



مقایسه روش‌های شبکه عصبی مصنوعی، ماشین بردار پشتیبان و شیء‌گرا در استخراج

کاربری و پوشش اراضی از تصاویر لندست ۸

فروش اسلمی^۱، اردوان قربانی^{۲*}، بهروز سبحانی^۳، محسن پناهنده^۴

۱. دانش‌آموخته کارشناسی ارشد سجش از دور و GIS، دانشگاه محقق اردبیلی
۲. دانشیار دانشکده فناوری کشاورزی و منابع طبیعی، دانشگاه محقق اردبیلی
۳. دانشیار دانشکده علوم انسانی، دانشگاه محقق اردبیلی
۴. کارشناس ارشد جغرافیا، سازمان فضایی ایران

مشخصات مقاله

پیشینه مقاله:
 دریافت: ۳ آذر ۱۳۹۳
 پذیرش: ۹ خرداد ۱۳۹۴
 دسترسی اینترنتی: ۲۵ آذر ۱۳۹۴

واژه‌های کلیدی:

سجش از دور
 کاربری / پوشش اراضی
 شبکه عصبی مصنوعی
 ماشین بردار پشتیبان
 شیء‌گرا
 استان اردبیل

چکیده

تهیه نقشه کاربری/پوشش اراضی، برای برنامه‌ریزی و مدیریت مکانی ضروری است. امروزه تصاویر ماهواره‌ای و تکنیک‌های سجش از دور، به دلیل فراهم آوردن داده‌های بهنگام و قابلیت بالای آنالیز تصاویر، کاربرد گسترده‌ای در تمامی بخش‌ها از جمله بخش‌های کشاورزی و منابع طبیعی دارند. در پژوهش حاضر طبقه‌بندی کننده‌های شبکه عصبی مصنوعی، ماشین بردار پشتیبان و شیء‌گرا جهت تهیه نقشه کاربری/پوشش اراضی شهرستان‌های اردبیل، نیر و نمین مورد ارزیابی قرار گرفت. تصویر سنجنده Operational Land Imager (OLI) لندست ۸ (سال ۲۰۱۳) پس از تصحیحات هندسی و توپوگرافیکی تحت این الگوریتم‌ها قرار گرفته و به ۹ طبقه کاربری و پوشش اراضی شامل پهنه‌های آبی، زراعت آبی، زراعت دیم، چمنزار، برونزدگی سنگی، جنگل، مرتع، عرصه‌های مسکونی و انسان-ساخت و فرودگاه طبقه‌بندی شد. پس از ارزیابی صحت، صحت کلی برای نقشه حاصل از شبکه عصبی مصنوعی، ماشین بردار پشتیبان و شیء‌گرا به ترتیب برابر با ۸۹/۹۱، ۸۵/۶۸ و ۹۴/۳۷ درصد و مقدار کاپای آن‌ها به ترتیب ۰/۸۸، ۰/۸۲ و ۰/۹۳ برآورد شد که نشان‌دهنده برتری روش شیء‌گرا در مقایسه با دو روش دیگر است. هر سه روش توانستند صحتی قابل قبول برای نقشه‌های کاربری/پوشش اراضی ارائه دهند. در کل، سه روش طبقه‌بندی پیشرفته، در منطقه ناهمگن با تغییرات ارتفاعی بیش از ۳۶۰۰ متر با استفاده از نسل جدید تصاویر سنجنده لندست ۸ آزمون و مناسب‌ترین روش تهیه نقشه کاربری/پوشش اراضی معرفی شد.

*پست الکترونیکی مسئول مکاتبات: a_ghorbani@uma.ac.ir

مقدمه

کاربری و پوشش اراضی توصیف نوع بهره‌برداری انسان برای یک یا چند هدف بر روی یک قطعه زمین است (۵). آگاهی از نوع و درصد کاربری و پوشش‌های مختلف نیازی بنیادی جهت شناخت و مدیریت یک منطقه بوده و از این اطلاعات پایه در ارزیابی منابع، قابلیت اراضی، خاکشناسی، پوشش گیاهی، فرسایش و رسوب، شناخت توان و استعداد اراضی، مرتع‌داری، جنگل‌داری، محیط زیست، آمایش سرزمین و در کل برنامه‌ریزی‌های خرد و کلان استفاده می‌شود (۱، ۲، ۱۵، ۱۸ و ۲۴). چرا که بنیان برنامه‌ریزی مکانی بر پایه کاربری و پوشش‌های اراضی گذشته، حال و آینده استوار بوده و همچنین تغییرات در مرز کاربری و پوشش اراضی توسط بهره‌برداران و تبدیل‌ها و تغییرها همواره موجب نگرانی در بخش‌های مختلف می‌باشد (۱، ۵، ۹ و ۲۴). تهیه یک نقشه کاربری صحیح و دقیق و استفاده از روشی مناسب امروزه تبدیل به موضوعی کلیدی شده و اخیراً نیز با توسعه روش‌های جدید طبقه‌بندی تصویر مورد توجه بسیاری از محققان قرار گرفته است (۱۳، ۱۷ و ۲۴). طبقه‌بندی تصویر رایج‌ترین روش کاربردی در تهیه نقشه‌های توزیع مکانی کاربری اراضی و پوشش زمین است (۱۹). تاکنون روش‌های طبقه‌بندی بسیاری برای طبقه‌بندی یک تصویر سنجش از دوری توسعه یافته‌اند، که مروری جامع از این روش‌ها در لو و ونگ (۱۷) ارائه شده است. روش‌های طبقه‌بندی نظارت‌شده بر اساس نمونه‌های تعلیمی سطح تصویر، پیکسل‌هایی از آن را که به لحاظ طیفی مشابه هستند با استفاده از روش‌های مختلف آماری طبقه‌بندی می‌کنند. روش‌های شبکه عصبی مصنوعی و ماشین بردار پشتیبان از جمله روش‌های نظارت شده می‌باشند که هر دو تا حد زیادی به نمونه‌های تعلیمی برداشت شده توسط کاربر بستگی دارند. شبکه‌های عصبی مصنوعی عمدتاً به صورت ناپارامتریک توصیف می‌شوند، که باعث می‌شود استفاده از یک شبکه عصبی به مفروضات توزیع آماری داده‌ها نیاز نداشته باشد. گرچه، کاربر باید ساختار شبکه را تعیین کند، و همچنین پارامترهایی نظیر نرخ تعلیم، که بر زمان تعلیم اثر می‌گذارد، و

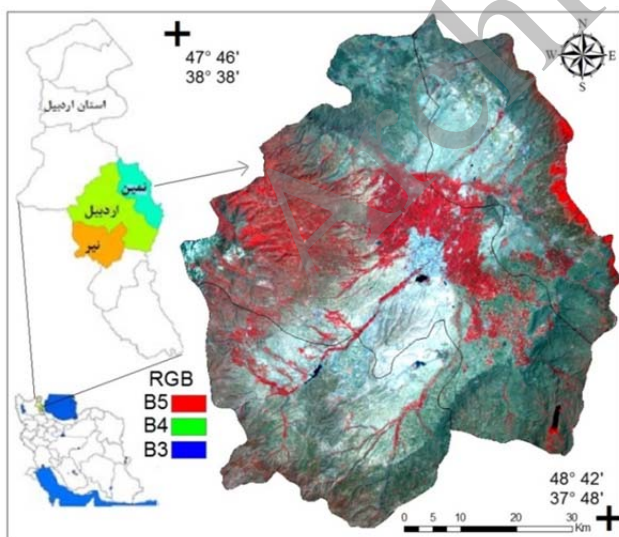
کارایی و میزان همگرایی شبکه عصبی را نیز تعریف کند. هیچ قاعده واضحی برای کمک به طراحی شبکه وجود نداشته، و تنها قواعد ابتکاری برای راهنمایی کاربران در انتخاب پارامترهای شبکه وجود دارد (۲۴). پرسپترون چندلایه‌ای (Multilayer perceptron) با استفاده از الگوریتم آموزشی انتشار بازگشتی (Back propagation) یکی از رایج‌ترین شبکه‌های عصبی مصنوعی است. در الگوریتم انتشار بازگشتی، نیاز است یک یا چند پارامتر توسط کاربر تعریف شود. انتخاب مقدار این پارامترها می‌تواند اثر بسیار مهمی بر کارایی شبکه داشته باشد (۲۴). برآورد گسترده از اثر این انتخاب‌ها بر توانایی شبکه برای طبقه‌بندی الگوهای ناشناخته توسط کاوازولگو (۱۲) انجام گرفته است. جذابیت ماشین‌های بردار پشتیبان یا SVM (Support vector machines) در قابلیت آن‌ها در حداقل کردن ریسک ساختاری، یا خطای طبقه‌بندی، هنگام حل مسئله‌ی طبقه‌بندی است (۲۵). عملکرد هسته‌ای SVMها، ساخت یک ابرصفحه مجزا (یعنی، یک مرز تصمیم‌گیری) بر مبنای خصوصیات نمونه‌های تعلیمی، به ویژه توزیع آن‌ها در فضای ویژگی می‌باشد. این ابرصفحه در معرض شرایطی قرار می‌گیرد که حاشیه تفکیک بین نمونه‌های طبقه +۱ و -۱ حداکثر شود (۲۴). طبقه‌بندی شیء‌گرا فرآیندی است که در آن کلاس‌های پوشش اراضی به اشیاء تصویری ارتباط داده می‌شود. این نوع از طبقه‌بندی بر پایه منطق فازی استوار است و ارزش عوارض را به ارزش فازی یعنی بین صفر تا یک با درجه عضویت معین برای هر کلاس تبدیل می‌کند. پیش از انجام طبقه‌بندی ابتدا سگمنت‌سازی انجام می‌شود. سگمنت گروهی از پیکسل‌های همسایه در داخل یک ناحیه است که شباهت از نظر ارزش عددی و بافت مهمترین معیار مشترک آن‌ها است (۱۲). سگمنت‌سازی مبنای طبقه‌بندی محسوب می‌شود و هر چقدر سگمنت‌سازی با دقت بالاتری انجام گیرد در کیفیت طبقه‌بندی تأثیر خواهد گذاشت. در فرآیند سگمنت‌سازی باید پارامترهای مقیاس، شکل، بافت، ضریب فشردگی در نظر گرفته شود و بر اساس نسبت اهمیت هر یک از این عوامل در خصوصیات کلاس‌های مورد نظر برای

اراضی اول اینکه این بخش از دانش سنجش از دوری با توجه به توسعه روز افزون آن یک تحقیق دامنه‌دار می‌باشد. دوم اینکه هر یک از این روش‌ها با توجه به شرایط منطقه مورد مطالعه، در یک منطقه از کارایی بهتری در مقایسه برخوردار می‌باشند. بنابراین، هدف از این تحقیق مقایسه روش‌های شبکه عصبی مصنوعی پرسپترون چندلایه، ماشین بردار پشتیبان و شیء‌گرا که از روش‌های در حال توسعه سنجش از دوری هستند، بوده تا ابتدا مقایسه کارایی آن‌ها در تهیه نقشه کاربری و پوشش اراضی انجام و سپس مناسب‌ترین روش در تهیه نقشه کاربری و پوشش اراضی با شرایط منطقه با پستی و بلندی زیاد در سطح شهرستان‌های اردبیل، نیر و نمین ارائه گردد.

مواد و روش‌ها

منطقه مورد مطالعه

در پژوهش حاضر شهرستان‌های اردبیل، نیر و نمین مورد مطالعه قرار گرفت. منطقه مورد مطالعه بین $47^{\circ} 46'$ و $47^{\circ} 38'$ تا $48^{\circ} 42'$ و $37^{\circ} 48'$ و طول شرقی و $38^{\circ} 38'$ و $38^{\circ} 38'$ عرض شمالی واقع شده است (شکل ۱).



شکل ۱. موقعیت منطقه مورد مطالعه و تصویر رنگی کاذب

سنجنده OLI لندست ۸

استخراج از تصاویر ماهواره‌ای، نسبت اهمیت آن‌ها را در فرآیند سگمنت‌سازی اعمال گردد. عدد مقیاس بزرگ سگمنت‌های بزرگ و برعکس عدد کوچک سگمنت کوچکی ایجاد خواهد کرد (۳).

بالاسچک (۶) در مروری بر تحقیقات طبقه‌بندی شیء‌گرا، توانایی آن را در استخراج اطلاعات مکانی از داده‌های سنجش از دوری مورد تأکید قرار داده است. ارزیابی روش‌های مختلف تهیه نقشه کاربری اراضی و پوشش زمین دارای اهمیت زیادی است، اینکه از کدام روش برای طبقه‌بندی تصویر و تهیه نقشه کاربری و پوشش اراضی استفاده گردد. تحقیقات قابل توجهی در این ارتباط در دنیا انجام گرفته و در حال انجام می‌باشد، تا با استفاده از رشد و توسعه امکانات سنجش از دوری اعم از تصویر، نرم‌افزار و غیره بتوان مناسب‌ترین روش را در تهیه نقشه کاربری و پوشش اراضی استفاده نمود. یانگ (۲۶) از تصویر ETM^+ (Enhancement Thematic Mapper) در شرق انگلستان برای ارزیابی روش‌های حداکثر احتمال، شبکه عصبی مصنوعی و ماشین بردار پشتیبان استفاده کردند و به ترتیب به صحت‌های $82/9$ ، $85/1$ و $87/9$ درصد برای روش‌های فوق دست یافتند.

لو و همکاران (۱۶) روش‌های حداکثر احتمال و شیء‌گرا را با استفاده از تصاویر TM (Thematic Mapper) برای منطقه آمازون برزیل مقایسه و نتیجه گرفتند که استفاده از روش شیء‌گرا باعث بهبود سه درصدی صحت طبقه‌بندی در مقایسه با الگوریتم حداکثر احتمال شده است.

روستایی و همکاران (۲۱) برای مقایسه روش‌های حداکثر احتمال، شبکه عصبی مصنوعی و شیء‌گرا در تبریز از تصویر ETM^+ استفاده و نتیجه گرفتند که روش شیء‌گرا به روش‌های دیگر برتری دارد.

مظاهری و همکاران (۴) روش‌های حداکثر احتمال، شبکه عصبی مصنوعی و ماشین بردار پشتیبان را در منطقه جیرفت مقایسه و به ترتیب به صحت‌های کلی $96/4$ ، $97/7$ و $84/7$ درصد برای روش‌های فوق دست یافتند. با توجه به مرور منابع و تئوری بحث در تهیه نقشه کاربری و پوشش

پردازش تصویر

پردازش تصویر با استفاده از سه روش طبقه‌بندی شامل: شبکه عصبی مصنوعی، ماشین بردار پشتیبان و شیء‌گرا بر روی تصویر آماده شده به شرح زیر انجام گرفت.

شبکه عصبی مصنوعی

پرسپترون چندلایه‌ای (Multilayer perceptron/MLP) با استفاده از الگوریتم تعلیمی انتشار بازگشتی از رایج‌ترین شبکه‌های عصبی مصنوعی است. بدین صورت که لایه ورودی بر خلاف دیگر لایه‌ها، هیچ محاسباتی را انجام نمی‌دهد. لایه مرکزی، لایه‌ای پنهان که در شبکه‌های پیچیده ممکن است بیشتر از یک لایه پنهان وجود داشته باشد. آخرین لایه سمت راست عصب‌ها، لایه خروجی است، که نتایج طبقه‌بندی را تولید می‌کند (شکل ۲). در پژوهش حاضر جهت استفاده از روش شبکه عصبی مصنوعی و بر اساس گزارش کاوازوگلو (۱۲) و کم بودن طبقات خروجی (۱۰) تنها از یک لایه پنهان استفاده شد. انتشار بازگشتی با دو مرحله انتشار رو به جلو و انتشار رو به عقب، تا زمانی که وضعیت عصبی آن بهتر شود تداوم پیدا کرد. در طول مرحله تعلیمی، هر نمونه در داخل لایه ورودی تغذیه شده، و فعالیت عصب‌ها از لایه ورودی تا لایه خروجی در قالب برخی توابع نگاشت به طور پی در پی بروز شده و وزن گرفتند. برای بروز رسانی این وزن‌ها از رابطه ۲ استفاده شد (۲۴).

$$w_{ji}^{n+1} = w_{ji}^n - \eta \frac{\partial E}{\partial w_{ji}^n} + \xi (w_{ji}^n - w_{ji}^{n-1}) \quad [2]$$

در این رابطه؛ w_{ji}^n بیانگر وزن، η پارامتر نرخ تعلیم و ξ ضریب مومنتوم می‌باشند. جهت تعیین مقدار این پارامترها همان طور که در تسو و ماتر (۲۴) اشاره شده است، تلاش شد تا η خیلی بزرگ انتخاب نشود، تا نتیجه جستجو ضعیف نشود. همچنین در انجام این مرحله مقدار η خیلی کوچک نیز انتخاب نگردید تا مرحله آموزشی شبکه زیاد وقت گیر نباشد (۲۴). بدین صورت که با توجه به کاوازوگلو (۱۲) و آزمون

کل محدوده مورد مطالعه مساحتی در حدود ۴۷۲۵۷۶ هکتار از استان اردبیل را در بر می‌گیرد. کم‌ترین و بیشترین ارتفاع منطقه برابر با ۱۱۵۱ و ۴۸۱۱ متر از سطح دریا می‌باشد، که این اختلاف ارتفاع زیاد بر لزوم تصحیح توپوگرافیکی تصویر ماهواره‌ای تأکید می‌کند.

داده‌های مورد استفاده

در این تحقیق از گذر- ردیف ۳۳/۱۶۷ و ۳۴/۱۶۷ تصاویر ماهواره لندست ۸ سنجنده (OLI) مربوط به ۲۰۱۳/۰۷/۱۹ میلادی (۱۳۹۲/۰۴/۲۸ شمسی) استفاده گردید.

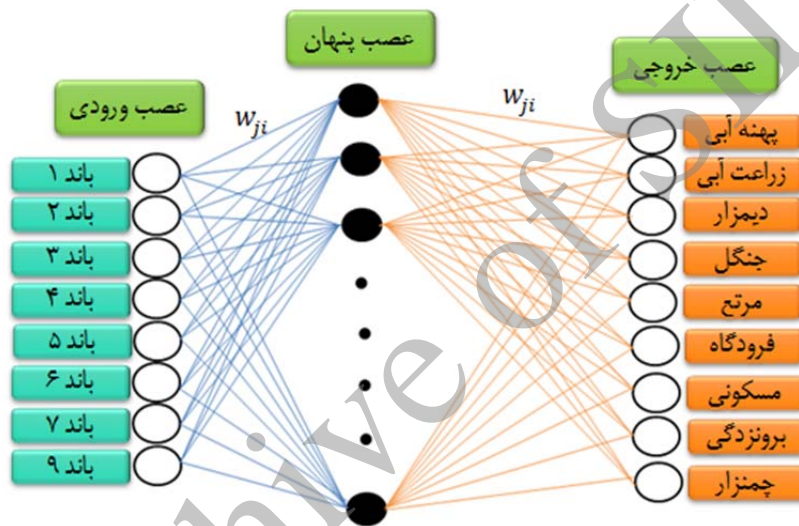
پیش‌پردازش و آماده‌سازی تصویر

طبقه‌بندی کاربری و پوشش اراضی بر اساس تصویر ماهواره‌ای و مقادیر ثبت شده در پیکسل‌ها می‌باشد. ابتدا جهت تصحیح هندسی، با وجود این‌که تصاویر زمین مرجع شده بودند (UTM / WGS84)، ولی با استفاده ۱۶ نقطه کنترل زمینی ثبت شده با GPS Garmin Oregon 550 تصاویر ابتدا کنترل و اصلاح شدند. سپس به دلیل اختلاف ارتفاع زیاد (۳۶۶۰ متر) منطقه مورد مطالعه، نرمال‌سازی توپوگرافیکی با استفاده از روش مینارت (رابطه ۱) و با استفاده از مدل رقومی ارتفاع (DEM) و آزیموت و ارتفاع خورشیدی حاصل از فایل متنی ضمیمه تصاویر انجام شد (۱۱).

$$BV_{\text{normal}\lambda} = \frac{BV_{\text{observed}\lambda} \cos e}{k(\cos i) (\cos e)} \quad [1]$$

که در این رابطه؛ $BV_{\text{normal}\lambda}$ مقادیر روشنایی نرمال‌شده، $BV_{\text{observed}\lambda}$ مقادیر روشنایی مشاهده شده، $\cos i$ کسینوس زاویه برخورد، $\cos e$ کسینوس زاویه شیب و k ثابت مینارت است. بدلیل اینکه منطقه مورد مطالعه در دو فریم تصویر قرار می‌گیرد، پیش از انجام پردازش تصاویر موزاییک شده و برش بر مبنای مرز سه شهرستان انتخاب شده انجام شد (شکل ۲).

نقشه نهایی به ترتیب ۰/۹، ۰/۱، ۰/۵، ۰/۱، ۱ و ۳۰۰۰ بوده است. نودهای ورودی برای طبقه‌بندی پس از نرمالیزه کردن داده‌ها، باندهای تصویر (به جز باندهای حرارتی و پانکروماتیک) و نودهای خروجی ۹ طبقه کاربری و پوشش اراضی (پهنه‌های آبی، عرصه‌های انسان‌ساخت و مسکونی، برونزدگی سنگی، فرودگاه، زراعت آبی، زراعت دیم، جنگل، مرتع و چمنزار) بوده‌اند. در این تحقیق از معماری شبکه عصبی مصنوعی پرسپترون ۳ لایه‌ای با انتشار بازگشتی استفاده شد (شکل ۲).



شکل ۲. معماری شبکه عصبی مصنوعی پرسپترون ۳ لایه‌ای با انتشار بازگشتی

توزیع نمونه‌های تعلیمی گسترش یافته بطوریکه جاسازی یک ابرصفحه خطی را آسان کند. نمونه‌های تعلیمی که در داخل فضایی با بعد بیشتر \mathcal{H} طرح‌ریزی شده‌اند، توسط یک تابع نگاشت بردار غیرخطی، $\Phi: R^d \rightarrow \mathcal{H}$ ، نامیده شدند (۲۴) که معادله آن به صورت رابطه ۳ مورد توجه قرار گرفت.

$$f(x) = \text{sign} \left(\sum_{i=1}^{n_{sv}} \alpha_i y_i \Phi(x) \cdot \Phi(x_i) + b \right) \quad [3]$$

از آن‌جا که واپنیک (۲۵) یک راه دیگر برای کاهش بار محاسباتی توسط یک تابع کرنل مثبت معین که با $K(x,y)$ مشخص می‌شود، پیشنهاد کرده است، به طوری که

خطا از مومتوم بین ۰/۵ تا ۰/۶ برای بروز رسانی وزن‌ها و برای نرخ تعلیمی نیز مقادیری بین ۰/۱ تا ۰/۲ استفاده و در نهایت مقدار ۰/۵ برای مومتوم و ۰/۱ برای نرخ تعلیم انتخاب شد. در مجموع در این روش، از مقادیر مختلف برای پارامترهای شرکت کننده در فرآیند تعلیم استفاده و در نهایت از بین نقشه‌های تولید شده، یک نقشه با بالاترین صحت نهایی انتخاب شد تا با روش‌های دیگر مقایسه شود. مقدار پارامترهای آستانه تعلیم، نرخ تعلیمی، مومتوم تعلیمی، RMS (Root Mean Square) تعلیم، تعداد لایه پنهان و تکرار تعلیم

ماشین بردار پشتیبان

معمولاً تنها می‌توان یک زیرمجموعه از نمونه‌های تعلیمی را بوسیله ابرصفحه به عنوان بردارهای پشتیبان انتخاب کرد که این ویژگی، منحصر به ماشین‌های بردار پشتیبان یا SVMهاست. در برخی موارد، که یک ابرصفحه‌ی خطی قادر به جداسازی مناسب طبقات نیست، SVMها یک استراتژی قدیمی‌تر تحت عنوان SVMهای غیر خطی را استفاده می‌کنند (۲۵). برای سطوح تصمیم‌گیری غیرخطی، همانطور که بوسر و همکاران (۷) پیشنهاد کردند، یک بردار ویژگی، $x_i \in R^d$ در داخل یک فضای اقلیدسی با بعد بیشتر یا یک جنرالیزاسیون فضای اقلیدسی تحت عنوان فضای Hilbert ترسیم شد، تا

بزرگ‌تر (یعنی، یک پنالتی سنگین‌تر) بود، وضوح کمتری داشت.

$$K(x_i, x_j) = \exp(-\gamma \|x_i, x_j\|^2), \quad \gamma > 0 \quad [7]$$

$$K(x_i, x_j) = \tanh(\gamma(x_i, x_j) - \delta), \quad \gamma > 0 \text{ و } \delta > 0 \quad [8]$$

پس از انجام مکرر طبقه‌بندی با مقدار پارامترهای مختلف، در نهایت، گاما در تابع کرنل، پارامتر پنالتی و سطوح هرم یا پیرامید در کرنل تابع پایه شعاعی به ترتیب برابر با ۰/۱۲۵، ۱۰۰ و ۱؛ و در کرنل حلقوی برابر با ۰/۱۲۵، ۱۰۰ و ۰/۱۲۵ انتخاب شد. آستانه هرم یا پیرامید در تابع پایه شعاعی نیز برابر با ۰/۹ و Bias یا اریب در تابع کرنل حلقوی برابر با ۱ انتخاب شد. در ادامه، نقشه حاصل از کرنل حلقوی نسبت به کرنل تابع پایه شعاعی صحت بالاتری فراهم کرد و به عنوان معرف SVM جهت مقایسه با دو روش دیگر مورد توجه قرار گرفت.

شیء‌گرا

در این روش مبنای طبقه‌بندی سگمنت‌سازی بوده و تلاش شد سگمنت‌سازی با دقت مناسب انجام گیرد. در فرآیند سگمنت‌سازی، همان‌طور که در شکل ۳ نیز مشخص است، هرچه مقدار اختصاص یافته به پارامتر مقیاس افزایش یافته است، اندازه‌ی شیء تفکیکی بزرگ‌تر شده و این موضوع از یک سو سبب کاهش زمان پردازش و از سوی دیگر چون در منطقه مورد مطالعه عوارض کوچک گسترش دارد، موجب می‌شد در پردازش وارد نشده و در نهایت کاهش صحت کلی را به دنبال داشته باشد. همچنین به پارامترهای ضریب فشردگی و شکل ۳ نیز مقادیر مختلف داده شد و پس از رؤیت و مقایسه نتایج سگمنت‌سازی و طبقه‌بندی حاصله در نهایت برای نقشه نهایی مقادیر ۶۰، ۰/۶ و ۰/۵ به ترتیب برای پارامترهای مقیاس، فشردگی و شکل انتخاب شد. سپس محدوده نمونه‌های تعلیمی در سطح محدوده اشیای تصویری مشخص و اشیای تصویری برای هر کلاس مورد نظر با استفاده الگوریتم نزدیک‌ترین همسایه طبقه‌بندی شد.

$K(x, y) = \Phi(x) \times \Phi(y)$ است، قاعده تصمیم‌گیری را به صورت رابطه ۴ تعمیم داده که در این تحقیق مورد توجه قرار گرفت:

$$f(x) = \text{sign} \left(\sum_{i=1}^{nsv} \alpha_i y_i K(x, x_i) + b \right) \quad [4]$$


با استفاده از رابطه ۴ یک تابع کرنل به صورت رابطه ۵ به دست آمد.

$$\begin{aligned} K(x, y) &= (x_1 y_1 + x_2 y_2)^2 \\ &= x_1^2 y_1^2 + 2x_1 y_1 x_2 y_2 + x_2^2 y_2^2 \\ &= (x_1^2, x_2^2, \sqrt{2}x_1 x_2) \\ &\quad \times (y_1^2, y_2^2, \sqrt{2}y_1 y_2) \\ &= \Phi(x) \times \Phi(y) \end{aligned} \quad [5]$$

قابل ذکر اینکه توابع کرنل که جهت جاسازی SVMها استفاده شده‌اند، باید شرط Mercer را دارا بوده، یعنی تابع کرنل $K(x, y)$ باید در شرط رابطه ۶ صدق می‌کرد:

$$\iint K(x, y) g(x) g(y) d(x) d(y) \geq 0 \quad [6]$$

در این رابطه؛ $g(x)$ تابع مربع انتگرال‌پذیر است، برای تضمین اینکه یک جفت نگاشت $\{\Phi, \mathcal{H}\}$ وجود داشته باشد، و بعداً در مرحله تعلیمی نیز همگرا شود (۲۴). با توجه به تسو و ماتر (۲۴)، کرنل‌های متعددی، مانند چندجمله‌ای (متجانس و نامتجانس)، تابع پایه شعاعی، تابع پایه شعاعی گوسین و کرنل حلقوی توسعه یافته‌اند. به دلیل اینکه کرنل‌های تابع پایه شعاعی (رابطه ۷) و حلقوی (رابطه ۸) در تحقیقات گذشته (۲۲) نتایج بهتری را به نسبت کرنل‌های خطی و غیرخطی داشته است، در این تحقیق نیز ابتدا مورد توجه قرار گرفتند. در کنار آن سایر کرنل‌ها نیز مورد توجه قرار گرفتند ولی هیچ یک نتایج رضایت‌بخشی تولید نکردند. علاوه بر انتخاب نوع کرنل، همچنین به پارامترهای وابسته به کرنل و جریمه خطای C نیز برای حصول نتایج رضایت‌بخش توجه گردید. به طور مثال در انتخاب مقدار C به این موضوع توجه شد که انتخاب مقدار C کوچک ($C=1$)، مرز تصمیم‌گیری در مقابل موردی که C



شکل ۳. اثر انتخاب مقادیر مختلفی از مقیاس در فرآیند سگمنت‌سازی طبقه‌بندی شیء گرای بخشی از تصویر ۲۰۱۳ (مقدار مقیاس در a، b و c به ترتیب برابر با ۳۰، ۶۰ و ۱۲۰ است)

نشان‌دهنده توافق حقیقی (مشاهده شده) به یک توافق احتمالی می‌باشد، بر اساس رابطه ۱۰ محاسبه شد. چنانچه مقدار (K) آن به یک نزدیک شود حالت ایده‌آل می‌باشد (۸)، که γ دقت مشاهده شده و ζ احتمال توافق است.

$$K = (\gamma) - (\zeta)/1 - \zeta \quad [10]$$

نتایج

شبکه عصبی مصنوعی

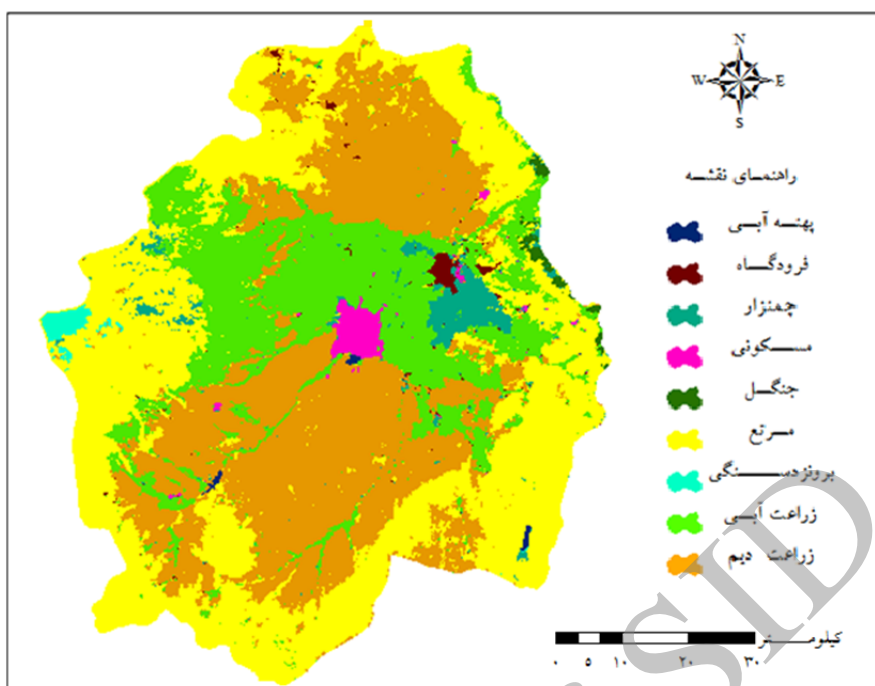
همان طور که اشاره شد، پارامترها نقشی مهم و اساسی در روند تعلیم شبکه‌های عصبی مصنوعی و طبقه‌بندی حاصل بازی می‌کنند. نقشه حاصل از طبقه‌بندی کننده شبکه عصبی مصنوعی و نمودار تعلیمی مربوط به آن به ترتیب در شکل‌های ۴ و ۵ نشان داده شده است. همان طور که در نمودار تعلیمی شبکه عصبی نیز مشهود است، کارایی شبکه تقریباً از تکرار ۲۸۰۰ به بعد تغییر زیادی نکرده است که نشان دهنده کافی بودن ۳۰۰۰ تکرار در تعلیم شبکه می‌باشد. سطح (هکتار) و درصد هر یک از طبقات کاربری و پوشش زمین حاصل از این طبقه‌بندی کننده در جدول ۱ ارائه شده است.

ارزیابی صحت

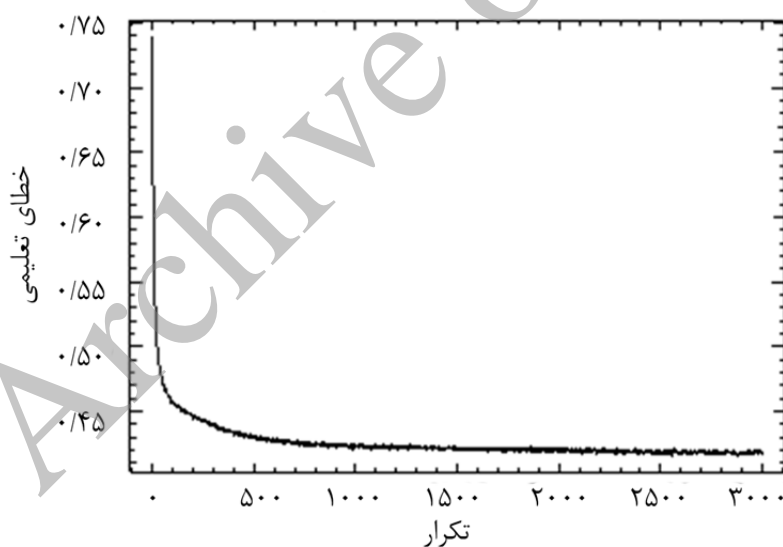
جهت ارزیابی صحت از روش ماتریس خطای اسمیت و همکاران (۲۳) و آماره کاپا و ۴۲۶ نقطه کنترل زمینی (با استفاده از GPS با توزیع مطلوب در سطح کاربری/ پوشش اراضی مختلف برداشت گردید. در این ماتریس پارامترهای صحت کلی (Overall Accuracy/OA)، صحت تولید کننده (Producer Accuracy) و صحت کاربر (User Accuracy) مورد توجه قرار گرفت. صحت کلی مطابق رابطه ۹ برآورد شد.

$$OA = \frac{\sum_{k=1}^N a_{kk}}{\sum_{i,k=1}^N a_{ik}} = \frac{1}{n} \sum_{k=1}^N a_{kk} \quad [9]$$

در این رابطه؛ OA نشان‌دهنده صحت کلی و N معرف تعداد کل پیکسل‌های طبقه‌بندی شده و $\sum_{k=1}^N a_{kk}$ نمایه مجموع پیکسل‌های قطر اصلی ماتریس خطا یا تعداد کل پیکسل‌های درست طبقه‌بندی شده می‌باشد (۱۴ و ۲۳). صحت تولید کننده از تقسیم تعداد پیکسل‌هایی که در هر طبقه به درستی طبقه‌بندی شده‌اند بر تعداد پیکسل‌های مورد استفاده آن طبقه یا جمع ستون به دست آمد و جهت برآورد صحت کاربر نیز تعداد پیکسل‌های درست طبقه‌بندی شده بر تعداد کل پیکسل‌های آن طبقه یا جمع ردیف تقسیم شد (۱۴ و ۲۳). ضریب آماره کاپا، که معیار دیگر ارزیابی صحت است (۸) و



شکل ۴. نقشه حاصل از شبکه عصبی (آستانه، نرخ، مونتوم و تکرار تعلیم به ترتیب برابر با ۰/۹، ۰/۱، ۰/۵ و ۳۰۰۰ است)



شکل ۵. نمودار تعلیمی شبکه عصبی مصنوعی

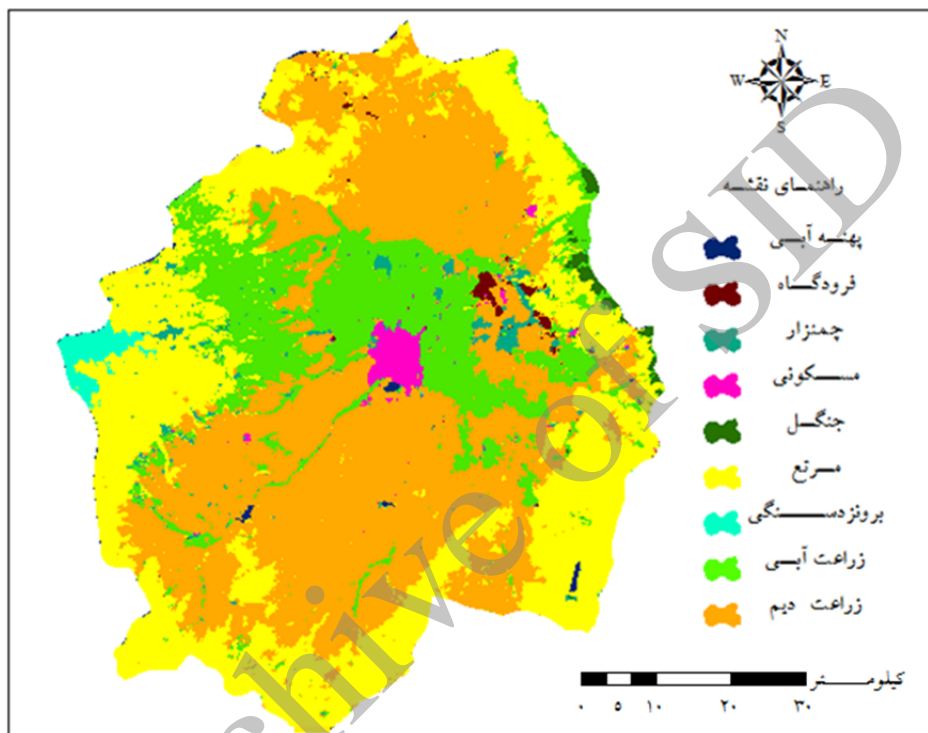
جدول ۱. سطح کاربری/ پوشش اراضی در نقشه حاصل از شبکه عصبی

LULC	پهنه آبی	فرودگاه	چمنزار	مسکونی	جنگل	مرتع	برونزدگی سنگی	زراعت آبی	زراعت دیم
سطح (هکتار)	۸۱۴/۵۳	۱۰۷۸۴/۰۸	۲۲۱۸۰/۱۷	۵۹۱۸/۸۱	۲۰۴۰/۶۰	۱۷۳۸۸۲/۳۲	۳۸۷۳/۵۶	۹۳۸۶۸/۵۷	۱۵۹۲۱۳/۷۰
سطح (درصد)	۰/۱۷	۲/۲۸	۴/۶۹	۱/۲۵	۰/۴۳	۳۶/۷۹	۰/۸۲	۱۹/۸۶	۳۳/۶۹

ماشین بردار پشتیبان

استفاده شد. سطح هر یک از طبقات کاربری/پوشش اراضی بر اساس نقشه حاصله از روش ماشین بردار پشتیبان (کرنل حلقوی) در جدول ۲ ارائه شده است. همان گونه که به صورت بصری نیز مشخص است کرنل حلقوی در تفکیک طبقات چمنزار، فرودگاه و مسکونی خوب عمل نکرده است.

نقشه حاصل از ماشین بردار پشتیبان (کرنل حلقوی) در شکل ۶ نشان داده شده است. در انتخاب نوع کرنل (تابع پایه شعاعی و حلقوی)، پارامترهای وابسته به کرنل و پهنای خطای C با دقت کامل برای تضمین نتایج رضایت‌بخش انتخاب گردید. در این تحقیق از پهنای برابر با ۱۰۰ برای وضوح بیشتر



شکل ۶. نقشه حاصل از ماشین بردار پشتیبان: کرنل حلقوی

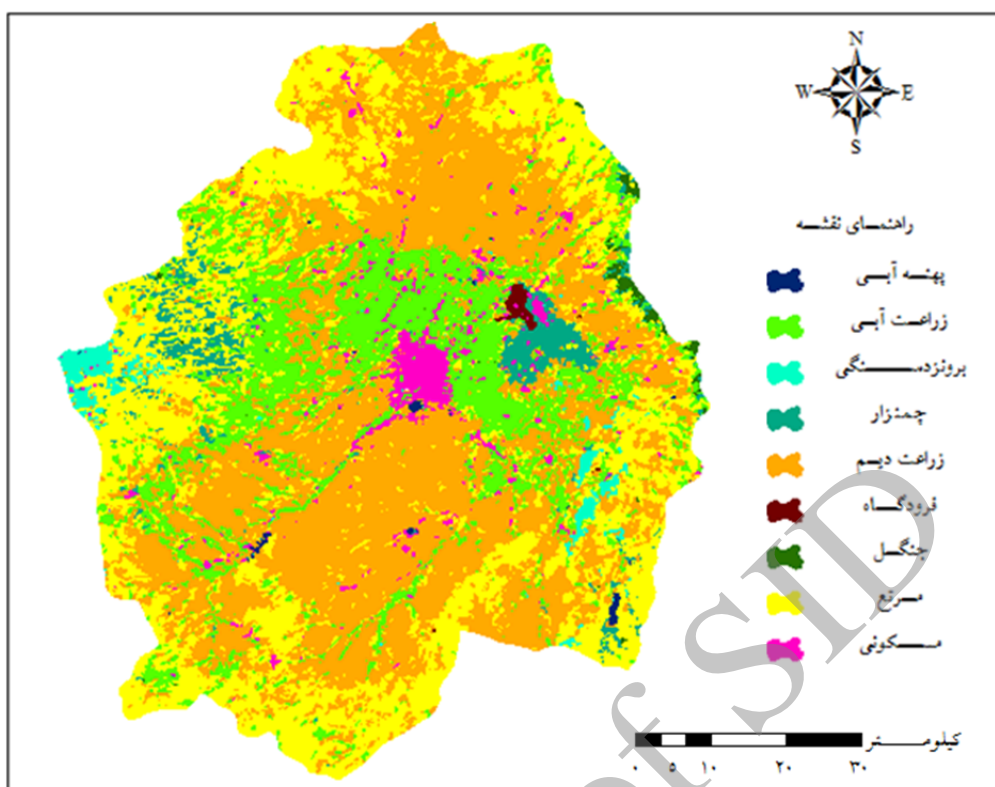
جدول ۲. سطح کاربری/پوشش اراضی در نقشه‌ی حاصل از روش ماشین بردار پشتیبان

LULC	پهنه آبی	فرودگاه	چمنزار	مسکونی	جنگل	مرتع	برونزدگی سنگی	زراعت آبی	زراعت دیم
سطح (هکتار)	۱۳۱۹/۲۸	۵۶۱۸/۳۰	۲۱۷۸۰/۳۶	۶۴۲۵/۷۳	۲۹۵۴/۲۳	۱۵۳۲۰/۱/۸۶	۵۶۹۳/۱۴	۸۰۰۷۸/۱۹	۱۹۵۴۹۲/۱۱
سطح (درصد)	۰/۲۸	۱/۱۹	۴/۶۱	۱/۳۶	۰/۶۳	۳۲/۴۲	۱/۲۱	۱۶/۹۵	۴۱/۳۷

شیء گرا

بسیار بهتر از دو طبقه‌بندی کننده قبلی تفکیک شده‌اند. سطح و درصد طبقات کاربری اراضی/پوشش در جدول ۳ ارائه شده است.

شکل ۷ نقشه حاصل از روش شیء گرا را نشان می‌دهد. همان طور که در شکل نیز مشخص است جزئیات در این نقشه



شکل ۷. نقشه حاصل از طبقه‌بندی شی‌گرا

جدول ۳. سطح کاربری / پوشش اراضی در نقشه حاصل از شی‌گرا

LULC	پهنه آبی	فرودگاه	چمنزار	مسکونی	جنگل	مرتع	برونزده سنگی	زراعت آبی	زراعت دیم
سطح (هکتار)	۹۵۸/۲	۱۱۶۶/۲	۱۵۳۱۶/۲	۱۳۳۸۲/۴	۱۸۷۱/۷	۱۵۴۹۷۹/۸	۷۱۴۸/۹	۷۷۲۳۰/۶	۲۰۰۵۱۶/۴
سطح (درصد)	۰/۲۰	۰/۲۵	۳/۲۴	۲/۸۳	۰/۴۰	۳۲/۷۶	۱/۵۱	۱۶/۳۴	۴۲/۴۳

نتایج ارزیابی صحت

خلاصه‌ای از نتایج ارزیابی صحت در جدول ۴ ارائه شده است. همانطور که از این جدول نیز مشخص است، روش شی‌گرا در مقایسه با طبقه‌بندی شبکه عصبی مصنوعی

پرسپترون با انتشار برگشتی و ماشین بردار پشتیبان نتیجه بهتری در بر داشته و صحتی بالغ بر ۹۴ درصد تولید کرده است. کرنل حلقوی ماشین بردار پشتیبان نیز صحتی حدود ۸۵ درصد داشته است.

جدول ۴. نتایج ارزیابی صحت روش‌های مختلف

روش‌ها	شبکه عصبی مصنوعی (MLP)	ماشین بردار پشتیبان	شی‌گرا
صحت کلی (%)	۸۹/۹۱	۸۵/۶۸	۹۴/۳۷
کاپا	۰/۸۸	۰/۸۲	۰/۹۳

مورد مطالعه زراعت دیم با سطح حدود ۴۲ درصد از کل منطقه و پس از آن کاربری مرتع با حدود ۳۳ درصد و جمعاً حدود ۷۵ درصد و بقیه کاربری‌ها و پوشش اراضی حدود ۲۵ درصد سطح منطقه مورد مطالعه را در بر گرفتند.

بحث و نتیجه‌گیری

با توسعه تکنیک‌های متعدد در زمینه طبقه‌بندی تصویر ماهواره‌ای و آشکارسازی تغییرات به ویژه در دهه اخیر، توجه به مقایسه روش‌ها و انتخاب بهترین و صحیح‌ترین روش برای تهیه نقشه کاربری و پوشش اراضی در مناطق مختلف رشد روز افزونی داشته است. تاکنون، محققان زیادی روش‌های مختلف طبقه‌بندی تصاویر مختلف ماهواره‌ای را مورد بررسی و مقایسه قرار داده‌اند (۲۰، ۲۱ و ۲۶). به طور مثال، مقایسه روش‌های شبکه عصبی مصنوعی و ماشین بردار پشتیبان در مطالعه یانگ (۲۶) نشان می‌دهد که صحت روش ماشین بردار پشتیبان ۲/۸ درصد از شبکه عصبی مصنوعی بالاتر بوده در حالی که در مطالعه مظاهری و همکاران (۴) صحت شبکه عصبی مصنوعی، بهبودی ۱۳ درصد نسبت به ماشین بردار پشتیبان را نشان می‌دهد و این اختلاف صحت در پژوهش حاضر تنها ۴/۲ درصد به نفع شبکه عصبی مصنوعی می‌باشد. بنابراین، این نتایج نشانگر وابستگی روش‌های مختلف طبقه‌بندی به شرایط منطقه و نوع تصاویر مورد استفاده بوده و همچنین ضرورت دارد مقایسه روش‌ها در مناطق مختلف مورد توجه و روش مناسب برای منطقه مورد نظر معرفی گردد. در مواردی که روش شیء‌گرا با روش‌هایی نظیر ماشین بردار پشتیبان و شبکه عصبی مصنوعی مقایسه شده، اکثراً حاکی از کارایی برتر روش شیء‌گر بوده است (۲۰ و ۲۱)، که در پژوهش حاضر نیز چنین نتیجه‌ای حاصل شد. هر چند با توجه به مقادیر صحت کلی بیش از ۸۵ درصد، نقشه‌های حاصل از هر سه روش با استناد به منابعی مانند لیل‌سند و همکاران (۱۵) قابل قبول و قابل استناد می‌باشند. اما در پژوهش حاضر پس از مقایسه صحت روش‌های مختلف، روش طبقه‌بندی شیء‌گرا با صحت کلی و کاپای بالاتر نسبت به روش‌های شبکه عصبی

با توجه به بازدهی‌های میدانی و شناختی که از منطقه وجود داشت، در حالت کلی روش شیء‌گرا واحدهای کاربری اراضی کوچک‌تر را در مقایسه با دو روش دیگر بهتر تفکیک کرد و نقشه مطلوب‌تری حاصل شد. تقریباً تمامی واحدهای کاربری و پوشش اراضی تعیین شده شامل مسکونی و انسان‌ساخت، فرودگاه، زراعت دیم و زراعت آبی، مرتع، جنگل، چمنزار، برونزدگی سنگی و پهنه‌های آبی در سطح نقشه شیء‌گرا به صورت مطلوب تفکیک شد. ولی در دو نقشه دیگر بعضاً کاربری‌ها و یا پوشش اراضی به صورت مطلوب و دقیق تفکیک نشدند. به طور مثال، همان طور که در شکل ۶ دیده می‌شود، طبقه چمنزار به ویژه در پیرامون فرودگاه با استفاده از روش ماشین بردار پشتیبان به خوبی تفکیک نشده است. نواحی مسکونی و انسان ساخت نیز در هر دو روش طبقه‌بندی شبکه عصبی مصنوعی و ماشین بردار پشتیبان نسبت به روش شیء‌گرا با جزئیات آشکار نشدند و حالتی کلی دارند، در حالی که همین نواحی در نقشه شیء‌گرا همراه با راه‌ها و جاده‌ها و با جزئیات کامل تر تفکیک شده است. هر سه روش در تفکیک پهنه‌های آبی به دلیل خصوصیت طیفی متفاوت آن موفق عمل کردند. در تفکیک برونزد سنگی نیز روش شیء‌گرا مطلوبتر عمل کرده و بیرونزدگی‌های سنگی جنوب شرقی منطقه را بخوبی تفکیک کرده است.

این واحد پوششی توسط دو روش دیگر به خوبی شناسایی نشده است. طبقه‌بندی شیء‌گرا در تفکیک اراضی دیم از مراتع نیز نسبت به دو روش دیگر عملکرد بهتری داشته است. عملکرد بهتر طبقه‌بندی شیء‌گرا با نتایج ارزیابی صحت مطابقت داشته و این روش توانسته با صحت کلی بیش از ۹۴ درصد و ضریب کاپای ۰/۹۳ از نظر کمی نیز نتیجه بهتری داشته باشد. در حالی که ماشین بردار پشتیبان و شبکه عصبی مصنوعی به ترتیب با صحت کلی حدود ۹۰ و ۸۶ درصد و کاپای ۰/۸۸ و ۰/۸۲ از نتایج ضعیف‌تری در مقایسه با شیء‌گرا برخوردار بوده‌اند. مساحت هر یک از کاربری‌ها و پوشش‌های اراضی حاصل از نقشه شیء‌گرا در جدول ۴ نشان می‌دهد که در سال ۲۰۱۳ بیشترین سطح کاربری در سطح سه شهرستان

تهیه نقشه کاربری و پوشش اراضی در استان اردبیل و مناطق نظیر آن توصیه می‌گردد از روش شیء‌گرا در این ارتباط استفاده گردد. در مجموع، در این تحقیق سه روش پیشرفته و در حال توسعه در سطح منطقه‌ای با بیش از ۳۶۰۰ متر تغییرات ارتفاعی، با سطوح ناهمگن و با استفاده از تصاویر نسل جدید سنجنده ماهواره لندست ۸ آزمون و مناسب‌ترین روش تهیه نقشه کاربری اراضی معرفی شد.

منابع مورد استفاده

۱. ارزانی، ح.، خ. میرآخورلو و س. ز. حسینی. ۱۳۸۸. تهیه نقشه کاربری اراضی با استفاده از داده‌های سنجنده ETM^+ ماهواره Landsat7 (مطالعه موردی: قسمتی از مراتع حوزه آبخیز طالقان). تحقیقات مرتع و بیابان ایران، ۱۶(۲): ۱۵۰-۱۶۰.
۲. رسولی، ع. ا. ۱۳۸۷. مبانی سنجش از دور کاربردی با تأکید بر پردازش تصاویر ماهواره‌ای. انتشارات دانشگاه تبریز، ۵۴۴ صفحه.
۳. فیضی‌زاده، ب. و ح. هلالی. ۱۳۸۹. مقایسه روش‌های پیکسل پایه، شیء‌گرا و پارامترهای تأثیرگذار در طبقه‌بندی پوشش کاربری اراضی استان آذربایجان غربی. پژوهش‌های جغرافیای طبیعی (پژوهش‌های جغرافیایی)، ۴۲(۱۷): ۷۳-۸۴.
۴. مظاهری، م. م. اسفندیاری، م. ح. مسیح‌آبادی و ا. کمالی. ۱۳۹۲. پایش تغییرات زمانی کاربری اراضی با استفاده از تکنیک‌های سنجش از دور و سیستم اطلاعات جغرافیایی (مطالعه‌ی موردی: جیرفت، استان کرمان)، کاربرد سنجش از دور و GIS در علوم منابع طبیعی، ۴(۲): ۲۵-۳۹.
5. Baban SM, Wan Yusof K. 2001. Mapping land use/cover distribution on a mountainous tropical island using remote sensing and GIS. *International Journal of Remote Sensing*, 22(10): 1909-1918.
6. Blaschke T. 2010. Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65(1): 2-16.
7. Boser BE, Guyon IM, Vapnik VN. 1992. A training algorithm for optimal margin classifiers. *proceeding of 5th Annual Workshop on Computational Learning Theory*, Pittsburgh, PA, USA, 8pp.

مصنوعی و ماشین بردار پشتیبان به عنوان روش برتر برای منطقه مورد مطالعه انتخاب گردید. همانطور که اشاره شد، در نقشه شیء‌گرا کاربری‌ها و پوشش اراضی مختلف مانند نواحی مسکونی و انسان ساخت کوچک و بزرگ، فرودگاه و اراضی زراعی آبی و دیم نسبت به دو نقشه دیگر با جزئیات بهتری طبقه‌بندی شده است، چرا که روش شیء‌گرا قادر است اشکال هندسی منظم نظیر مناطق انسان‌ساخت یا اراضی کشاورزی را در فرآیند سگمنت‌سازی به خوبی تشخیص دهد. در تفکیک طبقه چمنزار روش‌های شبکه عصبی و ماشین بردار پشتیبان نتوانسته‌اند نتیجه خوبی ارائه دهند. در استفاده و مقایسه روش‌های شبکه عصبی مصنوعی و ماشین بردار پشتیبان این نکته شایان توجه است که شبکه عصبی مصنوعی و ماشین بردار پشتیبان از نظر زمان پردازش با ابعاد منطقه مورد مطالعه این پژوهش زمانی بالغ بر ۱۶ ساعت را طلب می‌کند و قابل مقایسه با زمان کمتر از ۱۰ ساعت روش شیء‌گرا نمی‌باشد. با مقایسه زمان پردازش هر یک از روش‌ها و صحت حاصل از آن‌ها نیز بر کارایی روش شیء‌گرا تأکید می‌شود. انتخاب پارامترها در روش‌های شبکه عصبی مصنوعی و ماشین بردار پشتیبان اثر قابل توجهی بر صحت و زمان طبقه‌بندی دارد و از این جهت که هیچ منبع و اساسی برای انتخاب پارامترها وجود نداشته و کاملاً جنبه تجربی دارند، حائز توجه بیشتر می‌باشند. از طرفی سگمنت‌سازی روش شیء‌گرا نیز مستلزم انتخاب تجربی و همراه با سعی و خطای چند پارامتر است که مقدار داده شده به این پارامترها تعیین کننده صحت و ظرافت طبقه‌بندی نهایی هستند. در مجموع می‌توان این گونه استنباط کرد که مقایسه روش‌ها تا حدودی به منطقه و تصویر استفاده شده و گروه روش‌های مورد مقایسه بستگی دارد. در اینجا هر سه روش طبقه‌بندی شبکه عصبی مصنوعی، ماشین بردار پشتیبان و شیء‌گرا نشان دادند که قابلیت تهیه نقشه‌های مطلوب را دارا می‌باشند، از این بین روش شیء‌گرا به دلیل دخالت دادن فاکتورهایی نظیر مقیاس، شکل و بافت علاوه بر استفاده از ارزش پیکسلی عملکرد بهتر و دقیق‌تری در طبقه‌بندی کاربری و پوشش اراضی نشان داد. لذا در مطالعات

8. Congalton RG, Green K. 2009. Assessing the accuracy of remotely sensed data principles and practices, CRC Press, Boca Raton, Florida. 200 pp.
9. Jansen LJ, Di Gregorio A. 2004. Obtaining land-use information from a remotely sensed land cover map: results from a case study in Lebanon. *International Journal of Applied Earth Observation and Geoinformation*, 5(2): 141-157.
10. Kanellopoulos I, Wilkinson G. 1997. Strategies and best practice for neural network image classification. *International Journal of Remote Sensing*, 18(4): 711-725.
11. Karathanassi V, Andronis V, Rokos D. 2000. Evaluation of the topographic normalization methods for a Mediterranean forest area. *International Archives of Photogrammetry and Remote Sensing*, 33(B7/2; PART 7): 654-661.
12. Kavzoglu T. 2001. An investigation of the design and use of feed-forward artificial neural networks in the classification of remotely sensed images, PhD thesis, Geography group, The University of Nottingham, Nottingham, 128p.
13. Lambin E, Jonckheere I, Muys B. 2001. Digital change detection methods in natural ecosystem monitoring: A review. In: *Proceedings of the First International Workshop on the Analysis of Multi-temporal Remote Sensing Images*: University of Trento, Italy, 13-14 September.
14. Lefsky MA, Cohen WB. 2003. Selection of remotely sensed data. In: (eds.), *remote sensing of forest environments: concepts and case studies*. Edited by: Wulder M.A., and Franklin S.E., Kluwer Academic Publishers, Boston, USA. PP. 13-46.
15. Lillesand TM, Kiefer RW, Chipman JW. 2008. *Remote sensing and image interpretation*, John Wiley & Sons Inc Press, New York. 804 pp.
16. Lu D, Li G, Moran E, Freitas CC, Dutra L, Sant'Anna SJS. 2012. A comparison of maximum likelihood classifier and object-based method based on multiple sensor datasets for land use/land cover classification in the Brazilian Amazon. *Proceedings of 4th GEOBIA, Rio de Janeiro, Brazil*, 8pp.
17. Lu D, Weng Q. 2007. A survey of image classification methods and techniques for improving classification performance. *International Journal of Remote sensing*, 28(5): 823-870.
18. Mathur PM. 2005. *Computer processing of remotely-sensed images*, John Wiley and Sons Publishers, Toronto. 450 pp.
19. Mathur A, Foody GM. 2008. Crop classification by support vector machine with intelligently selected training data for an operational application. *International Journal of Remote Sensing*, 29(8): 2227-2240.
20. Petropoulos GP, Kalaitzidis C, Vadrevu KP. 2012. Support vector machines and object-based classification for obtaining land-use/cover cartography from Hyperion hyperspectral imagery. *Computers & Geosciences*, 41: 99-107.
21. Roostaei S, Alavi S, Nikjoo M, Kamran KV. 2012. Evaluation of object-oriented and pixel based classification methods for extracting changes in urban area. *International Journal of Geomatics and Geosciences*, 2(3): 738-749.
22. Schölkopf B, Sung K-K, Burges CJ, Girosi F, Niyogi P, Poggio T, Vapnik V. 1997. Comparing support vector machines with Gaussian kernels to radial basis function classifiers. *Signal Processing, IEEE Transactions on*, 45(11): 2758-2765.
23. Smits P, Dellepiane S, Schowengerdt R. 1999. Quality assessment of image classification algorithms for land-cover mapping: a review and a proposal for a cost-based approach. *International Journal of Remote Sensing*, 20(8): 1461-1486.
24. Tso B, Mather PM. 2009. *Classification methods for remotely sensed data*, Taylor and Francis Group, LLC, CRC Press, New York. 376 pp.
25. Vapnik V. 1995. *The nature of statistical learning theory*, Springer-Verlag, New York. 314 pp.
26. Yang X. 2011. Parameterizing support vector machines for land cover classification. *Photogrammetric Engineering & Remote Sensing*, 77(1): 27-37.



Comparing artificial neural network, support vector machine and object-based methods in preparation land use/cover maps using landSat-8 images

F. Aslami¹, A. Ghorbani^{2*}, B. Sobhani³, M. Panahandeh⁴

1. MSc. Graduated of Remote Sensing and GIS, University of Mohaghegh Ardabili

2. Assoc. Prof. College of Agricultural Technology and Natural Resources, University of Mohaghegh Ardabili

3. Assoc. Prof. College of Humanities, University of Mohaghegh Ardabili

4. MSc. of Geography, Space Organization of Iran

ARTICLE INFO

Article history:

Received 24 November 2014

Accepted 30 May 2015

Available online 16 December 2015

Keywords:

Remote sensing

Land use/cover

Artificial neural network

Support vector machine

Object-based

Ardabil

ABSTRACT

Preparing the maps of land use/cover for spatial planning and management is essential. Nowadays, satellite images and remote sensing techniques have widespread applications according to their capabilities to produce the updated data and analyze the images in all disciplines such as agriculture and natural resources. In the present study, Artificial Neural Network, Support Vector Machines and Object-Based techniques were utilized for drawing the land use and vegetation maps in Ardabil, Namin, and Nir counties. The images of LandSat-8 Operational Land Imager (OLI) (2013) were used after geometric correction and topographic normalization and classified into 9 land use/cover classes including water bodies, irrigated farming, rainfed farming, meadows, outcrops, forests, rangelands, residential and airport areas. After the accuracy assessment, overall accuracy for the produced maps of ANN, Support Vector Machine (SVM) and Object-based (OB) techniques was estimated as 89.91, 85.68 and 94.37%, respectively and Kappa's coefficients were 0.88, 0.82 and 0.93, respectively indicating that the object-based method in comparison with two other methods has more advantages; on the other hand, all three methods could provide the desirable accuracy for the land use/cover maps. Overall, three advanced classification methods were examined in the heterogeneous area with elevation changes up to 3600m using the images of new launched Landsat 8 and the most appropriate land use/cover mapping method was introduced.

* Corresponding author e-mail address: a_ghorbani@uma.ac.ir