

استفاده از روش‌های پیشرفته یادگیری ماشین در پایش فرسایش بادی در جنوب ایران

مهروز رضائی*: استادیار بخش مهندسی علوم خاک، دانشکده‌ی کشاورزی، دانشگاه شیراز، شیراز

عبدالمجید ثامن: دانشیار بخش مهندسی علوم خاک، دانشکده‌ی کشاورزی، دانشگاه شیراز، شیراز

سید رشید فلاح شمسی: دانشیار بخش منابع طبیعی و محیط زیست، دانشکده‌ی کشاورزی، دانشگاه شیراز، شیراز

تاریخ پذیرش: ۱۵/۷/۱۳۹۷

تاریخچه مقاله (تاریخ دریافت: ۱۳۹۷/۳/۱۸)

چکیده

یکی از مهم‌ترین فاکتورهای مؤثر در فرسایش بادی، تغییر کاربری/ پوشش اراضی است. پایش دقیق کاربری/ پوشش اراضی و شواهد فرسایش بادی، در مناطق خشک و نیمه‌خشک اهمیت زیادی دارد. تفکیک پوشش‌های اراضی حاصل از فرسایش بادی نظیر پهنه‌های ماسه‌ای و نبک‌ها، نیازمند استفاده از روش‌های دقیق سنجش از دور است. در این تحقیق برای تهیه‌ی نقشه‌ی کاربری/ پوشش اراضی در زمینه‌ی فرسایش بادی، توانایی تکنیک‌های پیشرفته‌ی یادگیری ماشینی بر تصاویر لندست ارزیابی شد. بدین منظور، تصاویر لندست ۷ (۲۰۰۶) و لندست ۸ (۲۰۱۳) از نظر هندسی و رادیومتریکی تصحیح شد. روش‌های بارزسازی تصاویر، اعمال شد و با الگوریتم‌های ماشین بردار پشتیبان با چهار نوع تابع کرنل خطی، چندجمله‌ای، تابع شعاعی مینا و حلقوی و روش شبکه عصبی مصنوعی خودسازمان‌دهنده‌ی کوهنن، طبقه‌بندی و با روش حداکثر شباهت مقایسه شد. با استفاده از آزمون‌های جدایی‌پذیری، بهترین ترکیب باند ورودی طبقه‌بندی انتخاب شد. ارزیابی دقت نشان داد که بهترین نقشه با ترکیبی از باندهای خام و پردازش شده و با الگوریتم ماشین بردار RBF (دقت کلی ۸۸٪ و ۹۰/۸۷٪ برای تصاویر لندست ۷ و ۸) حاصل می‌شود. اختلاف دقت این روش با روش‌های ماشین بردار خطی، چندجمله‌ای، SOM، حلقوی و ML به ترتیب ۱/۵، ۲/۹، ۸/۳، ۱۲/۴ و ۱۶/۴ درصد برای لندست ۷ و به ترتیب ۲/۱۶، ۴/۱۶، ۶/۱۹، ۱۳/۸۹ و ۱۴/۶۷ درصد برای لندست ۸ است. نتایج نشان داد که دقت طبقه‌بندی با استفاده از ترکیب باندهای پردازش شده و باندهای خام، در مقایسه با باندهای خام به تنهایی به میزان زیادی افزایش می‌یابد.

واژگان کلیدی: فرسایش بادی، کاربری/ پوشش اراضی، لندست، ماشین بردار پشتیبان.

۱- مقدمه

فرسایش بادی از مهم‌ترین عوامل تخریب خاک در نواحی خشک و نیمه‌خشک و یکی از جدی‌ترین مشکلات زیست‌محیطی جهان به شمار می‌رود. توانایی پیش‌بینی دقیق فرسایش بادی خاک برای بسیاری منظرها از جمله برنامه‌های حفاظتی، منابع طبیعی و کاهش آلودگی هوا ضروری است. حفاظت از خاک در برابر فرسایش بادی تنها زمانی ممکن است که از وضعیت فرسایش، شناخت کافی حاصل شود. این در حالی است که مطالعات انجام شده


در زمینه‌ی فرسایش بادی در ایران بسیار اندک و پراکنده است؛ از این رو، هرگونه پژوهش در این زمینه برای ایران - که حدود ۸۰ میلیون هکتار آن را مناطق خشک و نیمه‌خشک فرا گرفته - ضرورتی انکارناپذیر است. در استان فارس نیز ۱۷ شهرستان در معرض خطر بیابان‌زایی قرار دارد و به عنوان کانون‌های بحرانی فرسایش بادی شناسایی شده‌است (NRWMO, 2005). بسیاری از فاکتورهای مؤثر در فرسایش بادی در یک منطقه‌ی معین برای مدت زمان کوتاه ثابت است؛ اما کاربری/پوشش اراضی و مدیریت سرزمین، از فاکتورهای مهم در فرسایش خاک است که می‌تواند در طول زمان تغییر کند؛ بنابراین، پایش تغییرات کاربری/پوشش اراضی می‌تواند در ردیابی فرسایش خاک مؤثر باشد. در سال‌های اخیر برای اثبات اثر این تغییرات بر فرسایش خاک، مطالعات متعددی انجام شده‌است (Garcia-Ruiz, 2010 & Wijitkosum, 2012). در این راستا استفاده از فنون سنجش از دور از جمله طبقه‌بندی تصاویر ماهواره‌ای، به طور وسیعی در تولید نقشه‌های کاربری/پوشش اراضی قابل توجه قرار گرفته‌است. تصاویر ماهواره‌ای چند طیفی به خصوص تصاویر لندست، از مهم‌ترین منابع برای پایش کاربری/پوشش اراضی است. با راه‌اندازی لندست ۸، منبع جدید و دقیق‌تری برای این پایش فراهم شد (Jia et al, 2014).

پهنه‌بندی فرسایش بادی به روش طبقه‌بندی طیفی در مناطقی که با پدیده‌ی انباشت ماسه‌های بادی در سطوح بزرگ مواجه نیستند، به دقت بالایی نیاز دارد. یادگیری ماشینی به عنوان یکی از شاخه‌های پرکاربرد هوش مصنوعی، به کشف الگوریتم‌هایی می‌پردازد که براساس آنها رایانه‌ها توانایی یادگیری می‌یابند. مطالعات نشان داده در طبقه‌بندی تصاویر ماهواره‌ای، روش‌های شبکه عصبی مصنوعی نسبت به سایر روش‌ها از دقت بیشتری برخوردار است (Benediktsson and Ahmadi Nadooshan, Sveinsson, 1997 & Bischof, et al, 1991). همکاران (۲۰۰۹) در تهیه‌ی نقشه‌ی پوشش اراضی اراک، بیان کردند که شبکه عصبی نسبت به روش حداکثر شباهت از صحت بالاتری برخوردار است. Yuan و همکاران (۲۰۰۹)، سیستم شبکه عصبی مصنوعی اتوماتیک را برای طبقه‌بندی کاربری اراضی از تصاویر ماهواره‌ای لندست معرفی کردند. در این سیستم، از دو روش شبکه عصبی SOM و پرسپترون چند لایه استفاده شد. Goodarzimehr و همکاران (۲۰۱۲)، برای تفکیک واحدهای سنگ‌شناسی روش ماشین‌بردار پشتیبان را با روش‌های ML و شبکه عصبی مقایسه و بیان کردند که SVM بیشترین دقت را ارائه می‌دهد. همچنین این روش با ۵۰٪ از داده‌های تعلیمی، می‌تواند به دقتی معادل با استفاده از ۱۰۰٪ نمونه‌های تعلیمی برسد. Kumar و همکاران (۲۰۱۲)، الگوریتم‌های یادگیری ماشینی پیشرفته را در طبقه‌بندی داده‌ی لندست ETM+ ارزیابی کردند. آنها طبقه‌بندی متنی با استفاده از تخمین پسین حداکثر را بهترین روش طبقه‌بندی معرفی کردند. Fathizad و همکاران (2015) برای استخراج نقشه‌ی پوشش مرتعی در حوزه‌ی دویرج دهلران بیان کردند که نتایج شبکه عصبی مصنوعی آرتمپ فازی نسبت به روش طبقه‌بندی ML از دقت بیشتری برخوردار است. آنها علت این امر را غیر خطی بودن شبکه عصبی عنوان کردند.

اگرچه مطالعات زیادی در زمینه‌ی استفاده از روش‌های یادگیری ماشینی در تهیه‌ی نقشه‌ی کاربری/پوشش اراضی انجام شده، تاکنون پژوهشی در در زمینه‌ی فرسایش بادی با روش‌های مذکور صورت نگرفته‌است. بنابراین، پژوهش حاضر با هدف بررسی کارایی روش‌های یادگیری ماشینی در تهیه‌ی نقشه و بررسی تغییرات کاربری/پوشش اراضی در زمینه‌ی فرسایش بادی و مقایسه‌ی آنها با دیگر روش‌های رایج انجام شد. همچنین انتخاب بهترین باندهای ورودی برای طبقه‌بندی نیز در این مطالعه بررسی شده‌است.

۲- منطقه‌ی مورد مطالعه

دژگاه، در استان فارس با مساحتی معادل ۱۷۲۳۰ هکتار در $52^{\circ} 07' 36''$ تا $52^{\circ} 23' 55''$ طول جغرافیایی و $28^{\circ} 07' 15''$ تا $28^{\circ} 07'$ عرض جغرافیایی واقع شده است (شکل ۱). بر اساس آمار ۱۳ ایستگاه هواشناسی، میانگین بارندگی سالیانه ۱۹۰/۱۹ میلی‌متر و میانگین سالیانه دما ۲۵/۴۵ درجه‌ی سانتی‌گراد است. میزان متوسط تبخیر و تعرق نیز ۱۹۲۷/۳۵ میلی‌متر است. اقلیم منطقه طبق روش آمبرژه، بیابانی گرم میانه است. این منطقه‌ی مطالعاتی، به عنوان بحرانی‌ترین کانون فرسایش بادی استان فارس شناخته شده است (NRWMO, 2005).



شکل ۱: موقعیت جغرافیایی و شواهد فرسایش بادی در منطقه

۳- مواد و روش‌ها

- داده و پیش پردازش تصاویر

در این تحقیق از تصاویر ماهواره‌ای لندست ۷ (۵ جولای ۲۰۰۶) و لندست ۸ (۳۰ جون ۲۰۱۳) استفاده شد. جدیدترین ماهواره‌ی لندست، لندست ۸ است که در ۱۱ فوریه‌ی ۲۰۱۳ راه اندازی شد. این ماهواره با دو سنسور عملیاتی تصویرساز زمین و سنسور حرارتی مادون قرمز، اطلاعات تصویر را برای ۹ باند موج کوتاه و ۲ باند طول موج حرارتی جمع‌آوری می‌کند (Masek et al, 2001). لندست ۸ حدود ۴۰۰ تصویر در روز می‌گیرد که نسبت به ۲۵۰ تصویر ماهواره‌ی لندست ۷، افزایش زیادی یافته است (Jia et al, 2014). روش‌های مختلف تحقیق در نرم‌افزارهای ENVI 5، IDRISI Taiga و ArcGIS 9.3 انجام شد. تصاویر دانلود شده از سایت USGS از نظر هندسی تصحیح شده است، اما برای اطمینان، این تصاویر با استفاده از نقشه‌ی آبراهه و جاده‌ها کنترل شد. تصحیح رادیومتریکی نیز با روش کاهش تیرگی پدیده^۱ انجام شد. در این روش، بخش‌هایی از تصویر مثل آب عمیق با ارزش عددی صفر بررسی شد. در صورتی که ارزش عددی تصویر بیش از صفر باشد، این امر بیانگر خطاست. برای انجام تصحیح رادیومتری، ارزش‌های رقومی ابتدا به تابش طیفی (معادله‌ی ۱)، سپس به بازتاب طیفی (معادله‌ی ۲) تبدیل می‌شود.

^۱ Dark Object Subtraction

$$L = \text{Gain} * \text{DN} + \text{Offset} \quad (1)$$

$$p = \frac{\pi L d^2}{\text{ESUN} \cdot \cos(SZ)} \quad (2)$$

L تابش طیفی ($\mu\text{m}^{-1} \text{Ster}^{-2} \text{Wem}$)، DN ارزش رقومی، Gain و Offset ضرایب کالیبراسیون، p بازتاب طیفی، d^2 مجذور فاصله‌ی زمین و خورشید، ESUN ارتفاع خورشید و SZ زاویه‌ی خورشید است.

- نمونه‌های تعلیمی

به علت وجود تنوع زیاد در منطقه، انتخاب نمونه‌ی تعلیمی مناسب و به تعداد کافی اهمیت زیادی دارد. همچنین سهم کاربری‌های مختلف با مدیریت متفاوت در فرسایش بادی یکسان نیست؛ از این رو، انتخاب نمونه تعلیمی نیازمند داشتن شناخت دقیق نسبت به منطقه‌ی مورد مطالعه است که این مهم از طریق بازدیدهای میدانی متعدد با استفاده از GPS (با دقت یک تا سه متر) و ترکیبات رنگی مختلف تصاویر لندست صورت گرفت. در این تحقیق از نشانه‌های مستقیم بر روی زمین لخت، نشانه‌های ارائه شده توسط پوشش گیاهی و کاربری اراضی و نشانه‌های ارائه شده توسط ژئوفرم‌ها در ایجاد رابطه با فرسایش بادی استفاده شده است.

- پردازش تصاویر ماهواره‌ای و انتخاب باندهای بهینه

به علت تنوع زیاد کاربری/پوشش اراضی در منطقه و مشکل بودن تشخیص شواهد فرسایش بادی به طور مستقیم از روی تصاویر ماهواره‌ای، پردازش و بارسازی تصاویر امری ضروری است. استفاده‌ی ساده از باندهای خام تصاویر ماهواره‌ای در طبقه‌بندی، در بسیاری از موارد دقت لازم را در پی نخواهد داشت. بنابراین در این تحقیق، به بررسی بهترین ترکیب باندی ورودی پرداخته شد. همچنین در این تحقیق از تکنیک‌های بارسازی شامل ترکیبات رنگی کاذب، کشش کنتراست^۲، تحلیل مؤلفه‌های اصلی^۳، فیوژن تصاویر، آنالیز بافت و شاخص‌های پوشش گیاهی و خاک استفاده شد. استراتژی این تحقیق در انتخاب بهترین باندهای ورودی برای طبقه‌بندی، انتخاب باندهایی است که حداکثر جدایی‌پذیری بین طبقات را ارائه دهند. هر طبقه‌ای که توسط این باند به خوبی جدا نشود، توسط باند یا شاخص اختصاصی تشخیص داده می‌شود. این روش سلسله‌مراتبی می‌تواند به نتایج بهتری در طبقه‌بندی منجر شود. برای بررسی جدایی‌پذیری طبقات، ابتدا نمودار جدایی‌پذیری نمونه‌های تعلیمی در مقابل باندهای ورودی ترسیم شد. سپس ماتریس همبستگی بین باندهای انتخاب شده از نمودارها ایجاد و باندهای دارای همبستگی بالا با یکدیگر حذف شد. در نهایت، ارزیابی کمی جدایی‌پذیری با شاخص‌های جفری ماتوسیا و واگرایی تبدیل شده بررسی شد (Richards and Jia, 2006). در این تحقیق سه ترکیب باند ورودی برای طبقه‌بندی مقایسه شد: باندهای اصلی تصویر لندست ۸، باندهای حاصل از PCA و باندهای انتخابی از باندهای اصلی و پردازش شده براساس آنالیز جدایی‌پذیری. علت استفاده از روش PCA این است که باندهای چند طیفی همبستگی

² Stretching

³ Principal Component Analysis (PCA)

بالایی با هم دارند که به نوعی، تکرار اطلاعات یک باند در باند دیگر است و ضرورتی نیست که از تمامی باندها در تجزیه و تحلیل استفاده شود.

- طبقه‌بندی تصاویر ماهواره‌ای

برای طبقه‌بندی تصاویر ماهواره‌ای، از روش‌های یادگیری ماشینی شبکه عصبی کوهنن (Kohonen, 1990) و SVM با ۴ تابع کرنل استفاده شد. در نهایت با فیلتر پایین‌گذر میانه 3×3 پیکسل، پیکسل‌های منفرد در سطح تصویر طبقه‌بندی شده، حذف شد.

- شبکه عصبی مصنوعی خود سازمان دهنده کوهنن

تاکنون انواع مختلفی از شبکه عصبی مصنوعی برای استخراج نقشه‌ی کاربری/پوشش اراضی از تصاویر ماهواره‌ای ارائه شده‌است که یکی از متداول‌ترین آنها شبکه عصبی کوهنن است. در طبقه‌بندی شبکه عصبی سه مرحله وجود دارد: فرایند آموزشی با استفاده از داده‌های ورودی، فاز اعتبارسنجی و طبقه‌بندی. در شبکه‌ی SOM، از روش یادگیری رقابتی برای آموزش استفاده شد و ساختار آن دارای یک لایه‌ی ورودی و تعدادی نرون خروجی است (Kohonen, 1990). پس از آموزش شبکه به داده‌ها، نمونه‌ها به شبکه معرفی می‌شود. خروجی شبکه نیز بر اساس کمترین فاصله است. تعداد نرون‌های ورودی همان تعداد باندهای ورودی است. در شبکه عصبی چنانچه سرعت یادگیری زیاد انتخاب شود، نتایج ضعیفی به دست می‌آید. در این تحقیق، تمامی پارامترها با معرفی مقادیر مختلف، آزموده و مقادیر بهینه برای شبکه انتخاب شد (جدول ۳).

- ماشین بردار پشتیبان

ماشین بردار پشتیبان، تکنولوژی جدید یادگیری ماشینی است که روش آماری غیر پارامتریک و نیمه‌نظارت شده‌است. ویژگی اصلی این روش، توانایی بالا در استفاده از نمونه‌های تعلیمی کمتر و رسیدن به دقت بالاتر در مقایسه با سایر روش‌ها است. اگر طبقات تفکیک خطی نداشته باشند، SVM فضای پدیده‌ها را در فضایی چندبعدی با استفاده از کرنل ترسیم می‌کند. سپس طبقات را در فضای جدید، تفکیک می‌سازد. این مورد در حل مشکلات طبقه‌بندی‌های پیچیده موفق بوده‌است (Tzotsos et al, 2011 & Persello, 2010). علاوه بر این، داده‌های سنجش از دور معمولاً توزیع مشخصی ندارند؛ در حالی که فرض اولیه‌ی روش‌هایی مانند ML، نرمال بودن داده است (Jia et al, 2014). ماشین بردار پشتیبان، مدلی بر پایه‌ی کرنل است و با انتخاب کرنل مناسب می‌توان بر این مشکلات غلبه کرد. در الگوریتم SVM، فاصله‌ی نمونه X_i از ابر صفحه ماشین بردار پشتیبان از معادله‌ی زیر بدست می‌آید:

$$f(x_i) = \sum_{j=1}^n \alpha_j y_j K(x_j, x_i) + b \quad (3)$$

در این رابطه، $k(x_j, x_i)$ کرنل است که تشابه بین نمونه X_i و بردار پشتیبان X_j را تعریف می‌کند. اینها پیکسل‌هایی هستند که ضریب غیرصفر α_j را نشان می‌دهند. ضریب y_j وکتور پشتیبان برای نمونه‌هایی که طبقه مثبت دارند، +۱ و برای آنهایی که طبقه منفی دارند، -۱ است. برای بررسی دقیق‌تر این روش، چهار تابع مختلف خطی (رابطه‌ی ۴)، چندجمله‌ای

(۵)، حلقوی (۶) و RBF (۷) ارزیابی شد. در صورتی که ابرداها تداخل زیادی داشته باشند، می‌توان از کرنل‌های چند-جمله‌ای با درجات و گامای متفاوت یا از کرنل RBF استفاده کرد (روابط ۴، ۵، ۶ و ۷).

$$K(x_i, x_j) = x_i^T x_j \quad (۴)$$

$$K(x_i, x_j) = (g x_i^T x_j + r) d, g > 0 \quad (۵)$$

$$K(x_i, x_j) = \tanh(g x_i^T x_j + r) \quad (۶)$$

$$K(x_i, x_j) = \exp(-g \|x_i - x_j\|^2), g > 0 \quad (۷)$$

در این روابط T ماتریس ترانهاده، g گاما، d درجه‌ی چند جمله‌ای و x_i و x_j نشان‌دهنده‌ی بردار مؤلفه‌ی i ام و j ام است.

- ارزیابی صحت

بدین منظور نقاط کنترل تصادفی و مستقل تولید و نوع کاربری/پوشش اراضی و پتانسیل فرسایش بادی واقعی آنها از طریق بازدیدهای زمینی بررسی شد. همچنین از تفسیر بصری تصاویر، با قدرت تفکیک بالای پایگاه اطلاعاتی گوگل‌ارت استفاده شد. سپس با مقایسه‌ی نقشه‌های طبقه‌بندی با نقشه‌ی واقعیت زمینی، پارامترهای برآورد دقت شامل دقت کلی و ضریب کاپای کوهن حاصل از ماتریس خطا محاسبه شد. در نهایت با مقایسه‌ی بهترین نقشه‌های تولیدی در سال ۱۳۸۵ و ۱۳۹۲، تغییرات پتانسیل فرسایش بادی در منطقه مورد بررسی قرار گرفت.

۴- یافته‌ها (نتایج)

نمونه‌های تعلیمی انتخاب شده براساس تفاوت در پتانسیل فرسایش بادی یا وجود شواهد این فرسایش نظیر پهنه‌ها و تپه‌های ماسه‌ای، نیکها و غیره در دوازده کلاس قرار گرفت: مرتع با پوشش مناسب، مرتع با پوشش ضعیف، پهنه‌های ماسه‌ای، تپه‌های ماسه‌ای فیتوژنیک (نیکا)، کشاورزی با تراکم نسبتاً متراکم، کشاورزی زیر پلاستیک با تراکم متوسط، کشاورزی با تراکم بسیار کم، اراضی کشاورزی رها شده، مناطق دارای پوسته‌ی رسی سخت، مناطق سنگلاخی (زبری زیاد)، مخروط افکنه و سایر مناطق. ذکر این امر لازم است که طبقه‌بندی اراضی کشاورزی مختلف، به دلیل تفاوت در مدیریت و تراکم پوشش و در نتیجه تفاوت در پتانسیل فرسایش بادی است. بر اساس نتایج روش سلسله مراتبی در بررسی جدایی‌پذیری نمونه‌های تعلیمی، در نهایت ترکیب باندهای مادون قرمز، مادون قرمز کوتاه ۱، شاخص‌های پوشش گیاهی $WDVI^4$ و $SAVI^5$ ، شاخص آهک LI^6 و باندهای پردازش شده حاصل از آنالیز بافت لبه^۷ در جهت جغرافیایی شرقی، به عنوان بهترین باندهای ورودی انتخاب شد. آنالیز لبه به خصوص جهت شناسایی تپه‌های ماسه‌ای از اهمیت زیادی برخوردار بود. ارزیابی جدایی‌پذیری با جفری ماتوسیا (جدول ۳) نشان داد که ترکیبات جفتی طبقات موضوعی به خوبی قابل

⁴ Weighted Difference Vegetation Index

⁵ Soil-Adjusted Vegetation Index

⁶ Limestone Index

⁷ Edge

تفکیک‌اند. در PCA، سه مؤلفه‌ی اول دربرگیرنده‌ی بیشترین اطلاعات بود (جدول ۱)؛ بنابراین، به عنوان یک ترکیب ورودی در طبقه‌بندی ارزیابی شد.


پتانسیل فرسایش بادی با استفاده از دو الگوریتم یادگیری ماشینی SVM با چهار تابع کرنل خطی، چند جمله‌ای، RBF و حلقوی و شبکه عصبی SOM، تهیه و با روش ML مقایسه شد (شکل‌های ۴-۱۵). از پارامترهای بهینه برای ایجاد شبکه عصبی SOM مطابق جدول ۲ استفاده شد. پارامترهای آماری ماتریس خطا، دقت کلی و کاپا نقشه‌های طبقه‌بندی شده با تمامی روش‌ها (جدول ۴) نشان داد که با استفاده از تمامی روش‌های طبقه‌بندی، از بین سه ترکیب باند ورودی ترکیب باند انتخابی شامل باندهای اصلی انتخابی و باندهای پردازش شده نسبت به استفاده از باندهای خام لندست به تنهایی و سه مؤلفه‌ی PCA دقت بیشتری دارند. این موضوع اهمیت روش‌های بارسازی انجام شده بر تصاویر را قبل از طبقه‌بندی نشان می‌دهد. با توجه به جداول ۵ و ۶ به خوبی قابل مشاهده است که استفاده از باندهای انتخابی حتی با الگوریتم ساده ML (۷۱/۶ درصد برای لندست ۷ و ۷۶/۲ درصد برای لندست ۸) نسبت به استفاده از باندهای خام با الگوریتم یادگیری فعال دقت بالاتری دارد؛ بنابراین روشن می‌شود اگر قبل از طبقه‌بندی به انتخاب باند ورودی توجه نشود، حتی با دقیق‌ترین الگوریتم‌های طبقه‌بندی نیز دقت کافی به دست نخواهد آمد. ثانیاً از بین الگوریتم‌های طبقه‌بندی، روش SVM با تابع کرنل RBF با دقت کلی ۸۸ و ۹۰/۸۷ درصد و ضریب کاپای ۰/۸۸ و ۰/۹، به ترتیب برای تصاویر لندست ۷ و لندست ۸ از بالاترین دقت برخوردار بود.

جدول ۱: تحلیل مؤلفه‌های اصلی برای تصاویر لندست


کانال‌های ویژه	واریانس (%)	
	لندست ۷	لندست ۸
۱	۷۳/۴۳	۸۲/۳۸
۲	۲۳/۱۵	۱۳/۰۹
۳	۲/۳۴	۳/۷۴
۴	۰/۸۴	۰/۷۵
۵	۰/۱۶	۰/۰۴
۶	۰/۰۸	۰/۰۰۲
۷	-	۰/۰۰۰۳

جدول ۲: پارامترهای بهینه برای ایجاد شبکه عصبی SOM


مقادیر	پارامترها
۱۲، ۳، ۱۰، ۷	تعداد نرون ورودی
۱۲	تعداد نرون خروجی
۲۲/۲۱	شعاع اولیه همسایه
۰/۶	حداقل سرعت یادگیری
۱	حداکثر سرعت یادگیری
۰/۰۰۰۱	حداقل مدت باز یافت
۰/۰۰۰۵	حداکثر مدت باز یافت
LVQ2	الگوریتم فاز همگرایی ریز
۵۰	تعداد تکرار فاز همگرایی ریز




شکل ۴: نقشه‌ی مناطق دارای پتانسیل فرسایش بادی متفاوت با استفاده از الگوریتم ML در سال ۱۳۸۵.




شکل ۵: نقشه‌ی مناطق دارای پتانسیل فرسایش بادی متفاوت با استفاده از الگوریتم ML در سال ۱۳۹۲.




شکل ۶: نقشه‌ی مناطق دارای پتانسیل فرسایش بادی متفاوت با استفاده از الگوریتم ماشین بردار چند جمله‌ای در سال ۱۳۸۵.




شکل ۷: نقشه‌ی مناطق دارای پتانسیل فرسایش بادی متفاوت با استفاده از الگوریتم ماشین بردار خطی در سال ۱۳۸۵.




شکل ۸: نقشه‌ی مناطق دارای پتانسیل فرسایش بادی متفاوت با استفاده از الگوریتم ماشین بردار چند جمله‌ای در سال ۱۳۹۲.




شکل ۹: نقشه‌ی مناطق دارای پتانسیل فرسایش بادی متفاوت با استفاده از الگوریتم ماشین بردار خطی در سال ۱۳۹۲.




شکل ۱۰: نقشه‌ی مناطق دارای پتانسیل فرسایش بادی متفاوت با استفاده از الگوریتم ماشین بردار حلقوی در سال ۱۳۸۵.




شکل ۱۱: نقشه‌ی مناطق دارای پتانسیل فرسایش بادی متفاوت با استفاده از الگوریتم SOM در سال ۱۳۸۵.




شکل ۱۲: نقشه‌ی مناطق دارای پتانسیل فرسایش بادی متفاوت با استفاده از الگوریتم ماشین بردار حلقوی در سال ۱۳۹۲.



شکل ۱۳: نقشه‌ی مناطق دارای پتانسیل فرسایش بادی متفاوت با استفاده از الگوریتم SOM در سال ۱۳۹۲.



شکل ۱۴: نقشه‌ی مناطق دارای پتانسیل فرسایش بادی متفاوت با استفاده از الگوریتم ماشین بردار **RBF** بهینه شده در سال ۱۳۸۵.



شکل ۱۵: نقشه‌ی مناطق دارای پتانسیل فرسایش بادی متفاوت با استفاده از الگوریتم ماشین بردار **RBF** بهینه شده در سال ۱۳۹۲.

به طور کلی، می‌توان گفت روش SVM به جز کرنل حلقوی نسبت به SOM و ML دقت بالاتری دارد. مقایسه‌ی توابع کرنل متفاوت SVM نشان داد که RBF (۸۸ درصد برای لندست ۷ و ۹۰/۸۷ درصد برای لندست ۸) بهترین تابع بوده‌است. سپس به ترتیب توابع خطی (۸۶/۵ درصد برای لندست ۷ و ۸۸/۷۱ درصد برای لندست ۸)، چند جمله‌ای (۸۵/۱ درصد برای لندست ۷ و ۸۶/۷۱ درصد برای لندست ۸) و حلقوی (۷۵/۶ درصد برای لندست ۷ و ۷۶/۹۸ درصد برای لندست ۸) قرار دارند. اختلاف دقت روش ماشین بردار با تابع کرنل RBF برای تصویر لندست ۷، با روش‌های ماشین بردار خطی، چندجمله‌ای، SOM، حلقوی و ML به ترتیب ۱/۵، ۲/۹، ۸/۳، ۱۲/۴ و ۱۶/۴ درصد بود. همچنین اختلاف دقت روش ماشین بردار با تابع کرنل RBF برای تصویر لندست ۸، با روش‌های ماشین بردار خطی، چندجمله‌ای، SOM، حلقوی و ML به ترتیب ۲/۱۶، ۴/۱۶، ۶/۱۹، ۱۳/۸۹ و ۱۴/۶۷ درصد بود. اختلاف در مساحت کلاس‌های مختلف (جدول‌های ۵ و ۶) نیز بیان‌کننده‌ی اختلاف در دقت الگوریتم‌های طبقه‌بندی است.

روند تغییرات در پتانسیل فرسایش بادی در منطقه‌ی مورد مطالعه، از طریق مقایسه‌ی مساحت کلاس‌های مختلف و تغییرات نسبی آنها در جدول ۸ نشان داده شده‌است. با توجه به این جدول، تغییرات مهمی در فرسایش بادی و کاربری/پوشش اراضی در منطقه‌ی مورد مطالعه در مدت زمان کوتاهی رخ داده‌است. این تغییرات می‌تواند بر میزان هدررفت خاک و افزایش فرسایش بادی در منطقه‌ی مطالعاتی نقش داشته باشد. مراتع یکی از پوشش‌های مهم زمین است که با توجه به نتایج به دست آمده در سال ۱۳۹۲، به میزان ۷۳ درصد نسبت به سال ۱۳۸۵ کاهش یافته‌است. پهنه‌های ماسه‌ای، ۱۰ درصد از این مناطق را پوشانده‌است. این موضوع، پیشروی پهنه‌های ماسه‌ای را از مبدأ یعنی بستر رودخانه به درون اراضی طبیعی نشان می‌دهد. همچنین بیش از نیمی از مراتع به اراضی کشاورزی تبدیل شده‌است. پهنه‌های ماسه‌ای نیز در

منطقه‌ی مورد مطالعه حدود ۶۱ درصد افزایش یافته‌است. این پهنه‌های ماسه‌ای اغلب به سمت بخش‌های جنوب شرقی گسترش یافته‌اند. در مقابل، نیک‌ها به میزان ۵۷٪ کاهش داشته‌اند؛ این موضوع می‌تواند به دلیل کاهش در پوشش گیاهی بستر رودخانه باشد. طبق بازدیدهای صحرایی، نیک‌های موجود در منطقه‌ی مورد نظر ثبات کافی نداشتند؛ بنابراین، پتانسیل بالایی برای بادبردگی توسط نیروی باد و نشست در مناطق دیگر دارند. اراضی کشاورزی نوع ۱ در سال ۱۳۹۲، به میزان بسیار قابل توجهی نسبت به سال ۱۳۸۵ افزایش نشان داده‌اند. ۴۰ درصد از این اراضی، به اراضی کشاورزی نوع ۳ با مدیریت متفاوت تبدیل شده‌اند.

اراضی کشاورزی نوع ۴ شامل اراضی کشاورزی کرت‌بندی شده‌است که عملیات خاک‌ورزی در آنها انجام نشده و خاک آنها به صورت کلوخه‌ای در آمده‌است. این نوع اراضی در سال ۱۳۹۲ نسبت به سال ۱۳۸۵، به میزان ۶۳ درصد کاهش نشان داده‌است. مناطق مقاوم به فرسایش که پوسته‌ی سطحی دارند، به میزان ۵۹ درصد کاهش داشته‌است؛ اما مناطق مقاوم سنگلاخی به میزان کمی (۲/۳۹) کاهش یافته‌اند.

۵- بحث و نتیجه‌گیری

امروزه استفاده از فناوری سنجش از دور در پایش کاربری/پوشش اراضی، بیش از پیش قابل توجه قرار گرفته‌است. با راه‌اندازی موفق لندست ۸ در سال ۲۰۱۳، محققان زیادی در سراسر دنیا از این منبع دقیق برای بررسی تغییرات سطح زمین استفاده کردند. تصاویر لندست ۸ با داشتن باند پانکروماتیک، از دقت کافی برای طبقه‌بندی کاربری/پوشش اراضی در زمینه‌ی فرسایش بادی برخوردار است. اگر چه شناسایی شاخص‌های فرسایش خاک توسط تصاویر ماهواره‌ای تا زمانی که ابعاد آنها زیاد شود مقدور نیست، این امکان وجود دارد که اطلاعاتی در مورد فاکتورهای محیطی مؤثر در توسعه‌ی آنها به دست آید. اما آنچه مهم است نحوه‌ی پردازش باندها و استفاده از الگوریتم مناسب برای طبقه‌بندی این تصاویر با توجه به اهداف و شرایط منطقه‌ی مورد مطالعه است. با توجه به وجود تنوع زیاد در کاربری/پوشش اراضی و مشکل بودن تفکیک شواهد فرسایش بادی در منطقه‌ی مورد مطالعه، پردازش‌های مختلف تصویر و الگوریتم‌های پیشرفته‌ی یادگیری ماشینی مورد مقایسه قرار گرفت. در نهایت، روش SVM با تابع کرنل RBF به عنوان بهترین روش طبقه‌بندی با دقت کلی ۸۸٪ و ۹۰/۸۷٪ به ترتیب برای تصاویر لندست ۷ و ۸ معرفی شد. تحقیق حاضر نشان داد استفاده از باندهای انتخابی حتی با الگوریتم ساده ML دقت بالاتری (۷۱/۶ درصد برای لندست ۷ و ۷۶/۲ درصد برای لندست ۸) نسبت به استفاده از باندهای خام با الگوریتم یادگیری فعال دارد؛ بنابراین روشن می‌شود که اگر قبل از طبقه‌بندی به انتخاب باند ورودی توجه نشود، حتی با دقیق‌ترین الگوریتم‌های طبقه‌بندی نیز دقت کافی به دست نخواهد آمد.

روش SVM برای تهیه‌ی نقشه‌های کاربری/پوشش اراضی، دقت بیشتری نسبت به روش شبکه عصبی مصنوعی SOM و روش حداکثر احتمال ارائه می‌دهد؛ بنابراین این روش زمانی می‌تواند بسیار کارآمدتر از روش‌های رایج طبقه‌بندی باشد که هدف از آن، تفکیک و طبقه‌بندی پدیده‌هایی است که رفتار طیفی نزدیکی دارند مانند شواهد فرسایش بادی. از مهم‌ترین فواید طبقه‌بندی با الگوریتم یادگیری فعال این است که در این روش، نمونه‌های کمتری نسبت به دیگر روش‌های طبقه‌بندی نظارت شده جمع‌آوری می‌شود. این موضوع برای مناطق مختلف به خصوص مناطق صعب‌العبور اهمیت ویژه‌ای دارد. اگر چه در منطقه، تپه‌های ماسه‌ای خیلی بزرگ مانند آنچه در اراضی کویری ایران مشاهده می‌شود، وجود ندارد و

تنها محدود به پهنه‌های ماسه‌ای و تپه‌ها و نبکاهای کوچک است، تفکیک این اراضی با استفاده از ترکیبی از باندهای خام و پردازش شده تصاویر لندست و استفاده از روش‌های ماشین بردار پیشرفته با دقت قابل قبولی ممکن است. نتایج Mokhtari and Najafi (2014) نیز نشان داد که طبقه‌بندی با روش ماشین بردار پشتیبان، دقت بالاتری نسبت به روش شبکه عصبی ارائه می‌دهد. آنان نشان دادند که ماشین بردار پشتیبان، کلاس‌هایی را که دارای ویژگی‌های طیفی مشترک بود، بهتر تفکیک کرد. همچنین در قسمت‌های مرزی دو نوع طبقه، ماشین بردار پشتیبان نسبت به شبکه عصبی از قابلیت جداسازی بهتری برخوردار و مرز بین دو کلاس ملموس‌تر است.

جدول ۳: جدایی‌پذیری باندهای انتخاب شده با روش جفری ماتوسیا

نمونه‌های تعلیمی	مرتع ۱		پهنه ماسه‌ای		نبکا		کشاورزی ۱		کشاورزی ۲		کشاورزی ۳		کشاورزی ۴		مرتع ۲		مقاوم ۱		مقاوم ۲	
	L8	L7	L8	L7	L8	L7	L8	L7	L8	L7	L8	L7	L8	L7	L8	L7	L8	L7	L8	L7
مرتع ۱																				
پهنه ماسه																				
نبکا																				
کشاورزی ۱																				
کشاورزی ۲																				
کشاورزی ۳																				
کشاورزی ۴																				
مرتع ۲																				
مقاوم ۱																				
مقاوم ۲																				

جدول ۴: ماتریس خطای طبقه‌بندی به روش ماشین بردار تابع شعاعی مینا برای سال ۱۳۸۵

دقت کل کاربر (%)	کل	سایر مناطق	مخروط افکنه	مرتع ۱	مناطق مقاوم		بستر رودخانه	مرتع ۲	کشاورزی			نیکا	پهنه ماسه	
					۱	۲			۲	۳	۴			
۱۰۰	۱۰/۱۲	۰	۰	۹۸/۹۶	۰	۰	۰	۱/۴۶	۰	۰	۰	۰	۰	مرتع ۱
۱۰۰	۱/۵۰	۰	۰	۰	۰	۰	۴/۴۱	۰	۰	۰	۰	۰/۵۷	۹۶/۶۵	پهنه ماسه
۹۸/۲۴	۰/۵۲	۰	۰	۰	۰	۰	۵/۲۴	۰	۰	۰	۰	۷۰/۳	۰	نیکا
۹۴/۷۸	۹/۱۶	۱۰/۱۲	۰	۰	۰	۰	۰	۰	۰	۰	۹۵/۱۲	۰	۰	کشاورزی ۱
۱۰۰	۸/۹۸	۰	۰	۰	۰	۰	۰	۰	۰	۹۹/۵۲	۴/۸۸	۰	۰	کشاورزی ۲
۱۰۰	۱۸/۶۷	۰	۱/۶۶	۰	۰	۰	۰	۰	۲/۵۶	۱۰۰	۰/۴۸	۰	۰	کشاورزی ۳
۹۷/۷۶	۳/۷۸	۰	۰	۱/۰۴	۰	۰	۰	۰	۹۷/۴۴	۰	۰	۰	۱/۱۷	کشاورزی ۴
۹۹/۷۸	۳/۲۵	۱/۲	۰	۰	۰	۰	۹۰/۳۵	۰	۰	۰	۰	۰	۲۷/۱	بستر رودخانه
۵۴/۰۵	۷/۱۶	۰	۰	۰	۰	۰	۰	۹۸/۵۴	۰	۰	۰	۰	۰	مرتع ۲
۹۸/۵۴	۱/۹۲	۲/۱۸	۰	۰	۰	۹۹/۴۳	۰	۰	۰	۰	۰	۰	۰	مقاوم ۱
۹۲/۲۲	۱۰/۰۳	۱۲/۵	۰	۰	۹۵/۹۶	۰/۵۷	۰	۰	۰	۰	۰	۰	۰	مقاوم ۲
۸۵/۱۰	۲۴/۳۷	۱۲/۵۴	۹۸/۳۴	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	مخروط افکنه
۱۰۰	۳/۱۷	۵۹/۴۶	۰	۰	۴/۰۴	۰	۰	۰	۰	۰	۰	۰	۰	سایر مناطق
۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	کل
														دقت تولید کننده (%)
														۹۶/۶۵
														۷۰/۳
														۹۵/۱۲
														۹۹/۵۲
														۹۷/۴۴
														۱۰۰
														۹۰/۳۵
														۹۸/۵۴
														۹۷/۴۴
														۱۰۰
														۹۹/۵۲
														۹۵/۱۲
														۷۰/۳
														۹۶/۶۵

جدول ۵: مساحت (هکتار) کلاس‌های مختلف بر اساس الگوریتم‌های مختلف طبقه‌بندی بر روی تصویر لندست ۸

طبقه	حد اکثر احتمال	ماشین بردار خطی	ماشین بردار چند جمله‌ای	ماشین بردار تابع شعاعی مینا	ماشین بردار حلقوی	شبکه عصبی کوهن
پهنه ماسه‌ای	۱۲۶۶/۳۵	۱۴۳۴/۷۸	۱۴۰۲/۱۷	۱۴۵۹/۰۸	۱۲۹۱/۵۴	۱۳۷۷/۴۵
نیکا	۲۸۷/۵۵	۳۰۴/۰۹	۳۳۸/۴۷	۳۰۱/۲۳	۲۹۱/۶۸	۳۴۰/۶۸
کشاورزی ۱	۲۲۹۵/۴۲	۲۸۳۰/۱۵	۲۸۸۶/۶۶	۲۷۶۸/۳۱	۲۳۴۲/۴۸	۲۸۷۳/۷۶
کشاورزی ۲	۸۸۴/۱۹	۹۸۹/۱۹	۹۷۶/۶۳	۹۹۶/۱۲	۸۵۷/۴۹	۹۷۶/۵۱
کشاورزی ۳	۱۱۴۹/۸۲	۱۵۰۳/۷۸	۱۵۴۷/۱۷	۱۵۱۴/۸۸	۱۱۸۶/۰۳	۱۴۰۷/۲۴
کشاورزی ۴	۶۰۲/۶۱	۳۸۴/۱۹	۳۷۶/۶۳	۳۸۳/۴	۶۱۷/۴۹	۴۷۶/۵۱
بستر رودخانه	۸۹۷/۸۴	۸۴۲/۸	۸۳۷/۵۶	۸۴۹/۰۶	۸۹۰/۲۳	۸۲۱/۰۴
مناطق مقاوم ۱	۶۱۹/۱۲	۵۵۱/۷۵	۵۷۲/۱۴	۵۵۵/۹۳	۵۶۳/۱۲	۵۸۷/۱۸
مناطق مقاوم ۲	۶۹۹/۱۴	۶۳۷/۱۵	۶۴۷/۱۴	۶۲۹/۶۴	۷۱۹/۶۱	۶۵۲/۱۱
مرتع ۱	۳۸۵/۴۳	۴۱۲/۶۱	۴۱۴/۹۶	۴۰۰/۵	۳۸۹/۷۹	۳۸۷/۱۴
مرتع ۲	۲۲۰۸/۳۲	۱۵۷۶/۳۵	۱۵۶۱/۰۹	۱۵۶۵/۱۹	۲۱۴۳/۰۱	۱۸۱۸/۵۱
مخروط افکنه	۲۹۴۴/۰۷	۲۹۸۴/۹۳	۲۹۱۸/۷۶	۲۹۷۴/۵۹	۲۹۶۶/۸۵	۲۸۰۰/۵۱
سایر مناطق	۲۹۹۲/۳۵	۲۷۸۰/۴۴	۲۷۵۲/۸۳	۲۸۳۴/۲۸	۲۹۷۲/۸۹	۲۷۱۳/۵۷

* نویسنده مسئول: mahrooz.rezaei@gmail.com

جدول ۶: تغییرات مساحت کلاس‌های مختلف فرسایش بادی

تغییر (%)	مساحت (هکتار)		کلاس	
	۱۳۹۲	۱۳۸۵		
-۷۳	۴۰۰	۱۴۸۸	۱	مراتع
-۴۱	۱۵۶۵	۲۶۷۱	۲	
۶۱	۱۴۵۹	۹۰۵		پهنه ماسه
-۵۷	۳۰۱	۷۰۴		نبکا
۳۴۴	۲۷۶۸	۶۲۲	۱	اراضی
۳۰	۹۹۶	۷۶۲	۲	کشاورزی
۴۲	۱۵۱۴	۱۰۶۲	۳	
-۶۳	۳۸۳	۱۰۴۴	۴	
۹۳	۸۴۹	۴۳۹		بستر رودخانه
-۵۹	۵۵۵	۱۳۸۴	۱	اراضی
-۲	۶۲۹	۶۴۵	۲	مقاوم
-۱۳	۲۹۷۴	۳۴۴۱		مخروط افکنه
۳۷	۲۸۳۴	۲۰۵۹		سایر مناطق

دقت بالای ماشین بردار پشتیبان می‌تواند ناشی از مرز تصمیم‌گیری بهینه‌ی آن باشد؛ در حالی که شبکه عصبی و روش حداکثر شباهت نمی‌تواند این مرز را ایجاد کند. Goodarzimehr و همکاران (2012) در تفکیک واحدهای سنگ‌شناسی نتیجه گرفتند که از بین سه روش طبقه‌بندی حداکثر احتمال، شبکه عصبی و ماشین بردار پشتیبان بر تصاویر لندست TM، روش ماشین بردار پشتیبان در هر سه کرنل با دقت ۸۳/۴۲ درصد، بیشترین دقت را ارائه می‌دهد. تاکنون در منابع، تحقیقی با هدف مقایسه‌ی روش‌های پیشرفته‌ی یادگیری ماشینی با روش‌های رایج در زمینه‌ی فرسایش بادی ارائه نشده‌است.

با توجه به نتایج به دست آمده در منطقه‌ی مورد مطالعه، پیشروی پهنه‌های ماسه‌ای از مبدأ یعنی بستر رودخانه به درون اراضی طبیعی وجود دارد که این موضوع لزوم اجرای برنامه‌های حفاظتی در منطقه را نشان می‌دهد. یکی از مهم‌ترین شاخص‌های تخریب زمین و فرسایش بادی، میزان سندیفیکیشن (شنی شدن)^۱ است که شامل بادرفتنگی شن‌ها و جابجایی تپه‌های ماسه‌ای به سمت اراضی دیگر از جمله اراضی کشاورزی و مسکونی است (Karnieli et al, 2014 & Jiang, 2002). افزایش در میزان شنی شدن منطقه، بیانگر افزایش شدت فرسایش بادی در منطقه است.

تبدیل مراتع به اراضی کشاورزی کم بازده، یکی از دلایل مهم تخریب اراضی است. افزایش فرسایش بادی خاک، در اثر افزایش عملیات خاک‌ورزی در اراضی کشاورزی پیش‌بینی می‌شود. بعلاوه، سیستم آبیاری با بازده کم همراه با افزایش هدررفت خاک از اراضی کشاورزی، می‌تواند عملکرد و قدرت تولید این اراضی را کاهش دهد. Minwer

¹ Sandification

Archive of SID

Alkharabsheh و همکاران، این تبدیل اراضی منطقه‌ی جردن را در سال ۲۰۱۳ بررسی کردند. نتایج پژوهش در خصوص تبدیل اراضی این منطقه، برعکس منطقه‌ی دژگاه گزارش شد. در منطقه جردن کاهش اراضی کشاورزی و مناطق دیم یکی از مهم‌ترین عوامل کاهش فرسایش خاک گزارش شده‌است. تفاوت در مدیریت اراضی کشاورزی به خصوص از لحاظ میزان پوشش این اراضی نیز در حفاظت خاک نقش بسیار مهمی دارد. به دلیل استفاده از روش‌های خاک‌ورزی سنتی در منطقه‌ی مورد مطالعه، فصل کشت کوتاه یا به عبارتی دوران آیش طولانی مدت و نبود بادشکن، توان این اراضی برای فرسایش خاک بسیار زیاد است. تفاوت در زمان گرفتن تصاویر ماهواره‌ای تنها پنج روز است؛ بنابراین، تغییرات در پوشش گیاهی زمین نمی‌تواند به دلیل فاصله‌ی زمانی در فصل رشد باشد. در طول دوره‌ی آیش طولانی مدت، اراضی کشاورزی بدون پوشش گیاهی هستند و کشاورزان در زمان بارش باران، اراضی خود را چندین مرتبه شخم می‌زنند تا میزان نفوذ آب باران به خاک افزایش یابد؛ این امر به افزایش پتانسیل فرسایش بادی می‌انجامد. بنابراین، پتانسیل فرسایش بادی حاصل از اراضی کشاورزی در منطقه‌ی مورد مطالعه بسیار زیاد است و هر گونه افزایش در این اراضی، به منزله‌ی افزایش در پتانسیل فرسایش بادی قلمداد می‌شود. Fister and Ries (۲۰۰۹) نیز بر این باورند که تغییر کاربری از اراضی رها شده به اراضی کشاورزی، بر پتانسیل فرسایش بادی تأثیر زیادی می‌گذارد. نتایج آنان نشان داد که در زمین‌های رها شده‌ی قبلی، پوسته‌های فیزیکی خاک بیشتر گسترش دارد و کشاورزان با عملیات خاک‌ورزی در این اراضی، به افزایش فرسایش‌پذیری خاک می‌انجامند.

منابع

1. Ahmadi Nadooshan, M.; Sefyanian, A.; & S. J. Khajaddin, 2009. Land Use Map of Arak City using Artificial Neural Network and Maximum Likelihood Methods, *Physical Geography Research Quarterly*, 69, 83-98. (In Persian)
2. Benediktsson, J. A., & J. R. Sveinsson, (1997). Feature extraction for multisource data classification with artificial neural networks. *International Journal of Remote Sensing*. 18, 727-740.
3. Bischof, H.; Schneider, W.; & A. J. Pinz, 1991. Multispectral classification of landsat images using neural networks. *IEEE Trans, Geoscience Remote Sensing*, 30, 482-490.
4. Fathizad, H.; Fallah Shamsi, R.; Mahdavi, A.; & S. Arekhi, 2015. Comparison of two classification methods of maximum probability and artificial neural network of fuzzy Artmap to produce rangeland cover maps (Case study: Rangeland of Doviraj, Dehloran), *Iranian Journal of Range and Desert Research*, 22(1), 59-72.
5. Fister, W., & J. B. Ries., (2009). Wind erosion in the central Ebro Basin under changing land use management. Field experiments with a portable wind tunnel. *Journal of Arid Environment*. 73, 996-1004.
6. Garcia-Ruiz, J. M., 2010. The effects of land use on soil erosion in Spain: A review, *Catena*, 81, 1-11.
7. Goodarzimehr, S.; Abbaspour, R.; Ahadnejad, V.; & B. Khakbaz, 2012. Comparison of Support Vector Machine Method by Maximum Likelihood and Neural Network for Discriminating Lithology Units, *Iranian journal of Geology*, 22, 75-92. (In Persian)
8. Masek, J. G.; Honzak, M.; Goward, S. N.; Liu, P.; & E. Pak, 2001. Landsat-7 ETM+ as an observatory for land cover initial radiometrics and geometric comparisons with Landsat-5 Thematic Mapper, *Remote Sensing of Environment*, 78, 118-130.
9. Jia, K.; Wei, X.; Gu, X.; Yao, Y.; Xie, X.; & B. Li, 2014. Land cover classification using Landsat 8 Operational Land Imager data in Beijing, China, *Geocarto International*, 29, 8, 941-951.
10. Jiang, H., 2002. Culture, ecology and nature's changing balance: Sandification on Mu Us

- Sandy land, Inner Mongolia, China. In global desertification: Do humans cause deserts? Reynolds JF, Stafford Smith DM. Eds: Dahlem university press; 2002 Berlin, Germany. 181-196.
11. Karnieli, A.; Qin, Z.; Wu, B.; Panov, N.; & F. Yan, 2014. Spatio-temporal dynamics of land-use and land-cover in the Mu Us sandy land, China, Using the change vector analysis technique, *Remote Sens*, 6(10), 9316-9339.
 12. Kohonen, T., 1990. The Self-Organizing Map, *Proceedings of the IEEE*, 78, 1464-80.
 13. Kumar, U.; Dasgupta, A.; Mukhopadhyay, CH.; & T. V. Ramachandra, 2012. Advanced Machine Learning Algorithms based Free and Open Source Packages for Landsat ETM+ Data.
 14. Minwer Alkharabsheh, M.; Alexandridis, T. K.; Bilas, G.; Misopolinos, N.; & N. Silleos, 2013. Impact of land cover change on soil erosion hazard in northern Jordan using remote sensing and GIS, *Procedia Environmental Sciences*, 19, 912-92.
 15. Mokhtari, M. H., & A. Najafi., 2014. Comparison between Support Vector Machine and Artificial Neural Network Classification Methods in Extracting Land Uses from Landsat 7 Imageries. *Journal of Science and Technology of Agriculture and Natural Resources*. 72, 35-44. (In Persian).
 16. Natural Resources and Watershed Management Office (NRWMO) of Fars Province. 2005. The studies of the action plan of desert region management of Dowlatabad-Farashband region. Fars: Natural Resources and Watershed Management Office, 5-45 (in persian).
 17. Persello, C., 2010. Advanced Techniques for the Classification of Very High Resolution and Hyperspectral Remote Sensing Images, Phd thesis, DISI-University of Trento, Italy.
 18. Richards, J. A., & X. Jia, (2006). Remote sensing digital image analysis, an introduction. Springer, Berlin.
 19. Tzotsos, A.; Karantzalos, K.; & D. Argialas, 2011. Object-based image analysis through nonlinear scale-space filtering, *ISPRS Journal of Photogrammetry and Remote Sensing*, 66, 2-16.
 20. Wijitkosum, S., 2012. Impact of land use changes on soil erosion in Pa Deng Sub-district, Adjucent area of Kaeng Krachan national park, Thailand, *Soil & Water Resources*, 7(1), 10-1.
 21. Yuan, H.; Van Der Wiele, C. F.; & Khorram, S, 2009. An Automated Artificial Neural Network System for Land Use/Land Cover Classification from Landsat TM Imagery, *Remote Sensing*, 1, 243-265.

Advanced machine learning methods for wind erosion monitoring in southern Iran

Mahrooz Rezaei¹: *Assistant professor, Soil Science Department, School of Agriculture, Shiraz University, Shiraz*

Abdolmajid Sameni: *Associate professor, Soil Science Department, School of Agriculture, Shiraz University, Shiraz*

Seyed Rashid Fallah Shamsi: *Associate professor, Department of Natural Resources and Environmental Sciences, School of Agriculture, Shiraz University, Shiraz*

Article History (Received: 2018/06/8

Accepted: 2018/10/7)

Extended abstract

1- Introduction

Wind erosion is one the most important factors of land degradation in the arid and semi-arid areas and it is one the most serious environmental problems in the world. In Fars province, 17 cities are prone to wind erosion and are considered as critical zones of wind erosion. One of the most important factors in soil wind erosion is land use/cover change. Therefore, accurate mapping of land use/cover and wind erosion evidences in arid and semiarid regions is the utmost importance. Moreover, for discrimination of land covers resulting from wind erosion such as sand sheets and Nebka, we need accurate remote sensing methods. In this study, capability of the advanced machine learning techniques on Landsat 7 and 8 imageries in mapping land use/cover related to wind erosion is evaluated.

2- Methodology

The study area is located in the Fars province, in the southern part of Iran, (from 28°07'15" to 28°13'07"N and 52°07'36" to 52°23'55"E, covering an area of 17,230 ha), which is considered as the most critical wind erosion area of the province. Landsat 7 (2006) and Landsat 8(2013) images were corrected radiometrically using Dark Object Subtraction method. Although images from USGS website are corrected geometrically, we checked the images using stream and road maps. According to the variations in land use/cover spectral behavior across the study area, it was difficult to define training samples representing thematic classes in a supervised classification procedure. Then different image enhancement techniques were applied. Classification stopped using Support Vector Machine with four different types of kernels including linear, polynomial, Radial Basis Function, sigmoid and Kohonen's Self-Organizing Map neural network. Results were compared with Maximum Likelihood method. Using separability analysis, the best input band combination for classification was selected. The Overall Accuracy and Cohen's Kappa coefficient, derived from the error of matrix which were used for the accuracy assessment of the final maps.

3- Results

Results from accuracy assessment showed that the best map of the land use/cover in the relation to wind erosion was produced using a combination of original and processed bands and RBF vector machine (overall accuracy of 88 and 90.87 percent for L7 and L8, respectively). According to the separability metrics, the near infrared (NIR) and short infrared band (SWIR1), the WDVI, SAVI, LI indices, and processed bands by edge analysis in the aspect of E were finally selected as the best input band combination. The difference between accuracy of this method with

¹ mahrooz.rezaei@gmail.com

linear, polynomial, SOM, sigmoid and ML methods were 1.5, 2.9, 8.3, 12.4, and 16.4 percent for L7 and 2.16, 4.16, 6.19, 13.89, and 14.67 percent for L8, respectively. In addition, results indicated that there was a significant change in wind erosion potential and land use/cover in relation to wind erosion in the study area in a short period of time. Rangelands were decreased by 73 percent and 10 percent of these areas are covered by sand sheets. More than half of rangelands were converted to agricultural lands. Insusceptible areas with surface crust or rocks were decreased by 59 and 2.39 percent, respectively.

4- Discussion & Conclusions

The accuracy of classification increased using a combination of processed and original bands in comparison with using original bands alone. This indicates the fact that processing image classification without paying attention to the quality of input bands, will not results in accurate classification map. One of the advantages of active learning algorithm is its less training samples requirement. This is very important for areas which are difficult to have access to them. Although there were not distinct and large sand dunes in the study area like what can be seen in desert areas of Iran, but discrimination of these small sand dune and nebkas were done accurately using the combination of original and processed bands of Landsat imageries and support vector machine methods. Goodarzimehr et al., (2012) also indicated that support vector machine was a better algorithm for discriminating lithology units comparing to maximum likelihood and neural network methods. Sandification was also recognized using remote sensing methods in this study which is one the indices of land degradation and wind erosion. Sand sheets showed and expansion mostly to the southeastern parts. The results indicated the change of rangelands into agricultural lands which will increase wind erosion potential. Low-efficiency irrigation systems combined with an increase in soil loss from arable lands leads to reduction in productivity. This is in line with findings by Minwer Alkharabsheh et al. (2013) who reported the progressive decrease of the agricultural areas and mixed rain-fed areas as the main reason of declining in soil erosion in Jordan. Generally, this study showed the capability of Landsat imageries and support vector machine learning in study of wind erosion potential in arid areas.

Key Words: Wind Erosion, Land use/cover, Landsat, Support Vector Machine.