسی انجام شد. تصاویری که درصد ابرناکی نزدیک صفر بود از آرشیو سازمان زمین‌شناسی ایالات متحده تهیه گردید. در این تحقیق از تصاویر مربوط به ماه‌های اردیبهشت، خرداد، تیر، مرداد، شهریور، مهر و آبان (به دلیل انطباق با دوره رویشی) سال نمونه‌برداری (1392) استفاده شد. اطلاعات مربوط به ارتفاع از مدل رقومی ارتفاع (DEM) با قدرت تفکیک مکانی 30 متر به دست آمد.

استخراج شاخص گیاهی تعدیل‌کننده اثرات خاک (SAVI)

SAVI شاخص تصحیح‌شده NDVI است که اثرات خاک زمینه و رطوبت خاک را در شاخص NDVI کاهش می‌دهد. این شاخص طبق رابطه زیر محاسبه می‌گردد (علوی پناه 1382):

$$SAVI = \frac{(1+L)(NIR - Red)}{(NIR + Red + L)} \quad [5]$$

Red: مقادیر بازتاب در باند قرمز، NIR: مقادیر بازتاب در باند مادون قرمز نزدیک، L فاکتور تصحیح اثرات خاک است که دامنه آن از صفر برای پوشش گیاهی متراکم و یک برای پوشش گیاهی با تراکم کم هست. روش محاسبه این فاکتور با استفاده از اطلاعات تصاویر موجود، از رابطه زیر محاسبه گردید.

$$L = 1 - 2 * a * NDVI * WDVI \quad [6]$$

$$WDVI = \rho_{nir} - \gamma \rho_{red} \quad [7]$$

ρ_{red} : مقادیر بازتاب در باند قرمز، ρ_{nir} : مقادیر بازتاب در باند مادون قرمز نزدیک، $a = 1/6$ ، γ : ضریب خط خاک⁷ هست که در واقع شیب خط برازش داده شده بر نمودار بازتاب طیفی باندهای مادون قرمز نزدیک و قرمز است (پرویز و همکاران 1389).

شبکه عصبی مصنوعی

شبکه عصبی مصنوعی بر اساس استنباط از سیستم عصبی بیولوژیکی استوار است. در این روش تلاش بر این است که بر اساس روابط ذاتی میان داده‌ها، نگاهی غیرخطی بین متغیرهای مستقل (X_n) و هدف (y_n) برای یک سری متناهی از داده‌های ورودی و خروجی $T = \{(x_n, y_n), n = 1, 2, \dots, n_p\}$ برقرار گردد. در این روش بین هدف با داده‌های ورودی به وسیله تابع قطعی غیرخطی $\mu_y(x)$ ارتباط برقرار می‌شود. در نهایت با استفاده از تابع $\mu_y(x)$ و اعمال وزن مناسب، تخمین مطلوبی از خروجی شبکه $f(x_n; \hat{w})$ خواهیم داشت. البته الگوریتم یادگیری شبکه به گونه‌ای است که در طی آن مقادیر وزن‌ها، گام به گام تا به کمینه رسیدن مقدار خطای پیش‌بینی شبکه تعدیل می‌گردد.

بر اساس پژوهش‌های پیشین، یک شبکه پرسپترون با یک لایه پنهان در تقریب زدن هر تابع غیر خطی توانست. از این رو در این تحقیق برای طراحی شبکه عصبی از شبکه پرسپترون دو لایه با روش آموزش مارکوآرت- لورنبرگ و تعداد نرون‌های متفاوت در لایه پنهان و تابع محرک تانژانت هیپربولیک استفاده شده است. از آنجاکه دامنه این تابع بین یک و منهای یک است. لذا عمل نرمال‌سازی روی داده‌های ورودی صورت گرفت. در مجموع 12 متغیر به عنوان متغیر مستقل و شیب منحنی رطوبتی در نقطه عطف آن (S_i) به عنوان متغیرهای وابسته در نظر گرفته شدند. کل داده‌ها شامل متغیرهای مستقل و وابسته ابتدا نرمال و سپس به طور تصادفی به دو گروه (141 نمونه به طور تصادفی برای آموزش و 35 نمونه برای صحت‌سنجی) تقسیم شدند. تعداد نرون‌های موجود در لایه پنهان با سعی و خطا در جهت کاهش مقدار خطا مشخص گردید. تعداد تکرارهای لازم در فرآیند یادگیری شبکه 1000 در نظر گرفته شد. برای اجرای شبکه عصبی از نرم‌افزار MATLAB استفاده شد.

شبکه عصبی مصنوعی بوتاسترپ

یک مدل مناسب باید بتواند توزیعی دقیق و قطعی از پیش‌بینی ارائه دهد. قطعیت توزیع پیش‌بینی به‌وسیله گستره آن اندازه‌گیری می‌شود. شبکه عصبی مصنوعی- (ANN) ابزار قابل‌قبول در توسعه توابع انتقالی خاک می‌باشند، لیکن قادر به تخمین عدم قطعیت پارامترهای خروجی نیستند. بنابراین نیاز است که منابع مختلف عدم قطعیت که بر وزن \hat{w} تأثیر دارد، محاسبه گردد (تومی و اسمیت 1998). برای نیل به این مقصود، برای رفع نگرانی در مورد تخمین خروجی $f(x_n; \hat{w})$ از روی $\mu_y(x)$ ، باید این نکته در نظر گرفته شود که سری داده‌های $T = \{(x_n, y_n), n = 1, 2, \dots, n_p\}$ که در آموزش شبکه استفاده می‌شوند یکی از بی‌نهایت داده‌های ممکن است که از داخل داده‌های موجود در ورودی (x) ، مشتق شده‌اند. در حقیقت تنوع در آموزش سری داده‌ها به دلیل تعدد در نمونه‌گیری توأمان از ورودی‌ها (X_n) و خروجی‌های متناظر این ورودی‌ها (y_n) است. آموزش با هر سری از داده‌های T به سری متفاوتی از وزن‌های شبکه منجر می‌شود. بنابراین یک توزیعی از تابع خطا خواهیم داشت که واریانس آن از رابطه زیر به دست می‌آید (افرون و تیپ شیرانی 1993):

$$\sigma_f^2(x) = E\{\hat{f}(x_n; \hat{w}) - E\hat{f}(x_n; \hat{w})\}^2 \quad [9]$$

در عمل ساختار شبکه عصبی یک الگوریتم کامل نیست و به‌طور سیستماتیک بیش‌برآوردی در تخمین‌ها، محتمل است یعنی مقادیر مورد انتظار $E\hat{f}(x_n; \hat{w})$ برابر با عملکرد واقعی $m_f(x)$ نباشد. این اختلاف، اریب (بایاس⁸) نامیده می‌شود. واریانس خطا $f(x; \hat{w}) - \mu_y(x)$ برابر است با:

$$E\{(f(x_n; \hat{w}) - \mu_y(x))^2\} = E\{\hat{f}(x; \hat{w}) - E\hat{f}(x; \hat{w})\}^2 + E\{\hat{f}(x; \hat{w}) - \mu_y(x)\}^2 \quad [10]$$

نخستین عبارت بعد از علامت مساوی واریانس تابع توزیع $f(x; \hat{w})$ ، عبارت دوم مربع اریب است. خطا در تخمین $\mu_y(x)$ از انتخاب نامناسب ساختار شبکه ناشی می‌شود. به‌علاوه در شبکه‌های با تعداد گره‌های خیلی کم از آنجایی‌که تابع توزیع $f(x; \hat{w})$ انعطاف ناکافی برای مدل کردن داده‌ها دارد، اریب زیاد می‌شود. از طرف دیگر انعطاف‌پذیری مدل با افزایش تعداد گره‌ها (تعداد پارامترهای ورودی) به‌طور فزاینده‌ای افزایش می‌یابد که افزایش واریانس (عبارت اول در معادله 10) سبب افزایش اریب و در نتیجه بیش‌آموزشی در شبکه خواهد شد. منابع دیگر عدم قطعیت در اجرا شبکه، از این امر ناشی می‌شود که هنگام کمی‌شدن تابع خطا، الگوریتم نیز خود را به کمی‌برداند، که در این صورت آموزش ممکن است قبل از موعد مقرر و قبل از رسیدن به کمی‌نه، متوقف شود (افرون و تیپ شیرانی 1993). کمی کردن دقت تخمین $f(x; \hat{w})$ از یک عملکرد قطعی درست، (از نظر فاصله اطمینان) مستلزم فرض یک توزیع برای خطا $(f(x; \hat{w}) - \mu_y(x))^2$ در معادله 10 و تخمین واریانس آن است. در عمل معمول است که فرض کنیم اریب (عبارت دوم در معادله 10) با توجه به عبارت اول نادیده گرفته شده است. در حقیقت شبکه عصبی در مجموعه داده‌های آموزشی به‌طور اریب‌دار برآورد را انجام می‌دهد. در بسیاری از موارد منظور از اصطلاح واریانس در واقع همان اریب است (استورت و همکاران 1992) به‌همین دلیل در این پژوهش تمرکز بر روی مسئله تخمین واریانس $\delta_f^2(x)$ با استفاده از تکنیک بوت استرپ است. با فرض توزیع یکنواخت داده‌ها، بوت‌استرپینگ می‌تواند با ساخت تعدادی بازنمونه (نمونه‌هایی تصادفی با جایگذاری از مجموعه داده‌های اصلی) پیاده‌سازی شود. آموزش شبکه به‌طور جداگانه برای هر یک از نمونه‌های تولیدشده انجام می‌شود. فرض کنید داده‌ها از یک سری داده‌های تصادفی $T^0 = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$ با اندازه n که از جمعیتی با توزیع احتمالی نامعلوم F گرفته شده

$$\hat{\delta}_{boot}^2 = \frac{\hat{a}_{b=1}^B \hat{a}_{i=A_b} (y_i - f_{ANN}(x_i, w_b/T^b))^2}{B-1} \quad [13]$$

معنی‌داری فواصل اطمینان در سطح احتمال نشان‌گر تکرارپذیری این روش است. مقدار معمول برای 0/05 است که با توجه به فرمول $\% (1-a) * 100$ برابر حدود اطمینان 95 هست. به منظور تعیین فواصل اطمینان در سطح احتمال موردنظر رابطه 14 بکار رفت (افرون و تیپ شیرانی 1993):

$$\hat{\theta}_{(x)} \pm t_{n-p}^{\alpha/2} \delta(x) \quad [14]$$

$\delta(x)$ انحراف استاندارد B تعداد تخمین حاصل از بوت استرپ است. مقدار t از جدول t - استیودنت و از بوت استرپ درصد $\frac{a}{2}$ برای توزیع t - استیودنت با درجه آزادی p و $n-p$ کل پارامترها در شبکه عصبی و تعداد کل مشاهدات است.

معیارهای ارزیابی

ارزیابی صحت و اعتبار توابع انتقالی از نمایه های ضریب همبستگی¹ (R) و ریشه میانگین مربعات خطا (RMSE²) محاسبه شده از روابط 15، 16 صورت گرفت. بهترین مقدار برای این دو معیار به ترتیب یک و صفر هست.

$$R = \frac{\hat{a}_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\hat{a}_{i=1}^n (x_i - \bar{x})^2 \hat{a}_{i=1}^n (y_i - \bar{y})^2}} \quad [15]$$

$$RMSE = \sqrt{\frac{1}{n} \hat{a}_{i=1}^n (x_i - y_i)^2} \quad [16]$$

در روابط بالا X_i و Y_i به ترتیب مقادیر مشاهداتی و محاسباتی، n تعداد داده‌ها، \bar{x} و \bar{y} به ترتیب میانگین مقادیر مشاهداتی و محاسباتی هست. علاوه بر معیارهای فوق از آزمون مرگان-گرنجر-نیوبلد³ (MGN) برای معنی‌دار بودن تفاوت RMSE و R بین توابع انتقالی ایجاد شده، استفاده می‌شود. در این روش

است. جایی که $\{(x_i, y_i)\}^0$ یک نمونه تصادفی با توزیع مستقل و یکسان از F و شامل بردار پیش‌بینی کننده x_i و متغیر خروجی y_i متناظر آن است. \hat{F} تابع توزیع تجربی از T_n و T^n نمونه تصادفی با اندازه n که از یک توزیع مستقل و یکسان که با جایگذاری از \hat{F} گرفته شده است. درحالی‌که \hat{F} یک مشاهده تصادفی منفرد از $\{(x_i, y_i)\}^0$ است. B سری از نمونه‌های بوت استرپ شده به صورت T^1, T^2, \dots, T^B ارائه شده که B تعداد نمونه‌های بوت استرپ شده است که دامنه آن بین 50 تا 200 است (افرون و تیپ شیرانی 1993). برای هر T^B شبکه عصبی جداگانه اجرا می‌شود که خروجی آن با $f_{ANN}(x_i, w_b/T^b)$ نشان داده می‌شود. برای ارزیابی آموزش شبکه از ی‌هایی که در داخل نمونه B نیستند، استفاده می‌شود. برای محاسبه خطای تعمیم از میانگین نتایج حاصل از اجراء مدل برای نمونه‌های بوت استرپ شده، استفاده می‌شود. در نهایت خطای تعمیم برای شبکه عصبی از رابطه زیر حاصل شده است (تومی و اسمیت 1998):

$$E_0 = \frac{\hat{a}_{b=1}^B \hat{a}_{i=A_b} (y_i - f_{ANN}(x_i, w_b/T^b))^2}{\hat{a}_{b=1}^B (A_b)} \quad [11]$$

در فرمول بالا خروجی‌های حاصل از نمونه‌های بوت استرپ با علامت $f_{ANN}(x_i, w_b/T^b)$ نشان داده می‌شود. A_b مجموعه‌ای از شاخص A_b های مربوط به جفت‌های مشاهده‌ای است که شامل نمونه‌های بوت استرپ T^B نیستند، w_i, x_i به ترتیب نشان‌گر بردار وزن و ورودی، $(A_b)^1$ تعداد شاخص‌های جفت مشاهده‌ای در A_b است. برای یک وردی جدید x ، تخمین شبکه عصبی بوت استرپ شده (که در حقیقت متوسط B تخمین حاصل از بوت استرپ است) است که رابطه 12 به دست آمد. برای تخمین $\hat{\delta}_{boot}^2(x)$ از رابطه 13 استفاده شد.

$$\hat{\theta}_{(x)} = \frac{1}{B} \hat{a}_{b=1}^B f_{ANN}(x_i, w_b/T^b) \quad [12]$$

¹Correlation coefficient

²Root mean square error

³Morgan-Granger-Newbold test

که بر اساس طبقه‌بندی دکستر این نوع خاک‌ها، شاخص کیفیت فیزیکی و ساختمانی خوبی دارند. دکستر (2004) بر اساس اطلاعات جمع‌آوری شده از خاک‌های هفت‌کشور که مقادیر رس آن‌ها بین 4 تا 73 درصد بود سه کلاس $S_i < 0/020$ خیلی ضعیف، $0/02 < S_i < 0/035$ ضعیف، $S_i > 0/035$ خوب را برای شاخص کیفیت فیزیکی خاک پیشنهاد کرد.

جدول 2 نشان می‌دهد که در غالب موارد همبستگی‌های بالا و معنی‌داری بین ویژگی‌های خاک وجود دارد. وجود همبستگی بین ویژگی‌های خاک نشانه‌ای از وجود ارتباط بین آن‌ها هست که برای ایجاد توابع انتقال ضروری هست (بیات و همکاران 2011). شاخص S_i با بیشتر خصوصیات مورد مطالعه همبستگی بالایی دارد. در بین پارامترهای مورد بررسی همبستگی بین شاخص S_i با درصد رس، سیلت، جرم مخصوص ظاهری و رطوبت مزرعه‌ای منفی بوده و همبستگی آن با سایر پارامترها مستقیم هست (جدول 2).

روند کاهش شاخص S_i با افزایش مقدار رس توسط دکستر (2004)، امامی و همکاران (1387) گزارش شده است. وجود رس زیاد در خاک باعث می‌شود نسبت منافذ بافتی به منافذ ساختمانی افزایش یافته و در نتیجه باعث کاهش شاخص S_i می‌شود. در رابطه با همبستگی منفی بین شاخص S_i و جرم مخصوص ظاهری می‌توان گفت احتمالاً با افزایش جرم مخصوص ظاهری میزان تخلخل بافتی نسبت به ساختمانی افزایش یافته است. چنین نتایجی توسط دکستر (2004) و امامی و همکاران (1387) به دست آمده است.

ابتدا خطای پیش‌بینی دو تابع انتقال مختلف که با $e_{1,i}, e_{2,i}$ نشان داده می‌شود، محاسبه شد.

$$e_{1,i} = X_{mi} - X_{1i} \quad [17]$$

$$e_{2,i} = X_{mi} - X_{2i} \quad [18]$$

$$s_i = e_{1,i} + e_{2,i} \quad [19]$$

$$d_i = e_{1,i} - e_{2,i} \quad [20]$$

به ترتیب مقادیر خروجی توابع انتقالی اول و دوم برای یک ویژگی و X_{mi} مقادیر اندازه‌گیری شده همان ویژگی می‌باشند. آزمون برابری میانگین مجذور خطای دو روش مختلف، در مقابل کمتر بودن خطای روش اول با استفاده از آماره MGN ارزیابی شد.

$$MGN = \frac{P_{sd}}{\sqrt{\frac{1 - P_{sd}}{n - 1}}} \quad [21]$$

که در آن ضریب همبستگی بین S_i و d_i ، n تعداد مشاهدات است. مقدار MGN محاسبه شده با جدول t با درجه آزادی $n-1$ مقایسه می‌گردد (دیبولد و ماریانو 1995).

نتایج و بحث

مروری بر ضریب تغییرات متغیرهای مستقل و وابسته نشان می‌دهد (جدول 1) که عمده متغیرهای مربوط به بافت، ساختمان و خصوصیات شیمیایی خاک (به استثناء وزن مخصوص ظاهری و تخلخل) دارای دامنه تغییرات نسبتاً بالایی هستند. توزیع بافت 176 نمونه، خاک از 12 کلاس بافتی به جز دو کلاس شن و سیلت بقیه را پوشش می‌دهند. میانگین S_i در خاک‌های مورد مطالعه 0/045 و دامنه آن در محدوده 0/02-0/18

جدول 1- ویژگی‌های آماری متغیرهای مستقل و وابسته اندازه‌گیری شده بر روی 176 نمونه خاک.

متغیر	Silt (%)	Clay (%)	Sand (%)	Db (g cm ⁻³)	Sg (mm)	dg (mm)	f (cm ³ m ⁻³)	MWD (mm)
کمین	7/17	4/99	0/0	1/17	5/08	0/00	0/43	0/1
بیشینه	64/79	62/86	80/64	1/66	33/63	0/38	0/55	6/33
میانگین	36/15	31/91	31/93	1/35	18/08	0/05	0/49	2/08
انحراف استاندارد	10/75	13/35	20/10	0/10	6/77	0/06	0/03	1/99
ضریب تغییرات (%)	29	41	62	7	37	120	6	95/6
متغیر	pH (-)	EC (dS m ⁻¹)	OM (%)	CCE (%)	SAVI (-)	DEM (m)	Si (-)	
کمین	5/46	0/01	0/31	0/91	0/12	-2	0/02	
بیشینه	8/57	66/80	4/74	26/69	0/68	1710	0/18	
میانگین	7/53	4/58	1/61	12/26	0/39	1000	0/045	
انحراف استاندارد	0/64	11/30	1/03	5/97	0/15	658	0/022	
ضریب تغییرات (%)	8	246	63	48	39	65	50/3	

FC رطوبت معادل 30 کیلو پاسکال، جرم مخصوص ظاهری (Db)، تخلخل کل (f)، مقدار ماده آلی (OM)، درصد

کربنات کلسیم معادل (CCE)، میانگین هندسی قطر خاکدانه‌ها (dg)، انحراف استاندارد هندسی قطر خاکدانه‌ها (Sg)،

میانگین هندسی قطر خاکدانه‌ها (MWD)، شاخص Si و شاخص پوشش گیاهی (SAVI) و مدل رقومی ارتفاع (DEM).

ورودی ممکن، از شبکه عصبی سلسله مراتبی¹ استفاده شد. در این نوع شبکه به منظور یافتن مناسب‌ترین ورودی‌ها، متغیرها به صورت گام‌به‌گام مطابق جدول 3 وارد مدل گردیدند. انتخاب متغیرها بر اساس سهل‌الوصول بودن و میزان تأثیر بر پایداری ساختمان خاک هست. در هر مرحله دقت تخمین برای مجموعه داده‌های صحت‌سنجی محاسبه گردید. اگر ورود متغیری باعث کاهش معنی‌دار RMSE گردید، در مراحل بعد در مدل باقی ماند و در غیر این صورت از مدل حذف شد. تفاوت آماری قدرت تخمین توابع ایجاد شده، برحسب آزمون MGN، از روی اختلاف مقادیر تخمین زده شده توسط تابع و مقادیر اندازه‌گیری مورد ارزیابی قرار گرفت. تمام 12 مرحله فوق به دو روش شبکه عصبی معمولی و بوت استرپ شده انجام و نتایج آن‌ها با هم مقایسه شد.

وجود همبستگی مثبت بین شاخص Si و شاخص SAVI، مواد آلی و کربنات کلسیم معادل خاک نشان‌دهنده نقش این عوامل در تشکیل و پایداری ساختمان خاک است. در رابطه با تأثیر کربنات کلسیم بر ساختمان خاک، امرسون و گرین لند (1990) عنوان کردند که کربنات‌ها به عنوان منبع یون Ca⁺² عمل نموده و به فولکوله شدن ذرات رس و پایداری منبع کمپلکس تبادل می‌کنند. رابطه مثبت بین کربنات کلسیم معادل و شاخص Si توسط امامی و همکاران (1387) نیز مشاهده شده است. همچنین وجود همبستگی مثبت بین شاخص Si و EC عصاره اشباع بیان‌گر این مسئله است که املاح موجود در محلول خاک به تشکیل خاکدانه‌ها کمک می‌کنند. لذا با افزایش مقدار EC، شاخص Si نیز افزایش یابد (جدول 2).

انتخاب متغیرهای مناسب به عنوان ورودی توابع

انتقالی، در توانایی پیش‌بینی مدل از اهمیت ویژه‌ای برخوردار است. به همین دلیل برای یافتن مناسب‌ترین

¹Hierarchical artificial neural network

جدول 2- ضرایب همبستگی بین متغیرهای ورودی و خروجی.

	MW D	FC	CCE	OM	EC	pH	f	D _b	dg	Sg	Clay	Silt	Sand	DEM	SAVI
S _i	0/47**	- 0/22**	0/34* *	0/31**	0/27* *	0/33*	0/24**	-0/24 **	0/13	0/24**	-0/25 **	-0/24 **	0/22**	0/41**	0/34* *
WD	1	0/39* *	- 0/36**	0/62**	- 0/22**	0/54*	0/002	0/01	-0/26*	0/48**	0/35**	0/36**	- 0/43**	- 0/80**	0/57* *
FC		1	0/17*	0/15*	-0/04	0/49*	0/42**	0/43**	-0/65*	0/51**	0/59**	- 0/55**	- 0/68**	-0/52*	0/05
CCE			1	0/14	-0/01	0/37*	-0/04	-0/01	-0/017	0/003	0/004	- 0/006	0/001	0/37*	- 0/20*
OM				1	- 0/17**	0/35*	-1/22	0/11	-0/07	0/34*	0/18	0/21	-0/23	-0/52*	0/51*
EC					1	0/05	0/06	-0/51	0/020	0/09	-0/07	-0/01	0/06	0/20*	- 0/18*
pH						1	0/26*	0/28**	0/42**	0/40**	- 0/42**	0/40* *	0/49**	0/73**	- 0/70*
f							1	0/89**	-0/43*	0/19*	0/30**	0/29* *	- 0/36**	-0/16	- 0/20*
D _b								1	0/53**	0/20*	- 0/30**	0/32* *	0/43**	0/18	0/20*
dg									1	0/49**	- 0/77**	- 0/67**	0/87**	0/44*	-0/01
Sg										1	- 0/61**	0/79* *	0/83**	0/65**	- 0/35*
Clay											1	0/38* *	- 0/87**	-0/57*	0/14
Silt												1	- 0/79**	-0/50*	0/18*
Sand													1	-0/50*	-0/19
DEM														1	0/52* *
SAVI															1

* و ** به ترتیب معنی داری در سطوح 5 و 1 درصد را نشان می دهند

در افزایش درستی تخمین S_i نگذاشت. علتش احتمالاً این است که با حضور درصد شن و سیلت و رس در لیست متغیرها افزودن Sg، Dg که از روی همان درصدها محاسبه می شوند بهبود چندانی در درستی تخمین ایجاد نشود. وارد کردن شاخص پوشش گیاهی در مرحله سوم، RMSE تابع انتقالی ایجاد شده را به طور معنی-داری کاهش داد (جدول 4). در مرحله چهارم نیز افزودن درصد ماده آلی به ورودی های مدل افزایش RMSE را به دنبال داشته است. شوکلا و ابینگر (2006) عنوان

در مرحله اول جدول 4 استفاده تنها از اطلاعات بافت خاک در تشکیل تابع انتقال سبب شده، کمترین ضریب همبستگی و بیشترین خطا در تخمین S_i نسبت به یازده تابع بعدی حاصل شود. وریکن و همکاران (1989) نیز در مقایسه 21 تابع انتقالی گزارش کردند که تنها استفاده از متغیر بافت خاک به نتایج نامطلوبی در پیش بینی میزان رطوبت در فشار 30-، 1500- کیلو پاسکال منجر خواهد شد. در مرحله دوم بهره گیری از اطلاعات جزئی تر بافت خاک (Sg، Dg) تأثیر چشمگیری

بهره‌گیری از SAVI و ارتفاع به‌عنوان ورودی PTF به اثبات می‌رساند ولی تحقیقی که در آن از SAVI و ارتفاع در تابع انتقال مربوط به شاخص S_i استفاده شده باشد، در منابع گزارش نشده است. در تابع انتقالی مرحله نهم افزودن تخلخل کل (f) به‌عنوان برآوردگر بهبود معنی-داری را در RMSE و R نسبت به مرحله قبلی نشان نداد (جدول 4). مرور کلی بر مقدار RMSE و R در جدول 4 نشان می‌دهد مدلی که ورودهای آن درصد سیلت، شن و رس، SAVI، DEM، MWD، درصد کربنات کلسیم و وزن مخصوص ظاهری، pH، EC، FC است، بهترین مدل برای پیش‌بینی شاخص S_i را می‌باشد.

کردند ماده آلی خاک باید به‌عنوان یک پارامتر مهم در بررسی کیفیت خاک لحاظ شود. به‌طور کلی افزایش مواد آلی به خاک باعث افزایش پایداری ساختمان خاک می‌شود. اما نتایج تحقیق بیان‌گر این مسئله است که اگر در تابع انتقال S_i ، SAVI جایگزین ماده آلی شود، می‌تواند با کمینه هزینه و زمان، تخمین بهتری از شاخص کیفیت فیزیکی ارائه نمود. در مرحله ششم افزودن ارتفاع به ورودی‌های مرحله قبل منجر به کاهش معنی‌دار RMSE شد. البته با توجه به تأثیر ارتفاع بر جریان توده‌های هوایی، میزان بارش، باد، دما و رطوبت (فرانکلین و همکاران 2000) چنین نتایجی دور از انتظار نیست. نتایج این تحقیق بهبود برآورد شاخص S_i را در صورت

جدول 3- متغیرهای ورودی در هر مرحله برای ایجاد PTF ها.

مرحله	متغیرهای ورودی جدید برای هر مرحله	تابع انتقالی ایجاد شده
1	Clay+ Silt+ Sand	PTF ₁
2	Dg, Sg+ PTF ₁	PTF ₂
3	SAVI+ PTF ₂	PTF ₃
4	OM+ PTF ₃	PTF ₄
5	MWD+ PTF ₄	PTF ₅
6	DEM + PTF ₅	PTF ₆
7	CCE + PTF ₆	PTF ₇
8	EC + PTF ₇	PTF ₈
9	f + PTF ₈	PTF ₉
10	Db+ PTF ₉	PTF ₁₀
11	FC+ PTF ₁₀	PTF ₁₁
12	pH + PTF ₁₁	PTF ₁₂

(ذوالفقاری و همکاران 2015، شارما و همکاران 2006، لی‌جی و همکاران 2004، پاچپسکی و همکاران 2001) گزارش شده است.

نگاهی به شکل 1 و مقایسه R^2 بین مقادیر اندازه‌گیری شده و برآوردهای حاصل از تابع انتقالی نهایی (تابع حاصل از مرحله 12) S_i با و بدون حضور دو متغیر SAVI، DEM، به وضوح نشان می‌دهد که با افزودن دو متغیر به خصوصیات پایه خاک بهبودی قابل توجهی (بهبود 16 درصدی در مرحله آموزش، 9 درصدی در مرحله صحت‌سنجی) در R^2 تابع حاصل شده است. البته بهبود حاصل از افزودن دو متغیر SAVI و DEM به خصوصیات پایه خاک به‌منظور تخمین خصوصیات هیدرولیکی و مکانیکی خاک توسط محققان

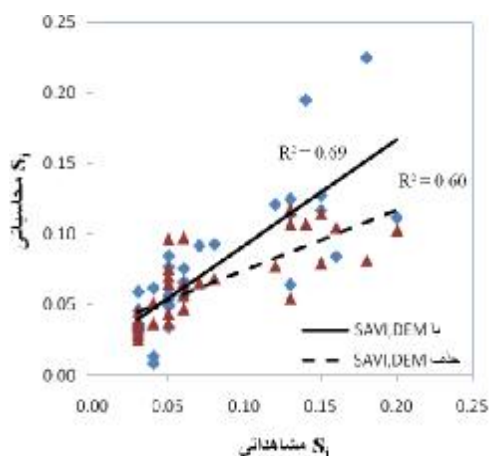
جدول 4- ضرایب همبستگی و ریشه میانگین مربعات خطا بین خروجی توابع ایجاد شده و مقادیر مشاهداتی S_i به دو روش

.ANN و BANN


MGN (آموزش)	BANN				ANN				متغیر PTF و رودی PTF	PTF
	آموزش		صحت سنجی		آموزش		صحت سنجی			
	R	RMSE (-)	R	RMSE (-)	R	RMSE (-)	R	RMSE (-)		
4/98	0/49	0/034	0/45	0/038	0/47	0/035	0/43	0/039	Clay+ Silt+ Sand	1
6/87	0/36	0/042	0/35	0/041	0/33	0/047	0/32	0/049	Dg, Sg+ PTF _v	2
3/86	0/59	0/032	0/56	0/033	0/57	0/033	0/52	0/034	SAVI+ PTF _v	3
5/08	0/55	0/033	0/46	0/038	0/51	0/034	0/43	0/045	OM+ PTF _v	4
2/45	0/66	0/030	0/62	0/031	0/65	0/031	0/59	0/032	MWD+ PTF _v	5
3/76	0/77	0/025	0/75	0/026	0/75	0/027	0/72	0/029	DEM + PTF _v	6
4/27	0/80	0/023	0/77	0/025	0/77	0/026	0/75	0/027	CCE + PTF _v	7
6/01	0/83	0/021	0/81	0/023	0/78	0/024	0/78	0/025	EC + PTF _v	8
3/83	0/75	0/027	0/73	0/028	0/73	0/028	0/69	0/030	f + PTF _v	9
6/98	0/85	0/020	0/76	0/025	0/80	0/025	0/75	0/027	Db+ PTF _v	10
2/74	0/87	0/018	0/86	0/020	0/85	0/021	0/83	0/024	FC+ PTF _v	11
4/69	0/90	0/017	0/89	0/019	0/86	0/019	0/85	0/021	pH + PTF _v	12

† جهت معنی دار شدن تفاوت بین توابع ایجاد شده به دو روش شبکه عصبی بوت استرپ و معمولی در یک مرحله مشابه در آموزش معیار MGN باید بیشتر از 2/01 باشد.

- علائم به کار رفته در جدول فوق زیر جدول 1 توصیف شده است.



(ب)



(الف)

شکل 1 - مقایسه مقادیر مشاهداتی و محاسباتی (الف) مرحله آموزش و (ب) مرحله صحت سنجی برای شبکه عصبی معمولی بعد و قبل از افزودن دو متغیر SAVI, DEM.

تحلیل عدم قطعیت

می‌دهد بیشترین کاهش در سطح عدم قطعیت با افزودن SAVI و ارتفاع به‌عنوان ورودی حاصل شده است. نتایج تحقیقات شارما و همکاران (2006) نشان دادند افزودن SAVI و ارتفاع در تمام نقاط پتانسیلی مورد مطالعه، کاهش در عدم قطعیت را به دنبال داشت است. عدم قطعیت حاصل از بوت‌استرپ دقیقاً با نتایج حاصل از ضریب همبستگی و RMSE همخوانی دارد (جدول 4). در مدل‌هایی که با ضریب همبستگی بالاتر و RMSE کمتری مواجه هستیم عدم قطعیت کمتری هم مشاهده شده است.

جدول 4 و مروری بر مقادیر ضریب همبستگی و خطا نشان می‌دهد در تمامی 12 مرحله توابع انتقالی ایجاد شده با روش شبکه عصبی بوت‌استرپ بطور معنی‌داری (آزمون MGN) از درستی تخمین بالاتری در مقایسه با شبکه عصبی معمولی برخورداراند.

جدول 5 فاصله اطمینان 95% (حد بالا) و 5% (حد پایین) حاصل از بوت‌استرپ را برای شاخص S_i نشان می‌دهد. فاصله بین دو حد بالا و پایین بیانگر عدم قطعیت در پیش‌بینی مدل است. در جدول 5 با افزایش سلسله مراتبی در ورودی مدل، با یک کاهش عمومی در عدم قطعیت‌ها مواجه می‌شویم. نتایج به وضوح نشان

جدول 5- فاصله اطمینان 95% برای شاخص S_i با استفاده از روش بوت‌استرپینگ.

شاخص S_i			PTF
حد بالا	حد پایین	میانگین	
۰/۰۴۳۸	۰/۰۳۸۵	۰/۰۴۲۵	Clay+ Silt+Sand
۰/۰۴۴۶	۰/۰۳۷۲	۰/۰۴۲۸	Dg, Sg+ PTF _۱
۰/۰۴۳۶	۰/۰۳۹۱	۰/۰۴۱۸	SAVI+ PTF _۲
۰/۰۴۳۸	۰/۰۳۸۸	۰/۰۴۰۷	OM+ PTF _۳
۰/۰۴۳۲	۰/۰۳۹۲	۰/۰۴۱۵	MWD+ PTF _۴
۰/۰۴۲۶	۰/۰۳۹۸	۰/۰۴۰۹	DEM + PTF _۵
۰/۰۴۲۳	۰/۰۴۰۰	۰/۰۴۱۰	CCE + PTF _۶
۰/۰۴۲۰	۰/۰۴۰۲	۰/۰۴۰۸	EC + PTF _۷
۰/۰۴۲۹	۰/۰۳۹۳	۰/۰۴۱۷	f + PTF _۸
۰/۰۴۱۸	۰/۰۴۰۳	۰/۰۴۱۳	Db+ PTF _۹
۰/۰۴۱۴	۰/۰۴۰۷	۰/۰۴۰۹	FC+ PTF _{۱۰}
۰/۰۴۱۲	۰/۰۴۰۸	۰/۰۴۱	pH + PTF _{۱۱}

نتیجه‌گیری کلی

افزودن SAVI و DEM به‌عنوان ورودی، سبب بهبود 16 درصدی و معنی‌دار از نظر آماری در برآورد تابع S_i شد. بنابراین با توجه به تأثیر غیر مستقیم ارتفاع و شاخص پوشش گیاهی بر خصوصیات فیزیکی و شیمیایی خاک و از طرفی سهولت دسترسی به داده‌های لندست 8 با قدرت تفکیک مطلوب سبب خواهد شد

وجود همبستگی معنی‌داری بین شاخص S_i با SAVI و DEM سبب شد علاوه بر ویژگی‌های متداول خاک که در اغلب تحقیقات و گزارشات خاک شناسی یافت می‌شود از این دو پارامتر نیز به‌عنوان متغیر مستقل در تابع تخمینی S_i استفاده شود. نتایج نشان داد برای تابع انتقالی S_i با ترکیبی از خصوصیات پایه خاک

مصنوعی انجام می‌دهند. به‌طور کلی شبکه عصبی مصنوعی بوت استرپ شده از اعتبار و اطمینان بالاتری در برآورد شاخص S_i خاک در مقایسه با شبکه عصبی مصنوعی متداول برخوردار است. ضمن اینکه روش مذکور قادر به برآورد عدم قطعیت تخمین‌ها نیز می‌باشد.

این دو متغیر به ابزاری مناسب در توسعه توابع انتقال درمقیاس زمین‌نما تبدیل شوند. از طرفی بررسی عملکرد شبکه عصبی مصنوعی بوت استرپ شده و معمولی در کنار یکدیگر نشان داد در تمامی توابع انتقال مورد مطالعه، شبکه عصبی بوت استرپ شده پیش‌بینی را با خطای کمتری نسبت به روش شبکه عصبی

منابع مورد استفاده

امامی ح، شرفاء م، نیشابوری مر و لیاقت عا، 1387. برآورد شاخص کیفیت فیزیکی خاک با استفاده از ویژگی‌های زود یافت خاک در تعدادی از خاکهای شور و آهکی. علوم کشاورزی ایران (مجله تحقیقات آب و خاک ایران)، دوره 39، شماره 1، صفحه-های 39 تا 46.

پرویز ل، خلقی م، ولی زاده خ، عراقی نژاد ش و ایران نژاد پ، 1389. ارزیابی کارایی شاخص تفاضل نرمال شده پوشش گیاهی از طریق پایش وضعیت پوشش گیاهی. صفحه‌های 432 تا 441. مجموعه مقالات همایش ملی ژئوماتیک. 1-2 اردیبهشت ماه، سازمان نقشه برداری کشور، تهران.

علوی پناه س ک، 1382. کاربرد سنجش از دور در علوم زمین (علوم خاک). مؤسسه انتشارات و چاپ دانشگاه تهران، صفحه‌های 45 تا 46.

- Bates BC and Townley LR, 1988. Nonlinear, discrete flood event models: 3. Analysis of prediction. Uncertainty. *J Hydrol.* 99: 91–101.
- Bayat H, Neyshabouri MR, Mohammadi K and Nariman-Zadeh N, 2011. Estimating water retention with pedotransfer functions using multi-objective group method of data handling and ANNs. *Pedosphere* 21: 107-114.
- Blak GR and Hartge KH, 2002. Bulk density. Pp. 809-812. In: Dan JH and Topp GC (eds) *Methods of Soil Analysis. Part 4. Physical Methods.* ASA and SSSA, Madison WI.
- Dane JH and Hopmans JW, 2002. Pressure plate extractor. Pp.688-690. In: Dan J H and Topp GC (eds) *Methods of Soil Analysis. Part 4. Physical Method.* ASA and SSSA, Madison WI.
- Diebold FX and Mariano RS, 1995. Comparing Predictive Accuracy. *J. Bus and Econ. Stat* 13: 253–263.
- Dexter AR, 2004. Soil physical quality. Part I: Theory, effects of soil texture, density, and organic matter, and effects on root growth. *Geoderma* 120: 201-214.
- Efron B and Tibshirani RJ, 1993. *An Introduction to the Bootstrap.* Chapman and Hall, London, UK.
- Emerson WW and Greenland DJ, 1990. Soil aggregates-formation and stability. Pp. 485-511. In: De Boodt MF, Hayes MHB and Herbillion A (eds). *Soil Colloids and Their Associations in Aggregates.* Plenum Press, New York.
- Franklin J, Mccullough P and Gray C, 2000. Terrain variables used for predictive mapping of vegetation communities in Southern California. Pp331-354. In: Wilson JP and Gallant JC (eds) *Terrain Analysis: Principles and Applications.* John Wiley and Sons. New York.
- Gee GW and Bauder JW, 1986. Particle - size analysis. Pp. 383–411. In: Klute A (ed) *Methods of Soil Analysis Part 1. 2nd ed. Physical and Mineralogical Methods.* ASA and SSSA, Madison, WI.
- Guerif J, Richard G, Durr C, Machet JM, Recous S and Rogrerestrade J, 2001. A review of tillage effects on crop residue management, seedbed conditions and seedling establishment. *Soil Tillage Res* 61: 13-32.
- Leij FJ, Romano N, Palladino M and Schaap MG, 2004. Topographical attributes to predict soil hydraulic properties along a hillslope transect. *Water Resour Res* 40: 1–15.
- Nelson RE, 1982. Carbonate and gypsum. Pp. 181-197. In Page AL(ed) *Methods of Soil Analysis. Part 2. 2nd ed.* Agron. Monogr. 9. ASA and SSSA, Madison, WI.
- Pachepsky YA, Timlin DJ and Rawls WJ, 2001. Soil water retention as related to topographic variables. *Soil Sci Soc Am J* 65: 1787– 1795.

- Romano N, Hopmans JW and Dane JH, 2002. Suction table. Pp.692-698. In: Dan JH and Topp GC (eds) *Methods of Soil Analysis. Part 4. Physical Methods*. ASA and SSSA, Madison WI.
- Sharma SK, Mohanty BP, Zhu J, 2006. Including topography and vegetation attributes for developing pedotransfer functions in southern great plains of USA. *Soil Sci Soc Am J* 70: 1430–1440.
- Shirazi MA and Borema L, 1984. A unifying quantitative of soil texture. *Soil Sci Soc Am J* 48: 142- 147.
- Shukla MK, Lal R and Ebinger M, 2006. Determining soil quality indicators by factor analysis. *Soil Tillage Res* 87(2): 194-204.
- Stuart G, Bienenstock E and Doursat R, 1992. Neural networks and the bias/variance dilemma. *NC* 4:1-58.
- Twomey JM and Smith AE, 1998. Bias and variance of validation methods for function approximation neural networks under conditions of sparse data. *IEEE Transactions on Systems, Man and Cybernetics C: Applications and Reviews* 28(3): 417–430.
- Van Genuchten MTh, Leij FJ and Yates SR, 1991. The RETC code for quantifying the hydraulic functions of unsaturated soils. Kerr S, Environmental Research Laboratory, Office of Research and Development, U.S. Environmental Protection Agency. Ada OK 74820.
- Vereecken H, Maes J, Feyen J and Darius P, 1989. Estimating the soil moisture retention characteristics from texture, bulk density and carbon content. *Soil Sci Soc Am J* 148(6): 389-403.
- Walkley A and Black IA, 1934. An examination of the Degtjareff method for determining soil organic matter and a proposed modification of the chromic acid titration method. *Soil Sci* 37: 29-39.
- Yoder RE, 1936. A direct method of aggregate analysis and a study of a physical nature of erosion losses. *J Am Agron* 28: 337-351.
- Zolfaghari Z, Mosaddeghi MR and Ayoubi S, 2015. ANN-based pedotransfer and soil spatial prediction functions for predicting Atterberg consistency limits and indices from easily available properties at watershed scale in western Iran. *Soil Use Manag.* doi: <http://dx.doi.org/10.1111/sum.12167>.