

## طبقه‌بندی ناهمواری‌های کارستی با استفاده از شاخص‌های ژئومورفومتریک و شبکه عصبی مصنوعی (مطالعه موردی: بخشی از حوضه‌های خرم‌آباد، بیرانشهر و الشتر)

- ❖ علیرضا سپه‌وند؛ دانشجوی دکتری علوم و مهندسی آبخیزداری، دانشکده منابع طبیعی، دانشگاه تهران.
- ❖ حسن احمدی\*؛ استاد دانشکده منابع طبیعی، دانشگاه تهران.
- ❖ سیاستیانو ترویسانی؛ استادیار دانشکده زمین‌شناسی کاربردی و محیطی، دانشگاه ونیز ایتالیا.

### چکیده

استفاده از شاخص‌های ژئومورفومتري در تفکیک ناهمواری‌های سطح زمین کاربرد گسترده‌ای را طی دهه گذشته در علم ژئومورفولوژی داشته است. در این تحقیق از روش پرسپترون چند لایه شبکه عصبی مصنوعی برای طبقه‌بندی ناهمواری‌های کارستی استفاده شد. ابتدا با استفاده از نقشه مدل رقومی ارتفاع، شاخص‌های ژئومورفومتري تهیه شد و سپس این شاخص‌ها به‌عنوان نرون‌های لایه ورودی در شبکه عصبی مصنوعی استفاده شد. علاوه بر این از نمودارهای جعبه‌ای برای تحلیل ارتباط ناهمواری‌های کارستی همچون دولین، تپه، دشت کارستی، دره کارستی و پرتگاه با شاخص‌های ژئومورفومتري استفاده شد. نتایج طبقه‌بندی نشان داد که ناهمواری‌های منطقه مورد مطالعه به ترتیب شامل ۳۴، ۶/۹، ۱/۰۷، ۴۸/۵ و ۹/۵۱ درصد دره، دشت، دولین، پرتگاه و تپه می‌باشد. علاوه بر این، نتایج نشان داد که مدل بهینه شبکه عصبی مصنوعی برای طبقه‌بندی ناهمواری‌ها، مدل ۱-۹-۱۲ با ضریب یادگیری ۰/۱ و ضریب تبیین ۸۷/۱۸ درصد بود و دقت روش ابداعی برای طبقه‌بندی ناهمواری‌های کارستی ۹۰/۵۸ درصد می‌باشد. همچنین تحلیل‌ها نماینده این است که تغییرات شاخص‌های ژئومورفومتري در ناهمواری‌های تپه، پرتگاه و دره کارستی بسیار نمایان بوده ولی در دشت و دولین کمی دارای همپوشانی هستند.

کلید واژگان: لرستان، کارست، شبکه عصبی مصنوعی، طبقه‌بندی ناهمواری‌ها، نمودار جعبه‌ای.

## ۱. مقدمه

کارست نوع مشخصی از سیمای سرزمین است که از توسعه فرآیند انحلال آب بر روی سنگ بستر انحلال پذیر (مانند سنگ آهک و مرمر، سنگ گچ و هالیت) در اقلیم‌های مختلف ایجاد می‌شود و در حدود ۳۰-۲۰ درصد از سطح زمین را به خود اختصاص داده است [۲۹]. بنابراین در مناطق کارستی اشکال بسیار متنوع از ناهمواری‌ها (فرسایش و رسوب‌گذاری از ابعاد میکرو تا ماکرو) دیده می‌شود. عناصر ناهمواری مناطق کارستی شامل دامنه‌ها، کوه‌ها، قله‌ها، دره‌ها، دشت‌ها، کانیون‌ها و... می‌باشند [۲۶]. در این زمینه، شناسایی سیمای سرزمین مختلف در مناطق کارستی از نظر نوع مدیریت آن‌ها در مدیریت حوزه‌های آبخیز کارستی از اهمیت زیادی برخوردار است.

در ژئومورفولوژی با استفاده از پارامترسازی مدل رقومی ارتفاع (DEM)، می‌توان لندفرم‌ها را به‌صورت عناصر پستی و بلندی ساده توصیف و کمی کرد. بیش از چند دهه ژئومورفولوژیست‌ها برای توصیف و بررسی لندفرم‌ها از روش‌های کیفی استفاده می‌کردند، اما در اوایل دهه ۱۹۶۰، روش‌های کمی وارد مطالعات لندفرم‌ها شد [۱۹، ۲۸]. یکی از این روش‌های کمی، علم ژئومورفومتری می‌باشد. ژئومورفومتری علم تحلیل کمی سطح زمین می‌باشد که با استفاده از تکنیک‌های ریاضی، آماری و پردازش تصویر به بررسی و کمی‌سازی ویژگی‌های مورفولوژیکی، هیدرولوژیکی، اکولوژیکی و سایر ویژگی‌های سطح زمین می‌پردازد [۲۰، ۲۱، ۲۲]. مطالعات کمی توپوگرافی سطح زمین در سال‌های اخیر در دو زمینه تحقیقاتی و کاربردی به‌طور چشمگیری برای تهیه یک نظم خاص در مطالعات ژئومورفولوژی افزایش یافته است [۳، ۹، ۳۲، ۳۵]. در بیشتر موارد برای شناسایی و جداکردن آن‌ها باید بر پایه تفسیر بصری عکس‌های هوایی

و حضور در منطقه، بهره‌گیری کرد. آنچه مسلم است دسترسی سریع و دقیق به ناهمواری‌های موجود در رابطه با نوع فرآیند غالب از اهمیت زیادی برخوردار است. در این زمینه استفاده از تحلیل‌های کمی مبتنی بر نمایه‌های ژئومورفومتری می‌تواند بسیار سودمند باشد. برای طبقه‌بندی لندفرم‌ها روش‌های زیادی وجود دارد که همه این روش‌ها تقریباً مشابه هستند؛ از جمله می‌توان روش شاخص موقعیت توپوگرافی (TPI) [۱۴، ۱۵، ۱۶، ۲۳، ۲۶، ۳۰] را نام برد. یکی از روش‌های جدید که برای طبقه‌بندی لندفرم‌ها قابلیت استفاده دارد و متفاوت با روش‌های قبلی است، روش شبکه عصبی مصنوعی می‌باشد. روش شبکه عصبی مصنوعی یک مکانیسم محاسباتی است که قادر است با گرفتن اطلاعات و محاسبه کردن آن‌ها یک سری اطلاعات جدید را ارائه دهد [۱۱، ۱۳، ۲۵]. در این شبکه سعی بر این است که ساختاری مشابه ساختار بیولوژیکی مغز انسان ساخته شود تا همانند مغز قدرت یادگیری، تعمیم‌دهی و تصمیم‌گیری داشته باشد [۸، ۱۸، ۲۵، ۳۴]. روش شبکه عصبی مصنوعی نسبت به روش‌های دیگر دارای مزیت‌هایی است، از آن جمله این روش از توزیع آماری داده‌ها مستقل است و به متغیرهای آماری مخصوصی نیاز ندارد [۶، ۱۳، ۱۸]. این مدل با بررسی خصوصیات همه شاخص‌های ژئومورفومتری و ناهمواری‌های منطقه، قادر است که نوع ناهمواری‌های مناطق مختلف را تعیین کند. روش شبکه عصبی یکی از مناسب‌ترین روش‌ها برای طبقه‌بندی می‌باشد که بعد از دهه ۱۹۹۰ به‌طور گسترده‌ای برای طبقه‌بندی مورد استفاده قرار گرفته است [۱، ۲۵، ۲۷، ۳۳، ۳۶، ۳۷]. مدل شبکه عصبی مصنوعی دارای چند نوع می‌باشد که در این تحقیق از روش چند لایه پرسپترون<sup>۳</sup> (MLP) استفاده شده است. مدل چند لایه پرسپترون

<sup>۱</sup>Digital Elevation Model<sup>۲</sup>Topographic Position Index<sup>۳</sup>Multi-layer Perseptron

موقعیت جغرافیایی برای طبقه بندی لندفرم‌های مختلف در شمال غرب بلژیک پرداختند. آن‌ها در این تحقیق علاوه بر طبقه بندی لندفرم‌ها به بررسی کارایی TPI و انحراف ارتفاع متوسط (DEV) پرداختند. نتایج این تحقیق نشان داد که DEV از دقت بیشتری نسبت به TPI برای طبقه بندی لندفرم‌ها برخوردار است [۲۳]. در زمینه طبقه بندی ناهمواری‌های کارستی فقط [۲۴] به بررسی روش‌های طبقه بندی ناهمواری‌های کارستی پرداخت و به این نتیجه رسید که با استفاده از سیستم LIDAR و GIS می‌توان ناهمواری‌های کارستی را طبقه بندی کرد. لذا در این تحقیق به بررسی کارایی استفاده از شبکه عصبی مصنوعی برای طبقه بندی ناهمواری‌های کارستی پرداخته شد.

## ۲. روش شناسی

### ۱،۲. معرفی منطقه مورد مطالعه

منطقه مورد مطالعه از نظر ژئومورفولوژی یک در بخش مرکزی سلسله جبال زاگرس در استان لرستان قرار دارد که خود بخشی از زیر حوزه آبخیز کرخه می‌باشد. زیر حوزه بیرانشهر با مساحت ۳۵۶۲/۱۲ کیلومتر مربع مطابق شکل ۱ بین طول‌های جغرافیایی  $47^{\circ}52'18''$  تا  $59^{\circ}48'09''$  شرقی و عرض‌های  $35^{\circ}49'39''$  تا  $57^{\circ}35'11''$  شمالی قرار دارد. بلندترین نقطه حوضه در بخش شمالی با ارتفاع ۳۵۷۸ متر از سطح دریا و پست‌ترین نقطه حوضه در بخش غربی یعنی خروجی حوضه با ارتفاع ۱۱۵۸ متر از سطح دریا قرار دارد (شکل ۲). میانگین بارندگی منطقه بین ۴۰۰ تا ۵۰۰ میلی‌متر و

که اولین بار توسط ویدور<sup>۱</sup> و روزنبلات<sup>۲</sup> مطرح شد، شامل سه لایه ورودی<sup>۳</sup>، پنهان<sup>۴</sup> و خروجی<sup>۵</sup> می‌باشد که هر لایه از تعدادی واحد پردازشگر به نام نرون تشکیل شده است و برای طبقه بندی مورد استفاده قرار می‌گیرد [۱۸، ۳۶، ۳۷].

### ۱،۱. مشخص کردن توپولوژی مسئله

در این مرحله تعداد نرون‌ها در لایه ورودی و تعداد نرون‌ها در هر لایه، نوع شبکه و توابع پایه و محرک انتخاب می‌شوند [۱۲، ۱۷]. اجرای شبکه عصبی مصنوعی شامل مراحل آموزش و آزمایش شبکه می‌باشد. مرحله آموزش شبکه شبیه به کالیبراسیون می‌باشد. منظور از آموزش شبکه، اصلاح مقادیر وزن‌های شبکه برای نمونه‌های متعدد است. اطلاعات مورد نظر به‌عنوان داده‌های آموزشی به شبکه معرفی می‌شوند و شبکه در جریان فرآیند یادگیری بر اساس اشتباه یا تفاوت بین خروجی شبکه و عکس‌العمل مورد انتظار، مقادیر وزن‌های خود را اصلاح می‌کند [۱۰، ۱۳، ۱۷]. پس از این که مرحله آموزشی شبکه تکمیل شد، شبکه برای سری اطلاعات معلوم امتحان می‌شود و نواقص احتمالی بر طرف می‌گردد. پس از تکمیل این مرحله شبکه آماده استفاده می‌شود [۶، ۱۸]. در زمینه طبقه بندی ناهمواری‌ها تحقیقاتی انجام گرفته است که در زیر به برخی اشاره شده است. برخی محققان به طبقه بندی تصاویر ماهواره‌ای با استفاده از شبکه عصبی مصنوعی پرداختند. آن‌ها در تحقیق خود با استفاده از روش طبقه بندی نظارت شده، نمونه‌های آموزشی شبکه عصبی مصنوعی را مشخص کردند. نتایج تحقیق نشان داد که روش شبکه عصبی، روشی مناسب برای طبقه بندی تصاویر ماهواره‌ای است [۳۴]. برخی دیگر از محققان به بررسی کاربرد شاخص

<sup>۱</sup>Widrow

<sup>۲</sup>Rosenblatt

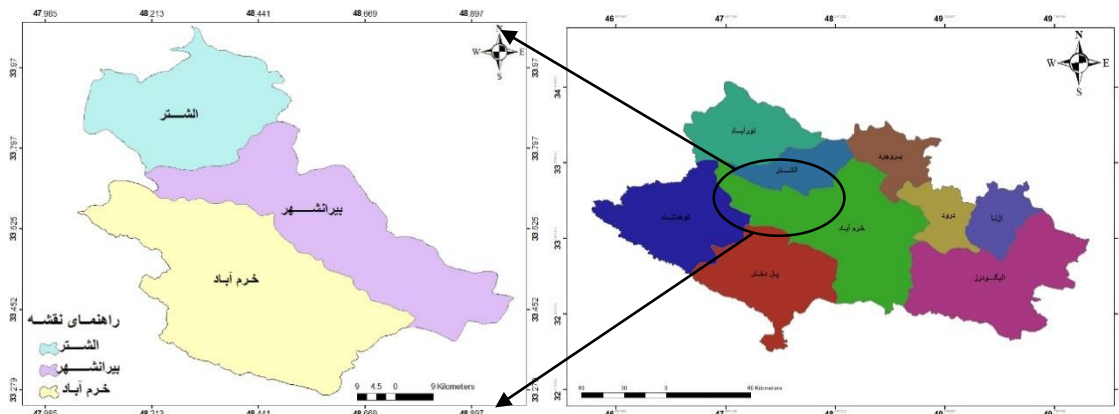
<sup>۳</sup>Input Layer

<sup>۴</sup>Hidden Layer

<sup>۵</sup>Output Layer

<sup>۶</sup>Neuron

دارای اقلیم نیمه خشک و سرد می باشد.

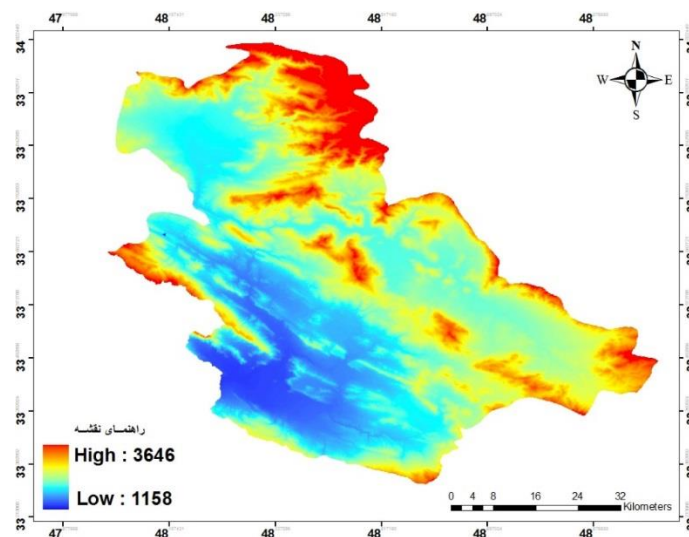


شکل ۱. موقعیت جغرافیایی منطقه مورد مطالعه روی نقشه استان لرستان

منطقه در شکل ۲ نشان داده شده است. در ادامه به وسیله برنامه های Land Facet Corridor Designer و DEM Surface tools در محیط نرم افزار GIS شاخص های ژئومورفومتریک تهیه شدند.

## ۲.۲. روش انجام پژوهش

در این تحقیق از مدل رقومی ارتفاعی (DEM) با دقت ۱۰ متر در محیط نرم افزار GIS برای تهیه شاخص های ژئومورفومتریک استفاده شد که نقشه مدل رقومی ارتفاعی



شکل ۲. نقشه مدل رقومی ارتفاعی منطقه مورد مطالعه

انحنای مقطع، تانژانت انحنای، انحنای طول، انحنای کل، انحنای متقاطع، انحنای عمومی، انحنای سطح، شاخص

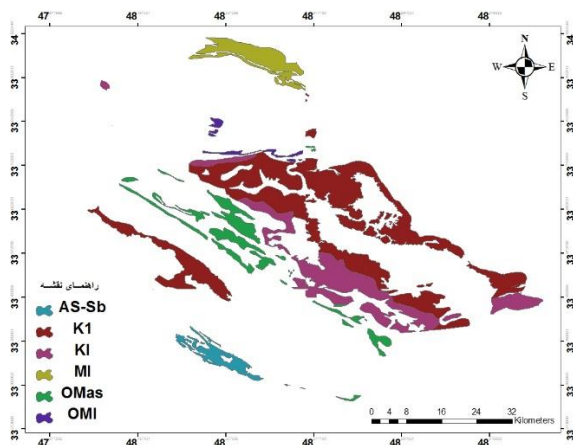
بعد از تهیه شاخص های ژئومورفومتریک (شیب، انحنای سطح، نسبت سطح، شاخص موقعیت توپوگرافی،

<sup>1</sup>Digital Elevation Model

<sup>2</sup>Geographic Information System

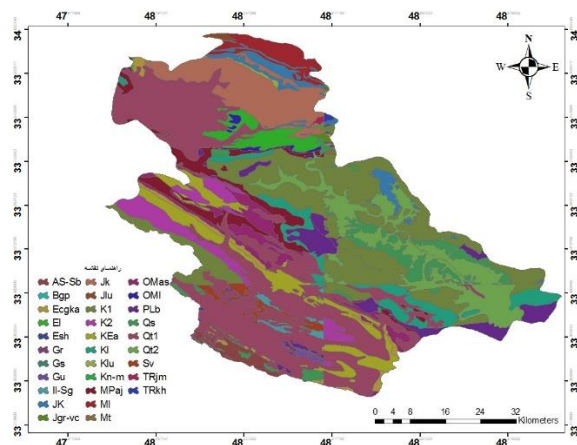
شاخص در محل نقاطه نمونه برداری استخراج شد و به صورت ستون‌های عددی به نرم افزار SPSS انتقال داده شدند و تغییرات کمی این شاخص‌ها به صورت نمودار مورد تجزیه و تحلیل قرار گرفتند. این نمودارها به نمودار جعبه‌ای معروف هستند. در این نمودارها ضلع بالای مستطیل نشان دهنده چارک سوم است، یعنی ۷۵ در صد داده‌ها کمتر یا مساوی آن هستند و ضلع پایین نشان دهنده چارک اول<sup>۲</sup>، یعنی ۲۵ در صد داده‌ها کمتر یا مساوی آن هستند و خط افقی داخلی جعبه، میانه و علامت خارج مستطیل داده پرت است (شکل ۶) [۲، ۴، ۳۱].

ناهمواری‌های مشخص شده در منطقه و شاخص‌های ژئومورفومتریک در فرمت‌های برداری و رستری در محیط GIS ذخیره و برای انجام تحلیل‌های مبتنی بر شبکه عصبی مصنوعی در نرم‌افزار MATLAB<sup>۴</sup> 7.8.0 (R2009a) مورد استفاده قرار گرفتند. از مساحت ناهمواری‌های مشخص شده در منطقه، ۷۰ درصد داده‌ها به‌طور تصادفی برای آموزش شبکه و ۳۰ در صد باقیمانده برای آزمایش و صحت سنجی شبکه به‌کار برده شدند. شکل ۴ نقشه ناهمواری‌های کارستی تعیین شده در منطقه را نشان می‌دهد.



شکل ۴. نقشه سازندهای کارستی منطقه مورد مطالعه

زبری سطح)، با استفاده از نقشه زمین شناسی منطقه (با مقیاس ۱:۱۰۰۰۰۰) (شکل ۳)، بخشی از منطقه که دارای سازندهای کارستی بود (شکل ۴)، با استفاده از گزینه Extract by mask از نقشه اصلی در نرم افزار GIS جدا گردید که این سازندها ۱۰۳۸/۲ کیلومتر مربع از مساحت منطقه را در بر گرفته‌اند. در ادامه با استفاده از عکس‌های هوایی منطقه، نرم افزار گوگل ارث و بازدید صحرائی، ۵ نوع از ناهمواری‌های سازندهای کارستی (دولین، دشت، تپه، دره کارستی و پرتگاه) در مناطق مختلف شناسایی شدند و با استفاده از GPS موقعیت آن‌ها تعیین شد و با انتقال این موقعیت‌ها به نرم افزار GIS اقدام به ترسیم نقشه این ناهمواری‌ها شد (شکل ۵). این ناهمواری‌ها حدود ۳/۴ کیلومتر مربع از مساحت منطقه را شامل می‌شدند. البته لازم به ذکر است که در منطقه ناهمواری‌های میکرو کارستی، هم‌چون کارن‌های زیادی مشاهده شد که با توجه به اندازه خیلی کوچک، امکان بررسی آن‌ها در این تحقیق وجود نداشت. در ادامه برای تحلیل نمایش ناهمواری‌های کارستی به وسیله شاخص‌های ژئومورفومتری، مقدار عددی این




شکل ۳. نقشه زمین شناسی منطقه مورد مطالعه

<sup>۱</sup>First Quartile

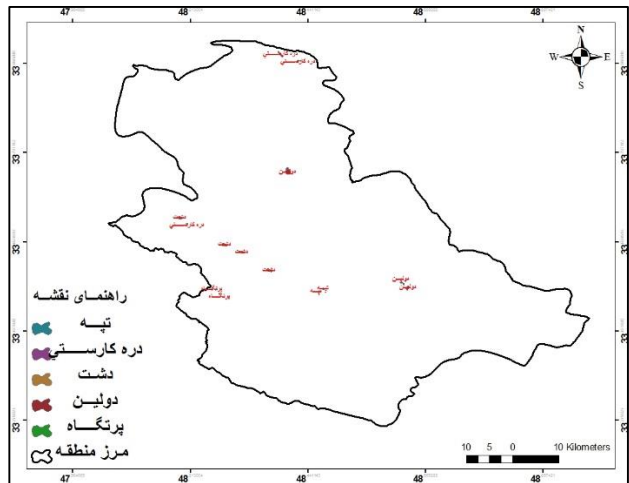
<sup>۲</sup>Outlier

<sup>۴</sup>Matrix Laboratory

<sup>۳</sup>Third Quartile



شکل ۶. پارامترهای نمودار جعبه‌ای



شکل ۵. ناهمواری‌های کارستی تعیین شده در منطقه مورد مطالعه

ناهمواری پیش‌بینی شده توسط شبکه عصبی مصنوعی برای هر پیکسل خواهد بود. این ماتریس‌ها در نرم افزار اکسل تهیه شد و در ادامه ماتریس تهیه شده را به دو صورت می‌توان وارد نرم افزار مطلب کرد: الف) یا فایل اکسل را با پسوند xls ذخیره و با نوشتن یک برنامه در نرم‌افزار MATLAB، فایل را فراخوانی کنیم، ب) ماتریس را به یک فایل Note Pad با پسوند prn انتقال داده و فایل را با نوشتن یک کد فراخوانی می‌کنیم. در این تحقیق از روش الف استفاده شد.

در این تحقیق برای آموزش شبکه از الگوریتم پس انتشار خطا (BP) استفاده شد. در شبکه عصبی مراحل وزن دهی عوامل شامل دو مرحله است که در مرحله اول به‌طور تصادفی هر عامل دارای وزن می‌شود و سپس طی مراحل آموزش شبکه عصبی مصنوعی، وزن نهایی نرون‌های لایه ورودی تعیین می‌شود [۱۳، ۱۸]. با استفاده از وزن نهایی هر عامل، خروجی شبکه به دست می‌آید. در نهایت برای قرار دادن خروجی شبکه در یک محدوده خاص (در این تحقیق محدوده ۰-۱ مد نظر بود) از تابع غیرخطی سیگموئید ( $f$ ) به‌دلیل مشتق پذیر بودن،

برای ورود اطلاعات مربوط به کل پیکسل‌های منطقه مورد مطالعه به نرم افزار در محیط نرم‌افزار مطابق زیر عمل شد. عوامل ورودی در این تحقیق ۱۲ عامل (شاخص‌های مورفومتریک) بودند که این عوامل در ۱۲ ستون شاخص‌های مورفومتری با ترتیب انحنای مقطع، تانژانت انحنای طول، انحنای کل، انحنای متقاطع، انحنای عمومی، انحنای سطح، شیب، نسبت سطح، مساحت سطح، شاخص موقعیت توپوگرافی و شاخص زبری سطح در فایل ورودی قرار گرفتند. سپس با توجه به هدف تحقیق یعنی طبقه‌بندی لندفرم‌های کارستی، بخش سازندهای کارستی از این شاخص‌ها با گزینه Extract by mask در نرم افزار GIS از نقشه اصلی جدا شد و سپس بخش جدا شده به فرمت Point تبدیل گردید و از جدول مشخصات نقشه خروجی گرفته شد که این کار برای تمام نقشه شاخص‌های ژئومورفومتریک انجام شد و با کپی کردن Value خروجی گرفته شده در نرم افزار اکسل، یک ماتریس درست شد که تعداد ستون‌های این ماتریس برابر تعداد نرون لایه ورودی و تعداد سطرها برابر تعداد پیکسل‌های منطقه می‌باشد. لایه خروجی شامل نوع

<sup>۱</sup>Sigmoid Function



$Q_i^{simav}$  = مقدار میانگین برآورد شده،  $Q_i^{obs}$  = مقدار مشاهده‌ای برای نقطه  $i$ ام،  $Q_i^{obsav}$  برابر میانگین مشاهداتی و  $n$  = تعداد داده‌ها می‌باشد. ضریب تبیین بین صفر تا یک تغییر می‌کند و مقدار بهینه آن یک است و این حالت مربوط به زمانی است که در آن مقادیر شبیه سازی شده دقیقاً مشابه مقادیر مشاهداتی باشد.

در نهایت ساختاری که دارای کمترین خطا بود به‌عنوان ساختار بهینه انتخاب شد. بعد از آن خروجی ساختار بهینه شبکه به صورت یک ماتریس و در محدوده ۰ تا ۱ ارائه شد. سپس این ماتریس در محیط GIS با توجه به ارزش‌های مدل‌سازی شده به نقشه رستری ناهمواری‌های کارستی تبدیل شد. در نهایت ارزیابی نقشه تهیه شده در مرحله آزمایش، توسط ۳۰ درصد داده که در مرحله آموزش مورد استفاده قرار نگرفتند، صورت گرفت.

### ۳. نتایج

در این تحقیق ابتدا نقشه شاخص‌های ژئومورفومتری تهیه شدند که شکل‌های ۷ تا ۸، نقشه دو شاخص موقعیت توپوگرافی و شاخص زبری توپوگرافی را به‌عنوان نمونه نشان می‌دهند.

سادگی و کاربرد آن در بیشتر تحقیق‌های مبتنی بر شبکه عصبی مصنوعی مطابق رابطه ۱ استفاده شد [۸، ۱۳].

$$f(net_{pi}) = \frac{1}{1 + e^{-net_{pi}}} \quad \text{رابطه ۱}$$

### ۳.۲. تعیین ساختار بهینه شبکه عصبی مصنوعی

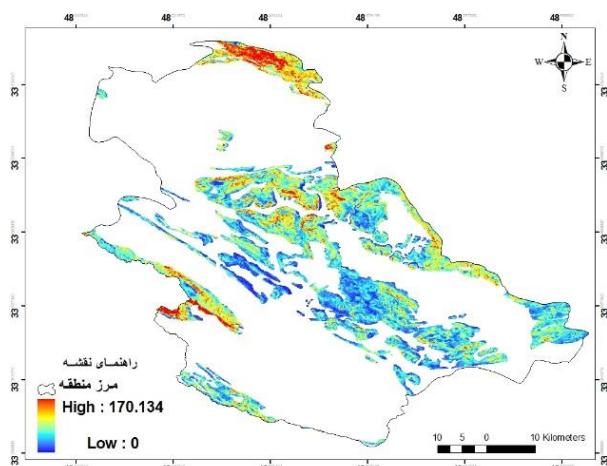
برای انتخاب ساختار بهینه شبکه عصبی مصنوعی و طبقه‌بندی ناهمواری‌های کارستی تعداد نرون لایه میانی از ۱ تا ۲۵ و ضریب یادگیری ۰/۱ در نظر گرفته شد. در هر مرحله ریشه میانگین مربعات خطا و ضریب تبیین<sup>۲</sup> مطابق رابطه ۲ و ۳ محاسبه گردید.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Q_i^{sim} - Q_i^{obs})^2} \quad \text{رابطه ۲}$$

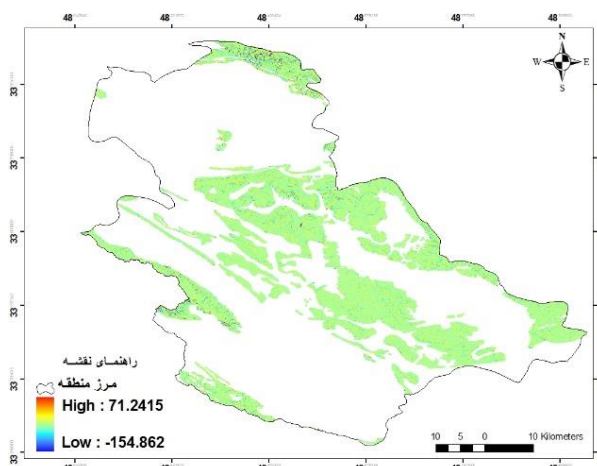
مقدار ریشه میانگین مربعات خطا بین صفر تا بینهایت متغیر است و مقدار بهینه آن صفر می‌باشد. بنابراین بهترین شبیه‌سازی مربوط به شبیه‌سازی با حداقل مقدار RMSE می‌باشد [۱۸].

$$R^2 = \frac{\left[ \sum_{i=1}^n (Q_i^{sim} - Q_i^{simav})(Q_i^{obs} - Q_i^{obsav}) \right]^2}{\sum_{i=1}^n (Q_i^{sim} - Q_i^{simav})^2 \sum_{i=1}^n (Q_i^{obs} - Q_i^{obsav})^2} \quad \text{رابطه ۳}$$

که در آن:  $Q_i^{sim}$  = مقدار برآوردی بر نقطه  $i$ ام،




شکل ۸. شاخص ژئومرفومتریک زبری توپوگرافی




شکل ۷. شاخص ژئومرفومتریک موقعیت توپوگرافی

این تحقیق نشان می‌دهند.


شکل‌های ۹ تا ۳۰ تغییرات عددی شاخص‌های ژئومرفومتریک را در محل ناهمواری‌های تعیین شده در




شکل ۱۰. نمودار تغییرات تانژانت انحنای در لندفرم‌های مختلف



شکل ۹. نمودار تغییرات شاخص زبری توپوگرافی در لندفرم‌های مختلف




شکل ۱۲. نمودار تغییرات انحنای طول در لندفرم‌های مختلف




شکل ۱۱. نمودار تغییرات انحنای متقاطع در لندفرم‌های مختلف







شکل ۱۴. نمودار تغییرات انحنای طرح در لندفرم‌های مختلف




شکل ۱۳. نمودار تغییرات انحنای عمومی در لندفرم‌های مختلف




شکل ۱۶. نمودار تغییرات انحنای مقطع در لندفرم‌های مختلف




شکل ۱۵. نمودار تغییرات نسبت سطح در لندفرم‌های مختلف



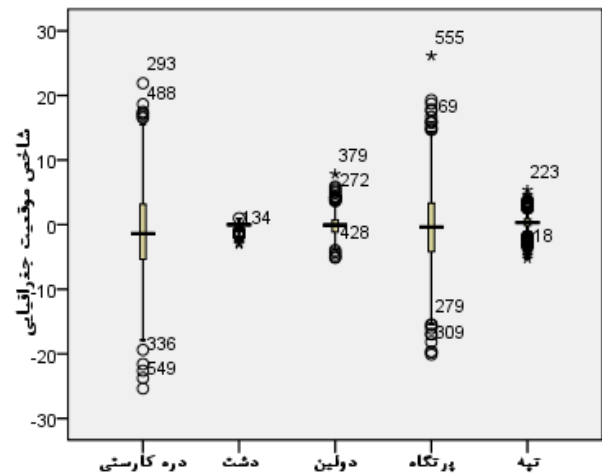
شکل ۱۸. نمودار تغییرات شیب در لندفرم‌های مختلف



شکل ۱۷. نمودار تغییرات مساحت سطح در لندفرم‌های مختلف



شکل ۲۰. نمودار تغییرات انحنای کل در لندفرم‌های مختلف



شکل ۱۹. نمودار تغییرات شاخص موقعیت توپوگرافی در لندفرم‌های مختلف

نتایج شکل ۲۱ و جدول ۱ نشان می‌دهد که مقدار خطا با ضریب یادگیری ۰/۱ و تعداد ۹ نرون در لایه میانی به کمترین مقدار در مرحله آزمایش رسیده است. لذا با توجه به نتایج فوق، مدل شبکه عصبی مصنوعی تهیه شده با ضریب یادگیری ۰/۱ و تعداد ۹ نرون در لایه میانی، به‌عنوان مدل بهینه شبکه عصبی مصنوعی (دارای کمترین خطا و بهترین جواب) انتخاب شد و ناهمواری‌های کارستی کل منطقه مورد مطالعه (دولین، دشت، دره کارستی، تپه و پرتگاه) با این مدل طبقه‌بندی گردید.

### ۳،۳. ضریب تبیین در شبکه عصبی مصنوعی

برای تعیین درجه همبستگی مرحله آموزش، صحت سنجی و آزمایش، جواب‌های به‌دست آمده از خروجی شبکه با داده‌های شاهد موجود مقایسه شدند. ضریب تبیین که بین خروجی شبکه و داده‌های شاهد به‌دست آمد، بیانگر همبستگی بالای بین داده‌های شاهد با داده‌های خروجی از شبکه بود که در جدول ۱ نشان داده شده است. ضریب تبیین در مجموع برای مرحله آموزش، صحت سنجی و آزمایش برای مدل بهینه برابر ۸۷/۱۸ درصد و بهترین خطی که بین این دو سری داده‌ها می‌توان رسم کرد مطابق با رابطه ۴ است.

$$y = 0.9958X + 0.006 \quad \text{رابطه ۴}$$


نتایج شکل‌های ۹ تا ۲۰ دامنه تغییرات شاخص‌های مختلف ژئومورفومتریک مورد بررسی در این تحقیق را نشان می‌دهند. همان‌طوری که در این نمودارها مشخص است به وضوح می‌توان تغییرات این شاخص‌ها را بر روی ناهمواری‌های دشت، دولین، تپه، پرتگاه و دره کارستی مشاهده کرد. این تغییرات در برخی از شاخص‌ها برای ناهمواری‌های پرتگاه، تپه و دره کارستی بسیار نمایان بوده ولی در دشت و دولین کمی دارای همپوشانی هستند.

### ۱،۳. تعداد تکرار بهینه

به‌طور معمول با افزایش تعداد تکرار خطای مرحله آموزش کم می‌شود ولی خطای آزمایش تا حدی از تعداد تکرار کم می‌شود و بعد از آن دوباره خطا زیاد می‌شود. در این تحقیق در مدل انتخابی بهینه، خطای مرحله آموزش ابتدا تا تعداد تکرار ۱۱۰ کاهش یافت ولی بعد از آن خطا شروع به افزایش گذاشت. در نتیجه تعداد تکرار بهینه ۱۱۰ با ریشه میانگین مربعات خطای مرحله آموزش، صحت سنجی و آزمایش به ترتیب ۰/۰۵۶، ۰/۰۵۱۹ و ۰/۰۵۴۳ انتخاب شد.

### ۲،۳. ساختار بهینه شبکه عصبی مصنوعی

نتایج تعیین ساختار بهینه شبکه عصبی مصنوعی در جدول ۱ و شکل ۲۱ مشاهده کرد.



شکل ۲۱. منحنی کمترین خطای شبکه (RMSE) در تعداد نرون‌های میانی مختلف

جدول ۱. نتایج تکرارها برای تعیین مدل بهینه در شبکه عصبی مصنوعی

کل شبکه	آموزش		صحت سنجی		آزمایش		
	R <sup>2</sup>	RMSE	R <sup>2</sup>	RMSE	R <sup>2</sup>	RMSE	
۱-۱-۱۲	۷۹/۲۴	۷۴/۱۸	۰/۰۷۴۲	۷۲/۱۱	۰/۰۷۱۴	۸۳/۱۸	۰/۰۷۳۱
۱-۲-۱۲	۸۳/۳۲	۷۲/۷۱	۰/۰۸۰۱	۷۴/۷۶	۰/۰۷۸۳	۸۹/۹۲	۰/۰۷۳۴
۱-۳-۱۲	۸۸/۵۶	۸۰/۳۱	۰/۰۷	۸۰/۳	۰/۰۷۳۲	۹۳/۸۲	۰/۰۷
۱-۴-۱۲	۸۸/۷۷	۷۸/۸۹	۰/۰۷۲۱	۸۲/۸۷	۰/۰۶۷۴	۹۳/۸۷	۰/۰۶۸۷
۱-۵-۱۲	۷۴/۰۱	۶۴/۳	۰/۰۷۰۶	۷۳/۶	۰/۰۶۷۲	۷۷/۴۱	۰/۰۶۸۲
۱-۶-۱۲	۸۰/۵۹	۷۴/۶۴	۰/۰۷۴۱	۷۰/۷۱	۰/۰۶۹۷	۸۶/۴۲	۰/۰۶۷۱
۱-۷-۱۲	۸۷/۶	۸۴/۴۲	۰/۰۶۲	۸۱/۸۶	۰/۰۵۹	۹۰/۸۳	۰/۰۵۲۹
۱-۸-۱۲	۸۵/۳۱	۸۷/۴۷	۰/۰۶۲۴	۷۴/۷۱	۰/۰۶۳۴	۹۱/۳۲	۰/۰۵۹۲
۱-۹-۱۲	۸۷/۱۸	۷۸/۰۳	۰/۰۵۴۳۴	۸۱/۸۸	۰/۰۵۶۹۱	۹۲/۳۴	۰/۰۵۶۰۱
۱-۱۰-۱۲	۸۶	۷۸/۱۹	۰/۰۵۶۳	۸۱/۱۸	۰/۰۶۲۶	۹۱/۷۲	۰/۰۵۶۴
۱-۱۱-۱۲	۸۱/۷۱	۷۷/۶۵	۰/۰۶۹۸	۷۴/۳۹	۰/۰۶۶۱	۸۵/۹۴	۰/۰۶۱۹
۱-۱۲-۱۲	۸۹/۷۵	۸۴/۸۷	۰/۰۷۶۷	۷۶/۴۶	۰/۰۶۸۷	۹۶/۴۸	۰/۰۶۳۹
۱-۱۳-۱۲	۸۶/۴۶	۸۱/۳۳	۰/۰۷۵۶	۷۵/۰۴	۰/۰۶۵۱	۹۲/۴۴	۰/۰۶۲۴
۱-۱۴-۱۲	۸۷/۵۵	۸۱/۷۹	۰/۰۶۴۴	۷۹/۹۷	۰/۰۶۴	۹۲/۱۸	۰/۰۵۸۲
۱-۱۵-۱۲	۸۶/۹۴	۷۲/۶۸	۰/۰۶۴۳	۷۹/۰۶	۰/۰۶۱۹	۹۴/۸۵	۰/۰۵۵
۱-۱۶-۱۲	۸۲/۵	۶۸/۵۲	۰/۰۶۸۷	۷۶/۲۳	۰/۰۶۸۹	۸۹/۵۴	۰/۰۶۷
۱-۱۷-۱۲	۸۲/۱۱	۷۲/۲۳	۰/۰۶۵۷	۷۶/۴۴	۰/۰۶۶۸	۷۶/۴۴	۰/۰۵۹۹
۱-۱۸-۱۲	۸۴/۹۵	۷۶/۱۶	۰/۰۷۹۷	۷۵/۶۹	۰/۰۵۹	۹۲/۰۸	۰/۰۵۱۹
۱-۱۹-۱۲	۸۷/۵۱	۷۶/۷۳	۰/۰۷۰۹	۷۶/۴۷	۰/۰۶۵۱	۹۵/۱	۰/۰۵۰۹
۱-۲۰-۱۲	۸۹/۸۸	۷۷/۲۸	۰/۰۶۸۱	۸۰/۶۶	۰/۰۷۱۳	۹۷/۶۷	۰/۰۶۳۳
۱-۲۱-۱۲	۸۴/۰۴	۷۴/۴۴	۰/۰۶۴۴	۷۷/۸۴	۰/۰۶۵۱	۸۹/۷۴	۰/۰۵۲۱
۱-۲۲-۱۲	۸۷/۹۷	۷۶/۸۵	۰/۰۶۲۷	۷۴/۸۴	۰/۰۵۸۱	۹۷/۶۰۳	۰/۰۵۴۵
۱-۲۳-۱۲	۹۰/۰۳	۷۹/۳۵	۰/۰۶۸۷	۷۴/۶۴	۰/۰۷۰۶	۹۹/۶۳	۰/۰۶۸۴
۱-۲۴-۱۲	۷۹/۲۳	۶۸/۶۷	۰/۰۷۰۸	۷۸/۰۳	۰/۰۷۰۴	۸۳/۲۶	۰/۰۷۰۲
۱-۲۵-۱۲	۸۶/۳۲	۷۸/۲۹	۰/۰۶۸۳	۸۳/۵۱	۰/۰۶۱۴	۸۹/۹۴	۰/۰۵۲۰۵

ضرب شود. نتایج جدول ۲ نشان می‌دهد که دقت مدل بهینه شبکه عصبی مصنوعی در مرحله آزمایش برابر ۹۰/۵۸ درصد بوده است. در بخش دیگر نتایج این جدول مشخص شد که شبکه عصبی مصنوعی در تعیین پیکس‌های ناهمواری‌های دولین و پرتگاه به ترتیب با دقت ۹۷/۵۶ و ۸۰/۷۸ درصد دارای بیشترین و کمترین دقت بوده است.

### ۴.۳. دقت شبکه عصبی مصنوعی<sup>۱</sup>

برای تعیین درصد دقت شبکه عصبی مصنوعی در طبقه‌بندی ناهمواری‌های کارستی، بایستی مطابق جدول ۲ تعداد پیکسل‌های که در مرحله آزمایش شبکه به درستی توانسته نوع ناهمواری کارستی را تشخیص دهد، مشخص و بر کل پیکسل‌ها تقسیم و در نهایت در ۱۰۰

جدول ۲. مقادیر مربوط به عملکرد شبکه در مرحله آزمایش برای تشخیص جواب‌های درست

ناهمواری	تعداد کل	پیکسل‌های که به درستی پیش‌بینی شده‌اند	پیکسل‌هایی که به درستی پیش‌بینی نشده‌اند	دقت شبکه (درصد)
دولین	۲۸۷	۲۸۰	۷	۹۷/۵۶
تپه	۲۲۲	۱۹۸	۲۴	۸۹/۱۸
دشت	۲۸۹	۲۶۴	۲۵	۹۱/۳۴
پرتگاه	۳۰۷	۲۴۸	۵۹	۸۰/۷۸
دره کارستی	۳۱۹	۲۹۸	۲۱	۹۳/۴۱
تمام ناهمواری‌ها	۱۴۲۴	۱۲۹۰	۱۳۴	۹۰/۵۸

پیکسل مقدار عددی بین ۰ و ۱ تعیین کرد. با دسته‌بندی مقادیر به دست آمده از شبکه و انتقال این مقادیر به نرم‌افزار GIS، می‌توان منطقه را به نواحی متفاوتی از نظر نوع لندفرم تقسیم‌بندی کرد. شکل ۲۳ نقشه طبقه‌بندی ناهمواری‌های کارستی با استفاده از نتایج به دست آمده از شبکه عصبی مصنوعی می‌باشد. شایان ذکر است که این نتیجه در تعداد مختلف نرون در لایه پنهان دارای کمترین خطا (RMSE) می‌باشد. نتایج به دست آمده از طبقه‌بندی ناهمواری‌های کارستی مطابق شکل ۲۲ حاکی از آن است که ۳۴ درصد دره، ۶/۹ درصد در دشت، ۱/۰۷ درصد دولین، ۴۸/۵ درصد پرتگاه و ۹/۵۱ درصد تپه می‌باشد.

### ۵.۳. تهیه نقشه نهایی طبقه‌بندی ناهمواری‌های

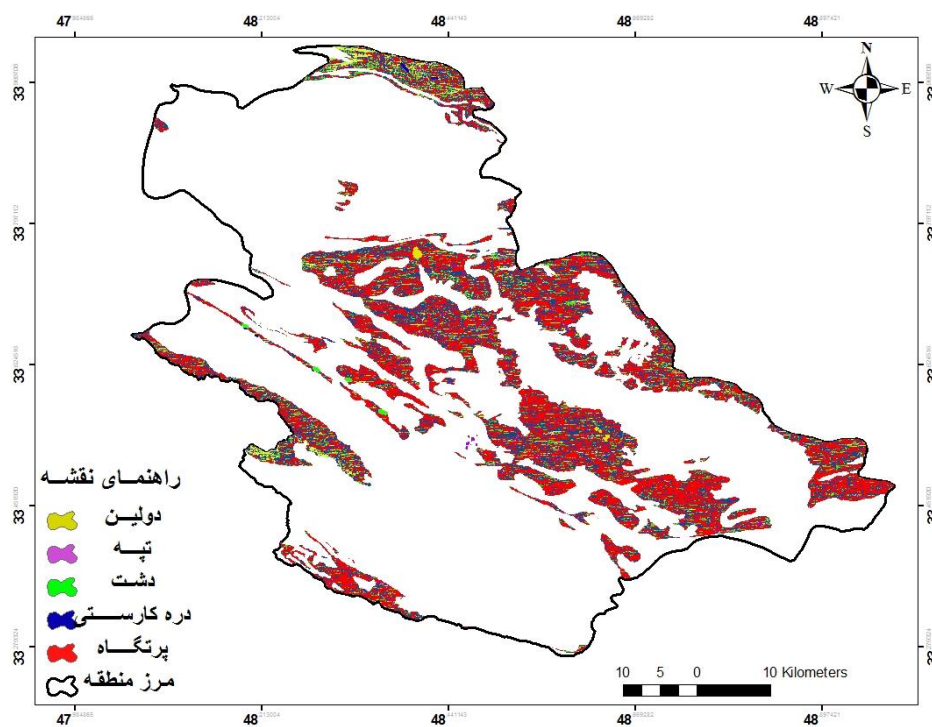
#### کارستی منطقه مورد مطالعه

با توجه به مواردی که آورده شد بعد از مشخص کردن ساختار اصلی شبکه عصبی و فراهم آوردن اطلاعات مورد نظر برای آموزش شبکه عصبی مصنوعی و همچنین رسیدن به خطای قابل قبول، شبکه آماده شد تا تحلیل مناطقی را که قبلاً با آن‌ها مواجه نشده است را انجام دهد. به این منظور با در دست داشتن وزن‌های مرحله پایانی مربوط به آموزش شبکه (ضریب یادگیری ۰/۱ با ۹ نرون در لایه پنهان)، داده‌های کل منطقه در اختیار شبکه قرار گرفت. بعد از انجام این مرحله شبکه عصبی برای هر

<sup>۱</sup>Accuracy of Artificial Neural Network



شکل ۲۲. درصد مساحت ناهمواری‌های کارستی



شکل ۲۳. نقشه طبقه‌بندی ناهمواری‌های کارستی با مدل بهینه شبکه عصبی مصنوعی

#### ۴. بحث و نتیجه‌گیری

مطالعه با توجه به وجود سازندهای آهکی و با توجه به شرایط مناسب کارست شدگی، منجر به وجود آمدن ناهمواری‌های کارستی (دولین، تپه، دره کارستی،...) شده است.

کارستی شدن اغلب در سنگ‌های کربناته همانند آهک و دولومیت و به‌طور کمتر در سنگ‌های سولفاته همانند ژپس و انیدریت رخ می‌دهد [۵]. در منطقه مورد

ناهمواری‌های کارستی می‌باشد. علاوه بر این مدل بهینه شبکه عصبی مصنوعی (ساختار ۱-۹-۱۲) در تعیین ناهمواری‌های دولین و پرتگاه، به ترتیب دارای بیشترین و کمترین دقت بود. دقت شبکه عصبی مصنوعی در تحقیقات مختلف متفاوت می‌باشد، به عنوان [۱۸] با دقت ۹۲/۳ در صد به بهترین جواب رسیدند و [۳۶] مدل بهینه شبکه عصبی تحقیق‌شان دارای دقت ۸۸/۱۳ در صد بود. این نتایج نشان می‌دهد که از شبکه عصبی مصنوعی می‌توان به عنوان یک روش جدید برای طبقه‌بندی و شناسایی ناهمواری‌های کارستی، از جمله دولین، تپه، دره کارستی، ... استفاده کرد. علاوه بر این نتایج کمی‌سازی شاخص‌های ژئومورفومتری برای تفکیک ناهمواری‌های دولین، دشت، دره کارستی، پرتگاه و تپه با استفاده از نمودارهای جعبه‌ای نشان داد که این شاخص‌ها توانایی تفکیک این ناهمواری‌ها را دارند ولی بهتر است که برای جداسازی و تشخیص بهتر، این شاخص‌ها با هم مورد بررسی قرار گیرند تا تفکیک بهتری از ناهمواری‌ها مشاهده شود، نتایج این بخش با نتایج [۳۱] همخوانی دارد.

در مورد شناسایی ناهمواری‌های کارستی، مدیریت بهره‌برداری منابع آب کارست و جاذبه‌های توریستی آنها تحقیقاتی انجام نشده است. مطالعه کارست از دیدگاه کاربردی دارای اهمیت فراوانی، به ویژه در ارتباط با منابع آب زیرزمینی است. لذا در این تحقیق به شناسایی و طبقه‌بندی ناهمواری‌های کارستی با استفاده از شاخص‌های ژئومورفومتری و شبکه عصبی مصنوعی پرداخته شد و توصیه می‌شود که مطالعات بیشتری در زمینه ناهمواری‌های کارستی، به منظور بررسی قابلیت‌های مختلف این پارامترها در مطالعات ژئومورفولوژی صورت گیرد. بر همین اساس پیشنهاد می‌شود در بررسی‌های آینده طبقه‌بندی ناهمواری‌های کارستی از شاخص‌های دیگر از جمله هیدروژئولوژی و فراوانی چشمه‌ها نیز بهره‌گیری شود.

نتایج به دست آمده از روش شبکه عصبی مصنوعی برای طبقه‌بندی حاکی از این بود که تعداد تکرار مناسب برای جلوگیری از خطر بیش آموزش و پیش‌بینی با کمترین خطا ۱۱۰ تکرار به دست آمد که در تحقیق‌های مختلف با توجه به ماهیت آن، تعداد تکرار مناسب متفاوت می‌باشد. در این تحقیق ۲۵ مورد آزمایشی برای رسیدن به بهترین ساختار شبکه عصبی مصنوعی موجود بود. تعداد نرون در لایه پنهان در این تحقیق با روش سعی و خطا مشخص شد که در نهایت شبکه با ۹ نرون با ریشه میانگین مربعات خطای ۰/۰۵۴۳۴ و ضریب تبیین ۸۷/۱۸ درصد در مرحله آزمایش بهترین جواب را تولید کرد. تعداد نرون در لایه پنهان چون با سعی و خطا انتخاب می‌شود در نتیجه در تحقیقات مختلف، متفاوت است. [۱۸] با ۱۴ نرون در لایه پنهان و ضریب تبیین ۹۶/۲ در صد، [۸] با ۲۴ نرون و ضریب تبیین ۹۹/۸ در صد، [۷] با ۶ نرون در لایه پنهان و ضریب تبیین ۹۰ در صد، [۱۱] با ۳ نرون در لایه پنهان و ضریب تبیین ۹۲ در صد و [۶] با ۷ نرون در لایه پنهان به بهترین جواب دست یافتند. در نهایت ساختار ۱-۹-۱۲ (۱۲ نرون در لایه ورودی شامل ۱۲ شاخص ژئومتری، ۹ نرون در لایه پنهان و ۱ نرون در لایه خروجی) با ضریب یادگیری ۰/۱ به عنوان ساختار بهینه برای طبقه‌بندی ناهمواری‌های کارستی در منطقه مورد مطالعه انتخاب شد. در نهایت با توجه به میزان مقدار پیش‌بینی شده شبکه برای هر پیکسل برای هر نوع ناهمواری، مشخص شد که ۳۴ در صد دره، ۶/۹ در صد در دشت، ۱/۰۷ در صد دولین، ۴۸/۵ درصد پرتگاه و ۹/۵۱ درصد تپه می‌باشد. این نتایج نشان دهنده کوهستانی منطقه می‌باشد.

بر اساس نتایج مدل بهینه شبکه عصبی مصنوعی، ۹۰/۵۸ درصد از نقاط ناهمواری مشاهده شده در بررسی میدانی، بر اساس پیش‌بینی و طبقه‌بندی در مرحله آزمایش به درستی پیش‌بینی شدند که این مورد هم بیانگر دقت بالای شبکه عصبی مصنوعی برای طبقه‌بندی



## References

- [1] Babu, G.P. (1997). Self-organizing neural networks for spatial data. *Patt. Recogn. Lett*, 18, 133–142.
- [2] Benjamini, Y., (1988). Opening the Box of a Boxplot, *The American Statistician*, 42(4), 257-262.
- [3] Bishop, M.P., James, L.A., Shroder, J.F., and Walsh, S.J., (2012). Geospatial technologies and digital geomorphological mapping: concepts, issues and research. *Geomorphology*, 137, 5–26.
- [4] Bruffaerts C., Verardi V., and Vermandele C., (2014). A generalized boxplot for skewed and heavy-tailed distributions, *Statistics and Probability Letters*, 95, 110–117.
- [5] Calaforra J.M., and Bosch P.A., (2003). Evolution of the gypsum karst of Sorbas (SE Spain), *Geomorphology*, 50(1-3), 173–180.
- [6] Caniani D., Pascale S., Sdao F. and Sole A., (2008). Neural networks and landslide susceptibility: a case study of the urban area of Potenza, *Natural Hazards*, 45, 55–72.
- [7] Grip H., Ohberg F., Wiklund U., Sterner Y., Karlsson J.S., and Gerdle B., (2003). Classification of Neck Movement Patterns Related to Whiplash-Associated Disorders Using Neural Networks, *IEEE transactions on information technology in biomedicine*, 7(4), 412 - 418.
- [8] Hejmanowski R., and Witkowski W.T., (2015). Suitability assessment of artificial neural network to approximate surface subsidence due to rock mass drainage, *journal of sustainable mining*, 14, 101-107.
- [9] Hengl, T., and Reuter, H.I., (2009). *Geomorphometry: concepts, software, applications*. Developments in Soil Science, 33. Elsevier, Amsterdam.
- [10] Jakson, A.B.V., (2004). *Introduction to Neural Networks*, Mahmoud Alborzi, 2ed Edition, Sharif University, 137 p. (In Persian).
- [11] Lee A., Kim S.E., and Suh K.D., (2015). Estimation of Stability Number of Rock Armor Using Artificial Neural Network Combined with Principal Component Analysis, *Procedia Engineering*, 116, 149 – 154.
- [12] Lee S., Ryu J. H., Lee M. J. and Won J. S., (2003). Use of an artificial neural network for analysis of the susceptibility to landslides at Boun, Korea, *Environmental Geology*, 44, 820–833.
- [13] Lee S., Ryu J. H., Lee M. J. and Won J. S., (2006). The Application of artificial neural networks to landslide susceptibility mapping at Janghung, Korea, *Mathematical Geology*, 38(2), 199-220.
- [14] Liu, M., Hu, Y., Chang, Y., He, X., and Zhang, W., (2009). Land use and land cover change analysis and prediction in the upper reaches of the Minjiang River, China. *Environmental Management* 43, 899–907.
- [15] McGarigal, K., Tagil, S., and Cushman, S., (2009). Surface metrics: an alternative to patch metrics for the quantification of landscape structure. *Landscape Ecology* 24, 433–450.
- [16] Mokarram M., and Seif A., (2014). GIS-Based Automated Landform Classification in Zagros Mountain, *Bull. Env. Pharmacol. Life Sci.*, 3 (3), 20-32.
- [17] Moradi, H.R., Sepah Vand, A.R., and Abdolmaleki, P., (2012). Assessment the Effect of Input Factors Number in Accuracy of Artificial Neural of Network for Landslide Hazard Zonation, *Journal of Range and Watershed Management, Iranian Journal of Natural Resources*, 65(2), 231-243. (In Persian).
- [18] Moradi, H.R., Sepah Vand, A.R., and Abdolmaleki, P., (2014). Landslide Hazard Mapping Using the Artificial Neural Network a Part of Haraz Watershed, *Pajouhesh and Sazandegi*, 104, 1-14. (In Persian).
- [19] Pavlopoulos K., Evelpidou N., and Vassilopoulos A., (2009). *Mapping Geomorphological environments*, Springer-Verlag Berlin.
- [20] Pike R.J., (2000). Geomorphometry—diversity in quantitative surface analysis, *Progress in Physical Geography*, 24 (1), 1–20.
- [21] Pike, R.J., Evans, I., and Hengl, T., (2008). *Geomorphometry: A Brief Guide*. In: *Geomorphometry-Concepts, Software, Applications*, Hengl, T. and Hannes I. Reuter (eds.), Series Developments in Soil Science, Elsevier, 33, 3-33.

- [22] Rasemann, S., Schmidt, J., Schrott, L., and Dikau, R., (2004). Geomorphometry in mountain terrain. In: Bishop, M.P., Shroder, J.F. (Eds.), GIS & Mountain Geomorphology. Springer, Berlin, 101–145.
- [23] Reu J.D., Bourgeois J., Bats M., Zwertvaegher A., Gelorini V., Smedt P.D., Chu W., Antrop M., Maeyer P. D., Finke P., Meirvenne M. V., Verniers J., and Crombé P., (2013). Application of the Topographic Position Index to heterogeneous landscapes, *Geomorphology*, 186, 39–49.
- [24] Rosa J.M., (2012). Karst Landform Classification Techniques, *Geomorphological Techniques*, 3, 1-15.
- [25] Saravanan K., and Sasithra S., (2014). Review on classification based on Artificial Neural Networks, *International Journal of Ambient Systems and Applications (IJASA)*, 2(4), 1-8.
- [26] Seif A., (2014). Using Topography Position Index for Landform Classification, *Bulletin of Environment, Pharmacology and Life Sciences*, 3 (11): 33-39.
- [27] Serpico S.B., and Roli F., (1995). Classification of multisensor remote-sensing images by structured neural networks. *IEEE Trans. Geosci. Rem. Sens*, 33, 562–578.
- [28] Shayan, S., Yamani, M., Faraj Zadeh Asl, M., and Ahmad Abadi, A., (2012). Supervised landform classification using the parameters Geomorphometric in arid regions, *Iranian Journal of Remote Sensing and GIS*, 4(2(Successive 14)), 19-30. (In Persian).
- [29] Stokes T., Griffiths P., Ramsey C., (2010). *Karst Geomorphology, Hydrology and Management*,
- [30] Tagil S., and Jenness J., (2008). GIS-based automated landform classification and Topographic, Land cover and Geologic attributes of landforms around the Yazoren Polje, Turkey, *Journal of Applied Sciences*, 8(6), 910-921.
- [31] Tazeh, M., (2014). Assessment the Geomorphometry parameters in the separation of alluvial fans in desert areas, *Desert Ecosystem Engineering Journal*, 3(5), 1-8. (In Persian).
- [32] Trevisani S., Cavalli M., and Marchi L., (2012). Surface texture analysis of a high-resolution DTM: Interpreting an alpine basin, *Geomorphology*, (161–162), 26–39.
- [33] Verbeke L.P.C.; Vancoillie F.M.B., and Wulf D.R.R., (2004). Reusing back-propagation artificial neural networks for land cover classification in tropical savannahs. *Int. J. Remote Sens*, 25, 2747–2771.
- [34] Wang Y.G., and Li H.P., (2010). Remote sensing image classification based on artificial neural network “, *International Conference on Computer, Mechatronics, Control and Electronic Engineering (CMCE)*, 1(2), 17-20.
- [35] Wilson, J.P., (2012). Digital terrain modeling, *Geomorphology*, 137: 107–121.
- [36] Yuan H., Cynthia F., Wiele C., and Khorram S., (2009). An Automated Artificial Neural Network System for Land Use/Land Cover Classification from Landsat TM Imagery, *Remote Sens*, 1, 243-265.
- [37] Zhang G.P., (2000). Neural Networks for Classification: A Survey *IEEE transactions on systems, man, and cybernetics*, 30(4), 451 - 462.