

# الگوریتم مناسب برای شناسایی تغییرات میکرو لندفرمها با استفاده از تصاویر پهپاد (مطالعه موردی: ناحیه برگ جهان در پهنه جاجروم ۱۳۹۶-۱۳۹۷)

محمدحسن توکل<sup>۱</sup>، منیژه قهرودی تالی<sup>(۲)\*</sup>، سید حسن صدق<sup>۳</sup> و خدیجه علی نوری<sup>۴</sup>

۱. دانشجوی دکتری ژئومورفولوژی، دانشکده علوم زمین، دانشگاه شهید بهشتی
۲. استاد گروه جغرافیا طبیعی، دانشکده علوم زمین، دانشگاه شهید بهشتی
۳. استاد گروه جغرافیا طبیعی، دانشکده علوم زمین، دانشگاه شهید بهشتی
۴. پژوهشگر پسادکتری، دانشکده علوم زمین، دانشگاه شهید بهشتی

تاریخ دریافت: ۱۴۰۱/۰۱/۲۰

تاریخ پذیرش: ۱۴۰۱/۰۳/۰۳

## چکیده

یکی از اصلی‌ترین و مهم‌ترین مباحث ژئومورفولوژی شناسایی و ارزیابی تغییرات میکرو لندفرمهاست. شناخت و نحوه پراکنش فضایی آن‌ها به منظور درک و ارزیابی تحولات، مطالعات پایداری و برنامه‌ریزی ناحیه‌ای، از نیازهای اساسی علم ژئومورفولوژی کاربردی است. ناحیه برگ جهان در حوضه آبریز جاجروم متأثر از تغییرات محیطی زیادی قرار دارد. در این مطالعه، براساس رویکرد ژئومورفولوژیکی ریزمقیاس با استفاده از تصاویر پهپاد به همراه بررسی میدانی در برگ جهان، تحولات میکرو لندفرمها بررسی شد. تصاویر پهپاد با رزولوشن مکانی ۵/۲ سانتی‌متر در بازه زمانی ۱۳۹۶-۱۳۹۷ از وزارت نیرو تهیه شد. این تصاویر با استفاده از نرم‌افزارهای ENV5.1 و Arc Map 10.3 تصحیح شد و سپس با استفاده کدنویسی در Python الگوریتم‌های موردنظر اجرا شد. با الگوریتم‌های یادگیری ماشین و مدل‌های جنگل تصادفی، SVM با کرنل RBF، جنگل تصادفی با ویژگی‌های استخراجی از شبکه‌های CNN و SVM با کرنل خطی با ویژگی‌های استخراجی از شبکه‌های عصبی عمیق تغییرات بررسی شد. نتایج نشان داد مدل RBF-SVM با درصد نسبت به مدل‌های دیگر دقت کمتری دارد به طوری که تفکیک بین طبقه‌ها محدود بود. در جنگل تصادفی با ۸۸ درصد طبقه‌ها با مرزهای خطی تا حدی قابل تفکیک بودند. مدل نزدیک به ایده‌آل در الگوریتم جنگل تصادفی با یادگیری عمیق به میزان دقت ۹۶ درصد مشاهده شد. بررسی‌ها نشان داد بیشترین تغییرات میکرو لندفرمها در این مدل، مربوط به تغییر پوشش گیاهی به خاک به میزان ۴۵/۰۳ و در تبعه بعدی تغییر آبکند به فرسایش ورقه‌ای به میزان ۲۲/۰۵ بود. با توجه به نتایج به دست آمده و مشاهدات میدانی در سال ۱۳۹۷ مشخص شده سیل سال ۱۳۹۷ در ناحیه برگ جهان سبب تغییرات عمده‌ای در ناحیه شده است. بیشترین تأثیر آن بر روی پوشش گیاهی بوده است و نمودار، آن را در بالاترین حد آشفتگی نشان می‌دهد. در این بازه جریان سطحی و خندق در ناحیه بیشتر شده و میزان بالای فرسایش و تغییرات بسیار زیاد میکرو لندفرمها در پهنه مطالعاتی را نشان می‌دهد.

واژه‌های کلیدی: الگوریتم یادگیری عمیق، جنگل تصادفی، میکرو لندفرم، SVM، RBF.

## مقدمه

به تکامل چشم‌اندازهای شرق استرالیا بررسی شده است (Salles et al., 2017). تغییرات تراس‌های کشاورزی با توجه به تغییرات دینامیکی لندفرم‌ها و تغییر اقلیم با استفاده از پهپاد توسط ووی و همکاران (Wei et al., 2017) بررسی شده است. همچنین تحولات دینامیکی با توجه به تغییرات حوضه‌های هیدرولیکی در یکی از مناطق هند بررسی شده است (Panda and Narasimham, 2018). مقاوه‌ای با عنوان تأثیر تغییرات لندفرم‌ها و الگوهای پوشش گیاهی توسط برتن و همکاران (Baartman et al., 2018) به چاپ رسیده است. برنال و همکاران (Bernal et al., 2018) تأثیر زئومورفولوژیکی حوضه ایکا را بر پاسخ‌های دینامیکی شهر با استفاده از روش‌های ژئوفیزیکی بررسی کرده‌اند.

لیو و کلتارد (Liu and Coulthard, 2017) یک مدل سلولی تپه بادی و مدل فلوویال را برای شبیه‌سازی فرایندها تعامل استفاده کردند. اسپنسر و همکاران (Spencer et al., 2017) به تغییرات گستره اقلیم و نقش آن در سیستم‌های زئومورفولوژی و درک بهتر سیستم‌های پاسخ پرداخته‌اند. فرسایش خندقی یک مشکل جدی برای تخریب زمین در طیف وسیعی از محیط‌ها است. برای مدل‌سازی وقوع فرسایش خندقی در کشکان رحمتی و همکاران (Ralmati et al., 2017) از مقایسه عملکرد هفت مدل پیشرفت‌های یادگیری ماشین<sup>1</sup> SVM<sup>2</sup> با چهار نوع هسته RF-ANN، BP-ANN و BRT استفاده کردند. فراوانی و درجه تغییر شکل لندفرم بینش‌هایی را در مورد تکامل لندفرم‌های پیچیده ارائه می‌دهد. برای کمی کردن این جنبه از تنوع مورفولوژیکی لندفرم، از الگوریتم یادگیری ماشینی استفاده شده است (Brigham et al., 2022).

با وجود پیشرفت‌های اخیر در مطالعات زئومورفولوژیکی مناطق بدون بخ، کاربردهای یادگیری ماشینی برای تولید نقشه‌های لندفرم در قاره قطب جنوب کم است. تغییرات سطح زمین و تخریب به علت‌های مختلف مانند تغییرات

طبقه‌بندی شکل زمین یکی از مهم‌ترین روش‌ها در نقشه‌برداری زئومورفولوژیکی و درک بیشتر فرآیندهای سطح زمین است (Bocco et al., 2001). تحولات دینامیکی در دوره‌های مختلف و شرایط موجود نظیر تغییر اقلیم و فعالیت‌های انسانی متفاوت عمل می‌کنند و تقاضه این تحولات در دوره‌های مختلف، رفتارها و شکل لندفرم‌ها را دستخوش دگرگونی می‌کند.

چورلی و همکاران (۱۳۷۵) به اهمیت تحولات دینامیکی لندفرم‌ها و نقش مقیاس در بررسی لندفرم‌ها پرداخته‌اند. از زمان گیلبرت تاکنون ارزیابی، اندازه‌گیری و رفتار سنجی این تحولات دغدغه اصلی زئومورفولوژیست‌ها بوده است. رابطه بین لندفرم‌ها و فرایندهای زئومورفیک توسط وندزل (Wondzell et al., 1996) به چاپ رسیده است. آشکارسازی تغییرات لندفرم‌های ساحلی در ناحیه عسلویه توسط نعیمی و همکاران (۱۳۸۸) با استفاده از شناسایی تغییرات انجام شد. ارزیابی کارایی شاخص‌های ژئومورفولوژیک به روش Wood در طبقه‌بندی مناطق خشک انجام شده است (شایان و همکاران، ۱۳۹۱). قهروندی و علی نوری (۱۳۹۳، ۱۳۹۶) تحولات میکرونلندفرم‌ها و تغییرات مکانی پلایای حوض سلطان را موربد بررسی قراردادند. بررسی روند تکاملی پهنه‌های گلی و آشفتگی میکرو لندفرم‌های باتلاق گاوخونی با استفاده از مدل فرکتال نیز در پژوهشی بررسی شد (قهروندی و خدربی غریبوند، ۱۳۹۵؛ خدربی غریبوند و همکاران، ۱۳۹۷). در پژوهشی طبقه‌بندی لندفرم‌ها با استفاده از شبکه عصبی خود سازنده در حوضه آبخیز گاوخونی انجام شده است (مکرم و نگهبان، ۱۳۹۴). موضوع لندفرم‌ها و طبقه‌بندی آن‌ها در علم زئومورفولوژی نیز در پژوهشی دیگر موربد بررسی قرار گرفت (آراء، ۱۳۹۲). رعیتی شوازی و همکاران (۱۳۹۶) نیز کارایی الگوریتم‌های طبقه‌بندی در مطالعات تغییرات لندفرم‌های بیابانی را در دشت یزد اردکان بررسی کرده است. مهاجرت کانال‌های آبی و تأثیر آن بر لندفرم‌های اطراف با استفاده از GIS و سنجش از دور انجام شده است (Debnath et al., 2017). تأثیر زئومورفولوژی دینامیکی

1. Change detection

2. Support vector machines

## گستره مورد مطالعه

حوضه آبریز جاجرود در شمال شرقی شهرستان تهران، بین طول  $51^{\circ} 22'$  تا  $51^{\circ} 52'$  شرقی و عرض  $35^{\circ} 45'$  تا  $36^{\circ} 5'$  شمالی واقع شده است. حوضه کلی آبریز جاجرود با مساحتی حدود ۱۸۹۰ کیلومترمربع در دامنه جنوبی رشته کوه البرز مرکزی قرار دارد. از مساحت اشاره شده حدود ۷۱۰ کیلومترمربع در بالادست سد لتيان و ۱۱۸۰ کیلومترمربع در پایین‌دست سد لتيان قرار دارد. اين حوضه از شمال و شمال شرق به حوضه رودخانه لار، از شرق به حوضه رودخانه حبله رود، از شرق و جنوب شرق به حوضه نمرود، از شمال غرب به حوضه رود کرج و از غرب به رودهای کوچک جنوب تهران و کویر نمک محدود می‌شود. پهنه برگ جهان در حوضه جاجرود بین لشکرک، لوسان و جاجرود کم‌وبیش در بخش مرکزی حوضه جاجرود قرار دارد (شکل ۱).

## روش پژوهش

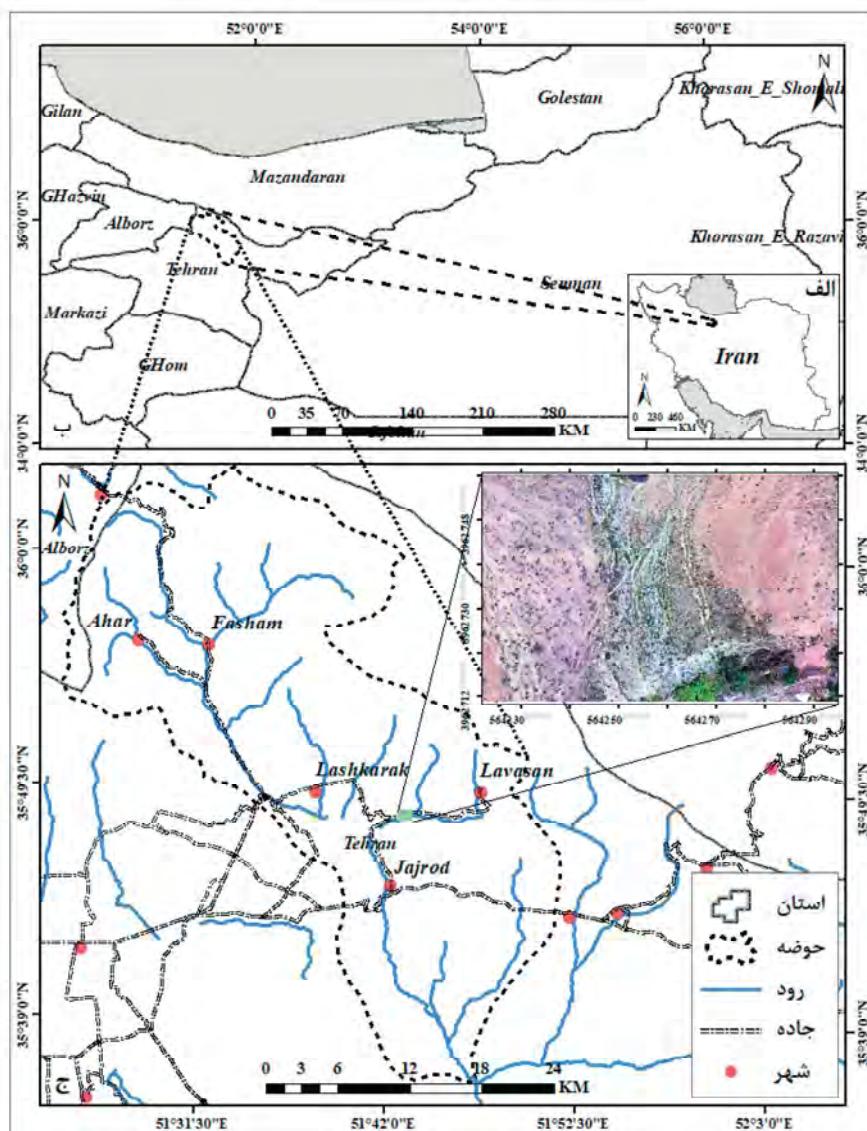
در این پژوهش مرزهای ناحیه مطالعاتی با استفاده از نقشه‌های توپوگرافی ۱:۵۰۰۰۰، تصاویر لندست هشت و پهپاد محدود شد. با بازدید میدانی که در پاییز ۱۳۹۷ از ناحیه صورت گرفت میکرولندرمها شناسایی و با GPS موقعیت مکانی آن‌ها ثبت شد (شکل ۲). سپس با استفاده از تصاویر برداشت شده از دو دوره زمانی سال‌های ۱۳۹۶ و ۱۳۹۷ به بررسی تغییرات و طبقه‌بندی عوارض ناحیه برگ جهان در حوضه جاجرود پرداخته شده است. با نرمافزارهای ENVI 5.1، Arc GIS 10.3 تصاویر پهپادی پردازش شد. وضوح مکانی این تصاویر پهپادی متر با مقیاس  $1/250$ ، مربوط به دو دوره زمانی ۱۳۹۶ و ۱۳۹۷ از وزارت نیرو تهیه شد (شکل ۳). با استفاده از تصاویر پهپاد و اجرای مدل‌های جنگل تصادفی، SVM با کرنل خطی، SVM با کرنل<sup>۱</sup> RBF، جنگل تصادفی با ویژگی‌های استخراجی از شبکه‌های CNN و SVM با کرنل خطی با ویژگی‌های استخراجی از شبکه‌های عصبی عمیق طبقه‌بندی میکرولندرمها و تحولات آن‌ها استخراج

اقليمی و عوامل دیگر به صورت گستردۀ در حال وقوع هستند. تخریب اراضی بهویژه در پهنه‌هایی با تراکم جمعیت بالا به طور قابل توجهی روی زیستگاه‌ها، کشاورزی و اقتصاد تأثیر می‌گذارد. فرسایش خندقی، یکی از چالش‌های اصلی برای تخریب زمین است (Chakrabortty et al., 2022). تشخیص تغییر توپوگرافی یک ابزار قدرتمند در ژئومورفوژی برای ارتباط دادن فرآیندها و پراکندگی‌ها به نرخ والگوهای فرسایش و رسوب است (James and Robson, 2012). الگوریتم‌های جدید و شبکه عصبی پیچشی<sup>۲</sup> CNN به یک راه حل جدید برای حل چندین مسئله، مانند طبقه‌بندی تصویر، تشخیص شی، تقسیم‌بندی معنایی و غیره تبدیل شده‌اند. CNN می‌تواند نمایش تصویر سلسله موتابی را از داده‌های ورودی با تفکیک موردقبول، ویژگی‌های موردنظر برای حل چندین مسئله از زمینه‌های مختلف، از جمله سنجش از دور مورداستفاده قرار گرفت و در آن مزایای بسیار خوبی با توجه به مشکلات مختلف از جمله طبقه‌بندی مبتنی بر روش پیکسل‌ها برای کاربری اراضی، تشخیص هدف مانند لندفرم‌ها، جاده‌ها، عوارض انسانی و طبیعی و وضوح تصویر نشان داده‌اند (Laurentiis et al., 2019).

برای برنامه‌ریزی پهنه، ایجاد مدل‌ها و الگوریتم‌های مختلف، شناسایی و رفتار سنجی تغییرات دینامیکی و همراه آن تغییرات میکرولندرمها ضروری است. در طول زمان آگاهی از تغییرات در مقیاس میکرولندرمها به عنوان شاخصی برای شناسایی تغییرات با مقیاسی بزرگ‌تر در لندفرم‌ها بسیار مهم است. در این راستا استفاده از تصاویر پهپاد این امکان را می‌دهد تا با استفاده از داده‌های با وضوح بالا، حداقل  $2/5$  سانتی‌متر، پوشش گستردۀ، بازدیدهایی کوتاه‌مدت و سریع به نتایج موردنظر دست یافتد. به همین دلیل در این پژوهش سعی شده تا با استفاده از روش‌های سریع، کم‌هزینه و داده‌های با دقت بالا، همچنین الگوریتم‌های مناسب تغییرات میکرولندرمها ارزیابی شود.

1. Convolutional Neural Network

2. Radial basis function



شکل ۱. (الف) موقعیت حوضه در کشور ایران، (ب) حوضه آبریز جاگرود در استان تهران، (ج) موقعیت برگ جهان در حوضه به همراه تصویر پهپاد سال ۱۳۹۷

شد. مدل‌های مورد استفاده در پژوهش به شرح زیر است:

#### ماشین‌های بردار پشتیبان

روش طبقه‌بندی SVM رده‌ها را با استفاده از مزدی تصمیم‌گیری جدا می‌کند و حاشیه بین دو گروه را به حداقل می‌رساند. این مرز به اصطلاح «بهترین ابر صفحه جداکننده» نامیده می‌شود. نتایج رویکرد SVM مقادیر تصمیم‌گیری هر پیکسل هستند و برای برآورد مقادیر احتمال به کار می‌روند. در این روش احتمال «درست» بر اساس احتمالات بین

#### مدل‌های CNN، جنگل تصادفی

CNN شبکه عصبی پیچشی از شبکه‌های عصبی عمیق است و همواره برای انجام تحلیل‌های تصویری در یادگیری ماشین استفاده می‌شود. شبکه‌های عصبی پیچشی زیر دامنه یادگیری ماشینی قرار می‌گیرند و یادگیری عمیق نامیده می‌شود. الگوریتم‌های با آموزش عمیق، اطلاعات را به همان روشی که مغز انسان انجام می‌دهد، پردازش می‌کند.

1. Convolutional neural network

شده است و از نقشه‌های ویژگی مجموعه‌ای از لایه‌های همگشت به عنوان ویژگی برای تعیین نواحی تغییرپذیره استفاده می‌کند. با توجه به عملیات نمونه‌برداری فرعی و ادغام در CNN، هر نقشه ویژگی با استفاده از درون‌یابی دوخطی به اندازه یکسانی از تصاویر ورودی تغییر اندازه می‌یابد.

### VGG16

یک مدل شبکه عصبی پیچشی است که به عنوان شبکه‌های پیچش بسیار عمیق برای تشخیص تصویر در مقیاس بزرگ پیشنهاد شده است. این مدل در یک مجموعه داده با بیش از ۱۴ میلیون تصویر متعلق به ۱۰۰۰ طبقه در شبکه تصاویر با دقت بالای ۹۲.۷ درصد دست می‌یابد. این روش با جایگزین کردن فیلترهای سایز بزرگ، کرنل (به ترتیب یازده و پنجم در لایه همگشت اول و دوم) با فیلترهای متعدد با اندازه کرنل  $3 \times 3$  یکی پس از دیگری، منجر به بهبود تصاویر می‌شود. در این پژوهش با اعمال کرنل  $3 \times 3$  بر روی تصاویر پهپاد پهنه برگ جهان در حوضه جاگرد کیفیت تصاویر افزایش داده شد.

### همگی متصل

لایه‌ی دیگری که در شبکه‌های عصبی عمیق وجود دارد، لایه‌ی همگی متصل<sup>۲</sup> است. این لایه‌ها نقشه‌های عارضه<sup>۳</sup> دو بعدی حاصله از مرحله ادغام<sup>۴</sup> را به عارضه‌های وکتوری<sup>۵</sup> یک بعدی تبدیل می‌کند. لایه‌های تماماً متصل همانند همتایان خود در شبکه‌های عصبی مصنوعی سنتی عمل می‌کنند و کم و بیش ۹۰ درصد پارامترهای یک شبکه CNN را شامل می‌شوند. یکی از مزیت‌های لایه همگی متصل ارائه دادن نتیجه شبکه در قالب یک بردار با اندازه مشخص است. در این پژوهش از این بردار برای دسته‌بندی و همچنین از آن جهت ادامه پردازش‌های بعدی استفاده شد.

1. Image net
2. Fully connected
3. Feature map
4. Pooling
5. Feature vector

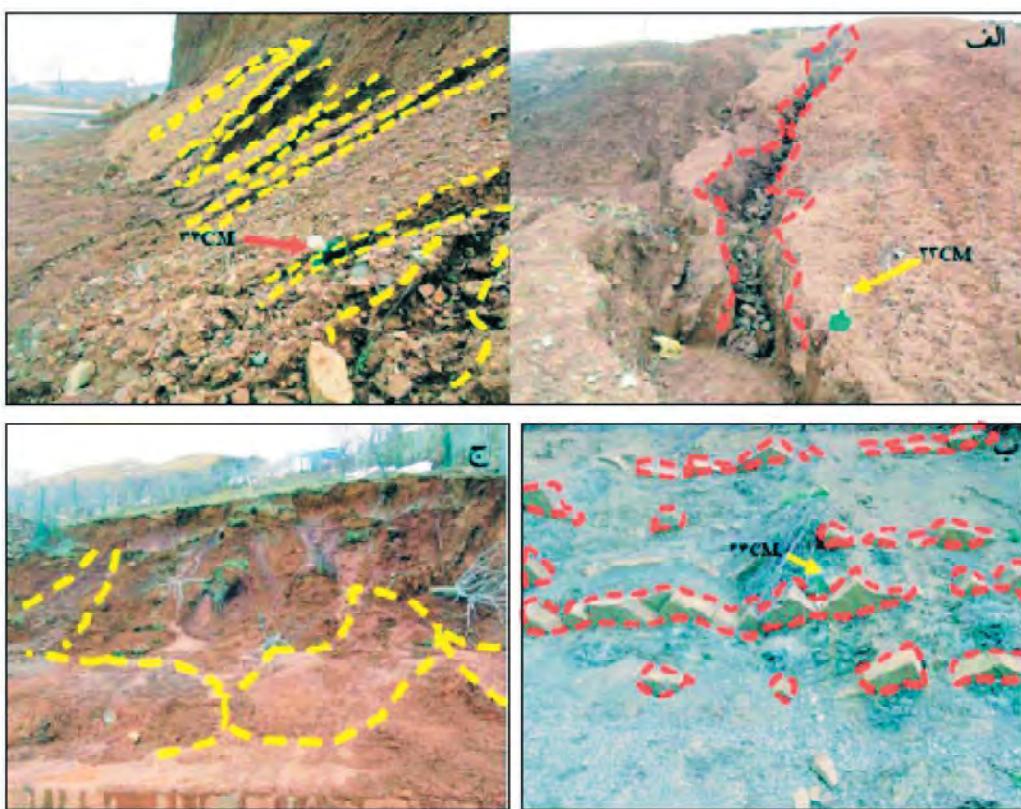
صفرو یک نشان داده می‌شوند و مجموع این مقادیر در هر پیکسل برابر با یک است. سپس طبقه‌بندی از طریق انتخاب حداقل احتمال به دست می‌آید.

توابع کرنل، مانند توابع خطی، توابع چندجمله‌ای، RBF و توابع سیگموئید، به طور گسترده در بسیاری از مطالعات مورد استفاده قرار می‌گیرند. طبقه‌بندی کننده جنگل تصادفی شامل ترکیبی از طبقه‌بندی کننده‌های درخت است و در آن هر طبقه‌بندی کننده با استفاده از یک بردار تصادفی نمونه‌برداری شده به طور مستقل از بردار ورودی تولید می‌شود و هر درخت یک رأی واحد برای بالارزش‌ترین رده برای طبقه‌بندی بردار ورودی ایجاد می‌کند. طبقه‌بندی کننده جنگل تصادفی مورد استفاده در این مطالعه شامل ویژگی‌های انتخابی تصادفی یا ترکیبی از ویژگی‌ها در هر گره برای رشد یک درخت است.

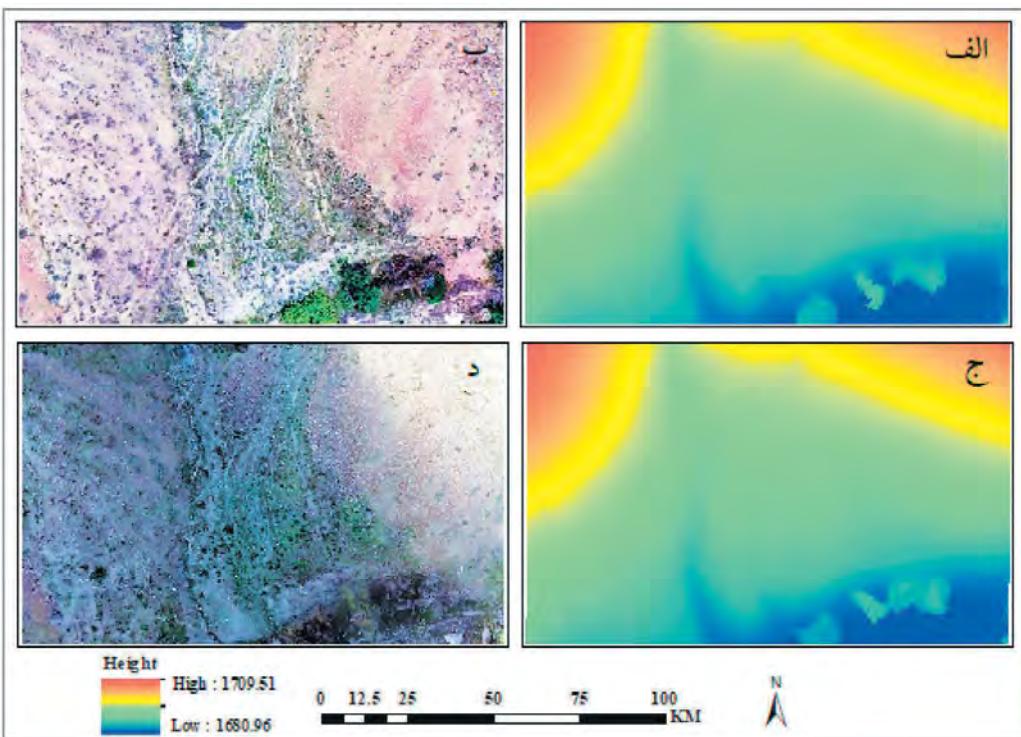
برچسب زدن، روشی برای تولید یک مجموعه داده آموزشی با رسم تصادفی است. برای مثال با جایگزینی N که در آن N اندازه مجموعه آموزشی اصلی است. برای هر ترکیب ویژگی، ویژگی انتخاب شده مورد استفاده قرار می‌گیرد. هر نمونه (پیکسل) با در نظر گرفتن بالارزش‌ترین رده از تمام پیش‌بینی کننده‌های درخت در جنگل طبقه‌بندی می‌شوند. طراحی یک درخت تصمیم‌گیری نیاز به انتخاب یک معیار انتخاب ویژگی و یک روش بازبینی دارد. رویکردهای زیادی برای انتخاب ویژگی‌های مورد استفاده برای القای درخت تصمیم‌گیری وجود دارد و اکثر رویکردها یک معیار کیفیت را مستقیم به صفت اختصاص می‌دهند. در این پژوهش برای ترکیب هر ویژگی، ویژگی‌های انتخاب شده مورد استفاده قرار گرفت؛ با توجه به بالارزش‌ترین رده طبقه‌بندی صورت گرفت.

### CNN

مدل CNN توانایی زیادی در استخراج ویژگی‌های تصویر نشان داده است، استفاده از آن‌ها برای پردازش تصاویر سنجش از دور به نسبت جدید است. در این پژوهش، به بررسی قابلیت CNN به عنوان استخراج کننده ویژگی برای نمایش تصاویر پهپادی پرداخته شده است. از ابر ستون‌هایی از پیکسل‌ها برای انجام قطعه‌بندی و جای گزیدگی شیء استفاده شده است، در این پژوهش نیز ایده مشابهی اعمال



شکل ۲. تصاویر میکرولندfrmها و تغییرات سطوح در بازدید میدانی (پاییز ۱۳۹۷)، (الف) فرسایش خندقی، (ب) فرسایش و بروزدگی سطوح سنگی، (ج) جریان سطحی و تخریب پوشش گیاهی

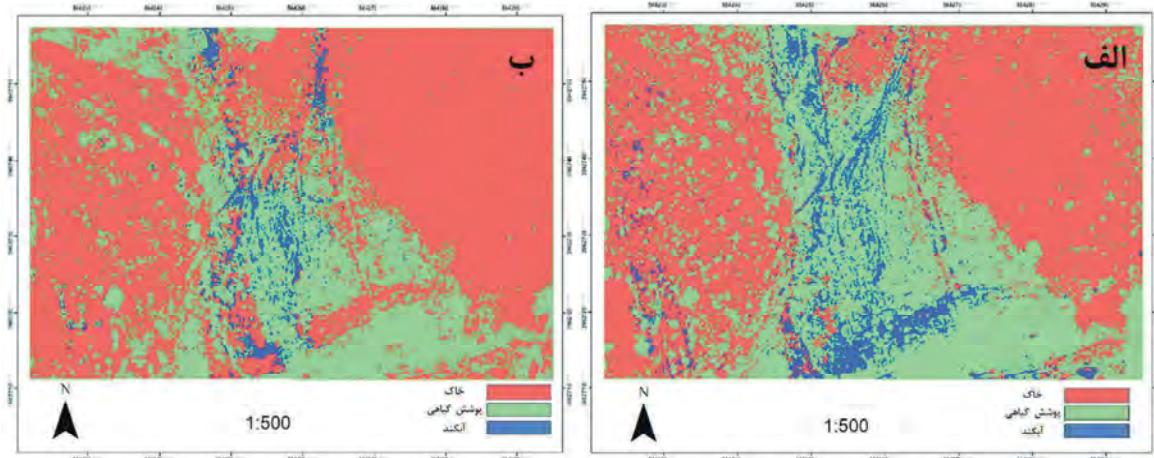


شکل ۳. مدل ارتفاعی و تصویر پهپاد پهنه برگ جهان، (الف) مدل ارتفاعی استخراج شده از تصاویر پهپاد سال ۱۳۹۶، (ب) تصویر پهپاد سال ۱۳۹۶  
ج) مدل ارتفاعی استخراج شده از تصاویر پهپاد سال ۱۳۹۷، (د) تصویر پهپاد سال ۱۳۹۷

## بحث

رده عمدۀ خاک، پوشش گیاهی و گالی تشخیص داده شد و طبقه‌بندی صورت پذیرفت. همان‌طور که شکل ۴ نشان می‌دهد در بازه زمانی یک سال قبل و بعد از سیل سال ۱۳۹۷ تغییرات نسبت پوشش گیاهی به خاک در پهنه برگ جهان زیاد استند.

**SVM-RBF** مدل طبقه‌بندی میکرولندفرم‌ها براساس شکل (۴) طبقه‌بندی میکرولندفرم‌ها در بازه ۱۳۹۶-۱۳۹۷ با استفاده از شبکه عصبی RBF را نشان می‌دهد. یک شبکه عصبی سه لایه است و از یک لایه پنهان تشکیل شده است. در نقشه اولیه که با پایتون برنامه‌نویسی شد، سه



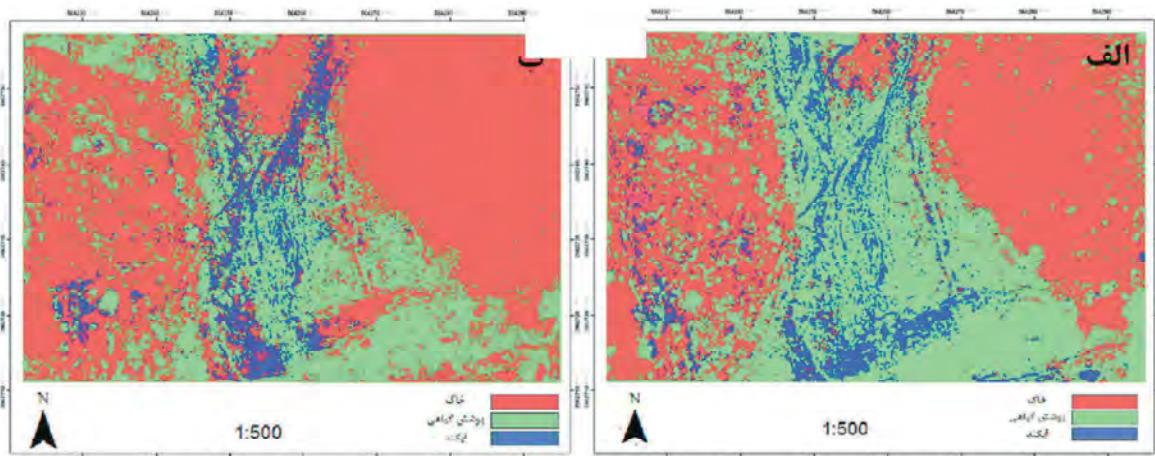
شکل ۴. طبقه‌بندی میکرولندفرم‌ها با تصاویر پهپاد، (الف) طبقه‌بندی تصاویر براساس مدل اس‌وی‌ام اربی اف سال ۱۳۹۶، (ب) طبقه‌بندی تصاویر براساس مدل اس‌وی‌ام اربی اف سال ۱۳۹۷

درنهایت با استفاده از رأی‌گیری بهترین راه حل را انتخاب می‌کند. شکل ۵، طبقه‌بندی میکرولندفرم‌ها در بازه ۱۳۹۶-۱۳۹۷ با استفاده از جنگل تصادفی را نشان می‌دهد. در نقشه اولیه که با پایتون برنامه‌نویسی شد سه رده عمدۀ خاک پوشش گیاهی و فرسایش خندقی تشخیص داده شد و طبقه‌بندی صورت پذیرفت. همان‌طور که شکل ۵ نشان می‌دهد تغییرات پوشش گیاهی به خاک در پهنه برگ جهان بالا است (جدول ۱).

**TG-SVM-RBF** تغییرات میکرولندفرم‌ها براساس مدل پس از طبقه‌بندی و ایجاد رده در نقشه‌های طبقه‌بندی شده در دو سال مختلف تغییرات میکرولندفرم‌ها شناسایی شد. بررسی‌ها نشان داد که ۴۹ درصد تغییرات ایجاد شده مربوط به تغییر پوشش گیاهی به خاک بوده است. در رتبه بعدی تغییرات، ایجاد جریان سطحی و فرسایش خندقی در ناحیه است (شکل‌های ۸ و ۹). میانگین دقت این الگوریتم ۸۸ درصد است (جدول ۱).

**TG-SVM-RBF** تغییرات میکرولندفرم‌ها براساس مدل جنگل تصادفی پس از طبقه‌بندی و ایجاد رده در نقشه‌های دو سال مختلف و تهیه نقشه نهایی، تغییرات میکرولندفرم‌ها در ناحیه شناسایی شد. بررسی‌ها نشان داد که ۶۴ درصد تغییرات با میانگین دقت ۹۲ درصد مربوط به تغییر پوشش گیاهی به خاک در گستره مطالعاتی است (جدول ۱). در رتبه بعدی تغییرات پوشش گیاهی به خاک، تبدیل خندق‌ها به جریان سطحی و ایجاد خندق قرار دارد (شکل‌های ۸ و ۹).

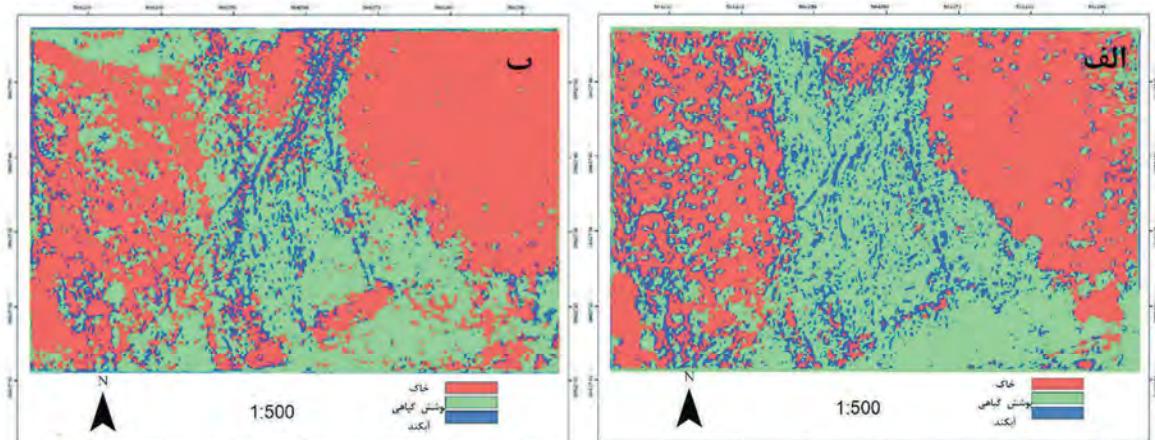
**طبقه‌بندی میکرولندفرم‌ها براساس مدل جنگل تصادفی** جنگل تصادفی یک الگوریتم یادگیری تحت نظرارت است که برای طبقه‌بندی و رگرسیون استفاده می‌شود. جنگل از درختان تشکیل شده است و تعداد بیشتر درختان به معنای جنگل مقاومتر است. به همین ترتیب، الگوریتم جنگل تصادفی، درختان تصمیم‌گیری را روی نمونه‌های داده ایجاد می‌کند و سپس پیش‌بینی را از هر یک از آن‌ها می‌گیرد و



شکل ۵. طبقه‌بندی میکرو لندفرمها با تصاویر پهپاد، (الف) طبقه‌بندی تصاویر براساس مدل جنگل تصادفی سال ۱۳۹۶، ب) طبقه‌بندی تصاویر براساس مدل جنگل تصادفی سال ۱۳۹۷

### طبقه‌بندی میکرو لندفرمها بر اساس مدل SVM خطی با Deep Learning

را در بازه ۱۳۹۷-۱۳۹۶ بر اساس مدل SVM خطی با Deep Learning نشان می‌دهد. در نقشه اولیه که با پایتون نوشته شد سه ردۀ عمدۀ خاک، پوشش گیاهی و گالی تشخیص داده شد و طبقه‌بندی صورت گرفت، همان‌طور که در شکل مشخص است در این بررسی نیز تغییرات پوشش گیاهی به خاک زیاد است.



شکل ۶. طبقه‌بندی میکرو لندفرمها بر اساس تصاویر پهپاد، (الف) طبقه‌بندی تصاویر براساس مدل SVM خطی با Deep Learning سال ۱۳۹۶، ب) طبقه‌بندی تصاویر براساس SVM خطی با Deep Learning سال ۱۳۹۷

شد. بررسی‌هانشان داد که ۳۱ درصد تغییرات ایجاد شده مربوط به تغییر پوشش گیاهی به خاک است (جدول ۱). میانگین دقت این الگوریتم ۹۰ درصد است (شکل‌های ۸ و ۹).

### تغییرات میکرو لندفرمها بر اساس مدل SVM خطی با Deep Learning

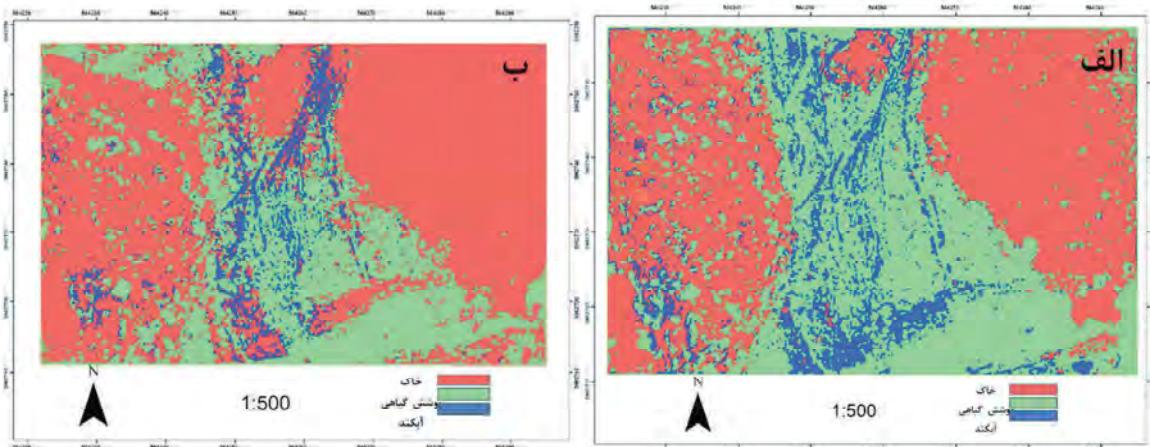
پس از طبقه‌بندی و ایجاد ردۀ در نقشه‌های دو سال مختلف، نقشه نهایی تغییرات میکرو لندفرمها در گستره تهیه

1. Artificial mesh

طبقه‌بندی میکرولندفرمها بر اساس مدل جنگل تصادفی با Deep Learning انجام شد. همان‌طور که در شکل ۷ مشاهده می‌شود در بازه زمانی ۱۳۹۶-۱۳۹۷ تغییرات پوشش گیاهی به خاک در گستره بالا است.

### طبقه‌بندی میکرو لندفرمها بر اساس مدل جنگل تصادفی با Deep Learning

در نقشه اولیه که با پایتون نوشته شد سه رده عمده خاک، پوشش گیاهی و خندق تشخیص داده شدو

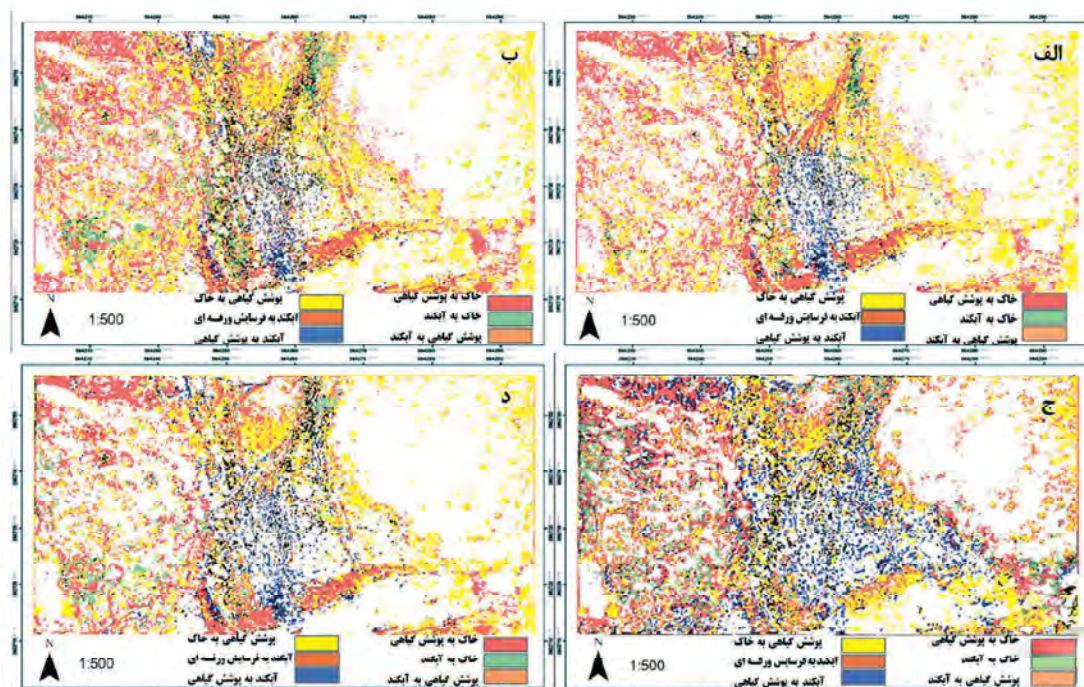


شکل ۷. طبقه‌بندی میکرولندفرمها با تصاویر پهپاد، الف) طبقه‌بندی میکرو لندفرمها بر اساس مدل جنگل تصادفی با Deep Learning سال ۱۳۹۶، ب) طبقه‌بندی میکرو لندفرمها بر اساس مدل جنگل تصادفی با ۱۳۹۷

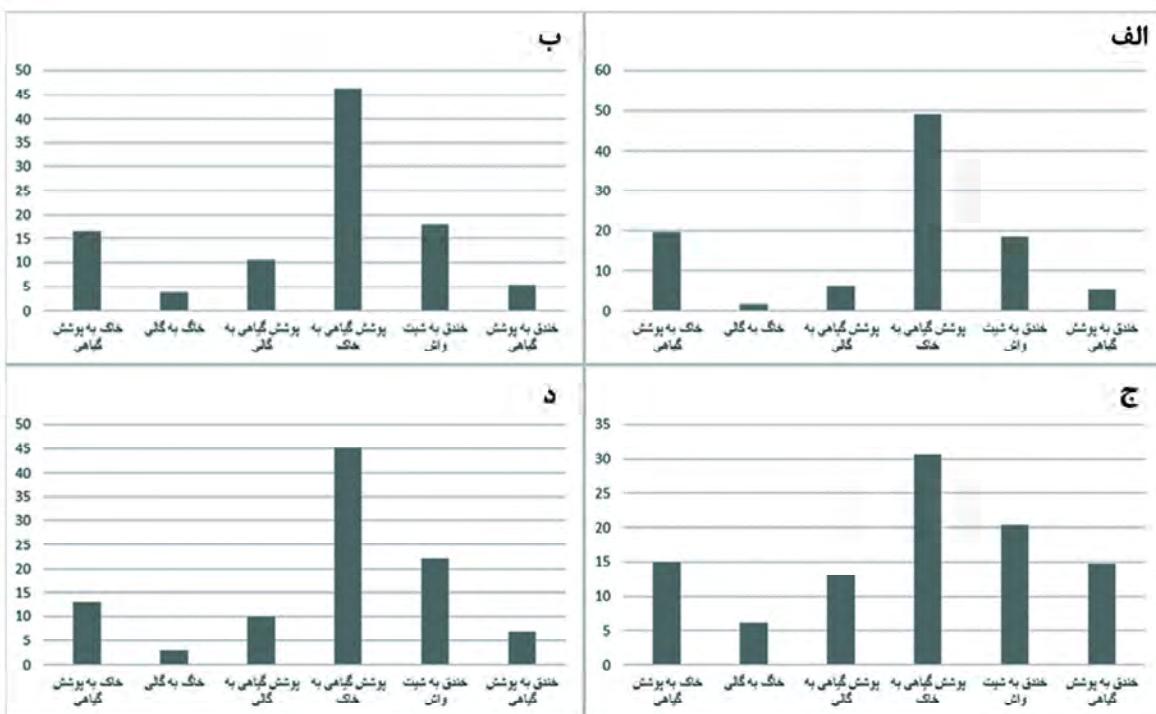
میکرولندفرمها در ناحیه تهیه شد. بررسی‌ها نشان داد که ۴۵ درصد تغییرات با میانگین دقت ۹۶ درصد در گستره مربوط به تغییر پوشش گیاهی به خاک است (جدول ۱).

### تغییرات میکرو لندفرمها بر اساس مدل جنگل تصادفی با Deep Learning

بر اساس مدل‌های جنگل تصادفی با Deep Learning با طبقه‌بندی در نقشه‌ها انجام شد و نقشه نهایی تغییرات



شکل ۸. تغییرات میکرولندفرمها بر اساس مدل‌ها، الف) مدل جنگل تصادفی، ب) مدل RBF SVM، ج) مدل SVM خطی با Deep Learning، د) مدل‌های جنگل تصادفی با Deep Learning



شکل ۹. درصد تغییرات میکرولندرمها براساس مدل‌ها، (الف) مدل جنگل تصادفی، (ب) مدل RBF SVM، (ج) مدل‌های SVM خطی با یادگیری عمیق، (د) مدل‌های جنگل تصادفی با یادگیری عمیق

جدول ۱. درصد تغییرات میکرولندرمها در مدل‌های SVM، جنگل تصادفی، RBF SVM، جنگل تصادفی با یادگیری عمیق و جنگل تصادفی با یادگیری عمیق

میکرولندرم	مدل							
	SVM خطی با یادگیری عمیق	جنگل تصادفی با یادگیری عمیق	SVM	جنگل تصادفی	RBF SVM	مدل	مدل	مدل
درصد	تعداد پیکسل	درصد	تعداد پیکسل	درصد	تعداد پیکسل	درصد	تعداد پیکسل	درصد
۱۳/۰۳۱	۲۲۴۴۸	۱۵/۰۲	۴۹۳۹۵	۱۶/۴۴	۴۵۸۲۰	۱۹/۰۲	۴۶۹۶۴	خاک به پوشش گیاهی
۲/۹۹	۷۴۵۵	۶/۰۵	۱۹۸۹۲	۳/۷۰	۱۰۳۲۷	۱/۵۱	۳۶۴۰	خاک به خندق
۱۰/۰۴	۲۵۰۱۲	۱۳/۰۶	۴۲۹۶۰	۱۰/۴۹	۲۹۲۴۰	۶/۲۴	۱۵۰۲۹	پوشش گیاهی به خندق
۴۵/۰۳	۱۱۲۱۲۶	۳۰/۶۸	۱۰۰۸۹۰	۴۶/۱۷	۱۲۸۶۹۲	۴۹/۲۷	۱۱۸۵۱۵	پوشش گیاهی به خاک
۲۲/۰۵	۵۴۸۹۶	۲۰/۳۷	۶۶۹۶۴	۱۷/۸۰	۴۹۶۲۶	۱۸/۴۰	۴۴۲۷۶	خندق به جریان سطحی
۶/۸۵	۱۷۰۵۶	۱۴/۸۱	۴۸۶۹۵	۵/۳۸۳۱	۱۵۰۰۳	۵/۰۳۵	۱۲۱۱۲	خندق به پوشش گیاهی
۱۰۰	۲۴۸۹۹۳	۱۰۰	۳۲۸۷۹۶	۱۰۰	۲۷۸۷۰۸	۱۰۰	۲۴۰۵۳۶	کل تغییرات
۹۶ درصد		۹۰ درصد		۹۲ درصد		۸۸ درصد		میانگین دقت
۲۶ درصد		۳۴ درصد		۲۹ درصد		۲۵ درصد		کل تغییرات

استفاده شد. برای بررسی رفتار میکرولندرمها و تأثیر خطی و غیرخطی بودن مدل‌ها از کرنل‌های خطی استفاده شد. نتایج به دست آمده نشان داد مدل RBF SVM با ۸۸ درصد نسبت به مدل‌های دیگر دقت کمتری دارد، به طوری که تفکیک بین طبقه‌ها در آن محدود بود. کرنل RBF با انتقال

**نتیجه‌گیری**  
در این پژوهش برای بررسی تغییرات میکرولندرمها و شناسایی الگوریتم مناسب در پیش‌بینی رفتار پیچیده آنها از مدل‌های RBF SVM، جنگل تصادفی، SVM خطی با یادگیری عمیق و جنگل تصادفی با یادگیری عمیق

- خدری غریب وند، ل.، قهرومدی تالی، م.، سبک خیز، ف. و سپهر، ع.، ۱۳۹۷. بررسی روند تکاملی پهنه‌های گلی با تلاقی گاوخونی با استفاده از مدل فرکتال. جغرافیا و برنامه‌ریزی محیطی، ۲۹(۲)، ۱۱۳-۱۲۸. ۱0.22108.113-128. ۱0.98241.0%gep.2018.98241.0
- رعیتی شوازی، م.، کرم، ا.، غفاریان مالمیری، ح. و سپهر، ع.، ۱۳۹۶. مقایسه کارائی برخی الگوریتم‌های طبقه‌بندی در مطالعه تغییرات لندفرم‌های بیابانی دشت یزد-اردکان. پژوهش‌های زئومورفولوژی کمی، ۱(۲۱)، ۵۷-۷۳.
- شایان، س.، احمدآبادی، ع.، یمانی، م.، فرجزاده اصل، م. و احسان الله کبیر، م.، ۱۳۹۱. ارزیابی شاخص‌های زئومورفومتریک به روش وود در طبقه‌بندی لندفرم‌های مناطق خشک (مطالعه موردی: منطقه منجان). برنامه‌ریزی و آمایش فضاء، ۱۶(۱)، ۱۰۵-۱۲۰.
- قهرومدی تالی، م. و علی نوری، خ.، ۱۳۹۶. تغییرات مکانی پلایایی حوض سلطان در دوره ۱۹۹۱-۲۰۱۶. پژوهش‌های زئومورفولوژی کمی، ۲۰(۴)، ۱۰۳-۱۲۰.
- قهرومدی تالی، م. و علی نوری، خ.، ۱۳۹۳. ردیابی مخاطرات پلایایی حوض سلطان با بررسی آشفتگی میکرولندفرم‌ها. مدیریت مخاطرات محیطی، ۱(۲)، ۲۴۱-۲۵۲.
- قهرومدی تالی، م. و خدری غریب وند، ل.، ۱۳۹۵. رویکرد فرم‌شناسی در استراتژی مدیریت تالاب‌ها و پلایاهای بررسی موردي: پلایایی گاوخونی. فصلنامه علوم محیطی، ۱۴(۲)، ۱۱۸-۱۰۹.
- مکرم، م. و نگهبان، س.، ۱۳۹۴. طبقه‌بندی لندفرم‌ها با استفاده از شبکه‌های عصبی خود سازنده (Selforganization map). فصلنامه کواترنری ایران، ۱(۳)، ۲۲۵-۲۳۸.
- نعیمی نظام‌آباد، ع.، قهرومدی تالی، م. و ثروتی، م.، ۱۳۸۸. آشکارسازی تغییرات لندفرم‌های ساحلی منطقه عسلویه. جغرافیایی سرزمین، ۲۲(۲)، ۵۹-۶۵.
- Baartman, J. E., Temme, A. J. and Saco, P. M., 2018. The effect of landform variation on vegetation patterning and related sediment dynamics. Earth Surface Processes and Landforms, 43(10), 2121-2135.
- Bernal, I., Tavera, H., Sulla, W., Arre-

داده‌ها به فضاهای ویژگی با ابعاد بالاتر و طبقه‌بندی در آن باعث خطی شدن رفتار میکرولندفرم‌ها در فضا با ابعاد بالا شد و تفکیک بین رده‌ای را در آن محدود انجام داد. در مدل جنگل تصادفی با دقت ۹۲ درصد رده‌های موجود در ناحیه با مرزهای خطی تا حدی قابل تفکیک بودند. اطلاعات متنی قابل استخراج از شبکه‌های عصبی عمیق از پیش آموزش داده شده بر روی ویژگی‌های استخراج شده از مدل جنگل تصادفی با دقت بالاتری ۹۶ درصد تغییرات میکرولندفرم‌ها را نشان داد. همچنین ارزیابی تحولات میکرولندفرم‌ها در ناحیه برگ جهان از معیار دقت نشان داد، استفاده از ویژگی‌های به دست آمده از این شبکه‌ها در قابلیت تفکیک طبقه‌های مختلف در تصاویر پهپاد بسیار پرکاربرد است. به طوری که سبب ایجاد مدل نزدیک به ایده‌آل در الگوریتم جنگل تصادفی با یادگیری عمیق شد. بررسی‌ها نشان داد بیشترین تغییرات میکرولندفرم‌ها در این مدل، مربوط به تغییر پوشش گیاهی به خاک به میزان ۴۵/۰۳ و در رتبه بعدی تغییر خندق به جریان سطحی به میزان ۲۲/۰۵ است. با توجه به نتایج به دست آمده مشخص شد که سیل در حوضه جاجروم به ویژه ناحیه برگ جهان در سال ۱۳۹۷ سبب تغییرات عمده‌ای در گستره شده است. به طوری که بیشترین تأثیر آن بر روی پوشش گیاهی ناحیه داشته و درصد بسیاری از آن را زیستگاه است به طوری که تغییرات آن را در بالاترین حد آشافتگی نشان می‌دهد. علاوه بر موارد ذکر شده با توجه به کاهش بارندگی، خشکسالی‌های اخیر و سیل؛ جریان سطحی، خندق در گستره بیشتر ایجاد شده است و نشان‌دهنده میزان بالای فرسایش و تغییرات بسیار زیاد میکرولندفرم‌ها در ناحیه مطالعاتی است.

## منابع

- آراء، م.، ۱۳۹۲. لندفرم‌ها و طبقه‌بندی آن‌ها در علم زئومورفولوژی (مطالعه موردی: حوضه آبریز جاجروم در شمال شرق تهران). فصلنامه علمی-پژوهشی اطلاعات جغرافیایی سپهر، ۲۲(۸۶)، ۱۷-۲۲.
- چورلی، ر.، ج.، استانی، ا.ش. و دیوید، ا.، ۱۳۷۵. زئومورفولوژی. ترجمه احمد، معتمد (جلد اول) تهران، انتشارات سمت، ۱۶۸.

- dondo, L. and Oyola, J., 2018. Geomorphology Characterization of Ica Basin and Its Influence on the Dynamic Response of Soils for Urban Seismic Hazards in Ica, Peru, International Journal of Geophysics.43-59
- Bocco, G., Mendoza, M. and Velazquez, A., 2001. Remote sensing and GIS-based regional geomorphological mapping a tool for land use planning in developing countries. *Geomorphology*, 39(3-4), 211-219.
  - Cassandra, A.P. B. and Crider, G. J., 2022. A new metric for morphologic variability using landform shape classification via supervised machine learning, *Geomorphology*, 399(108065), doi.org/10.1016/j.geomorph.2021.108065.
  - Chakrabortty, R., Pal, S. C., Santosh, M., Roy, P. and Chowdhuri, I., 2022. Gully erosion and climate induced chemical weathering for vulnerability assessment in sub-tropical environment. *Geomorphology*, 398,108027, doi:10.1016/j.geomorph.2021.108027.
  - Debnath, J., Pan, N. D., Ahmed, I. and Bhowmik, M., 2017. Channel migration and its impact on land use/land cover using RS and GIS: A study on Khowai River of Tripura, North-East India, *The Egyptian Journal of Remote Sensing and Space Science*, 20(2), 197-210.
  - James, M. and Robson, Stuart, 2012. Straightforward reconstruction of 3D surfaces and topography with a camera: Accuracy and geoscience application, *Journal of Geophysical Research*, 117, F03017, doi:10.1029/2011JF002289.
  - Laurentiis, D.L., Pomente, A., Del, F. F. and Schiavon, G., 2019. Capsule and convolutional neural network-based SAR ship classification in Sentinel-1 data, 11154, 1115405, doi:10.1117/12.2532551.
  - Liu, B. and Coulthard, T., 2017. In Dynamic Equilibrium: The Autogenic Landform Change in a Fluvial-Aeolian Interacting Field. In Fifth International Planetary Dunes, 1961, 3001.
  - Panda, P. and Narasimham, M., 2018. Dynamic Geomorphology of the Kosi Fan in Consequence to a Mega-Avulsion Aided by Space Inputs and Hydraulic Modeling, *J Remote Sensing and GIS*, 7, 1000238, doi: 10.4172/2469-4134.1000238.
  - Rahmati, O., Tahmasebipour, N., Haghizadeh, A., Pourghasemi, H. R. and Feizizadeh, B., 2017. Evaluation of different machine learning models for predicting and mapping the susceptibility of gully erosion, *Geomorphology*, 298, 118-137.
  - Salles, T., Flament, N. and Muller, D., 2017. Influence of dynamic topography on the evolution of the eastern Australian landscape since the Upper Jurassic Epoch, In EGU General Assembly Conference Abstracts, 11432.
  - Sawagaki, T., LAMSAL, D., Byers, A. and Watanabe, T., 2012. Changes in surface morphology and glacial lake development of Chamlang South Glacier in the eastern Nepal Himalaya since 1964, *Global Environment of Research* 16, 83-94.
  - Spencer, T., Larissa, N., Stuart, L., Stephen, D., Mark, M., Francis, M. and Iris., M., 2017. Stormy geomorphology: an introduction to the Special Issue, *Earth Surface Processes and Landforms*, 42, 238-241, doi: 10.1002/esp.4065.
  - Simonyan, K., and Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv:1409.1556.
  - Wei, Z., Han, Y., Li, M., Yang, K., Yang, Y., Luo, Y. and Ong, S. H., 2017. A small UAV based multi-temporal image registration for dynamic agricultural terrace monitoring, *Remote Sensing*, 9(9), 904.
  - Wondzell, S. M., Cunningham, G. L. and Bachelet, D., 1996. Relationships between landforms, geomorphic processes, and plant communities on a watershed in the northern Chihuahuan Desert, *Landscape Ecology*, 11(6), 351-362.