

عملکرد داده‌های سنجش از دوری در ارزبایی تخریب خاک

* بهزاد رایگانی^۱

۱. استادیار دانشکده محیط زیست، سازمان حفاظت محیط زیست، کرج، ایران

* نویسنده مسئول: behzad.rayegani@gmail.com

تاریخ دریافت: ۱۳۹۳/۰۸/۰۹ تاریخ پذیرش: ۱۳۹۴/۱۲/۱۸

چکیده

در این تحقیق سعی شده است با بهره‌گیری از دو مدل میدانی، توانایی داده‌های سنجش از دوری در مدل‌سازی تخریب خاک مورد آزمون قرار گیرد. بر اساس یافته‌های این پژوهش، در بررسی سنجش از دوری کیفیت خاک، نوع پیش‌پردازش انجام شده بر روی داده‌ها، اثر قابل‌ملاحظه‌ای در مدل‌سازی‌ها نشان نخواهد داد. بر عکس نوع مدل میدانی مورد استفاده و شاخص‌ها و معیارهای آن، تاثیر زیادی بر روی دقت مدل‌سازی دارد. همچنین در مورد برخی شاخص‌های میدانی بررسی وضعیت خاک، استفاده از شاخص‌های سنجش از دوری مانند شاخص اکسید آهن و شاخص موادمعدنی، به افزایش دقت مدل‌سازی کمک قابل توجه‌ای می‌نماید. بر اساس نتایج بدست آمده، استفاده از سری‌زمانی داده‌های سنجش از دوری نسبت به داده‌های تک‌زمانه به طور چشمگیری توان مدل‌سازی پارامترها مرتبط با خاک را افزایش می‌دهد. همچنین استفاده از مدل‌سازی‌های شبکه‌های عصبی مصنوعی بجای استفاده از رگرسیون خطی با غیر خطی نمودن روابط، باعث افزایش توان مدل‌سازی‌های سنجش از دوری در حالت تک‌زمانه خواهد شد، اما دقت مدل‌سازی شبکه‌های عصبی سری‌های زمانی داده‌های سنجش از دوری با دقت مدل‌سازی‌های رگرسیونی تفاوت چندانی ندارد. در نهایت مشخص شد برخلاف آنچه تصور می‌گردد، افزایش بعد یا تعداد ورودی‌ها به مدل‌سازی شبکه عصبی در عمل باعث کاهش دقت واقعی مدل‌سازی خواهد شد نه افزایش آن.

واژگان کلیدی: ارزیابی پتانسیل بیابان‌زایی در ایران، متداولوزی بررسی تخریب زمین لادا، سری‌زمانی داده‌های سنجش از دور، رگرسیون چندمتغیره خطی، شبکه‌های عصبی مصنوعی

به متدولوژی مشروط ارزیابی و نقشهبرداری بیابان‌زایی^۱ که توسط فائو و یونپ ارائه گردیده است (*FAO/UNEP, 1983*)، نسبت داد. در این روش هفت فرآیند در تخریب زمین در نظر گرفته شده‌اند: ۱) تخریب پوشش گیاهی؛ ۲) فرسایش آبی؛ ۳) فرسایش بادی؛ ۴) شورشدن خاک؛ ۵) تشکیل سله و فشرده شدن خاک؛ ۶) کاهش مواد آلی؛ ۷) تجمع مواد سمی. در این فرآیندها شش نوع آن در ارتباط با تخریب خاک است.

متدولوژی نقشهبرداری مناطق زیستمحیطی حساس (ESAs)^۲ به بیابان‌زایی یا روش ارائه شده توسط پروژه *MEDALUS*^۳ در این روش انواع مختلف مناطق حساس زیست محیطی (ESAs) به بیابان‌زایی بوسیله معیارهای کلیدی خاصی قابل تشخیص و نقشهبرداری می‌باشند. این معیارها توانایی زمین را در مقاومت در برابر تخریب بیشتر، می‌سنجند یا نشان می‌دهند زمین تا چه اندازه‌ای برای یک استفاده خاص مناسب است. در روش مدل‌الوس معیارهای کلیدی برای تعريف مناطق حساس زیستمحیطی (ESAها) به بیابان‌زایی در چهار گروه کیفیت خاک، کیفیت اقلیم، کیفیت پوشش گیاهی و کیفیت مدیریت طبقه‌بندی شده است (Kosmas et al., 1999).

راهنمای میدانی لادا برای ارزیابی تخریب زمین در مقیاس محلی: پروژه‌ی ارزیابی تخریب زمین در مناطق خشک^۴ یا *LADA* که توسط سازمان خوار و بار جهانی^۵ (FAO) هدایت و اجرا شده است، در سال ۲۰۰۶ با هدف ایجاد پایه‌ای برای هدایت آگاهانه سیاسی در مورد تخریب زمین در سطح محلی، ملی و جهانی شروع به کار نمود. برای رسیدن به این هدف، نیاز بوده است، تخریب زمین در مقیاس‌های مختلف زمانی و مکانی ارزیابی شود و در سطح جهانی خطمنشی برای پایش در آینده ایجاد شود. مطابق با متدولوژی لادا تخریب زمین در سه بخش تخریب خاک، آب و پوشش گیاهی مورد ارزیابی قرار می‌گیرد (McDonagh & Bunning, 2009a, b).

در ایران، بر اساس نیاز محلی و منطقه‌ای مدل ایرانی ارزیابی پتانسیل بیابان‌زایی^۶ یا *IMDPA* در سال ۱۳۸۴ با

■ مقدمه

تخریب زمین یا بیابان‌زایی به علت اثرگذاری در کاهش توان بیولوژیکی یا اقتصادی آن از اهمیت ویژه‌ای برخوردار است. این تخریب از سه جزء اصلی تشکیل شده است: ۱) خاک؛ *de Paz et al., 2006; McDonagh & Bunning (2009a)* ۲) آب؛ ۳) پوشش گیاهی (. & Bunning, 2009a).

تخریب خاک به عنوان یکی از سه جزء اصلی تخریب زمین، همواره مطرح بوده (McDonagh & Bunning, 2009b) و بیش از چند دهه است، تلاش می‌شود، رابطه آن با بیابان‌زایی مشخص گردد. با توجه به اینکه خاک به عنوان یک منبع تجدیدناپذیر به شمار می‌رود (de Paz et al., 2006)، تخریب آن یک تهدید اساسی در سراسر کره زمین محسوب می‌شود، زیرا در دراز مدت، کاهش در توان تولیدی خاک و ناپایداری زیستمحیطی را به دنبال خواهد داشت (Diadato & Ceccarelli, 2004). بهطور کلی تخریب خاک زمانی مورد توجه قرار می‌گیرد که کمیت فرآیندهای طبیعی و انسانی درون خاک و کیفیت تولید زی توده خاک چهار نقصان شود بنابراین به منظور درک شرایط موجود، ناگزیر به ارزیابی شرایط و وضعیت خاک می‌باشیم (Snakin et al., 1996).

هر کدام از وجهه‌های تخریب خاک، شواهد و زیرمجموعه‌های مختلفی دارند و برای شناخت و ارزیابی آنها، معیارها و شاخص‌های مختلفی پیشنهاد شده است. تاکنون تلاش‌های زیادی برای گردآوری شاخص‌های تخریب خاک در قالب یک مدل صورت پذیرفته است و روش‌های مختلفی برای ارزیابی پذیره تخریب خاک ارائه شده است (Cammeraat & Imeson, 1998; de Paz et al., 2006; Diadato & Ceccarelli, 2004; McDonagh & Bunning, 2009a; Omuto, 2008; Rodríguez Rodríguez et al., 2005; Ruiz-Sinoga & Diaz, 2010; Sha-Sha et al., 2011; Snakin et al., 1996; Stocking & Murnaghan, 2000; Yanda, 2000) با این وجود شاید بتوان سه متدولوژی اصلی بررسی تخریب زمین را که در آنها معیار کیفیت خاک در نظر گرفته شده، به دلیل گستردگی بهره‌برداری، از دیگر مدل‌ها متمایز نمود:

متدولوژی ارزیابی و نقشهبرداری بیابان‌زایی فائو-یونپ: اولین روش ارزیابی و نقشهبرداری واقعی بیابان‌زایی را می‌توان

¹Provisional methodology for assessment and mapping of desertification

²Methodology for mapping Environmentally Sensitive Areas(ESAs) to Desertification

³ Mediterranean Desertification and Land Use

⁴ Land Degradation Assessment in Aridlands

⁵ Food and Agricultural Organization

⁶ Iranian Model of Desertification Potential Assessment

Haijiang et al., 2008; Helldén & Tottrup, 2008; Hill) (et al., 2008; Rasmussen et al., 2001 Feoli et al., 2002; Ibáñez et al., 2008; Jauffret & Visser, 2003; Okin et al., 2009; Ravi et al., 2010; Salvati & Zitti, 2009; Santini et al., 2010; Zucca et al., 2009) تجزیه و تحلیل نمایند.

اغلب پدیده‌های مختلف زیست محیطی را در قالب دو سناریو بررسی می‌نمایند (Wang et al., 2010): (الف) سناریوهای تک‌پارامتره (تکمعیاره؛ ب) سناریوهای چند پارامتره. در مطالعات سنجش از دوری ارزیابی خاک و تخریب آن نیز، به وضوح می‌توان هر دو سناریو را مشاهده نمود. اما بیشتر مطالعات سنجش از دوری بررسی وضعیت خاک تک‌پارامتره می‌باشند و حتی مطالعات چندپارامتره نیز در قالب یک مدل دیده نشده‌اند. در این میان مطالعات زیادی بر روی Douaoui et al., 2006; Gutierrez & Johnson, 2010; Masoud, 2014; Metternicht & Zinck, 2008; Wang et al., 2013 آشکارسازی سنجش از دوری شوری خاک (Gouze et al., 2011)، ترکیبات شیمیایی (Huang et al., 2007)، تکیک خاک‌های لخت از یکدیگر (Wang et al., 2013) و رطوبت خاک (Goodwin et al., 2005) (Zhao & Chen, 2005) به طور وسیع مورد بررسی قرار گرفته‌اند.

اما به ندرت می‌توان یک مطالعه سنجش از دوری چند معیاره تخریب خاک که در قالب یک مدل میدانی مورد پذیرش صورت گرفته باشد را مشاهده نمود.

بنابراین در این تحقیق سعی شده است با بهره‌گیری از دو مدل میدانی، توانایی داده‌های سنجش از دوری در مدل‌سازی تخریب خاک مورد آزمون قرار گیرد. در این پژوهش تلاش نمودیم ضمن بررسی عملکرد داده‌های سنجش از دوری، نشان دهیم این داده‌ها با چه دقیقی نقشه‌های تخریب خاک مورد نظر را بدست خواهند داد، در این قبیل مطالعات چه نوع داده‌های سنجش از دوری باید بکار گرفته شود؟، اصولاً داده‌های تک‌زمانه در مدل‌سازی دقیق بیشتری دارند یا داده‌های چند زمانه؟ و با غیرخطی نمودن مدل‌سازی تا چه اندازه می‌توان به بالا بردن دقیق مدل‌سازی امیدوار بود؟

بهینه‌سازی مدل *ESAs* ایجاد گردیده است (Ahmadi, 2005). برای انجام ارزیابی پتانسیل بیابان‌زایی در این مدل نه معیار مختلف پیشنهاد شده است: ۱) اقلیم؛ ۲) زمین‌شناسی-ژئومورفولوژی؛ ۳) خاک؛ ۴) پوشش گیاهی؛ ۵) کشاورزی؛ ۶) آب؛ ۷) فرسایش؛ ۸) اقتصادی-اجتماعی؛ ۹) تکنولوژی و توسعه شهری. در این مدل برای هر معیار سه تا چهار شاخص پیشنهاد شده است و در این بین، معیار خاک از چهار شاخص بافت خاک، عمق، شوری و درصد سنگریزه تشکیل شده است. در تمامی این مدل‌ها اساس ارزیابی، مطالعات میدانی و امتیازدهی به شرایط موجود می‌باشد. اما روش‌های میدانی به طور کلی زمان‌بر می‌باشند و استانداردهای لازم را در زمینه به روز بودن، قابل تعمیم بودن به دیگر مناطق و تجدید عملیات، ندارند و در مناطق بزرگ بسیار پر هزینه می‌باشند. در حالیکه روش‌های مرسوم برای تامین این گونه اندازه‌گیری‌ها، ناقص و بسیار هزینه‌بر می‌باشند، سیستم‌های تصویربرداری هوایی و سنجش از دوری ماهواره‌ای در این زمینه برتری‌های قابل ملاحظه‌ای دارند. با توجه به اینکه، این قبیل داده‌ها کل زمین را تحت پوشش قرار می‌دهند و داده‌های قابل تکرار، هدفمند و خلاصه‌ای در طیف‌ها و طول موج‌های مختلف فراهم می‌آورند، برای ارزیابی‌های منابع و پایش شرایط محیطی در مناطق خشک کاملاً مناسب می‌باشند (Pinet et al., 2006). بنابراین در تلاش‌های حاضر، به منظور بررسی کیفیت خاک و ارزیابی وضعیت آن، بیشترین تاکید بر روی تکنیک‌های سنجش از دوری قرار دارد تا مطالعات میدانی.

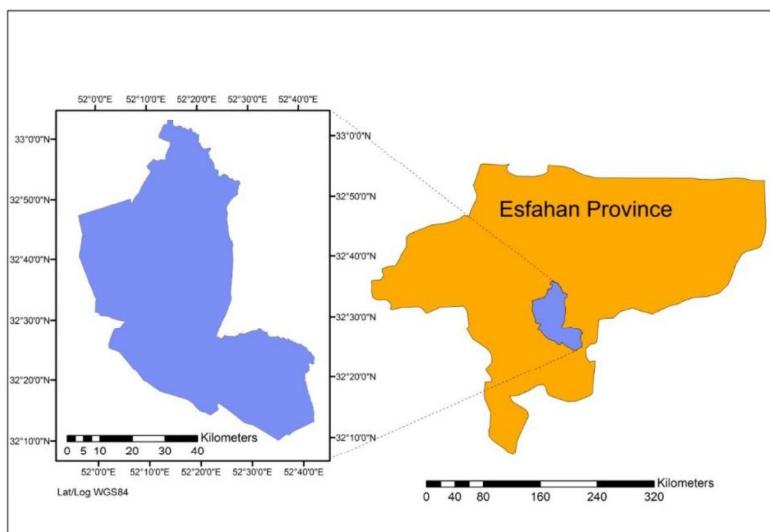
با توجه به وسعت مناطق بیابانی و دسترسی محدود به بسیاری از این مناطق، تلاش‌های زیادی صورت گرفته تا برخی از معیارها و شاخص‌های تخریب زمین و تخریب خاک (شناخت وضعیت و کیفیت آن) را بتوان به کمک داده‌های سنجش از دوری ارزیابی نمود، ولی هنوز هم یک سیستم شاخص و معیاری مناسب که از ترکیب داده‌های ماهواره‌ای دارای قدرت تفکیک زمینی بالا و مدل‌های اکولوژیکی حاصل شده باشد، وجود ندارد (Yang et al., 2005). با این وجود، با در نظر گرفتن جنبه‌های گستره‌ده و تهدیدکننده پدیده بیابان‌زایی و تخریب زمین در سراسر جهان، محققین بسیاری سعی نموده‌اند آنرا از طریق روش‌های و مدل‌های تجربی Geist & Lambin, 2004; Ladisa et al., 2012; Liu et al., 2003; Yang et al., 2005 روش‌های سنجش از دوری

و در مناطق مرتفع شمال در حدود ۲۵۰ میلیمتر در سال می‌باشد. رژیم بارندگی محدوده مطالعاتی، مدیترانه‌ای با فصل خشک متمنکز بر تابستان است. حداکثر بارش سالانه در بهمن ماه با میانگین ۱۵/۳ درصد بارش سالانه و حداقل آن در شهریور ماه با متوسط ۰/۲ درصد بارندگی سالانه به وقوع می‌پیوندد (Ahmadi, 2004). کاربری‌های عمده زمین در این ناحیه مطالعاتی شامل: ۱- مراتع و زمین‌های بدون پوشش (حدود ۶۵ درصد)، ۲- زمین‌های کشاورزی (حدود ۱۷ درصد) ۳- تاغزارها و ماسه‌زارها (حدود ۱۳ درصد) می‌باشند.

■ مواد و روش‌ها

منطقه مورد مطالعه

محدوده مورد مطالعه با مساحت ۳۴۵۵۹۱ هکتار بین طولهای شرقی "۵۶°۲۹'۵۶" تا "۵۱°۴۲'۲۲" و عرضهای شمالی "۳۲°۰۹'۰۵" تا "۳۳°۰۳'۰۵" در شرق استان اصفهان قرار گرفته است (شکل ۱). ارتفاع ناحیه مطالعاتی بین حدود ۱۱۰۰ متر در بخش جنوبی تا حدود ۳۵۰۰ متر در کوههای شمال شرق منطقه متغیر است. بخش وسیعی از محدوده مطالعاتی ارتفاع متوسط ۱۴۰۰ متر را تشکیل می‌دهد. میانگین بارش سالانه در مناطق کم ارتفاع حدود ۵۰ میلیمتر



شکل ۱- موقعیت منطقه مورد مطالعه در استان اصفهان

به منظور نمونه‌برداری از خاک منطقه مورد مطالعه از روش نمونه‌برداری لایه‌بندی شده تصادفی^۱ استفاده شده است تا بدین وسیله بتوان با ایجاد نواحی همگن نمونه‌برداری (Ravi et al., 2010; Salvati & Zitti, 2009) بیشتر تغییرات کمی و کیفی خاک را تحت پوشش قرار داد. بدین منظور نقشه‌های کاربری زمین، شبیب، سنگ‌شناسی، گروه بزرگ خاک در طبقه‌بندی FAO و تیپ پوشش گیاهی با یکدیگر ترکیب تا در مجموع ۱۷۲ سایت نمونه‌برداری ایجاد شد. نمونه‌برداری‌ها به طور تصادفی در داخل این سایتها صورت پذیرفت و در هر مکان نمونه‌برداری ضمن امتیازدهی و اندازه‌گیری برخی شاخص‌ها، از خاک نمونه‌هایی جهت کار در آزمایشگاه و اندازه‌گیری پارامترها تهیه شد. نمونه‌برداری‌ها و

روش مطالعه

نمونه‌برداری‌های میدانی

در این پژوهش دو متداول‌ترین بررسی کیفیت خاک بکار گرفته شده است: (۱) مدل ارزیابی پتانسیل بیابان‌زایی (Ahmadi, 2005) با توجه به سازگاری آن با شرایط آب و هوایی ایران، به عنوان اول روش بررسی شرایط خاک انتخاب گردیده است و (۲) راهنمای میدانی لادا برای ارزیابی تخریب زمین (McDonagh & Bunning, 2009a, b) نیز به علت به هنگام بودن و عدم مطالعه آن در کشور به عنوان روش دوم بکار گرفته شده است. جدول (۱) به طور خلاصه شاخص‌ها و معیارهای هر دو روش بررسی شرایط خاک در شرایط میدانی را نشان می‌دهد.

^۱ Stratified Random Sampling

گرفته شود. لازم به ذکر است در مورد شاخص‌هایی که کمی و قابل اندازه‌گیری بودند (pH ، EC ، سنگریزه و کربن آلی) در مدل‌سازی‌ها بجای امتیاز از مقدار کمی آن استفاده شده است تا خطا ناشی از مدل از بین برود.

اندازه‌گیری‌ها از تاریخ ۲۷ اردیبهشت ماه ۱۳۹۰ شروع و تا تاریخ ۱۷ تیرماه ۱۳۹۰ ادامه یافت. پس از کار آزمایشگاهی، امتیاز تمامی شاخص‌ها و معیارها بدست آمد تا آمار اندازه‌گیری‌ها و امتیاز‌ها در مدل‌سازی سنجش از دوری بکار

جدول ۱- شاخص‌ها و معیارهای مورد استفاده در این پژوهش (Ahmadi, 2005; McDonagh & Bunning, 2009a, b)

نام مدل	معیار	شاخص	شیوه امتیاز دهی
IMDPA	شوری	امتیازدهی به بیشترین میزان هدایت الکتریکی در پروفیل خاک (امتیاز ۰ تا ۴)	
	سنگریزه	امتیازدهی به درصد سنگریزه در پروفیل خاک (امتیاز ۰ تا ۴)	
	بافت	امتیازدهی به بافت غالب در پروفیل خاک (امتیاز ۰ تا ۴)	
	عمق خاک	امتیازدهی به عمق خاک (امتیاز ۰ تا ۴)	
	امتیاز کل کیفیت	میانگین هندسی هر چهار شاخص	
LADA	سخت لایه ناشی از کشت	وجود سخت لایه در پروفیل (امتیاز ۰ تا ۲)	
	توزیع اندازه خاکدانه‌ها	امتیازدهی به شیوه توزیع خاکدانه ناشی از شکست طبیعی (امتیاز ۰ تا ۲)	
	شاخص چشمی	امتیازدهی به تشکیل سله در سطح خاک (امتیاز ۰ تا ۲ مشت و منفی)	پوسته و سله خاک
	کیفیت خاک	امتیازدهی به مشاهده جانداران شاخص در پروفیل خاک (امتیاز ۰ تا ۲)	کرم‌های خاکی (یا دیگر جانواران)
	ریشه‌ها	امتیازدهی به مشاهده ناهنجاری در سیستم ریشه (امتیاز ۰ تا ۲)	
	امتیاز کل شاخص‌های چشمی	جمع وزنی شاخص‌ها (شاخص پوسته و کرم ضرب ۲؛ سایر شاخص‌ها ضرب ۳)	
	متلاشی شدن	امتیازدهی به شیوه متلاشی شدن خاکدانه در آب (امتیاز ۰ تا ۴)	متلاشی شدن و شکسته شدن
	pH خاک	امتیاز نمی‌گیرد فقط گزارش می‌شود	نفوذپذیری
	زمان نفوذ 400 ml	زمان نفوذ 400 ml آب داخل استوانه‌ای با قطر و ارتفاع 10 cm (امتیاز ۰ تا ۳)	کربن آلی ناپایدار
	شوری خاک (EC)	امتیاز به میزان کربن آلی (اسپکتروفوتومتر در آزمایشگاه) (امتیاز ۰ تا ۲)	شوری خاک (EC)
امتیاز کل وضعیت امتیاز کل	امتیاز کل شاخص‌های اندازه‌گیری	امتیاز کل شاخص‌های اندازه‌گیری (۱/۵)	
	امتیاز کل وضعیت امتیاز کل	جمع جبری امتیاز شاخص‌های چشمی و شاخص‌های اندازه‌گیری شونده	

۲- تصاویر دارای ابر نباشند یا مقدار ابر در آنها کمتر از ۱۰ درصد باشد.

۳- داده مشکل رادیومتری شامل نواری شدن^۱، بد پیکسل^۲، اثر ساقمه‌ای^۳، و چند قله بودن هسیتوگرامی در اثر پراکنش اتمسفری (Jensen, 2005) نداشته باشد و دست کم بر روی تصاویر رنگ کاذب، ناحیه‌ای با کنتراست نامناسب و غیرعادی ناشی از خطاهای رادیومتری دیده نشود.

۴- داده تک‌زمانه، به لحاظ زمانی کمترین فاصله را با تاریخ شروع و پایان نمونه‌برداری داشته باشد.

۵- برای انتخاب تاریخ در سناریو چند زمان چند پیش شرط در نظر گرفته شد: ۱) در هر فصل دست کم یک

پیش‌پردازش و پردازش سنجش از دوری

با توجه به هدف این تحقیق، دو سناریو برای مدل‌سازی سنجش از دوری بکار گرفته شده است: ۱) تک‌زمانه: داده سنجش از دوری هم زمان با نمونه‌برداری‌ها تهیه شده است؛ ۲) چند زمانه: داده‌های ماهواره‌ای در طول یکسال منتهی به زمان نمونه‌برداری‌ها تهیه شده‌اند. برای تهیه و سفارش داده سنجش از دوری چند شرط لحاظ گردیده است:

۱- با توجه به دسترسی به آرشیو داده‌های مختلف سنجنده‌های لندست ۴، ۵، ۷ و ۸ و توانایی این داده‌ها در شناسایی پارامترهای مرتبط با خاک (Gutierrez & Johnson, 2010; Li & Chen, 2014; Masoud, 2014; Metternicht & Zinck, 2008; Wang et al., 2013; Zhao & Chen, 2005) از داده‌های ماهواره‌ای لندست ۵ سنجنده TM در این پژوهش استفاده شد.

¹ Banding

² Bad Pixel

³ shot noise

پردازش‌های ذیل (Jensen, 2005; Liang, 2004; Mather & Koch, 2011) بر روی داده‌ها صورت پذیرفت تا در کل ۸ دسته داده در مدل‌سازی مورد آزمون قرار گیرد (جدول ۲) استخراج اتمسفری؛^۱ تصحیح زاویه تابش؛^۲ استخراج مقادیر تابندگی؛^۳ تصحیح توپوگرافی؛^۴ استخراج مقادیر با-تابندگی^۵ (Koch, 2011).

جدول ۲- داده‌های ماهواره‌ای، مورد استفاده در مدل‌سازی‌ها

داده انتخاب شود؛ ۲) پراکنش زمانی داده‌ها مناسب باشد به گونه‌ای، که فاصله‌های مانع داده‌ها خلی، کم باشند.

۶- برای آنکه بتوان نتایج دو سناریو را با یکدیگر مقایسه نمود، داده‌های هر دو سناریو جداگانه مدل سازی شدند و از ورود داده تک‌زمانه به مدل سازی چندزمانه اجتناب شد. با توجه به چندزمانه بودن یکی از سناریوهای مورد بررسی، به منظور انتخاب مناسب‌ترین داده و مقایسه عملکرد هر طبقه داده، به غیر از تصحیح هندسی و ثبت داده‌ها (*Jensen, 2005*)

نام ماهواره	توضیحات (Jensen, 2005; Liang, 2004; Mather & Koch, 2011)	داده مورد استفاده	دقت ٪
۱ عدد رقومی ^۱	ارزش روشنایی پیکسلی که نمونهبرداری در آن انجام شده، استخراج گردیده است		
۲ عدد رقومی تصحیح اتمسفری شده	به کمک اجسام تیره ^۲ و روش رگرسیون اعداد رقومی تصحیح اتمسفری شده اند		
۳ تابندگی ^۳	استخراج مقادیر تابندگی بر اساس اطلاعات متادینا		
۴ تابندگی تصحیح زاویه خورشیدی شده	تصحیح تابندگی بر اساس زاویه تابش خورشیدی (α)		
۵ تابندگی با تصحیح توپوگرافیک	$L = L \frac{1}{\sin(\alpha)}$		
۶ بازتابندگی ^۶	بوسیله مقادیر شبیه ^۴ β ، جهت شبیه ^۵ Φ ، زاویه زنیت θ_s و آزمیوت خورشیدی ϕ_s		
۷ بازتابندگی تصحیح زاویه خورشیدی شده	$L_N = \frac{L \cos(\theta_s)}{\cos^k(i) \cos(k)}$		
۸ بازتابندگی تصحیح توپوگرافیک شده	این بازتابندگی بوسیله اطلاعات ردیف ۳ بدست آمده است		
۹ LANDSAT ۵	$\pi L_A d^2$		
۱۰ بازتابندگی ^{۱۰}	$\rho_p = \frac{ESUN_A \cos \theta_s}{}$		
۱۱ بازتابندگی تصحیح زاویه خورشیدی شده	و برای یاند حرارتی (۶)		
۱۲ بازتابندگی تصحیح توپوگرافیک شده	$T = \frac{K2}{\ln(\frac{K1}{L_A} + 1)}$		
۱۳ بازتابندگی تصحیح زاویه خورشیدی شده	این بازتابندگی بوسیله اطلاعات ردیف ۴ بدست آمده است		
۱۴ بازتابندگی تصحیح توپوگرافیک شده	این بازتابندگی بوسیله اطلاعات ردیف ۵ بدست آمده است		

همچنین بر اساس مطالعات سنجش از دوری که بر روی پارامترهای مرتبط با خاک صورت پذیرفته، ضرایب کلاهک (Li & Chen, 2014; Masoud, 2014) و منگولهای (Zhao & Chen, 2005) شاخص‌های خاک لخت^۴ (Wang et al., 2013) شاخص‌های شوری خاک^۵ (Dogan, 2009)، کربن ترکیبات شیمیایی و معدنی^۶ (Goodwin et al., 2007) و رطوبت خاک (Huang et al., 2007) آلی (2008) بر روی تمامی تاریخ‌های داده‌های سنجش از دوری (داده‌های بازتابندگی ردیف ۶ جدول ۲) بکار رفته و مقادیر آنها در مکان‌های نمونهبرداری استخراج شد تا در مدل‌سازی‌ها از آنها استفاده شود (توضیح شاخص‌های خاک د، حدو، ۳).

برای انجام تصحیح هندسی، ابتدا داده به هنگام تکزمانه متعلق به تاریخ ۱۰ خرداد ۱۳۹۰ (به کمک برداشت‌های مختصات نقاط بوسیله دستگاه GPS تصحیح هندسی گردید، سپس تمامی داده‌ها در تاریخ‌های دیگر به داده مذکور ثبت داده شدند (Jensen, 2005).

پس از تصحیح هندسی اطلاعات هر کدام از این دسته داده‌ها (جدول ۲) در موقعیت مکان نمونه‌برداری‌ها (۱۷۲ نقطه) استخراج شدند تا در یک مدل رگرسیون خطی چندمتغیره همراه با تمامی شاخص‌ها و معیارهای کیفیت خاک بکار روند و از کل مدل‌ها بهترین دسته داده به عنوان ورودی مدل سازی‌های بعدی، بکار گرفته شود.

¹ Digital Number(Brightness Value)

Digital Transitions

³ Tasseled Cap Coefficients

⁴ normalized difference bareness index

⁵ Salinity Index

⁶ Chemical & Mineral Composition

جدول ۳- شاخص‌های ارزیابی خاک مورد استفاده در این پژوهش

نام شاخص ^۱	منبع	معادله
ضرایب کلاهک ^۲ منگولهای ^۳	<i>Li & Chen, 2014;</i> <i>(Masoud, 2014)</i>	$Brightness = (0.3037 * TM1) + (0.2793 * TM2) + (0.4343 * TM3) + (0.5585 * TM4) + (0.5082 * TM5) + (0.1863 * TM7)$ $Greenness = (-0.2848 * TM1) + (-0.2435 * TM2) + (-0.5436 * TM3) + (0.7243 * TM4) + (0.084 * TM5) + (-0.18 * TM7)$ $Wetness = (0.1509 * TM1) + (0.1793 * TM2) + (0.3299 * TM3) + (0.3406 * TM4) + (-0.7112 * TM5) + (-0.4572 * TM7)$
خاک لخت ^۴	<i>Zhao & Chen, (2005)</i>	$NDBal1 = TM7 - TM6/TM7 + TM6$ $NDBal2 = TM5 - TM6/TM5 + TM6$ $NDBal3 = TM3 - TM6/TM3 + TM6$
شوری خاک ^۵	<i>(Wang et al., 2013)</i>	$Salinity\ Index1 = TM5 - TM7/TM5 + TM7$ $Salinity\ Index2 = \sqrt{TM1 \times TM3}$ $Chemical\ Soil\ Composition = TM5 - TM6/TM3 + TM6$ $Ferrous\ Minerals = TM5/TM4$ $Iron\ Oxide = TM3/TM1$ $Clay\ Minerals = TM5/TM7$ $Moisture\ Index = TM5/TM7$
ترکیبات معدنی و شیمیایی ^۶	<i>(Dogan, 2009)</i>	$Normalized\ Difference\ Water\ Index = TM4 - TM5/TM4 + TM5$
رطوبت خاک ^۷	<i>Goodwin et al., (2008)</i>	

به عنوان یک ابزار قابل اعتماد در آمار کاربردی مدرن برای حل بسیاری از مشکلات دنیای واقعی که مدل‌های مرسوم ممکن است از پس آنها برآیند، وارد شده‌اند. موفقیت شبکه‌های مصنوعی به علت توانایی آنها در تشریح و مدل‌سازی مجموعه داده‌های مختلف، بدون توجه به طبیعت رابطه بین متغیرهای آن مجموعه داده، می‌باشد. در حقیقت شبکه‌های مصنوعی هیچگونه محدودیتی در نوع استفاده و زمینه استفاده ندارند و می‌توانند هر تابعی را با هر درجه پیچیدگی، تقریب بزنند (*Hill & Lewicki, 2006*)

شبکه‌های عصبی مصنوعی ابزارهای آماری‌ای هستند که کارکرد مغز را مدل‌سازی نموده‌اند. مانند مغز انسان، یک شبکه عصبی تشکیل می‌شود از تعداد زیادی نورون (سلول عصبی) که به عنوان گره^۳ یا واحد مخفی^۴ نیز شناخته می‌شوند که در صورت دریافت یک سیگنال دارای قدرت کافی از یک نورون دیگر که به آن متصل است، پیام مخابره می‌کند^۵. طبیعت سیگنال مخابره شده توسط یک نورون به نوع تابع اعمال شده بر روی آن بستگی دارد. در حقیقت می‌توان نورون‌ها یا گره‌هارا به عنوان یکسری واحدهای پردازش ضعیف با عملکرد موازی در نظر گرفت که هر کدام فقط یک تابع ریاضی هستند که به خودی خود نمی‌توانند کارکرد معنی‌داری داشته باشند، ولی وقتی تعداد مناسبی از آنها وجود داشته باشد و این نورون‌ها به

مدل‌سازی سنجش از دوری رگرسیون چند متغیره خطی

در ابتدا داده‌های مربوط به مناسب‌ترین دسته همراه با شاخص‌های مختلف خاک در یک رگرسیون خطی چندمتغیره به روش گام به گام^۶ به عنوان متغیرهای مستقل وارد شدند تا تک‌تک شاخص‌ها و معیارها (جدول ۱) را مدل‌سازی کنند. این آنالیز به طور جداگانه برای هر سناریو (تک‌زمانه و چند‌زمانه) بکار گرفته شد. از آنجایی که افزایش بُعد در مدل‌سازی آماری سنجش از دوری می‌تواند هزینه‌های اضافی به مدل وارد کند و نامطمئنی مدل را افزایش دهد (*Jensen, 2005*), در این مدل‌سازی‌های خطی ضمن سنجش توان بیشینه رگرسیون بدون محدودیت در تعداد جمله‌ها، مدل‌های سه لایه‌ای (متداول در روش‌های طبقه‌بندی (*Jensen, 2005*) نیز استخراج شدند تا در گام بعدی به منظور افزایش توان مدل، با غیرخطی نمودن پارامترها مورد آزمون قرار گیرند. همچنین به منظور درک میزان اثرگذاری شاخص‌ها با ورود به مدل‌سازی رگرسیونی، مقایسه‌ای بین مدل‌سازی بدون ورود شاخص‌های کیفیت خاک و همراه با این شاخص‌ها صورت پذیرفت.

شبکه‌های عصبی مصنوعی

به منظور غیرخطی نمودن مدل‌ها از شبکه‌های عصبی مصنوعی^۷ استفاده شده است. شبکه‌های عصبی مصنوعی

³ Neuron

⁴ Node

⁵ Hidden Unit

⁶ Fire

⁷ Stepwise

² Artificial neural network

(Ivancevic & Ivancevic, 2005). در این تحقیق در مجموع ۱۱ مدل مختلف شبکه عصبی مطابق با جدول (۴) بکار گرفته شده است تا افزایش توان بوسیله این مدل‌ها مورد ارزیابی قرار گیرد. بدین منظور بجای نتیجه رگرسیون بدون محدودیت لایه، نتایج حاصل از رگرسیونهای سه لایه‌ای بکار گرفته شدند تا در سنجش عملکرد امکان مقایسه دو مدل فراهم گردد و نامنطئی در پیش‌بینی‌ها (Jensen, 2005) به طور ناخواسته تشدید نگردد.

جدول ۴ - مدل‌های شبکه عصبی مورد استفاده همراه با شرح مختصر آنها

نام شبکه عصبی	تفصیل
Multilayer perceptrons (MLPs)	حسگرهای چندلایه ای نوعی شبکه‌های عصبی توان پخشانه جلوبرنده با لایه‌های متناوبی از نورونها و وزنهای هستند که یکی از معمولترین انواع شبکه‌های عصبی در کاربردهای مختلف به شمار می‌روند. حسن اصلی این شبکه‌ها آنست که به سادگی بکار می‌روند و می‌توانند هر نوع طرح ورودی و خروجی را تقریب بزنند. مشکل این شبکه‌ها آنست که تعلیم داده‌ها در آنها کند است و تعداد زیادی داده تعلیمی نیاز دارند.
Generalized feedforward networks	نوع خلاصه سازی شده از شبکه‌های MLP هستند که در آنها ارتباطها می‌تواند مرحله نباشد و پرش ارتباطی از یک لایه یا چند لایه اتفاق افتد. به لحاظ تنویری MLP‌ها می‌توانند هر آنچه GFN‌ها حل می‌کنند را حل کنند. در عمل GFN‌ها اغلب مشکل را کارآمدتر حل می‌کنند (ممولاً تعداد تکرارهای بسیار کمتر نیاز دارند).
Modular feedforward networks	این شبکه‌ها یک کلاس خاص از MLP هستند. در این شبکه‌ها داده ورودی بوسیله چندین MLP موازی پردازش می‌یابد و سپس نتایج با هم ترکیب می‌شوند. بر عکس MLP‌ها در این شبکه‌ها بین لایه‌ها ارتباط کامل و وجود ندارد. بنابراین برای یک شبکه نسبت به MLP تعداد وزن‌دهی‌های کمتری نیاز است. این امر سرعت تعلیم داده را بیشتر می‌کند و تعداد نمونه‌های تعلیمی مورد نیاز را کاهش می‌دهد.
Jordan and Elman networks	این شبکه‌ها نوع توسعه یافته MLP هستند که در آنها المانهای پردازشی (context units) فعالیت قبلی را بخاطر سپرده‌اند (در جایی به نام واحدهای سابقه). این واحدهای سابقه باعث می‌شوند شبکه بتواند اطلاعات زمانی را از داده استخراج کند در شبکه Elman فعالیت المانهای پردازش اولین به داخل واحد سابقه کمی شود در حالیکه در شبکه Jordan این اطلاعات به خروجی شبکه کمی شود.
Principal component analysis networks	این شبکه‌ها یادگیری نظارت شده و نظارت نشده را با یکدیگر در یکجا تلفیق نموده‌اند. آنالیز جزء اصلی یک روش خطی نظارت نشده است که یک مجموعه اجزاء اصلی غیروابسته را از ورودی پیدا می‌کند و سپس یک MLP بر روی این جزء‌ها، تعلیم نظارت شده انجام می‌دهد تا بر روی آنها طبقه‌بندی غیر خطی صورت دهد.
Radial basis function (RBF)	شبکه با تابع شعاعی محور نوعی شبکه هیبرید غیر خطی است که معمولاً فقط یک لایه مخفی یا تعدادی المان پردازشی دارد. این لایه بجای استفاده از توابع تبدیل شکل (sigmoidal functions) که در MLP‌ها مرسوم است از تابع تبدیل گوسین استفاده می‌کند. مرکز و عرض تابع گوسین بوسیله قوانین یادگیری نظارت شده تنظیم می‌شود و یادگیری نظارت شده به لایه خروجی اعمالی مشود. این شبکه هار بسیار سریع تر از MLP‌ها هستند.
Self-organizing feature maps (SOFMs)	این شبکه‌ها بعدهای ورودی به مدل را به یک یا دو بعد مجزا بر اساس یک محدود تپولوژیکی تبدیل می‌کنند که به عنوان نقشه‌های ترکیبی (feature maps) شناخته می‌شوند. این نقشه‌ها بر اساس یادگیری نظارت شده Kohonen محاسبه می‌شوند. خروجی این شبکه را می‌توان به عنوان ورودی در یک شبکه عصبی نظارت شده مانند MLP استفاده نمود. حسن این شبکه آنست که با دسته‌بندی، فضای ورودی را با یک پردازش خودسازمان یافته به ترکیب‌های فضایی می‌شکند. بنابراین ضمن حفظ فضای ورودی، بعد فضایی (تعداد ورودی) آن را کاهش می‌دهند.
Time lagged recurrent networks (TLRNs)	این MLP‌ها حافظه کوتاه مدت در آنها تقویت شده است. هر چند هنوز اغلب شبکه‌های عصبی طبقه‌بندی کننده‌ها استاتیک هستند ولی TLRN‌ها در طبقه‌بندی الگوی زمانی، تشخیص سیستم و پیش‌بینی غیرخطی توسط سری‌های زمانی موفق نشان داده‌اند.
Fully recurrent networks	این شبکه‌ها بازخور لایه مخفی را به خودش منتقل می‌کنند. شبکه‌های اندکی بازگشت کننده با یک شبکه بازگشت کننده کامل شروع می‌شوند و یک رابطه به سمت (جلو) (جلوبرنده) در آنها اضافه می‌شود که از بازگشت جلوگیری می‌کند و بخش بازگشت کننده را به عنوان یک حافظه بکار می‌گیرد. این شبکه‌های بازگشت کننده می‌توانند میزان حافظه بین نهایتی داشته باشند، بنابراین خواهند توانست با درنظر گرفتن فضای ورودی لحظه‌ای و تغییرات آن با گذشت زمان، روابط را پیدا کنند. این شبکه‌ها نیز در طبقه‌بندی الگوی زمانی، تشخیص سیستم و پیش‌بینی غیرخطی توسط سری‌های زمانی موفق نشان داده‌اند.
The CANFIS (Co-Active Neuro-Fuzzy Inference System)	این شبکه‌ها وارودی‌های فازی تطبیق یافته را با یک شبکه عصبی مدولار تلفیق کنند تا بدین وسیله بتوانند توابع پیچیده را سریع و دقیق تقریب بزنند.
The Support Vector Machine (SVM)	این شبکه‌ها از آنچایی ارزش زیادی دارند که می‌توانند توابع عضویت فازی (قوانین با طبیعت توصیفی) را با قدرت شبکه‌های عصبی جعبه سیاه ترکیب کنند.
	این شبکه‌ها بوسیله خوارزمیک kernel Adatron پیاده سازی می‌شوند. نقشه‌های حاصل از این خوارزمیک به یک فضای چندبعدی وارد می‌شوند و سپس بر اساس قرارگیری در یکسری مزه‌های خاص به کلاس‌هایی شکسته خواهند شد. این خوارزمیک در جداسازی مجموعه‌ای از داده‌ها که مزه‌های پیچیده مشترکی دارند، کل آمد نشان داده است. از SVM‌ها تنها می‌توان برای طبقه‌بندی استفاده نمود نه برای تقریب زدن یکتابع.

۷. هر مدل شبکه عصبی سه بار اجرا و سپس ۱۰ بار تکرار شد و بهترین عملکرد آن در داده‌های تعلیمی و آزمونی گزارش شدند.

با توجه به شکست کلیه نمونه‌برداری‌ها به دو بخش تعلیمی و آزمونی برای مقایسه عملکرد دو روش مدل‌سازی شبکه عصبی مصنوعی و رگرسیون خطی، مدل‌های رگرسیونی مجدداً بوسیله تابع ورود^۱ با همان لایه‌هایی که در شبکه عصبی بکار گرفته شده بودند برای داده تعلیمی ایجاد شد و سپس دقت آنها در داده‌های آزمون مورد ارزیابی قرار گرفت.

نتایج ■

نقش نوع داده مورد استفاده در کارکرد مدل

در جدول (۵) نتایج مدل‌سازی رگرسیونی داده‌های چند زمانه ارائه شده است. لازم به ذکر است در این جدول ستون ^۰ ضریب همبستگی بدست آمده از رگرسیون سه لایه‌ای را نشان می‌دهد در حالیکه *r_{total}*، ضریب همبستگی بدون محدودیت تعداد لایه‌ها را نشان می‌دهد. همانگونه که در جدول (۵) مشاهده می‌شود در تمامی معیارها و شاخص‌های مورد بررسی چه برای در مورد مدل‌سازی رگرسیونی سه لایه‌ای و چه برای مدل‌سازی بدون محدودیت، اختلاف قابل ملاحظه‌ای میان کارکرد داده‌های مختلف دیده نمی‌شود. تنها داده‌های تصحیح توپوگرافیک شده، اغلب دقت مدل‌سازی پایین‌تری نشان داده‌اند که با توجه به اینکه بیشتر ناحیه مورد بررسی وضعیت مسطح و دشتی داشته است، اندکی قابل پیش‌بینی بود. البته این اختلاف نیز قابل ملاحظه نیست. بنابراین هر چند اختلاف معنی‌داری در کارکرد داده‌ها دیده نشده است، ولی با توجه به توصیه بیشتر منابع علمی (Jensen, 2005, 2007; Liang, 2004; Mather & Koch, 2011) در کلیه مراحل بعدی مطالعاتی، اعداد بازتابندگی (ردیف ۶ جدول ۲) مورد استفاده قرار گرفته است.

نقش استفاده از شاخص‌های کیفیت خاک

در جدول (۶) تأثیر بکارگیری شاخص‌ها در مدل‌سازی رگرسیونی نشان داده شده است. همانگونه که مشاهده می‌شود در اغلب موارد تفاوت معنی‌داری در دو مدل با شاخص و بدون شاخص دیده نمی‌شود با این وجود در شاخص‌های توزیع اندازه

در ابتدا در یک مرحله پیش‌آزمون از خوارزمیک بهینه‌سازی ژنتیک^۱ استفاده شد تا داده‌های ورودی، مقدار شتاب^۲، المانهای پردازشی^۳ در لایه یا لایه‌های مخفی^۴ و همچنین تعداد لایه‌های مخفی هر مدل شبکه عصبی تعیین گردد. در این مرحله مشخص گردید با توجه به نزدیکی پیش از اندازه تایج تمامی مدل‌ها به یکدیگر امکان تفکیک عملکرد بدین صورت ناممکن است. بنابراین بهمنظور مقایسه کارکرد هر مدل شبکه چند پیش شرط اصلی در نظر گرفته شد:

۱. تمامی مدل‌ها در ساده‌ترین حالت ممکن مورد استفاده قرار گیرند (از افزایش تعداد لایه‌های مخفی و المانهای پردازشی اجتناب گردد).

۲. تعداد لایه‌های مخفی در مدل‌های مختلف تا حدامکان یکسان در نظر گرفته شود (بجز روش *MLP* که ماهیتاً دست کم دو لایه مخفی موادی می‌خواهد، *RBF*، *SVM* و *CANFIS* که لایه مخفی ندارند، تمامی مدل‌های دیگر با یک لایه مخفی استفاده شدند).

۳. تعداد المانهای پردازشی در لایه ورودی^۵ در لایه خروجی^۶ و در صورت وجود لایه مخفی تعداد المانهای پردازشی در تمامی مدل‌ها^۷ در نظر گرفته شد.

۴. در تمامی مدل‌ها تعداد نمونه‌ها^۸ معادل ۱۰۰ و تعداد بیشنه تکرار از مبدا جدید^۹ برابر ۱۰۰۰ وارد شدند.

۵. بجای مدل‌های *CANFIS* و *SVM* (با توجه به ساختارشان) تابع تبدیل تمامی مدل‌ها تائزانت هایپربولیک و قانون یادگیری^{۱۰} همگی *LevenbergMarquardt* در نظر گرفته شده است.

۶. به صورت تصادفی ۳۰ درصد نمونه‌برداری‌ها به عنوان داده آزمون^{۱۱} و ۷۰ درصد به عنوان داده تعلیمی^{۱۲} در نظر گرفته شدند (برای هر مدل میدانی تخریب خاک یکبار به شکل تصادفی این داده‌ها انتخاب شدند و سپس برای تمامی معیارها و شاخص‌های مورد بررسی آن مدل، این گزینش تغییری نداشت).

^۱ Genetic Optimization Algorithm

^۲ momentum values

^۳ processing elements

^۴ Hidden Layers

^۵ exemplar

^۶ The Maximum Epochs

^۷ Learning Rule

^۸ test

^۹ train

بهترین مدل شبکه عصبی دیده نمی‌شود. در واقع با پیچیده و غیرخطی شدن معادلات، فقط داده‌های تعلیمی افزایش توان یافته‌اند، ولی مدل‌های شکل گرفته در عمل، کارکرد خوبی نشان نداده‌اند. در کل همانند مدل‌سازی رگرسیونی، مدل‌سازی‌های شبکه‌های عصبی اغلب در سناریو چندماهه موفق‌تر نشان داده‌اند. این افزایش توان هم در ضریب همبستگی داده تعلیمی و هم در ضریب همبستگی داده آزمونی به وقوع پیوسته است.

در میان مدل‌های مختلف شبکه‌های عصبی مصنوعی مدل *SOFMs* و *Modular feedforward networks* در تمامی مدل‌سازی‌های شاخص‌ها و معیارهای مختلف این پژوهش از نظر ضریب همبستگی داده‌های تعلیمی بهترین عملکرد را نشان داده‌اند. ولی با در نظر گرفتن ضریب همبستگی داده آزمونی، نمی‌توان به راحتی بهترین مدل از نظر عملکرد را مشخص نمود. با این وجود مدل‌های *CANFIS* و *RBF* اندکی از دیگر مدل‌ها پاسخ‌های بهتری نشان داده‌اند.

مقایسه عملکرد دو مدل

در جدول (۹) و (۱۰) ضرایب همبستگی حاصل از رگرسیون خطی داده‌های تعلیمی مورد استفاده در شبکه‌های عصبی برای دو سناریو این پژوهش نشان داده شده است. ضریب همبستگی داده‌های آزمون پس از اعمال مدل بدست آمده از داده‌های تعلیمی بر روی داده‌های آزمایشی محاسبه شده است. با مقایسه اعداد ضرایب همبستگی داده‌های آزمایشی این جداول با داده‌های آزمایشی جداول (۷) و (۸) مشخص می‌شود در کل مدل‌های مختلف شبکه عصبی در برخی موارد بهتر از مدل‌های رگرسیونی عمل نموده‌اند (بیشتر در سناریو تک‌زمانه) و افزایش توان مدل در این موارد در بهترین وضعیت اندکی بیش از دوباره بوده است. هرچند در اینجا نیز دقت مدل‌سازی داده‌های تعلیمی مدل‌های شبکه‌های عصبی بطور قابل ملاحظه‌ای بالاتر از روش رگرسیونی می‌باشد. در سناریو چندماهه، نتایج رگرسیونی در بیشتر موارد با نتایج بهترین مدل شبکه عصبی اختلاف زیادی ندارند، در مواردی که شبکه‌های عصبی بهتر عمل کرده‌اند، تفاوت ضرایب همبستگی این دو کمتر از 20% است.

حاکدانه، متلاشی شدن، pH و کربن آلی در صورت استفاده از شاخص‌ها عملکرد بهتری دیده شده است (جدول ۶). بنابراین در ادامه آنالیزهای آماری اجازه داده شد، مدل رگرسیونی بدون محدودیت در انتخاب لایه، ورودی مدل را مشخص نماید (چه به صورت صرفاً مدل تشکیل شده از باندها و چه به صورت مدل همراه با شاخص‌های کیفیت خاک).

مدل‌سازی رگرسیون خطی: سناریو چند زمانه در برابر سناریو تک زمانه

مطابق آنچه در جدول (۶) مشاهده می‌شود، تقریباً در تمامی شاخص‌ها و معیارهای بررسی کیفیت خاک این پژوهش (جز کربن آلی در حالت بکارگیری شاخص‌های کیفیت خاک) سناریو چندماهه، عملکرد بهتری از سناریو تک‌زمانه یا همزمان با نمونه‌برداری‌ها نشان داده است. این بهبود توان مدل‌سازی سناریو چند زمانه، گاهی چند برابر سناریو تک‌زمانه بوده است. حتی در مورد شاخص متلاشی شدن در متداول‌وزیر *LADA* سناریو چند زمانه باعث ایجاد یک مدل برای پیش‌بینی گردیده، در حالیکه سناریو تک‌زمانه در ساخت یک مدل ناتوان نشان داده است. افزایش قدرت مدل‌سازی با استفاده از سناریو تک‌زمانه در مورد شاخص‌هایی که با اندازه‌گیری‌های آزمایشگاهی و میدانی بدست آمده‌اند، مانند pH ، EC ، سنگریزه و کربن آلی (در حالت بدون استفاده از شاخص‌های کیفیت خاک) نیز به خوبی دیده می‌شود.

مدل‌سازی شبکه عصبی مصنوعی: سناریو چند زمانه در برابر سناریو تک زمانه

در جدول (۷) و (۸) نتایج مدل‌سازی رگرسیونی با محدودیت لایه (حداکثر سه لایه) و انواع مختلف مدل‌های شبکه‌های عصبی مصنوعی در دو سناریو چندماهه و تک‌زمانه مشاهده می‌گردد. در نگاه اول با مقایسه ضریب همبستگی مدل‌سازی رگرسیونی و ضریب همبستگی داده‌های تعلیمی (*ttrain*) در مدل‌سازی‌های شبکه‌های عصبی اینگونه به نظر می‌آید که در اغلب موارد، تمامی مدل‌های شبکه عصبی عملکرد مناسب‌تری از مدل‌سازی رگرسیونی در هر دو سناریو دارند. اما وقتی به ضرایب همبستگی داده‌ای آزمونی (*ttest*) توجه شود، تفاوت قابل ملاحظه‌ای بین مدل رگرسیونی و

جدول ۵- مقایسه عملکرد رگرسیون‌های خطی در انواع مختلف داده‌های چند زمانه

جدول ۶- مقایسه عملکرد رگرسیون‌های ایجاد شده با یا بدون استفاده از شاخص‌ها

رگرسیون بازتابندگی					رگرسیون بازتابندگی*									
rits	rbts	ris	rbs	شاخص	معیار	مدل	rits	rbts	ris	rbs	شاخص	معیار	مدل	
.00	.00	.00	.00	کرم	شاخص چشمی کفیت خاک	.716	.68	.377	.345	شوری				
.394	.393	.340	.244	امتیاز کل		.829	.811	.699	.699	ستگریزه				
.560	.496	.00	.00	متلاشی شدن		.417	.410	.188	.188	پافت	ن	IMDPA		
.555	.456	.162	.00	pH	آناره‌گیری های بودایی کل	.567	.569	.527	.524	عمق				
.00	.00	.00	.00	نفوذپذیری	LADA	.362	.362	.281	.281	امتیاز کل				
.608	.575	.624	.438	کربن آلی ناپایدار		.428	.414	.352	.352	سخت‌لایه	ن	ن		
.694	.615	.433	.433	امتیاز کل		.470	.437	.409	.287	توزیع اندازه خاکدانه‌ها	ن	ن		
.546	.543	.419	.419	امتیاز کل	امتیاز کلی VS-Fast	.590	.590	.366	.366	بوسته و سله خاک	ن	LADA		
						0.00	.00	0.00	0.00	ریشه				

*: ضریب همبستگی داده‌های چند زمانه همراه با بکارگیری شاخص‌ها

: ضریب همبستگی داده‌های چند زمانه بدون بکارگیری شاخص‌ها

: ضریب همبستگی داده‌های تک‌زمانه همراه با بکارگیری شاخص‌ها

: ضریب همبستگی داده‌های تک‌زمانه بدون بکارگیری شاخص‌ها

جدول ۷- مقایسه عملکرد مدل رگرسیونی و مدل‌های مختلف شبکه عصبی مصنوعی در سارابو تک‌زمانه

	مدل‌های شبکه عصبی مصنوعی												رگرسیون			
	Co-Active Support Vector Machine Inference System	Fully- recurrent networks	Time- lagged recurrent networks	Self- organizing feature maps	Radial basis function networks	Principal component analysis networks	Jordan and Elman networks	Modular feedforward networks	Generalized feedforward networks	Multilayer perceptrons	Multilayer perceptrons	IMDPA	LADA	نکات تدریجی نمایش	نکات تدریجی نمایش	نکات تدریجی نمایش
0.232	0.254	-0.11	0.39	0.2	0.254	0.473	0.331	0.47	0.61	0.455	0.49	0.81	0.88	0.333	0.65	0.232
0.320	0.308	0.92	0.309	0.309	0.92	0.8	0.207	0.207	0.69	0.354	0.27	0.98	0.96	0.344	0.56	0.358
0.320	0.308	0.92	0.323	0.23	0.92	0.8	0.207	0.207	0.69	0.354	0.27	0.98	0.96	0.344	0.56	0.358
0.722	0.277	-0.207	0.197	0.197	0.93	0.93	0.207	0.207	0.62	0.354	0.27	0.8	0.8	0.311	0.753	0.997
0.72	0.330	0.86	0.315	0.315	0.96	0.96	0.86	0.86	0.67	0.67	0.67	0.83	0.72	0.330	0.74	0.385
0.74	0.385	0.336	0.336	0.3	0.95	0.95	0.336	0.336	0.62	0.62	0.62	0.84	0.99	0.277	0.753	0.997
0.72	0.330	0.86	0.315	0.315	0.96	0.96	0.86	0.86	0.67	0.67	0.67	0.83	0.72	0.330	0.74	0.385
0.72	0.311	0.213	0.145	0.145	0.93	0.93	0.213	0.213	0.62	0.64	0.64	0.88	0.99	0.277	0.753	0.997
0.74	0.385	0.336	0.336	0.3	0.95	0.95	0.336	0.336	0.62	0.62	0.62	0.84	0.99	0.277	0.753	0.997
0.72	0.330	0.86	0.315	0.315	0.96	0.96	0.86	0.86	0.67	0.67	0.67	0.83	0.72	0.330	0.74	0.385
0.72	0.311	0.213	0.145	0.145	0.93	0.93	0.213	0.213	0.62	0.64	0.64	0.88	0.99	0.277	0.753	0.997
0.74	0.385	0.336	0.336	0.3	0.95	0.95	0.336	0.336	0.62	0.62	0.62	0.84	0.99	0.277	0.753	0.997
0.72	0.330	0.86	0.315	0.315	0.96	0.96	0.86	0.86	0.67	0.67	0.67	0.83	0.72	0.330	0.74	0.385
0.74	0.385	0.336	0.336	0.3	0.95	0.95	0.336	0.336	0.62	0.62	0.62	0.84	0.99	0.277	0.753	0.997
0.72	0.330	0.86	0.315	0.315	0.96	0.96	0.86	0.86	0.67	0.67	0.67	0.83	0.72	0.330	0.74	0.385
0.74	0.385	0.336	0.336	0.3	0.95	0.95	0.336	0.336	0.62	0.62	0.62	0.84	0.99	0.277	0.753	0.997
0.72	0.330	0.86	0.315	0.315	0.96	0.96	0.86	0.86	0.67	0.67	0.67	0.83	0.72	0.330	0.74	0.385
0.74	0.385	0.336	0.336	0.3	0.95	0.95	0.336	0.336	0.62	0.62	0.62	0.84	0.99	0.277	0.753	0.997
0.72	0.330	0.86	0.315	0.315	0.96	0.96	0.86	0.86	0.67	0.67	0.67	0.83	0.72	0.330	0.74	0.385
0.74	0.385	0.336	0.336	0.3	0.95	0.95	0.336	0.336	0.62	0.62	0.62	0.84	0.99	0.277	0.753	0.997
0.72	0.330	0.86	0.315	0.315	0.96	0.96	0.86	0.86	0.67	0.67	0.67	0.83	0.72	0.330	0.74	0.385
0.74	0.385	0.336	0.336	0.3	0.95	0.95	0.336	0.336	0.62	0.62	0.62	0.84	0.99	0.277	0.753	0.997
0.72	0.330	0.86	0.315	0.315	0.96	0.96	0.86	0.86	0.67	0.67	0.67	0.83	0.72	0.330	0.74	0.385
0.74	0.385	0.336	0.336	0.3	0.95	0.95	0.336	0.336	0.62	0.62	0.62	0.84	0.99	0.277	0.753	0.997
0.72	0.330	0.86	0.315	0.315	0.96	0.96	0.86	0.86	0.67	0.67	0.67	0.83	0.72	0.330	0.74	0.385
0.74	0.385	0.336	0.336	0.3	0.95	0.95	0.336	0.336	0.62	0.62	0.62	0.84	0.99	0.277	0.753	0.997
0.72	0.330	0.86	0.315	0.315	0.96	0.96	0.86	0.86	0.67	0.67	0.67	0.83	0.72	0.330	0.74	0.385
0.74	0.385	0.336	0.336	0.3	0.95	0.95	0.336	0.336	0.62	0.62	0.62	0.84	0.99	0.277	0.753	0.997
0.72	0.330	0.86	0.315	0.315	0.96	0.96	0.86	0.86	0.67	0.67	0.67	0.83	0.72	0.330	0.74	0.385
0.74	0.385	0.336	0.336	0.3	0.95	0.95	0.336	0.336	0.62	0.62	0.62	0.84	0.99	0.277	0.753	0.997
0.72	0.330	0.86	0.315	0.315	0.96	0.96	0.86	0.86	0.67	0.67	0.67	0.83	0.72	0.330	0.74	0.385
0.74	0.385	0.336	0.336	0.3	0.95	0.95	0.336	0.336	0.62	0.62	0.62	0.84	0.99	0.277	0.753	0.997
0.72	0.330	0.86	0.315	0.315	0.96	0.96	0.86	0.86	0.67	0.67	0.67	0.83	0.72	0.330	0.74	0.385
0.74	0.385	0.336	0.336	0.3	0.95	0.95	0.336	0.336	0.62	0.62	0.62	0.84	0.99	0.277	0.753	0.997
0.72	0.330	0.86	0.315	0.315	0.96	0.96	0.86	0.86	0.67	0.67	0.67	0.83	0.72	0.330	0.74	0.385
0.74	0.385	0.336	0.336	0.3	0.95	0.95	0.336	0.336	0.62	0.62	0.62	0.84	0.99	0.277	0.753	0.997
0.72	0.330	0.86	0.315	0.315	0.96	0.96	0.86	0.86	0.67	0.67	0.67	0.83	0.72	0.330	0.74	0.385
0.74	0.385	0.336	0.336	0.3	0.95	0.95	0.336	0.336	0.62	0.62	0.62	0.84	0.99	0.277	0.753	0.997
0.72	0.330	0.86	0.315	0.315	0.96	0.96	0.86	0.86	0.67	0.67	0.67	0.83	0.72	0.330	0.74	0.385
0.74	0.385	0.336	0.336	0.3	0.95	0.95	0.336	0.336	0.62	0.62	0.62	0.84	0.99	0.277	0.753	0.997
0.72	0.330	0.86	0.315	0.315	0.96	0.96	0.86	0.86	0.67	0.67	0.67	0.83	0.72	0.330	0.74	0.385
0.74	0.385	0.336	0.336	0.3	0.95	0.95	0.336	0.336	0.62	0.62	0.62	0.84	0.99	0.277	0.753	0.997
0.72	0.330	0.86	0.315	0.315	0.96	0.96	0.86	0.86	0.67	0.67	0.67	0.83	0.72	0.330	0.74	0.385
0.74	0.385	0.336	0.336	0.3	0.95	0.95	0.336	0.336	0.62	0.62	0.62	0.84	0.99	0.277	0.753	0.997
0.72	0.330	0.86	0.315	0.315	0.96	0.96	0.86	0.86	0.67	0.67	0.67	0.83	0.72	0.330	0.74	0.385
0.74	0.385	0.336	0.336	0.3	0.95	0.95	0.336	0.336	0.62	0.62	0.62	0.84	0.99	0.277	0.753	0.997
0.72	0.330	0.86	0.315	0.315	0.96	0.96	0.86	0.86	0.67	0.67	0.67	0.83	0.72	0.330	0.74	0.385
0.74	0.385	0.336	0.336	0.3	0.95	0.95	0.336	0.336	0.62	0.62	0.62	0.84	0.99	0.277	0.753	0.997
0.72	0.330	0.86	0.315	0.315	0.96	0.96	0.86	0.86	0.67	0.67	0.67	0.83	0.72	0.330	0.74	0.385
0.74	0.385	0.336	0.336	0.3	0.95	0.95	0.336	0.336	0.62	0.62	0.62	0.84	0.99	0.277	0.753	0.997
0.72	0.330	0.86	0.315	0.315	0.96	0.96	0.86	0.86	0.67	0.67	0.67	0.83	0.72	0.330	0.74	0.385
0.74	0.385	0.336	0.336	0.3	0.95	0.95	0.336	0.336	0.62	0.62	0.62	0.84	0.99	0.277	0.753	0.997
0.72	0.330	0.86	0.315	0.315	0.96	0.96	0.86	0.86	0.67	0.67	0.67	0.83	0.72	0.330	0.74	0.385
0.74	0.385	0.336	0.336	0.3	0.95	0.95	0.336	0.336	0.62	0.62	0.62	0.84	0.99	0.277	0.753	0.997
0.72	0.330	0.86	0.315	0.315	0.96	0.96	0.86	0.86	0.67	0.67	0.67	0.83	0.72	0.330	0.74	0.385
0.74	0.385	0.336	0.336	0.3	0.95	0.95	0.336	0.336	0.62	0.62	0.62	0.84	0.99	0.277	0.753	0.997
0.72	0.330	0.86	0.315	0.315	0.96	0.96	0.86	0.86	0.67	0.67	0.67	0.83	0.72	0.330	0.74	0.385
0.74	0.385	0.336	0.336	0.3	0.95	0.95	0.336	0.336	0.62	0.62	0.62	0.84	0.99	0.277	0.753	0.997
0.72	0.330	0.86	0.315	0.315	0.96	0.96	0.86	0.86	0.67	0.67	0.67	0.83	0.72	0.330	0.74	0.385
0.74	0.385	0.336	0.336	0.3	0.95	0.95	0.336	0.336	0.62	0.62	0.62	0.84	0.99	0.277	0.753	0.997
0.72	0.330	0.86	0.315	0.315	0.96	0.96	0.86	0.86	0.67	0.67	0.67	0.83	0.72	0.330	0.74	0.385
0.74	0.385	0.336	0.336	0.3	0.95	0.95	0.336	0.336	0.62	0.62	0					

ردیف	نام پارامتر	تعریف	دسته بندی	مقدار	حکم	ردیفه ها	پیوسته و سله خاک
.507	.Clay Minerals	فلاتر مدل IMDPA ایجاد شده است	امتیاز کل	.433	بند ۱	.00.	شودی
.535	.0.735	با توجه به تک لایه بودن مدل رگرسیونی، مدل سازی شبکه های عصبی مصنوعی انجام نشده است	بند ۲	.00.	بند ۱	.00.	امتیاز کل
.529	.0.329	با توجه به تک لایه بودن مدل رگرسیونی، مدل سازی شبکه های عصبی مصنوعی انجام نشده است	بند ۴	.000	بند ۴	.366	پیوسته و سله خاک
.551	.0.351	با توجه به تک لایه بودن مدل رگرسیونی، مدل سازی شبکه های عصبی مصنوعی انجام نشده است	بند 6	.0.0	میچکدام	.202	کرم
.549	.0.949	با توجه به تک لایه بودن مدل رگرسیونی، مدل سازی شبکه های عصبی مصنوعی انجام نشده است	بند 8	.0.014	Salinity Index	.075	ریشه ها
.569	.-0.369	با توجه به تک لایه بودن مدل رگرسیونی، مدل سازی شبکه های عصبی مصنوعی انجام نشده است	بند 10	.0.004	Iron Oxide NDBS3	.340	امتیاز کل
.578	.0.278	با توجه به تک لایه بودن مدل رگرسیونی، مدل سازی شبکه های عصبی مصنوعی انجام نشده است	بند 12	.0.026	میچکدام	.0.0	متالاشی شدن
.581	.0.757	با توجه به تک لایه بودن مدل رگرسیونی، مدل سازی شبکه های عصبی مصنوعی انجام نشده است	بند 14	.0.073	میچکدام	.486	pH
.583	.0.336	با توجه به تک لایه بودن مدل رگرسیونی، مدل سازی شبکه های عصبی مصنوعی انجام نشده است	بند 16	.0.0268	میچکدام	.0.0	غذوبندهای ۰
.586	.0.69	با توجه به تک لایه بودن مدل رگرسیونی، مدل سازی شبکه های عصبی مصنوعی انجام نشده است	بند 18	.0.0986	میچکدام	.0.67	بند ۱
.587	.0.725	با توجه به تک لایه بودن مدل رگرسیونی، مدل سازی شبکه های عصبی مصنوعی انجام نشده است	بند 20	.0.0328	میچکدام	.0.075	ریشه ها
.590	.0.490	با توجه به تک لایه بودن مدل رگرسیونی، مدل سازی شبکه های عصبی مصنوعی انجام نشده است	بند 22	.0.0788	میچکدام	.0.004	آهنگردی
.593	.0.695	با توجه به تک لایه بودن مدل رگرسیونی، مدل سازی شبکه های عصبی مصنوعی انجام نشده است	بند 24	.0.0299	میچکدام	.0.026	کربن آلی
.596	.0.549	با توجه به تک لایه بودن مدل رگرسیونی، مدل سازی شبکه های عصبی مصنوعی انجام نشده است	بند 26	.0.071	میچکدام	.0.004	نپالیدار
.603	.0.404	با توجه به تک لایه بودن مدل رگرسیونی، مدل سازی شبکه های عصبی مصنوعی انجام نشده است	بند 28	.0.0349	میچکدام	.0.002	Compositi on
.608	.0.224	با توجه به تک لایه بودن مدل رگرسیونی، مدل سازی شبکه های عصبی مصنوعی انجام نشده است	بند 30	.0.063	میچکدام	.0.002	Faste
.613	.0.73	با توجه به تک لایه بودن مدل رگرسیونی، مدل سازی شبکه های عصبی مصنوعی انجام نشده است	بند 32	.0.0358	میچکدام	.0.002	Vs- ۳۵ جتی
.617	.0.186	با توجه به تک لایه بودن مدل رگرسیونی، مدل سازی شبکه های عصبی مصنوعی انجام نشده است	بند 34	.0.0331	میچکدام	.0.002	Clay Minerals
.624	.0.403	با توجه به تک لایه بودن مدل رگرسیونی، مدل سازی شبکه های عصبی مصنوعی انجام نشده است	بند 36	.0.044	میچکدام	.0.002	Clay Minerals
.633	.0.489	با توجه به تک لایه بودن مدل رگرسیونی، مدل سازی شبکه های عصبی مصنوعی انجام نشده است	بند 38	.0.044	میچکدام	.0.002	Clay Minerals
.637	.0.545	با توجه به تک لایه بودن مدل رگرسیونی، مدل سازی شبکه های عصبی مصنوعی انجام نشده است	بند 40	.0.0337	میچکدام	.0.002	Clay Minerals
.641	.0.549	با توجه به تک لایه بودن مدل رگرسیونی، مدل سازی شبکه های عصبی مصنوعی انجام نشده است	بند 42	.0.0360	میچکدام	.0.002	Clay Minerals
.645	.0.57	با توجه به تک لایه بودن مدل رگرسیونی، مدل سازی شبکه های عصبی مصنوعی انجام نشده است	بند 44	.0.0371	میچکدام	.0.002	Clay Minerals
.649	.0.695	با توجه به تک لایه بودن مدل رگرسیونی، مدل سازی شبکه های عصبی مصنوعی انجام نشده است	بند 46	.0.0396	میچکدام	.0.002	Clay Minerals
.653	.0.725	با توجه به تک لایه بودن مدل رگرسیونی، مدل سازی شبکه های عصبی مصنوعی انجام نشده است	بند 48	.0.0455	میچکدام	.0.002	Clay Minerals
.656	.0.490	با توجه به تک لایه بودن مدل رگرسیونی، مدل سازی شبکه های عصبی مصنوعی انجام نشده است	بند 50	.0.0396	میچکدام	.0.002	Clay Minerals
.663	.0.549	با توجه به تک لایه بودن مدل رگرسیونی، مدل سازی شبکه های عصبی مصنوعی انجام نشده است	بند 52	.0.044	میچکدام	.0.002	Clay Minerals
.666	.0.545	با توجه به تک لایه بودن مدل رگرسیونی، مدل سازی شبکه های عصبی مصنوعی انجام نشده است	بند 54	.0.0331	میچکدام	.0.002	Clay Minerals
.669	.0.69	با توجه به تک لایه بودن مدل رگرسیونی، مدل سازی شبکه های عصبی مصنوعی انجام نشده است	بند 56	.0.0377	میچکدام	.0.002	Clay Minerals
.673	.0.6	با توجه به تک لایه بودن مدل رگرسیونی، مدل سازی شبکه های عصبی مصنوعی انجام نشده است	بند 58	.0.0776	میچکدام	.0.002	Clay Minerals
.677	.0.556	با توجه به تک لایه بودن مدل رگرسیونی، مدل سازی شبکه های عصبی مصنوعی انجام نشده است	بند 60	.0.280	میچکدام	.0.002	Clay Minerals
.681	.0.707	با توجه به تک لایه بودن مدل رگرسیونی، مدل سازی شبکه های عصبی مصنوعی انجام نشده است	بند 62	.0.467	میچکدام	.0.002	Clay Minerals
.686	.0.224	با توجه به تک لایه بودن مدل رگرسیونی، مدل سازی شبکه های عصبی مصنوعی انجام نشده است	بند 64	.0.192	میچکدام	.0.002	Clay Minerals
.690	.0.817	با توجه به تک لایه بودن مدل رگرسیونی، مدل سازی شبکه های عصبی مصنوعی انجام نشده است	بند 66	.0.613	میچکدام	.0.002	Clay Minerals
.693	.0.403	با توجه به تک لایه بودن مدل رگرسیونی، مدل سازی شبکه های عصبی مصنوعی انجام نشده است	بند 68	.0.358	میچکدام	.0.002	Clay Minerals
.696	.0.186	با توجه به تک لایه بودن مدل رگرسیونی، مدل سازی شبکه های عصبی مصنوعی انجام نشده است	بند 70	.0.358	میچکدام	.0.002	Clay Minerals
.700	.0.859	با توجه به تک لایه بودن مدل رگرسیونی، مدل سازی شبکه های عصبی مصنوعی انجام نشده است	بند 72	.0.545	میچکدام	.0.002	Clay Minerals
.707	.0.270	با توجه به تک لایه بودن مدل رگرسیونی، مدل سازی شبکه های عصبی مصنوعی انجام نشده است	بند 74	.0.490	میچکدام	.0.002	Clay Minerals
.711	.0.81	با توجه به تک لایه بودن مدل رگرسیونی، مدل سازی شبکه های عصبی مصنوعی انجام نشده است	بند 76	.0.695	میچکدام	.0.002	Clay Minerals
.715	.0.261	با توجه به تک لایه بودن مدل رگرسیونی، مدل سازی شبکه های عصبی مصنوعی انجام نشده است	بند 78	.0.119	میچکدام	.0.315	Clay Minerals

جیو، ۸- مقابسه عملکرد دنای، گیوسوتی، و مدارهای مختلف شبکه عصب، مصنوعی، در سنتاژ یو جنینز مانه

جدول ۹- نتایج مدل سازی رگرسیون خطی، بر روی داده های تعلیمی، مدل های شکه عصبی، در سناریو تک زمانه

جدول ۱۰- نتایج مدل سازی رگرسیون خطی بر روی داده های تعلیمی مدل های شبکه عصبی در سناریو چند زمانه

استفاده بوجود آمده‌اند. به بیان بهتر این شاخص‌ها به غیرخطی نمودن روابط مدل‌سازی کمک می‌کنند، البته فقط در موارد خاصی که به درستی از آنها استفاده شود. در این میان، شاخص اکسید آهن بیشتر از سایر شاخص‌ها در مدل‌سازی‌ها بکار گرفته شده است و پس از آن شاخص مواد معدنی آهن دار^۲ در رتبه بعدی قرار دارد که هر دو به منظور شناسایی ترکیبات آهن بکار می‌روند. مطابق جدول (۶) و (۷) ورود شاخص مواد معدنی آهن دار در مدل‌سازی کربن آلی و pH دقیق مدل‌سازی را به طور چشمگیری افزایش داده است. این دو شاخص از جمله شاخص‌های نسبتی^۳ هستند که در مطالعات سنجش از دوری کاربرد فراوانی دارند (Jensen, 2005)، بنابراین توصیه می‌شود در مطالعات مشابه در مدل‌سازی‌ها، این نوع شاخص‌های نسبتی برای تمامی باندهای ممکن محاسبه و برای غیرخطی نمودن معادلات بکار گرفته شود.

تقریباً در تمامی پارامترهای مورد بررسی مدل‌سازی رگرسیونی با سناریو چندماهه عملکرد به مراتب بهتری از سناریو تک‌ماهه نشان داده است. هر چند اغلب پارامترهای مورد بررسی در این تحقیق در طول سال تغییرات اندکی خواهند داشت، ولی ممکن است در یک زمان خاص، شاخصی به علت شرایط محیطی و ساختار قیزیکوشیمیایی متمایزتر از شاخص دیگر نشان دهد. بنابراین پیشنهاد می‌شود در این قبیل مطالعات از سری‌های زمانی داده‌ها با تنوع بیشتر و پراکنش بهتر در طول سال استفاده شود.

مدل‌سازی توسط شبکه‌های عصبی مصنوعی
مانند مدل‌سازی رگرسیونی، در مدل‌سازی‌ها توسط شبکه‌های عصبی مصنوعی نیز در کل سناریو چندماهه چه به لحاظ همبستگی داده‌های تعییمی و چه از نظر همبستگی داده‌های آزمایشی، عملکرد بهتری از سناریو تک‌ماهه داشته است. به نظر می‌رسد در مواردی که سناریو تک‌ماهه بهتر عمل نموده، احتمالاً با توجه به اینکه این شبکه‌ها بسی نهایت مقدار بهینه محلی دارند (Ivancevic & Ivancevic, 2005). تکرار سناریو چندماهه به اندازه کافی نبوده است. مثلاً مدل MLP در مورد شاخص عمق خاک در سناریو چندماهه (جدول ۸) نشان

■ بحث و نتیجه‌گیری

نوع داده مورد استفاده

نتایج این پژوهش نشان داد، در صورتی که داده‌های عددی رقومی به شکل خطی، پیش‌پردازش گردند و داده‌های سنجش از دوری انتخابی، ضوابط اشاره شده در این تحقیق مانند نداشتن مشکلات رادیومتری و اتمسفری، درصد پوشش ابری کمتر از ۱۰٪ درصد و ... را رعایت نموده باشند، تفاوت معنی‌داری میان مدل‌سازی پارامترهای بررسی کیفیت خاک توسط اعداد رقومی، تابندگی و بازتابندگی وجود ندارد. تباهی پیش‌پردازش تصحیح عوارض زمین^۱ به علت در نظر گرفتن شیب زمین، نتایج متفاوتی از دیگر پیش‌پردازش‌ها نشان می‌دهد.

نوع متداول‌وزی میدانی بررسی کیفیت خاک

اصولاً در ارزیابی‌های سنجش از دوری تخریب زمین و بیابان‌زایی دو اشکال اساسی دیده می‌شود (Yang et al, 2005):
 ۱- نامطمئن بودن سیستم‌های اندازه‌گیری و ارزیابی میدانی،
 ۲- درست استفاده نکردن از توان داده‌های سنجش از دوری. نتایج نشان داد، نوع متداول‌وزی میدانی و معیار و شاخص‌های آن تاثیر زیادی در مدل‌سازی‌های سنجش از دوری دارد. بر اساس یافته‌های این تحقیق، اصولاً در زمانی که پارامتر مورد بررسی کیفیت خاک، کمی باشد و بتوان آن را دقیق اندازه‌گیری نمود، داده‌های سنجش از دوری نیز در مدل‌سازی آن کارآمدتر نشان خواهد داد. به عنوان مثال پارامترهای درصد سنگریزه، کربن آلی، EC و pH به علت کمی بودن بهتر از دیگر پارامترها مدل‌سازی شده‌اند. حتی امتیاز کلی که از اندازه‌گیری‌های کمی میدانی بدست آمده است نیز قابلیت مدل شدن را بروز داده است.

مدل‌سازی رگرسیون خطی
مطابق اعداد جدول (۶)، استفاده از شاخص‌های سنجش از دوری بررسی کیفیت خاک همیشه موثر نیست، ولی در مورد برخی شاخص‌ها (مانند توزیع اندازه خاکدانه و کربن آلی در سناریو تک‌ماهه و pH ، بکارگیری این شاخص‌ها می‌تواند به طور چشمگیری به افزایش دقیق مدل‌سازی کمک کند هر چند که این شاخص‌ها از تبدیل معادلاتی همان باندهای طیفی مورد

² Ferrous Minerals

³ Ratio Index

¹ terrain effect

ملاحظه همبستگی داده‌های تعلیمی، کماکان همبستگی داده‌های آزمایشی در بهترین حالت خود، در همان سطح مدل‌سازی‌های اولیه قرار دارد. در واقع پیش‌بینی‌های سنجش از دوری پارامترهای مرتبط با خاک بر اساس داده‌های حاضر، بیش از این قابلیت افزایش توان مدل‌سازی نشان ندادند.

شاید اینگونه تصویر شود که می‌توان با افزایش بعد ورودی‌ها، مدل‌های شبکه عصبی حاضر را تقویت نمود. ولی همانند آنچه ینسن متذکر شده است (Jensen, 2005)، در اینجا نیز با افزایش بعد ورودی‌ها (افزایش داده‌های ورودی به بیش از سه لایه) هزینه نامطمئنی خروجی‌های آزمایشی بالا رفت. این تحلیل علمی، در عمل نیز در مورد برخی شاخص‌های کمی مانند کربن آلی، سنگریزه، pH و EC مورد آزمون قرار گرفت و مشاهده گردید اگر حتی بعد ورودی به مدل شبکه عصبی، معادل خروجی رگرسیون گام به گام نیز باشند، علی‌رغم افزایش معنی‌دار دقت داده‌های تعلیمی، ضریب همبستگی در داده‌های آزمایشی کاهش قابل ملاحظه‌ای در تکرارها نشان می‌دهد.

مقایسه واقعی مدل‌سازی رگرسیونی و شبکه‌های عصبی به شیوه داده‌های تعلیمی و آزمایشی (جدول ۹ و ۱۰) نشان داد، هر چند ممکن است روابط داده‌های سنجش از دوری و پارامترهای مرتبط با خاک در بسیاری از موارد غیرخطی باشد (Jensen, 2007)، ولی با غیرخطی نمودن این روابط به شکل شبکه‌های عصبی نمی‌توان انتظار داشت دقت مدل‌سازی افزایش چشمگیری داشته باشد. با این وجود بر اساس مقایسه اعداد جداول (۷) و (۹) می‌توان توصیه نمود در سناریوهای تکزمانه بهتر است بجای مدل‌های خطی مانند رگرسیون از مدل‌سازی شبکه‌های عصبی بهره گرفت. ولی با مقایسه جداول (۸) و (۱۰) نمی‌توان با توجه به پیچیدگی استفاده از شبکه‌های عصبی و نامطمئنی که در داده‌ها ایجاد خواهد نمود، به راحتی این شبکه‌ها را توصیه نمود. در واقع در سناریو چندزمانه در اغلب موارد، دقت واقعی این دو مدل‌سازی (رگرسیون و بهترین مدل شبکه‌ها عصبی)، به یکدیگر نزدیک است (به استثنای pH).

می‌دهد، شاید بتوان با تکرار بیشتر مدل‌سازی به نتایج بسیار بهتری دست یافت.

هرچند با مشاهده همبستگی داده‌های تعلیمی ممکن است به نظر برسد مدل‌های شبکه عصبی مصنوعی، در مدل‌سازی تمامی شاخص‌ها و معیارهای (کمی، چه کیفی) موفق نشان داده‌اند، ولی با در نظر گرفتن همبستگی داده‌های تعلیمی و داده‌های آزمایشی می‌توان در کل به این نتیجه رسید که شبکه‌های عصبی داده‌های کمی را به مراتب بهتر مدل‌سازی نموده‌اند.

هرچند در میان شبکه‌های عصبی *Modular feedforward networks* در مورد تمامی شاخص‌ها بهترین همبستگی داده‌های تعلیمی را نشان داده است ولی باید اشاره شود که این مدل در اغلب تکرارهای مشاهده شده ضعیفترین همبستگی داده‌های آزمایشی را نشان داده بنابراین با در استفاده از این شبکه بسیار دقت به خرج داد و حتماً مدل را آزمایش نمود. این امر در مورد شبکه *SOFMs* که معمولاً بهترین همبستگی داده تعلیمی را پس از شبکه مدولار دارد، نیز تا حد زیادی صادق است.

برخی از شبکه‌های عصبی مدل‌سازی‌های نسبتاً یکنواخت و گاهی کاملاً یکسان در تکرارهای مختلف نشان دادند. در این میان مدل *SVM* از تمامی مدل‌های دیگر پایدارتر بود و استفاده از آن معمولاً به تکرار مجدد نیازی نداشت. پس از آن، شبکه *CANFIS* بیشترین پایداری را در مدل‌سازی تکرارهای مختلف نشان داد و *RBF* و *PCA* در رتبه‌های بعدی از نظر پایداری قرار داشتند. در این میان مدل‌های *MPL* و مدل‌های منشعب از آن در تکرارهای مختلف، نتایج مدل‌سازی بسیار متفاوتی نشان می‌دادند. بنابراین توصیه می‌شود قبل از انتخاب مدل‌سازی توسط این شبکه‌ها از تکرار کافی بهمنظور حصول اطمینان بالاتر استفاده شود (عمق خاک در سناریو چند زمانه (جدول ۸)).

پس از کسب نتایج اولیه مدل‌های شبکه عصبی مصنوعی سعی شد با بهره‌گیری از خوارزمیک ژنتیک، پارامترهای هر شبکه برای مدل‌سازی شاخص‌های کمی بررسی کیفیت خاک، بهینه‌سازی شوند، اما نتایج نشان داد علی‌رغم افزایش قابل

■ منابع

1. Ahmadi, H. (2005). *The final report of compiling a comprehensive service plan and methodology of indicators and indices of desertification potential assessment in Iran*. In. University of Tehran: College of Agriculture & Natural Resources, Faculty of Natural Resources, Department of Rehabilitation of Arid and Mountainous Regions
2. Bouaziz, M., Matschullat, J., & Gloaguen, R. (2011). Improved remote sensing detection of soil salinity from a semi-arid climate in Northeast Brazil. *Comptes Rendus Geoscience*, 343, 795-803
3. Cammeraat, L.H., & Imeson, A.C. (1998). Deriving indicators of soil degradation from soil aggregation studies in southeastern Spain and southern France. *Geomorphology*, 23, 307–321
4. de Paz, J.M., Sanchez, J., & Visconti, F. (2006). Combined use of GIS and environmental indicators for assessment of chemical, physical and biological soil degradation in a Spanish Mediterranean region. *J Environ Manage*, 79, 150-162
5. Diodato, N., & Ceccarelli, M. (2004). Multivariate indicator Kriging approach using a GIS to classify soil degradation for Mediterranean agricultural lands. *Ecological Indicators*, 4, 177-187
6. Dogan, H.M. (2009). Mineral composite assessment of Kelkit River Basin in Turkey by means of remote sensing. *Journal of Earth System Science*, 118, 701–710
7. Douaoui, A.E.K., Nicolas, H., & Walter, C. (2006). Detecting salinity hazards within a semiarid context by means of combining soil and remote-sensing data. *Geoderma*, 134, 217-230
8. FAO/UNEP (1983). *Provisional Methodology for Assessment and Mapping of Desertification*. FAO
9. Feoli, E., Vuerich, L.G., & Zerihun, W. (2002). Evaluation of environmental degradation in northern Ethiopia using GIS to integrate vegetation, geomorphological, erosion and socio-economic factors. *Agriculture, Ecosystems and Environment*, 91, 313–325
10. Geist, H.J., & Lambin, E.F. (2004). Dynamic Causal Patterns of Desertification. *BioScience*, 54, 817-829
11. Goodwin, N.R., Coops, N.C., Wulder, M.A., Gillanders, S., Schroeder, T.A., & Nelson, T. (2008). Estimation of insect infestation dynamics using a temporal sequence of Landsat data. *Remote Sensing of Environment*, 112, 3680-3689
12. Gutierrez, M., & Johnson, E. (2010). Temporal variations of natural soil salinity in an arid environment using satellite images. *Journal of South American Earth Sciences*, 30, 46-57
13. Haijiang, L., Chenghu, Z., Weiming, C., En, L., & Rui, L. (2008). Monitoring sandy desertification of Otindag Sandy Land based on multi-date remote sensing images. *Acta Ecologica Sinica*, 28, 627-635
14. Helldén, U., & Tottrup, C. (2008). Regional desertification: A global synthesis. *Global and Planetary Change*, 64, 169-176
15. Hill, J., Stellmes, M., Udelhoven, T., Röder, A., & Sommer, S. (2008). Mediterranean desertification and land degradation. *Global and Planetary Change*, 64, 146-157
16. Hill, T., & Lewicki, P. (2006). *Statistics: methods and applications: a comprehensive reference for science, industry, and data mining*. Tulsa, OK: StatSoft
17. Huang, X., Senthilkumar, S., Kravchenko, A., Thelen, K., & Qi, J. (2007). Total carbon mapping in glacial till soils using near-infrared spectroscopy, Landsat imagery and topographical information. *Geoderma*, 141, 34-42
18. Ibáñez, J., Valderrama, J.M., & Puigdefábregas, J. (2008). Assessing desertification risk using system stability condition analysis. *Ecological Modelling*, 213, 180-190
19. Ivancevic, V.G., & Ivancevic, T.T. (2005). *Natural biodynamics*. Hackensack, N.J.: World Scientific
20. Jauffret, S., & Visser, M. (2003). Assigning life-history traits to plant species to better qualify arid land degradation in Presaharian Tunisia. *Journal of Arid Environments*, 55, 1-28
21. Jensen, J.R. (2005). *Introductory digital image processing: a remote sensing perspective*. (3rd Ed.).

- Upper Saddle River, N.J.: Prentice Hall
22. Jensen, J.R. (2007). *Remote sensing of the environment: an earth resource perspective*. (2nd Ed.). Upper Saddle River, NJ: Pearson Prentice Hall
23. Kosmas, C., Kirkby, M., & Geeson, N. (1999). *The Medalus project Mediterranean desertification and land use: Manual on key indicators of desertification and mapping environmentally sensitive areas to desertification*. In: European Commission
24. Ladisa, G., Todorovic, M., & Trisorio Liuzzi, G. (2012). A GIS-based approach for desertification risk assessment in Apulia region, SE Italy. *Physics and Chemistry of the Earth, Parts A/B/C*, 49, 103-113
25. Li, S., & Chen, X. (2014). A new bare-soil index for rapid mapping developing areas using LANDSAT 8 data. *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XL-4, 139-144
26. Liang, S. (2004). *Quantitative remote sensing of land surfaces*. Hoboken, N.J.: Wiley-Interscience
27. Liu, Y., Gao, J., & Yang, Y. (2003). A Holistic Approach Towards Assessment Of Severity Of Land Degradation Along The Greatwall In Northern Shaanxi Province, China. *Environmental Monitoring and Assessment*, 82, 187–202
28. Masoud, A.A. (2014). Predicting salt abundance in slightly saline soils from Landsat ETM+ imagery using Spectral Mixture Analysis and soil spectrometry. *Geoderma*, 217-218, 45-56
29. Mather, P.M., & Koch, M. (2011). *Computer processing of remotely-sensed images: an introduction*. (4th ed.). Chichester, West Sussex, UK ; Hoboken, NJ: Wiley-Blackwell
30. McDonagh, J., & Bunning, S. (2009a). *Field Manual for Local Level Land Degradation Assessment in Drylands, LADA-L Part 1: Methodological Approach, Planning and Analysis*. In (p. 76): FAO
31. McDonagh, J., & Bunning, S. (2009b). *Field Manual for Local Level Land Degradation Assessment in Drylands, LADA-L Part 2: Local Assessment: Tools and Methods for Fieldwork*. In (p. 133): FAO
32. Metternicht, G., & Zinck, A. (2008). *Remote Sensing of Soil Salinization: Impact on Land Management*. CRC Press
33. Okin, G.S., Parsons, A.J., Wainwright, J., Herrick, J.E., Bestelmeyer, B.T., Peters, D.C., & Fredrickson, E.L. (2009). Do Changes in Connectivity Explain Desertification? *BioScience*, 59, 237-244
34. Omuto, C.T. (2008). Assessment of soil physical degradation in Eastern Kenya by use of a sequential soil testing protocol. *Agriculture, Ecosystems & Environment*, 128, 199-211
35. Pinet, P.C., Kaufmann, C., & Hill, J. (2006). Imaging spectroscopy of changing Earth's surface: a major step toward the quantitative monitoring of land degradation and desertification. *C. R. Geoscience*, 338, 1042–1048
36. Rasmussen, K., Fog, B., & Madsen, J.E. (2001). Desertification in reverse? Observations from northern Burkina Faso. *Global Environmental Change*, 11, 271–282
37. Ravi, S., Breshears, D.D., Huxman, T.E., & D'Odorico, P. (2010). Land degradation in drylands: Interactions among hydrologic–aeolian erosion and vegetation dynamics. *Geomorphology*, 116, 236-245
38. Rodríguez Rodríguez, A., Luis Mora, J., Arbelo, C., & Bordon, J. (2005). Plant succession and soil degradation in desertified areas (Fuerteventura, Canary Islands, Spain). *Catena*, 59, 117-131
39. Ruiz-Sinoga, J.D., & Diaz, A.R. (2010). Soil degradation factors along a Mediterranean pluviometric gradient in Southern Spain. *Geomorphology*, 118, 359-368
40. Salvati, L., & Zitti, M. (2009). Assessing the impact of ecological and economic factors on land degradation vulnerability through multiway analysis. *Ecological Indicators*, 9, 357-363
41. Santini, M., Caccamo, G., Laurenti, A., Noce, S., & Valentini, R. (2010). A multi-component GIS framework for desertification risk assessment by an integrated index. *Applied Geography*, 30, 394-415
42. Sha-Sha, F., Pei-Jun, L., Qian, F., Xiao-Jun, L., Peng, L., Yue-Bing, S., & Yang, C. (2011). Soil Quality Degradation in a Magnesite Mining Area. *Pedosphere*, 21, 98-106

43. Snakin, V.V., Krechetov, P.P., Kuzovnikova, T.A., Alyabina, I.O., Gurov, A.F., & Stepichev, A.V. (1996). *The system of assessment of soil degradation*. *Soil Technology*, 8, 331-343
44. Stocking, M., & Murnaghan, N. (2000). *A Handbook for the Field Assessment of Land Degradation*. Norwich: Routledge
45. Wang, F., Chen, X., Luo, G., Ding, J., & Chen, X. (2013). Detecting soil salinity with arid fraction integrated index and salinity index in feature space using Landsat TM imagery. *Journal of Arid Land*, 5, 340-353
46. Wang, Z., Daun, C., Yuan, L., Rao, J., Zhou, Z., Li, J., Yang, C., & Xu, W. (2010). Assessment of the restoration of a degraded semi-humid evergreen broadleaf forest ecosystem by combined single-indicator and comprehensive model method. *Ecological Engineering*, 36, 757-767
47. Yanda, P.Z. (2000). Use of soil horizons for assessing soil degradation and reconstructing chronology of degradation processes: the case of Mwisanga Catchment, Kondoa, central Tanzania. *Geomorphology*, 34, 209–225
48. Yang, X., Zhang, K., Jia, B., & Ci, L. (2005). Desertification assessment in China: An overview. *Journal of Arid Environments*, 63, 517-531
49. Zhao, H., & Chen, X. (2005). Use of Normalized Difference Bareness Index in Quickly Mapping Bare Areas from TM/ETM+. In, *International Geoscience & Remote Sensing Symposium, IGARSS* (pp. 1666-1668). Seoul, Korea: IEEE
50. Zucca, C., Biancalani, R., Hamrouni, H., Attia, R., & Bunning, S. (2009). Guidelines for the identification, selection and description of nationally based indicators of land degradation and improvement. In (p. 57): *LADA*

Remote Sensed Data Capacities to Assess Soil Degradation

B. Rayegani¹*

1. Assistant Prof., College of Environment, Department of Environment, Karaj, Iran

* Corresponding Author, Email: behzad.rayegani@gmail.com

Received date: 31/10/2014

Accepted date: 08/03/2016

Abstract

This research has tried to take advantage of the two-field models in order to assess the remote sensing data capacities for modeling soil degradation. Based on the findings, pre-processing analysis types have not shown significant effect on accuracy of the model. Conversely type of field model used and its indicators and indices have a large impact on the accuracy of modeling. Also using some remote sensed indices such as Iron Oxide index and Ferrous Minerals index can help to improve the modeling accuracy of some field indices of soil condition assessment. According to the results, using time-series remote sensed data compared to the use of single date data can improve the model capacities significantly. Also, if artificial neural networks used on single date remote sensed data instead of multivariate linear regression, accuracy of the model can be increased dramatically because it helps the model to take the form of nonlinear. However, if time series of remote sensed data used, the accuracy of the artificial neural network modeling is not much different than the accuracy of regression model. It turned out to be contrary to what is thought but according to the results, increasing the number of inputs to artificial neural network modeling in practice reduces the actual accuracy of the model.

Keywords: Soil Degradation, Iranian Model of Desertification Potential Assessment, LADA methodology of land degradation, Remote sensed time series, Multivariate linear regression, Artificial neural networks