

عملکرد داده‌های سنجش از دوری در ارزیابی 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 قابل‌توجهی می‌نماید. بر اساس نتایج بدست آمده، استفاده از سری‌زمانی داده‌های سنجش از دوری نسبت به داده‌های تک‌زمانه به‌طور 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 بر خلاف 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، متدولوژی بررسی تخریب زمین لادا، سری‌زمانی داده‌های سنجش از دور، رگرسیون چندمتغیره خطی، شبکه‌های عصبی مصنوعی

■ 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؛ (۲) آب؛ (۳) پوشش گیاهی (McDonagh & Bunning, 2009a; de Paz et al., 2006).

تخریب خاک به‌عنوان 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 به‌عنوان یک منبع تجدیدنپذیر 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 (Diodato & Ceccarelli, 2004). به‌طور کلی تخریب خاک زمانی مورد توجه قرار می‌گیرد که کمیت فرآیندهای طبیعی و انسانی درون خاک و کیفیت تولید زی‌توده خاک دچار نقصان شود بنابراین به‌منظور درک شرایط موجود، ناگزیر به ارزیابی شرایط و وضعیت خاک می‌باشیم (Snakin et al., 1996).

هر کدام از وجه‌های 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 پدیده تخریب خاک ارائه شده است (Cammeraat & Imeson, 1998; de Paz et al., 2006; Diodato & 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

به متدولوژی مشروط ارزیابی و نقشه‌برداری بیابان‌زایی 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 زیست‌محیطی (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 مدالوس معیارهای کلیدی برای تعریف 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 خط‌مشی 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

^۱ Provisional methodology for assessment and mapping of desertification

^۲ Methodology for mapping Environmentally Sensitive Areas (ESAs) to Desertification

^۳ Mediterranean Desertification and Land Use

^۴ Land Degradation Assessment in Aridlands

^۵ Food and Agricultural Organization

^۶ Iranian Model of Desertification Potential Assessment

Haijiang et al., 2008; Helldén & Tottrup, 2008; Hill)
 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
 به‌طور 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 پرهزینه 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، به‌منظور بررسی کیفیت خاک و
 ارزیابی وضعیت آن، بیشترین تاکید بر روی تکنیک‌های
 سنجش از دوری قرار دارد تا مطالعات میدانی.

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 تک-
 پارامتره می‌باشند و حتی مطالعات چندپارامتره نیز در قالب یک
 مدل دیده نشده‌اند. در این میان مطالعات زیادی بر روی
 آشکارسازی سنجش از دوری شوری خاک (Douaoui et al.,)
 2006; Gutierrez & Johnson, 2010; Masoud, 2014;
 2013 (Metternicht & Zinck, 2008; Wang et al.,) انجام
 پذیرفته و حجم وسیعی از مطالعات سنجش از دوری بررسی
 کیفیت خاک، بر روی فاکتور شیمیایی شوری خاک متمرکز
 شده‌اند (Bouaziz et al., 2011). اما بررسی‌های سنجش از
 دوری سایر پارامترهای مرتبط با خاک مانند کربن آلی
 (Dogan, 2009; Huang et al., 2007)، ترکیبات شیمیایی ()
 (Wang et al., 2013)، تفکیک خاک‌های لخت از یکدیگر
 (Zhao & Chen, 2005) و رطوبت خاک (Goodwin et al.,)
 2008) به‌طور 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 دقتی 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 دقت بیشتری دارند یا داده‌های چند زمانه؟ و با
 غیرخطی نمودن مدل‌سازی تا چه اندازه می‌توان به بالا بردن
 دقت 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
 به‌طور 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 پرهزینه 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، به‌منظور بررسی کیفیت خاک و
 ارزیابی وضعیت آن، بیشترین تاکید بر روی تکنیک‌های
 سنجش از دوری قرار دارد تا مطالعات میدانی.

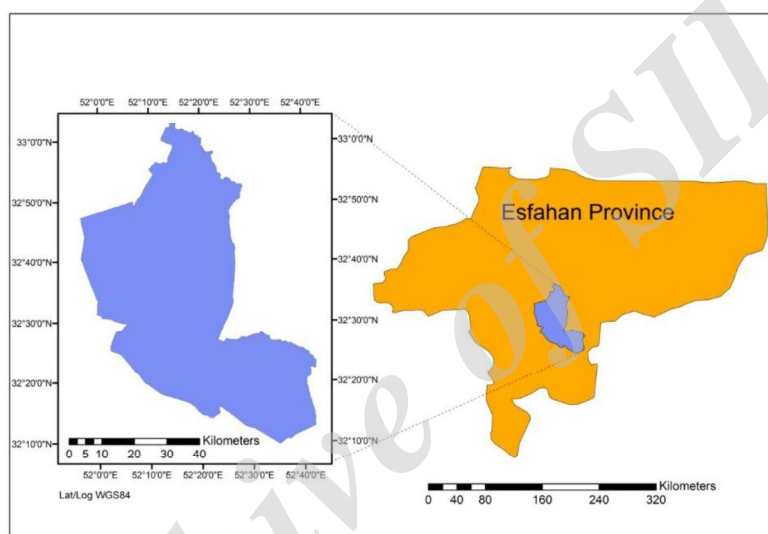
با توجه به وسعت مناطق بیابانی و دسترسی محدود به
 بسیاری از این مناطق، تلاش‌های زیادی صورت گرفته تا
 برخی از معیارها و شاخص‌های تخریب زمین و تخریب خاک
 (شناخت وضعیت و کیفیت آن) را بتوان به کمک داده‌های
 سنجش از دوری ارزیابی نمود، ولی هنوز هم یک سیستم
 شاخص و معیاری مناسب که از ترکیب داده‌های ماهواره‌ای
 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 گسترده 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.,)
 2005 (Yang et al., 2003)، روش‌های سنجش از دوری

■ مواد و روش‌ها

منطقه مورد مطالعه

محدوده مورد مطالعه با مساحت ۳۴۵۵۹۱ هکتار بین طولهای شرقی ۵۱°۵۶'۲۹" تا ۵۲°۴۲'۲۲" و عرض‌های شمالی ۳۲°۰۹'۴۱" 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 منطقه در مناطق کم ارتفاع حدود ۵۰ میلیمتر

و در مناطق مرتفع شمال در حدود ۲۵۰ میلیمتر در سال می‌باشد. رژیم بارندگی محدوده مطالعاتی، مدیترانه‌ای با فصل خشک متمرکز 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.



شکل ۱- موقعیت منطقه مورد مطالعه در استان اصفهان

روش مطالعه

نمونه‌برداری‌های میدانی

در این پژوهش دو متدولوژی 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، به‌عنوان 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 به‌عنوان 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.

به‌منظور 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، شیب، 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

^۱ Stratified Random Sampling

گرفته شود. لازم به ذکر است در مورد شاخص‌هایی که کمی و قابل اندازه‌گیری بودند (مانند pH ، EC سنگریزه و کربن آلی) در مدل‌سازی‌ها بجای امتیاز از مقدار کمی آن استفاده شده است تا خطای 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	خاک	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
	شاخص چشمی کیفیت خاک	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)
		پوسته و سله خاک	امتیازدهی به تشکیل سله در سطح خاک (امتیاز ۰ تا ۲ مثبت و منفی)
		کرم‌های خاکی (یا دیگر جانوران)	امتیازدهی به مشاهده جانداران شاخص در پروفیل خاک (امتیاز ۰ تا ۲)
		ریشه‌ها	امتیازدهی به مشاهده ناهنجاری در سیستم ریشه (امتیاز ۰ تا ۲)
LADA	امتیاز کل شاخص‌های چشمی	جمع وزنی شاخص‌ها (شاخص پوسته و کرم ضریب ۲؛ سایر شاخص‌ها ضریب ۳)	
	متلاشی شدن و شکسته شدن	امتیازدهی به شیوه متلاشی شدن خاکدانه در آب (امتیاز ۰ تا ۴)	
	pH خاک	امتیاز نمی‌گیرد فقط گزارش می‌شود	
	نفوذپذیری	زمان نفوذ $400ml$ آب داخل استوانه‌ای با قطر و ارتفاع $10cm$ (امتیاز ۰ تا ۲)	
	کربن آلی ناپایدار	امتیاز به میزان کربن آلی (اسپکتروفوتومتر در آزمایشگاه) (امتیاز ۰ تا ۲)	
	شوری خاک (EC)	امتیازدهی به میزان هدایت الکتریکی در خاک (امتیاز ۰ تا ۲)	
	امتیاز کل شاخص‌های اندازه‌گیری	جمع وزنی شاخص‌ها (شوری و نفوذپذیری وزن ۳؛ کربن ۲ و متلاشی شدن $1/5$)	
امتیاز کل وضعیت امتیاز کل	جمع جبری امتیاز شاخص‌های چشمی و شاخصهای اندازه‌گیری شونده		

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

۳- داده مشکل رادیومتری شامل نواری شدن^۱، بد پیکسل^۲، اثر ساچمه‌ای^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 پیش‌شرط 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

داده انتخاب شود؛ ۲) پراکنش زمانی داده‌ها مناسب باشد به گونه‌ای که فاصله زمانی داده‌ها خیلی کم یا زیاد نشود. ۶- برای آنکه بتوان نتایج دو سناریو را با یکدیگر مقایسه نمود، داده‌های هر دو سناریو جداگانه مدل‌سازی شدند و از ورود داده تک‌زمانه به مدل‌سازی چندزمانه اجتناب شد. با توجه به چندزمانه بودن یکی از سناریوهای مورد بررسی، به‌منظور انتخاب مناسب‌ترین داده و مقایسه عملکرد هر طبقه داده، به غیر از تصحیح هندسی و ثبت داده‌ها (Jensen, 2005,)

جدول ۲- داده‌های ماهواره‌ای مورد استفاده در مدل‌سازی‌ها

نام ماهواره	نوع تصحیح	داده مورد استفاده	توضیحات (Jensen, 2005; Liang, 2004; Mather & Koch, 2011)
LANDSAT 5 TM	۱ عدد رقومی	داده مورد استفاده	ارزش روشنایی پیکسلی که نمونه‌برداری در آن انجام شده، استخراج گردیده است
	۲ عدد رقومی تصحیح اتمسفری شده		به کمک اجسام تیره آ و روش رگرسیون اعداد رقومی تصحیح اتمسفری شده اند
	۳ تابندگی		استخراج مقادیر تابندگی بر اساس اطلاعات متادیتا
	۴ تابندگی تصحیح زاویه خورشیدی شده		تصحیح تابندگی بر اساس زاویه تابش خورشیدی (α) $\hat{L} = L \frac{1}{\sin(\alpha)}$
	۵ تابندگی با تصحیح توپوگرافیک		بوسیله مقادیر شیب β_T جهت شیب ϕ_T ، زاویه زینت θ_S و آزیموت خورشیدی ϕ_S $L_N = \frac{L \cos(\epsilon)}{\cos^k(i) \cos^k(\epsilon)}$
	۶ بازتابندگی		این بازتابندگی بوسیله اطلاعات ردیف ۳ بدست آمده است $\rho_p = \frac{\pi L_\lambda d^2}{ESUN_\lambda \cos \theta_s}$ و برای باند حرارتی (۶) $T = \frac{K2}{\ln\left(\frac{K1}{L_\lambda} + 1\right)}$
	۷ بازتابندگی تصحیح زاویه خورشیدی شده		این بازتابندگی بوسیله اطلاعات ردیف ۴ بدست آمده است
	۸ 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 کلاسیک منگولهای^۱ (Li & Chen, 2014; Masoud, 2014)، شاخص‌های خاک لخت^۲ (Zhao & Chen, 2005)، شاخص‌های شوری خاک^۳ (Wang et al., 2013)، ترکیبات شیمیایی و معدنی^۴ (Dogan, 2009)، کربن آلی^۵ (Huang et al., 2007) و رطوبت خاک (Goodwin et al., 2008) بر روی تمامی تاریخ‌های داده‌های سنجش از دوری (داده‌های بازتابندگی ردیف ۶ جدول ۲) بکار رفتند و مقادیر آنها در مکان‌های نمونه‌برداری استخراج شد تا در مدل‌سازی‌ها از آنها استفاده شود (توضیح شاخص‌های خاک در جدول ۳).

برای انجام تصحیح هندسی، ابتدا داده به‌هنگام 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 به‌عنوان ورودی مدل‌سازی‌های بعدی بکار گرفته شود.

¹ Digital Number(Brightness Value)

² Dark Object

³ Tasselled Cap Coefficients

⁴ normalized difference bareness index

⁵ Salinity Index

⁶ Chemical & Mineral Composition

جدول 3- شاخص‌های ارزیابی خاک مورد استفاده در این پژوهش

منبع	معادله	نام شاخص ³
Li & Chen, 2014;) (Masoud, 2014	$Brightness=(0.3037*TM1)+(0.2793*TM2)+(0.4343*TM3)+(0.5585*TM4)+(0.5082*TM5)+(0.1863*TM7)$ $Greenness=(-0.2848*TM1)+(-0.2435*TM2)+(-0.5436*TM3)+(0.7243*TM4)+(0.084*TM5)+(-0.18*TM7)$ $Wetness=(0.1509*TM1)+(0.1793*TM2)+(0.3299*TM3)+(0.3406*TM4)+(-0.7112*TM5)+(-0.4572*TM7)$	ضرایب کلاهک منگوله‌ای
Zhao & Chen,) (2005	$NDBa1 = TM7 - TM6/TM7 + TM6$ $NDBa2 = TM5 - TM6/TM5 + TM6$ $NDBa3 = TM3 - TM6/TM3 + TM6$	خاک لخت
(Wang et al., 2013)	$Salinity Index1 = TM5 - TM7/TM5 + TM7$ $Salinity Index2 = \sqrt{TM1 \times TM3}$ $Chemical Soil Composition = TM5 - TM6/TM3 + TM6$	شوری خاک ترکیبات
(Dogan, 2009)	$Ferrous Minerals = TM5/TM4$ $Iron Oxide = TM3/TM1$ $Clay Minerals = TM5/TM7$	معدنی و شیمیایی
Goodwin et al.,) (2008	$Moisture Index = TM5/TM7$ $Normalized Difference Water Index = TM4 - TM5/TM4 + TM5$	رطوبت خاک

به‌عنوان یک ابزار قابل اعتماد در آمار کاربردی مدرن برای حل بسیاری از مشکلات دنیای واقعی که مدل‌های مرسوم ممکن است از پس آنها برنیایند، 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 به‌عنوان گره⁴ یا واحد مخفی⁵ نیز شناخته می‌شوند که در صورت دریافت یک سیگنال دارای قدرت کافی از یک نورون دیگر که به آن متصل است، پیام مخابره می‌کند. طبیعت سیگنال مخابره شده توسط یک نورون به نوع تابع اعمال شده بر روی آن بستگی دارد. در حقیقت می‌توان نورون‌ها یا گره‌ها را به‌عنوان 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 گام¹ به‌عنوان متغیرهای مستقل وارد شدند تا تک‌تک شاخص‌ها و معیارها (جدول 1) را مدل‌سازی کنند. این آنالیز به‌طور جداگانه برای هر سناریو (تک‌زمانه و چند زمانه) 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 به‌منظور افزایش توان مدل، با غیرخطی نمودن پارامترها مورد آزمون قرار گیرند. همچنین به‌منظور 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

به‌منظور غیر خطی نمودن مدل‌ها از شبکه‌های عصبی مصنوعی² استفاده شده است. شبکه‌های عصبی مصنوعی

³ Neuron

⁴ Node

⁵ Hidden Unit

⁶ Fire

¹ 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 نامطئنی در پیش‌بینی‌ها (Jensen, 2005) به‌طور ناخواسته تشدید نگردد.

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

ردیف	نام شبکه عصبی	توضیحات (Ivancevic & Ivancevic, 2005)
۱	Multilayer perceptrons (MLPs)	حسگرهای چندلایه‌ای نوعی شبکه‌های عصبی توان بخشانه جلورونده با لایه‌های متناوبی از نورونها و وزن‌ها 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.
۲	Generalized feedforward networks	نوع خلاصه‌سازی 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 تئوری MLPها می‌توانند هر آنچه GFNها حل می‌کنند را حل کنند. در عمل GFNها اغلب مشکل را کارآمدتر حل می‌کنند (معمولاً تعداد تکرارهای بسیار کمتری نیاز دارند).
۳	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. برعکس MLPها در این شبکه‌ها بین لایه‌ها ارتباط کامل 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.
۴	Jordan and Elman networks	این شبکه‌ها نوع توسعه یافته MLP هستند که در آنها المانهای پردازشی (processing elements) فعالیت قبلی را بخاطر سپرده‌اند (در جایی به نام واحدهای سابقه (context units)). 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 کپی می‌شود در حالیکه در شبکه Jordan این اطلاعات به خروجی شبکه کپی می‌شود.
۵	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.
۶	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 نشده تنظیم می‌شود و یادگیری نظارت شده به لایه خروجی اعمالی می‌شود. این شبکه‌ها بسیار سریع تر از MLPها هستند.
۷	Self-organizing feature maps (SOFMs)	این شبکه‌ها بعدهای ورودی به مدل را به یک یا دو بعد مجزا بر اساس یک محدود توپولوژیکی تبدیل می‌کنند که به‌عنوان نقشه‌های ترکیبی (feature maps) شناخته می‌شوند. این نقشه‌ها بر اساس یادگیری نظارت نشده Kohonen محاسبه می‌شوند. خروجی این شبکه را می‌توان به‌عنوان ورودی در یک شبکه عصبی نظارت شده مانند MLP استفاده نمود. حسن این شبکه آنست که با دست‌بندی، فضای ورودی را با یک پردازش خودسازمان‌یافته به ترکیب‌های فضایی می‌شکنند. بنابراین ضمن حفظ فضای ورودی، بعد فضایی (تعداد ورودی) آن را کاهش می‌دهند.
۸	Time lagged recurrent networks (TLRNs)	TLRNها MLPهایی هستند که 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.
۹	Fully recurrent networks	این شبکه‌ها بازخور لایه مخفی را به خودش منتقل می‌کنند. شبکه‌های اندکی بازگشت‌کننده با یک شبکه بازگشت‌کننده کامل شروع می‌شوند و یک رابطه به سمت جلو (جلورونده) در آنها اضافه می‌شود که از بازگشت جلویی می‌کند و بخش بازگشت‌کننده را به‌عنوان یک حافظه بکار می‌گیرد. این شبکه‌های بازگشت‌کننده می‌توانند میزان حافظه بی‌نهایتی داشته باشند، بنابراین خواهند توانست با در نظر 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.
۱۰	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. این شبکه‌ها از آنجایی ارزش زیادی دارند که می‌توانند توابع عضویت فازی (قوانین با طبیعت توصیفی) را با قدرت شبکه‌های عصبی جمعه سیاه ترکیب کنند.
۱۱	The Support Vector Machine (SVM)	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 مرزهای خاص به کلاسهایی شکسته خواهند شد. این خوارزمیک در جداسازی مجموعه‌ای از داده‌ها که مرزهای پیچیده مشترکتی دارند، کارآمد نشان داده است. از SVMها تنها می‌توان برای طبقه‌بندی استفاده نمود نه برای تقریب زدن یک تابع.

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 ورودی^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 ۳ 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) تاثیر 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 بیش از اندازه تایج تمامی مدل‌ها به یکدیگر امکان تفکیک عملکرد بدین صورت ناممکن است. بنابراین به منظور 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 حد امکان یکسان در نظر گرفته شود (بجز روش MLP که ماهیتاً دست کم دو لایه مخفی موازی 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^۳ در لایه خروجی^۱ و در صورت وجود لایه مخفی تعداد المانهای پردازشی در تمامی مدل‌ها ۴ در نظر گرفته شد.

۴. در تمامی مدل‌ها تعداد نمونه‌ها^۵ معادل ۱۰۰ و تعداد بیشنه تکرار از مبدا جدید^۶ برابر ۱۰۰۰ وارد شدند.

۵. بجای مدل‌های SVM و $CANFIS$ (با توجه به ساختارشان) تابع تبدیل تمامی مدل‌ها تانژانت هایپربولیک و قانون یادگیری^۷ همگی $LevenbergMarquardt$ در نظر گرفته شده است.

۶. به صورت تصادفی ۳۰ درصد نمونه‌برداری‌ها به عنوان داده آزمون^۸ و ۷۰ درصد به عنوان داده تعلیمی^۹ 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، این‌گزینه تغییر نداشت).

¹ Genetic Optimization Algorithm

² momentum values

³ processing elements

⁴ Hidden Layers

⁵ exemplar

⁶ The Maximum Epochs

⁷ Learning Rule

⁸ test

⁹ train

¹⁰ enter

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 چندزمانه 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 *Modular feedforward networks* و *SOFMs* 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 دوبرابر بوده است. هرچند در اینجا نیز دقت مدل‌سازی داده‌های تعلیمی مدل‌های شبکه‌های عصبی بطور قابل ملاحظه‌ای بالاتر از روش رگرسیونی می‌باشد. در سناریو چندزمانه، 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 ۰/۲ است.

خاکدانه، 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 (بجز کربن آلی در حالت بکارگیری شاخص‌های کیفیت خاک) سناریو چندزمانه، 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 متدولوژی *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 چندزمانه 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 داده‌های آزمونی (*ttest*) توجه شود، تفاوت قابل ملاحظه‌ای بین مدل رگرسیونی و

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

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

* r_{its} : ضریب همبستگی داده‌های چند زمانه همراه با بکارگیری شاخص‌ها

r_{bts} : ضریب همبستگی داده‌های چند زمانه بدون بکارگیری شاخص‌ها

r_{is} : ضریب همبستگی داده‌های تک‌زمانه همراه با بکارگیری شاخص‌ها

r_{bs} : ضریب همبستگی داده‌های تک‌زمانه بدون بکارگیری شاخص‌ها

مدل‌های شبکه عصبی

The Support Vector Machine	Co-Active Neuro-Fuzzy Inference System		Fully recurrent networks		Time lagged recurrent networks		Self-organizing feature maps		Radial basis function		Principal component analysis networks		Jordan feedforward networks and Elman networks		Modular feedforward networks		Generalized feedforward networks		Multilayer perceptrons		سطحی معنی داری	r	رگرسیون	
	Ptest	Ftrain	Ptest	Ftrain	Ptest	Ftrain	Ptest	Ftrain	Ptest	Ftrain	Ptest	Ftrain	Ptest	Ftrain	Ptest	Ftrain	Ptest	Ftrain	Ptest	Ftrain				
0.146	0.714	0.160	0.153	0.189	0.576	0.266	0.69	0.315	0.925	0.1	0.55	0.207	0.73	-0.297	0.784	0.224	0.985	0.237	0.71	0.283	0.72	0.394	0.002	باند ۷-مهر
0.241	0.830	0.431	0.7	0.317	0.647	0.287	0.926	-0.187	0.913	0.337	0.150	0.857	-0.175	0.848	-0.169	0.992	0.994	0.332	0.86	0.305	0.86	0.516	0.000	هیچکدام
0.313	0.794	0.329	0.740	0.356	0.69	0.290	0.845	0.152	0.979	0.415	0.348	0.847	0.390	0.895	0.263	0.994	0.994	0.311	0.849	0.229	0.847	0.519	0.000	باند ۲-دی
0.283	0.63	0.670	0.674	0.618	0.57	0.616	0.845	0.368	0.978	0.536	0.588	0.798	0.516	0.878	0.445	0.997	0.997	0.596	0.864	0.589	0.876	0.567	0.000	هیچکدام
0.315	0.753	0.553	0.715	0.541	0.69	0.517	0.842	0.268	0.960	0.494	0.359	0.8	0.433	0.852	0.222	0.992	0.992	0.363	0.824	0.364	0.793	0.620	0.000	باند ۱-دی
0.75	0.753	0.553	0.715	0.541	0.69	0.517	0.842	0.268	0.960	0.494	0.359	0.8	0.433	0.852	0.222	0.992	0.992	0.363	0.824	0.364	0.793	0.546	0.000	باند ۶-دیبهشت
0.454	0.753	0.553	0.715	0.541	0.69	0.517	0.842	0.268	0.960	0.494	0.359	0.8	0.433	0.852	0.222	0.992	0.992	0.363	0.824	0.364	0.793	0.546	0.000	باند ۱-دی
VS- 0.454	0.753	0.553	0.715	0.541	0.69	0.517	0.842	0.268	0.960	0.494	0.359	0.8	0.433	0.852	0.222	0.992	0.992	0.363	0.824	0.364	0.793	0.546	0.000	NDBS3

با توجه به بدون لایه بون مدل رگرسیونی، مدل سازی شبکه‌های عصبی مصنوعی انجام نشده است
 با توجه به تک لایه بون مدل رگرسیونی، مدل سازی شبکه‌های عصبی مصنوعی انجام نشده است

جدول ۹- نتایج مدل‌سازی رگرسیون خطی بر روی داده‌های تعلیمی مدل‌های شبکه عصبی در سناریو تک‌زمانه

رگرسیون Reflectance by Origin Radiance			شاخص توزیع اندازه خاکدانه‌ها	رگرسیون Reflectance by Origin Radiance			شاخص توزیع اندازه کبریت‌های میدانی
نام مدل	معیار	شماره باند		نام مدل	معیار	شماره باند	
F_{test}	F_{train}			F_{test}	F_{train}		
0.364	0.420	Iron Oxide باند ۴	شاخص توزیع اندازه خاکدانه‌ها	0.2	0.422	باند ۴ NDBS2	شاخص توزیع اندازه کبریت‌های میدانی
0.270	0.318	Iron Oxide باند ۱ NDBS3		0.499	0.708	باند ۴ NDBS2	
0.164	0.182	Ferrous Minerals باند ۷	pH	0.230	0.235	باند ۴ NDBS3	شاخص توزیع اندازه کبریت‌های میدانی
0.565	0.387	Brightness Greenness Ferrous Minerals Chemical Soil Composition باند ۲	کربن آلی ناپایدار	0.494	0.540	باند ۶	شاخص توزیع اندازه کبریت‌های میدانی
0.223	0.484	Clay Minerals	امتیاز کل			باند ۵	

جدول ۱۰- نتایج مدل‌سازی رگرسیون خطی بر روی داده‌های تعلیمی مدل‌های شبکه عصبی در سناریو چندزمانه

رگرسیون بازتابندگی			شاخص توزیع اندازه خاکدانه‌ها	رگرسیون بازتابندگی			شاخص توزیع اندازه کبریت‌های میدانی
نام مدل	معیار	شماره باند		نام مدل	معیار	شماره باند	
F_{test}	F_{train}			F_{test}	F_{train}		
0.063	0.278	Ferrous Minerals pH Salinity Index1	شاخص توزیع اندازه خاکدانه‌ها	0.336	0.401	باند ۱ دی Iron	شاخص توزیع اندازه کبریت‌های میدانی
0.572	0.477	Wetness Greenness باند ۶ تیر Ferrous Minerals		0.439	0.506	باند ۱ دی Iron Oxide باند ۴ تیر باند ۴ اردیبهشت باند ۳ دی NDBS1	
0.576	0.661	باند ۱ دی امتیاز کل باند ۶ اردیبهشت	LADA	0.170	0.463	باند ۷ مهر Iron Oxide باند ۷ دی باند ۵ اردیبهشت	شاخص توزیع اندازه کبریت‌های میدانی
0.432	0.589	Moisture Index باند ۱ دی NDBS3	امتیاز کلی VS-Fast	0.368	0.563	باند ۲ دی باند ۴ اردیبهشت باند ۴ اردیبهشت Greenness مهر	شاخص توزیع اندازه کبریت‌های میدانی

■ بحث و نتیجه گیری

نوع داده مورد استفاده

نتایج این پژوهش نشان داد، در صورتی که داده‌های عدد 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. تنها پیش‌پردازش تصحیح عوارض زمین^۱ به علت در نظر گرفتن شیب زمین، نتایج متفاوتی از دیگر پیش‌پردازش‌ها نشان می‌دهد.

نوع متدولوژی 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 متدولوژی 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 خواهند داد. به‌عنوان 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 تک‌زمانه و pH)، بکارگیری این شاخص‌ها می‌تواند به طور چشمگیری به افزایش دقت مدل‌سازی کمک کند هر چند که این شاخص‌ها از تبدیل معادلاتی همان باندهای طیفی مورد

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 آهن‌دار^۲ در رتبه بعدی قرار دارد که هر دو به‌منظور شناسایی ترکیبات آهن بکار می‌روند. مطابق جدول (۶) و (۷) ورود شاخص موادمعدنی آهن‌دار در مدل‌سازی کربن آلی و pH دقت 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 غیر خطی نمودن معادلات بکار گرفته شود.

تقریباً در تمامی پارامترهای مورد بررسی مدل‌سازی رگرسیونی با سناریو چندزمانه عملکرد به مراتب بهتری از سناریو تک‌زمانه 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 قیژیکوشیمیایی 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 چند زمانه چه به لحاظ همبستگی داده‌های تعلیمی و چه از نظر همبستگی داده‌های آزمایشی، عملکرد بهتری از سناریو تک‌زمانه داشته است. به نظر می‌رسد در مواردی که سناریو تک‌زمانه بهتر عمل نموده، احتمالاً با توجه به اینکه این شبکه‌ها بی‌نهایت مقدار بهینه محلی دارند (Ivancevic & Ivancevic, 2005)، تکرار سناریو چندزمانه به اندازه کافی نبوده است. مثلاً مدل MLP در مورد شاخص عمق خاک در سناریو چند زمانه (جدول ۸) نشان

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 تصور شود که می‌توان با افزایش بعد ورودی‌ها، مدل‌های شبکه عصبی حاضر را تقویت نمود. ولی همانند آنچه یسنن 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، EC و pH 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 (به‌استثنای 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 معیارها (چه 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 اتمام 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-aolian 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

Archive of SID

Remote Sensed Data Capacities to Assess Soil Degradation

B. Rayegani^{1*}

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