

پژوهش و فناوری محیط زیست

ویگاه نشریه: www.journal.eri.acecr.ir



شایعه الکترونیکی: ۳۰۶۰-۲۶۷۶

پژوهشکده محیط زیست

بررسی تغییرات زمانی و مکانی کاربری اراضی با استفاده از سنجش از دور، مطالعه موردی: مراغه جیرانسو، خراسان شمالی

محبت نداف^{۱*}، رضا امیدی پور^۲، حسین سبحانی^۳

۱- گروه زیست شناسی، دانشگاه پیام نور، تهران، ایران

۲- گروه مرتع و آبخیزداری، دانشکده کشاورزی، دانشگاه ایلام

۳- کارشناسی ارشد منابع طبیعی، شهرستان آشخانه، خراسان شمالی

اطلاعات مقاله

چکیده	اطلاعات مقاله
اطلاع از روند تغییرات و همچنین مدیریت صحیح کاربری‌های اراضی در اکوسیستم‌های طبیعی اهمیت بالایی در حفاظت از منابع طبیعی دارد. در این راستا، استفاده از سنجش از دور به دلیل فراهم کردن اطلاعات مکانی و زمانی گسترده به یک رویه مرسوم تبدیل شده است. در تحقیق حاضر به منظور تهیه نقشه کاربری اراضی، ابتدا دقت سه روش مرسوم پیکسل پایه (حداکثر احتمال، یادگیری ماشینی (ماشین بردار پشتیبان) و شیء‌گرا با یکدیگر مقایسه شدند. سپس روند تغییرات زمانی و مکانی کاربری‌های اراضی در یک دوره ۲۶ ساله (۱۹۹۷-۲۰۲۳) با استفاده از شش تصویر ماهواره‌ای لنdest است انجام شد. ارزیابی دقت طبقه‌بندی با استفاده از شاخص‌های ضربی کاپا و صحت کلی و ارزیابی روند تغییرات با استفاده از روش ارزیابی متقطع و ارزیابی مکانی صورت گرفت. بر اساس نتایج، روش ماشین بردار پشتیبان دارای بالاترین ضربی کاپا (۰/۹۸ تا ۰/۰) و صحت کلی (۸۶ تا ۹۹ درصد) برای دوره‌های مورد مطالعه بود. بر اساس نتایج، مراغه با وضعیت فقیر دارای روند کلی کاهشی و کاربری‌های مراغه خیلی فقیر، اراضی بدون پوشش و زراعت دیم دارای روندهای افزایشی بودند. مساحت اراضی مرتضی فقیر از ۹۶۲ هکتار (۴۴/۳۶ درصد) در سال ۱۹۹۷ به ۴۸۹ هکتار (۲۲/۵۷ درصد) در سال ۲۰۲۳ کاهش یافتند، در حالی که مراغه خیلی فقیر در مدت مشابه از ۱۱۳۸ هکتار (۵۲/۴۸ درصد) به ۱۶۰۶ هکتار (۷۴/۰۵ درصد) افزایش داشته است. نتایج این تحقیق نشان داد که روند تغییرات کاربری اراضی در مراغه جیرانسو به سمت تخریب مراغه بوده و با گذشت زمان این روند در حال تشدید شدن است. همچنین، بر اساس نتایج بدست آمده از این تحقیق پیشنهاد می‌شود در تحقیقات آتی از روش‌های طبقه‌بندی مبتنی بر یادگیری ماشینی برای تهیه نقشه کاربری اراضی استفاده شود.	نوع مقاله: پژوهشی تاریخ دریافت: ۱۴۰۲/۰۵/۲۴ تاریخ پذیرش: ۱۴۰۲/۱۲/۰۲ دسترسی آنلاین: ۱۴۰۳/۰۱/۱۸
کلید واژه‌ها: ماهواره‌ی لنdest، تخریب منابع طبیعی، یادگیری ماشینی، طبقه‌بندی شیء‌گرا، مراغه جیرانسو	کلید واژه‌ها:



Assessment of Spatial and temporal changes in land use using remote sensing (case study: Jayransoo rangeland, North Khorasan)

Mohabbate Nadaf^{1*}, Reza Omidipour², Hossein Sobhani³

1- Department of Biology, Payam Noor University, Tehran, Iran

2- Department of Rangeland and Watershed Management, Faculty of Agriculture, Ilam University, Ilam, Iran

3- M.Sc. in Natural Resources, Ashkhane county, North Khorasan, Iran

Article Info

Abstract

Article type:
Research Article

Awareness of changes process, as well as the proper management of land use in natural ecosystems, is of great importance in conservation natural resources. In this regard, the use of remote sensing has become a common approach due to the provision an extent spatial and temporal information. In this research, in order to land use mapping, first, the accuracy of three common methods of pixel-based (maximum likelihood), machine learning (support vector machine) and object-oriented methods were compared. Then, the spatial and temporal changes of land use in a period of 26 years (1997-2023) assessed using six Landsat satellite imagery. The accuracy of image classification methods was evaluated using Kappa coefficient and overall accuracy indices and the change trend was evaluated using crosstab and spatial evaluation methods. Based on the results, the support vector machine method had the highest kappa coefficient (0.71 to 0.98) and overall accuracy (86 to 99%) for all studied courses. According to the results, poor rangeland had a decreasing trend, and the land uses of very poor rangeland, bare soil, and rainfed agriculture had increasing trends. The area of poor rangeland decreased from 962 hectares (44.36%) in 1997 to 489 hectares (22.57%) in 2023, while very poor rangeland increased from 1138 hectares (52.48%) to 1606 hectares (74.05 percent) in the same period. The results of this research indicated that the trend of land use changes in Jayransoo rangeland is towards the destruction of rangelands and with the passage of time this trend is intensifying. Also, based on the results obtained from this research, it is suggested to use machine learning based classification method to prepare land use mapping in future research.

Keywords:
Landsat satellite,
Destruction of
natural resources,
Machine learning,
Object-oriented
classification,
Jayransoo
rangeland

* Corresponding author E-mail address: m_nadaf@pnu.ac.ir

مقدمه

تغییرات اقلیمی و فعالیتهای انسانی، تأثیر مستقیمی روی نوع و سطح کاربری‌های مختلف از قبیل مراعع دارند (لئو و همکاران^۱، ۲۰۱۸). برای مثال، تغییرات میزان بارندگی و افزایش دما باعث تغییرات قابل توجهی در منابع آب و خاک و تعادل محیط زیست می‌شود. در سال‌های اخیر، تغییرات اقلیمی، بهویژه گرمایش زمین، رویدادهای مکرری مانند سیل، افزایش دما و خشکسالی را ایجاد کرده است که می‌تواند به بوم سامانه‌های زمینی آسیب برساند (ژو و همکاران^۲، ۲۰۱۴). از طرف دیگر، فعالیتهای انسانی مانند افزایش جمعیت و تغییرات کاربری اراضی که شرایط پایدار زمین را تغییر می‌دهند نیز باعث تخریب اراضی و پوشش می‌شوند (سان و همکاران^۳، ۲۰۲۳). پوشش گیاهی در مناطق خشک و نیمه‌خشک به دلیل حفاظت از تنوع زیستی، ترسیب کردن و چرای دام از اهمیت بالایی برخوردار است و منبع اصلی تأمین غذا (مستقیم و غیر مستقیم) برای سایر جانداران است (یانگ و همکاران^۴، ۲۰۱۲). با توجه به نقش تعیین کننده پوشش گیاهی و مراعع در تبادل انرژی و گردش آب، مدیریت دقیق و اصولی این عرصه‌ها بسیار حائز اهمیت است و مدیریت اصولی و کارآمد مراعع، اطلاعات جامع و دقیقی را در سطوح مختلف می‌طلبد (امیدی‌پور و همکاران، ۱۳۹۲).

بررسی روند تغییرات در دوره‌های چندین ساله نیز نیازمند جمع‌آوری داده‌های زمینی است. به دلیل وسعت منطقه و مشکل دسترسی، انجام مطالعات و نظارت زمینی در سیمای سرزمین سخت و گاهی غیرممکن است و از طرفی چنین داده‌هایی نیز در کشور ما وجود ندارد (رضایی و همکاران، ۱۴۰۱). لذا استفاده از علم سنجش از دور و تصاویر ماهواره‌ای در این مطالعات تسهیل کننده است و استفاده از سری زمانی تصاویر ماهواره‌ای، راهی مناسب برای یافتن روند تغییرات پدیده‌های طبیعی و انسانی و پیش‌بینی برای آینده است. در سال‌های اخیر مسئله تخریب عرصه‌های منابع طبیعی به عنوان یک بحران زیست محیطی یکی از مباحث مهم است (برهانی و همکاران، ۱۴۰۲). در ایران، مراعع دارای جایگاه ویژه‌ای در توسعه اقتصادی بوده و تضمین کننده بقاء و پایداری آب و خاک کشور می‌باشد (فتاحی، ۱۳۷۳). این عرصه‌ها از دیرباز محل زندگی ساکنین و عشایر و در معرض آسیب‌های فراوانی بوده‌اند که موجب محو جنگل‌ها و مراعع در بخش‌هایی از آن گردیده است. در نتیجه مدیریت و برنامه‌ریزی این کاربری‌های طبیعی با مشکلات فراوانی همراه است. بنابراین در برنامه‌ریزی و مدیریت بهینه منابع طبیعی و محیط‌زیست آگاهی از نسبت تغییرات پوشش گیاهی و کاربری اراضی و عوامل ایجاد‌کننده آن از ضروریات محسوب می‌شود (زارع‌گاریزی و همکاران، ۱۳۹۱).

یکی از مهمترین مناسب‌ترین راه‌ها برای حفظ و مدیریت کاربری اراضی، داشتن اطلاعات در مورد وضعیت کمی آن‌هاست (لانگ و کیو^۵، ۲۰۱۸). به عبارت دیگر، از مهمترین مشکلات در برنامه‌ریزی اقتصادی، مطالعات محیطی و مدیریت منابع طبیعی عدم در دسترس بودن اطلاعات صحیح و بهنگام می‌باشد (اسمیت و همکاران^۶، ۲۰۱۶). داشتن اطلاعات و پایش عرصه‌های منابع طبیعی مهمترین عوامل در ارزیابی صحیح و اتخاذ تصمیمات مدیریتی صحیح می‌باشد. این اطلاعات برای تجدید حیات، نگهداری، مدیریت و بهره‌برداری از منابع طبیعی بسیار مفید هستند. این اطلاعات در ایران با استفاده از روش سنتی و عملیات میدانی گرد آوری می‌شود اما به دلیل هزینه بالا، وقت‌گیر بودن و عدم دسترسی به تمام عرصه‌ها، در سطح

¹- Luo et al.,

²- Zhou et al.,

³-Sun et al.,

⁴-Yang et al.,

⁵- Long & Qu,

⁶-Smith et al.,

و سیع چندان مقرن به صرفه نیست (اسچنبل و همکاران^۱، ۲۰۱۵). این محدودیت‌ها بکارگیری روش‌های جایگزین را بطور جدی مطرح می‌کند.

یکی از بهترین راهکارها برای کسب این اطلاعات با نتایج قابل قبول استفاده از داده‌های ماهواره‌ای می‌باشد که به علت قدرت تفکیک مناسب، سهولت در پردازش و قابلیت تکرار زیاد، می‌تواند فرصت مناسبی را برای جمع‌آوری اطلاعات در مورد جنگل‌ها و مراتع ارائه کند. اطلاعات ماهواره‌ای و ابزارهای سنجش از دور از جمله مهمترین و دقیق‌ترین ابزارهای کاربردی برای پایش تغییرات کاربری اراضی در مقیاس مکانی و زمانی هستند (کومار و همکاران^۲، ۲۰۱۵؛ لی و همکاران^۳، ۲۰۲۰؛ وربیلا^۴، ۲۰۲۲). هرچند استفاده از روش‌های مختلف قبیل روش‌های مختلف طبقه‌بندی و تهیه نقشه کاربری اراضی به عنوان یک چالش بین محققین باقی مانده است (کلوندر-بارز و همکاران^۵، ۲۰۲۰). به عنوان مثال، در بین روش‌های نظارت شده مبتنی بر بر پیکسل، عمدۀ محققین بر کارای روش حداکثر احتمال تاکید دارند (سیسودا و همکاران^۶، ۲۰۱۴؛ اسد و بایس^۷، ۲۰۲۰). حال آنکه گروهی دیگر، کارائی روش‌های از قبیل شبکه عصب مصنوعی (زو و همکاران^۸، ۲۰۲۰)، روش‌های فازی (کائور و همکاران^۹، ۲۰۱۹) روش‌های مبتنی بر درخت تصمیم (لوهس و همکاران^{۱۰}، ۲۰۱۹) را بیشتر از روش حداکثر احتمال می‌دانند. از سوی دیگر، استفاده از روش‌های از قبیل طبقه‌بندی شیءگرا نیز دارای دقت بالایی عنوان شده است (رضایی و همکاران^{۱۱}). برای مثال، امیدی‌پور و همکاران (۱۳۹۲) نشان دادند که روش طبقه‌بندی شیءگرا در مقایسه با روش‌های پیکسل پایه از دقت بالاتری برخوردار است. در نهایت، در سال‌های اخیر با گستره شدن رویکرد استفاده از روش‌های یادگیری ماشینی و ورود آنها به عنوان روش‌های طبقه‌بندی (ریمال و همکاران^{۱۱}، ۲۰۲۰؛ ها و همکاران^{۱۲}، ۲۰۲۰) تحولات شگرفی در بهبود کیفیت و دقت طبقه‌بندی تصاویر ماهواره‌ای اتفاق افتاده است. به همین دلیل در تحقیق حاضر، سه رویکرد مختلف طبقه‌بندی تصاویر ماهواره‌ای شامل روش‌های پیکسل پایه، شیءگرا و نیز رویکرد جدید مبتنی بر یادگیری ماشینی در استان خراسان شمالی مورد مطالعه قرار گرفته‌اند. پس از تعیین بهترین روش، روند بلند مدت تغییرات کاربری‌های اراضی نیز مورد مطالعه قرار گرفته است. نتایج این تحقیق اطلاعات مناسبی را برای مدیران منابع طبیعی برای مدیریت صحیح و به هنگام منابع طبیعی فراهم می‌کند.

مواد و روش‌ها

منطقه مورد مطالعه در این تحقیق، مرتع قشلاقی جیرانسو در شهرستان مانه و سملقان، در استان خراسان شمالی واقع شده است و مساحتی برابر با ۲۱۶۸ هکتار دارد (شکل ۱). این مرتع در فاصله ۱۰۰ کیلومتری شمال غربی، مرکز بخش (شهر آشخانه) قرار گرفته است. این منطقه در عرض جغرافیایی ۵۶ درجه و ۸ دقیقه تا ۵۶ درجه و ۱۳ دقیقه و همچنین طول جغرافیایی ۳۷ درجه و ۳۸ دقیقه تا ۳۷ درجه و ۴۲ دقیقه قرار دارد. میزان بارندگی سالانه ثبت شده در آن برابر با ۲۰۱/۷

^۱-Schnebele et al.,

^۲-Kumar et al.,

^۳- Li et al.,

^۴- Verbyla,

^۵- Cavender-Bares et al.,

^۶-Sisodia et al.,

^۷-Asad & Bais,

^۸-Zhu et al.,

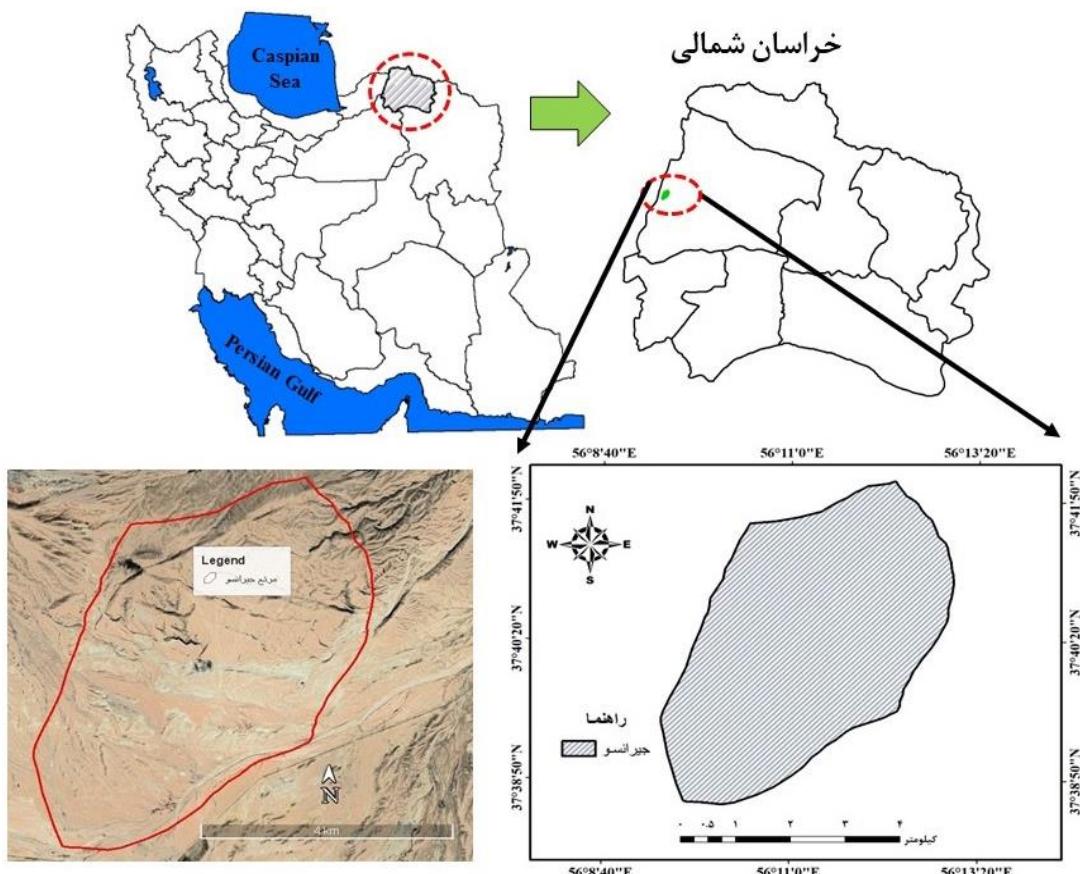
^۹-Kaur et al.,

^{۱۰}-Lohse et al.,

^{۱۱}-Rimal et al.,

^{۱۲}-Ha et al.,

میلی‌متر در سال است. بررسی پراکنش ماهانه بارش در سامان قشلاقی جیرانسو نشان می‌دهد که بیشترین میزان بارندگی در فروردین ماه و کمترین بارندگی در تیر ماه اتفاق می‌افتد. بارندگی‌های منطقه مورد مطالعه از اوخر آذر ماه شروع شده و تا اوخر اردیبهشت ماه ادامه دارد. بر اساس اطلاعات هواشناسی بدست آمده از ایستگاه جیرانسو، گرم‌ترین ماه سال تیر و مردادماه بوده و سردترین ماه سال دی و بهمن‌ماه است. دمای متوسط سالانه مرتق قشلاقی جیرانسو ۱۶/۰۲ درجه سانتی‌گراد است. بر اساس اقلیم‌نمای آمیروژه اقلیم منطقه از نوع خشک سرد و بر اساس اقلیم‌نمای دومارت، اقلیم منطقه از نوع خشک سرد است (منابع طبیعی و آبخیزداری استان خراسان شمالی، ۱۳۸۸).



شکل (۱) موقعیت منطقه جیرانسو در استان خراسان شمالی (منبع: نگارنده‌گان)

تهییه تصاویر ماهواره‌ای

در تحقیق حاضر، تصاویر ماهواره‌ای یک دوره زمانی ۲۶ ساله (۱۹۹۷-۲۰۲۳) از سنجده‌های مختلف ماهواره‌ی لندست (جدول ۱) با استفاده از سایت زمین‌شناسی ایالت متحده (USGS) تهییه شدند. با در نظر گرفتن نیازمندی تصاویر ماهواره‌ای به انجام تصحیحات هندسی و اتمسفریک، در این تحقیق از تصاویر فراهم شده با مجموعه دو (Collection 2) و سطح دو (Level 2) که دارای همه تصحیحات لازم هستند، استفاده شد (چوات و همکاران^۱، ۲۰۲۱).

^۱ -Choate et al.,

جدول (۱) اطلاعات تصاویر ماهواره‌ای مورد استفاده

ماهواره	سنجدنده	تاریخ تصویر	قدرت تفکیک مکانی (متر)	ابرناکی (درصد)	خطای هندسی (متر)
لنdest ۵	TM	۱۹۹۷/۵/۱۷	۳۰	۳	*
لنdest ۵	TM	۲۰۰۲/۵/۲۴	۳۰	۶	۴/۴۷
لنdest ۵	TM	۲۰۰۸/۵/۲۴	۳۰	۱/۲	۴/۳۵
لنdest ۸	OLI	۲۰۱۳/۵/۲۰	۳۰	۰/۱۷	۵/۲۹
لنdest ۸	OLI	۲۰۱۸/۵/۲۰	۳۰	۰/۱۵	۵/۱۳
لنdest ۹	OLI-2	۲۰۲۳/۵/۲۶	۳۰	۰/۲۱	۴/۶۸

*میزان خطای هندسی برای این سال در فایل اطلاعات پایه (Metadata) تصویر ارائه نشده است.

طبقه‌بندی تصاویر ماهواره‌ای

طبقه‌بندی پیکسل پایه، گروههای از روش‌های طبقه‌بندی دارای نظارت هستند که فرآیند طبقه‌بندی بر اساس نمونه‌های آموزشی اولیه (معرفی شده توسط کاربر) انجام می‌شود. در این روش طبقه‌بندی بر اساس نمونه‌های آموزشی است که کاربر با امضاهای طیفی به نرم افزار معرفی کرده است. نرم افزار طبقه‌بندی کننده تصویر ماهواره‌ای تعیین می‌کند که هر کلاسی چقدر به داده‌های آموزشی شباهت دارد و بر آن اساس طبقه‌بندی می‌کنند (امیدی‌پور و همکاران، ۱۳۹۲). بطور کلی طبقه‌بندی نظارت شده در سه مرحله انتخاب نقاط آموزشی، تولید فایل امضاء طیفی و طبقه‌بندی انجام می‌شود (رمضان و همکاران، ۱، ۲۰۲۱). در بین روش‌های مختلف طبقه‌بندی نظارت شده، روش طبقه‌بندی حداکثر احتمال مرسوم‌ترین روش بوده و در تحقیق حاضر نیز از این روش استفاده شد. برخلاف طبقه‌بندی پیکسل پایه، روش طبقه‌بندی شیء‌گرا مبتنی بر تعیین قطعات همگن و طبقه‌بندی براساس آنهاست (امیدی‌پور و همکاران، ۱۳۹۲). به عبارتی، در طبقه‌بندی شیء‌گرا، ابتدا تصویر به قطعات همگن تبدیل شده و سپس طبقه‌بندی تصویر براساس این قطعات همگن انجام می‌شود (جین و همکاران، ۲، ۲۰۱۹). نتیجه این روش تولید نقشه‌های کاربری اراضی به مراتب شفاف‌تر و فاقد تک پیکسل‌ها می‌باشد (امیدی‌پور و همکاران، ۱۳۹۲). بطور کلی، تصاویر می‌توانند براساس بافت، محتوا و شکل هندسی طبقه‌بندی شوند (جین و همکاران، ۲۰۱۹). در این تحقیق، به منظور تهیه مناطق همگن از چهار متغیر پهنه‌ای پنجره (۳)، تشابه (۱۰)، فاکتور میانگین وزن (۰/۵) و فاکتور واریانس وزن (۰/۵) استفاده شد.

علاوه بر دو روش قبل، در این تحقیق از روش طبقه‌بندی مبتنی بر یادگیری ماشینی (روش ماشین بردار پشتیبان) استفاده شد. بطور کلی این روش طبقه‌بندی خوبی را از داده‌های پیچیده و زیاد و نیز مناطق دارای نمونه‌های معرف کم را نیز می‌تواند دقت بالا طبقه‌بندی کند (شیخ‌موسی و همکاران، ۳، ۲۰۲۰). روش طبقه‌بندی ماشین بردار پشتیبان بر اساس نظریه یادگیری آماری بنا نهاده شده و یک روش آماری غیرپارامتریک نظارت شده است و با این فرض عمل می‌کند که هیچ اطلاعی از چگونگی توزیع مجموعه داده‌ها وجود ندارد (شیخ‌موسی و همکاران، ۲۰۲۰). در این روش با استفاده از اطلاعات همه باندها و یک الگوریتم بهینه‌سازی، نمونه‌هایی که مرزهای کلاس‌ها را تشکیل می‌دهند به دست می‌آید و با استفاده از آنها یک مرز تصمیم‌گیری خطی بهینه برای جدا کردن کلاس‌ها محاسبه می‌شود (سان و همکاران، ۴، ۲۰۱۹). این روش بر پایه چهار نوع

^۱-Ramezan et al.,

^۲-Jin et al.,

^۳-Sheykhoumousa et al.,

^۴-Sun et al.,

کرنل به نامهای خطی، چندجمله‌ای، تابع پایه شعاعی و هلالی انجام می‌شود (سنکانه^۱، ۲۰۱۹) که در این تحقیق از طبقه‌بندی ماشین بردار پشتیبان بر پایه کرنل شعاعی استفاده شد.

تهیه نمونه آموزشی و ارزیابی دقت طبقه‌بندی

بطور کلی، روش‌های طبقه‌بندی تصاویر ماهواره در دو گروه روش‌های نظارت شده و روش‌های نظارت نشده قرار می‌گیرند (دینگرا و کومار، ۲۰۱۹^۲). که روش‌های نظارت شده برای انجام نیازمند نمونه آموزشی (نمونه تعلیمی) هستند (امیدی‌پور و همکاران، ۱۳۹۲). پس از بررسی میدانی، در منطقه مورد بررسی سه نوع کاربری اراضی شامل اراضی مرتعی (در دو کلاس فقیر و خیلی فقیر)، اراضی بایر یا بدون پوشش و اراضی زراعی (زراعت دیم) مشاهده و نقاط آموزشی مربوط به هر کاربری برداشت شد. لازم به ذکر است به دلیل وسعت کم مناطق مسکونی (روستاهای) و پراکندگی ساختمان‌ها و همچنین استفاده از کاهگل به عنوان پوشش سقف (دارای بازتابش طیفی مشابه با خاک لخت)، امکان تفکیک اراضی مسکونی از اراضی بدون پوشش وجود نداشته و این دو کاربری در یک گروه طبقه‌بندی شدند. همچنین، به منظور افزایش تفکیک طیفی بین کاربری‌های مورد بررسی، شاخص NDVI محاسبه و به عنوان یک باند در مرحله طبقه‌بندی استفاده شد (تاکار و همکاران، ۲۰۱۵^۳). در تحقیق حاضر به منظور بررسی دقت نقشه‌های کاربری اراضی تولید شده با استفاده از روش‌های مختلف از دو شاخص مرسوم ضریب کاپا و صحت کلی استفاده شد (میرزائی و همکاران، ۲۰۱۵^۴).

بررسی زمانی و مکانی تغییرات کاربری اراضی

پس از تهیه نقشه کاربری اراضی براساس سه روش مورد استفاده، تغییرات ایجاد شده در دو دوره زمانی ۱۰ ساله شامل ۸-۱۹۹۷ و ۲۰۱۳-۲۰۲۳ مورد بررسی قرار گرفت. در این راستا، تغییرات با دور روش ارزیابی متقطع (Crosstab) و ارزیابی مکانی (Spatial Assessment) استفاده شد. برای تعیین دقیق تغییرات بین کاربری‌های مختلف، از ابزار مدلساز تغییر زمین (Land Change Modeler) استفاده شد.

یافته‌های پژوهش

بررسی دقت و صحت نقشه‌های کاربری اراضی برای دوره‌های زمانی مختلف نشان داد که همه نقشه‌های تولید شده از دقت بالایی برخوردار هستند به طوری که در روش حداکثر احتمال صحت کلی آنها بین ۶۳ تا ۹۷ درصد و ضریب کاپا آنها بین ۰/۵۹ تا ۰/۹۸ بود (جدول ۲). همچنین در روش ماشین بردار پشتیبان صحت کلی آنها بین ۸۶ تا ۹۹ درصد و ضریب کاپا آنها بین ۰/۷۱ تا ۰/۹۸ متغیر بود که بیانگر دقت بیشتر روش ماشین بردار پشتیبان نسب به روش حداکثر احتمال است (جدول ۲). در نهایت، در روش طبقه‌بندی شیءگرا صحت کلی آنها بین ۸۵ تا ۹۸ درصد و ضریب کاپا آنها بین ۰/۶۷ تا ۰/۹۶ متغیر بود (جدول ۲). بر اساس نتایج کمترین دقت مربوط به سال ۱۹۹۷ بود.

¹ -Senekane,

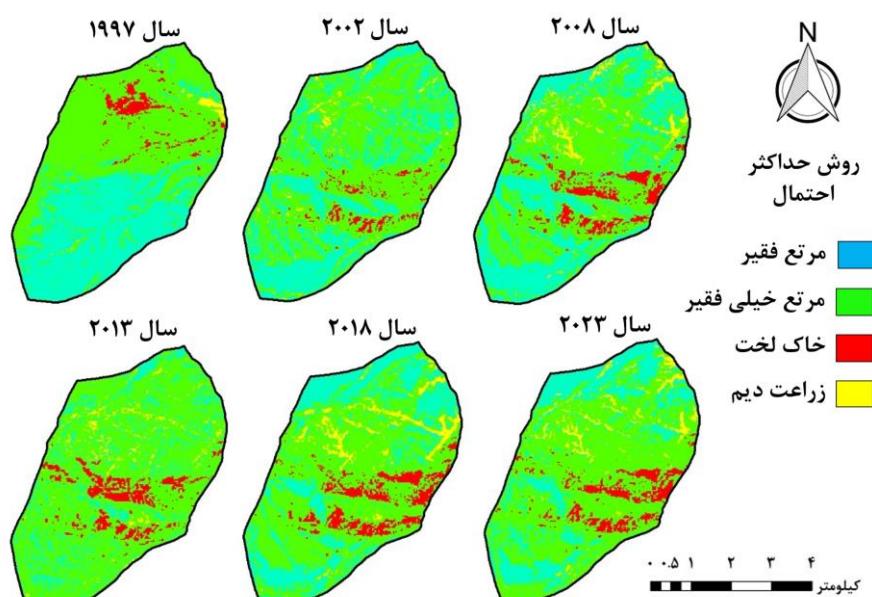
² -Dhingra & Kumar,

³ -Thakkar

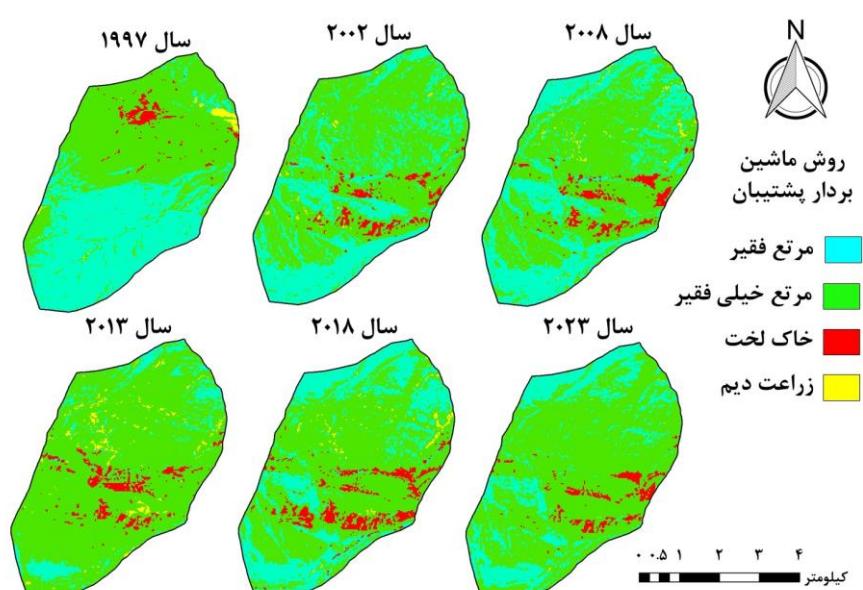
⁴ -Mirzaei

جدول (۲) ارزیابی دقت نقشه‌های کاربری اراضی در دوره‌های زمانی مختلف

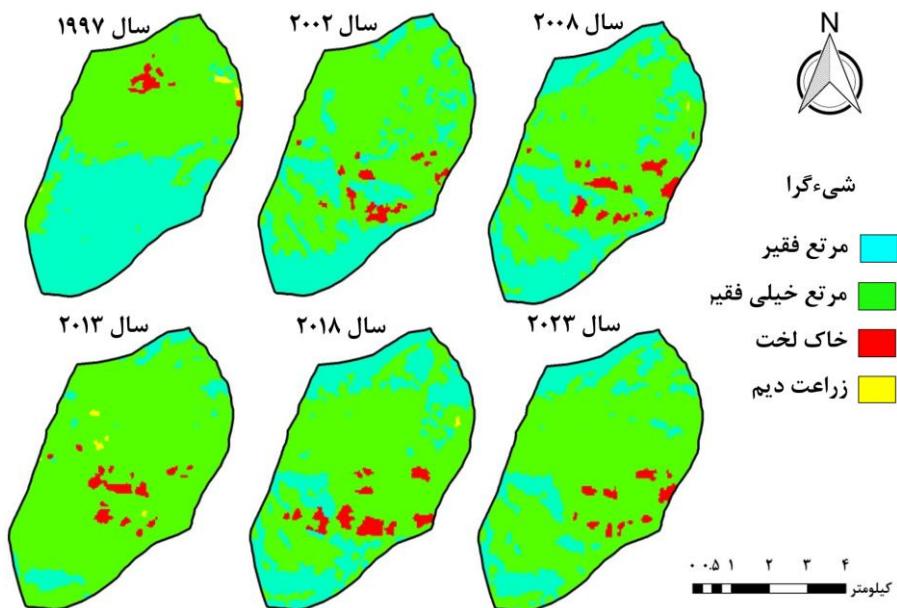
شی گرا		ماشین بردار پشتیبان		حداکثر احتمال شباهت		دوره زمانی
ضریب کاپا	صحت کلی (درصد)	ضریب کاپا	صحت کلی (درصد)	ضریب کاپا	صحت کلی (درصد)	
۰/۹۷۱۹	۸۵/۸۳	۰/۷۰۶۲	۸۶/۷۳	۰/۵۹۰۸	۶۳/۱۸	۱۹۹۷
۰/۹۴۴۷	۹۷/۷۳	۰/۸۲۲۳	۹۲/۴۲	۰/۷۲۳۴	۸۶/۸۳	۲۰۰۲
۰/۹۲۷۹	۹۶/۲۷	۰/۸۲۲۲	۹۱/۱۱	۰/۷۵۹۱	۸۶/۵۲	۲۰۰۸
۰/۹۵۷۴	۹۷/۶۲	۰/۹۸	۹۸/۸۶	۰/۹۵۰	۹۷/۲۳	۲۰۱۳
۰/۹۳۸۴	۹۷/۲۷	۰/۹۴۳۱	۹۷/۴۱	۰/۷۸۷۱	۸۸/۹۰	۲۰۱۸
۰/۹۰۸۹	۹۶/۳۲	۰/۸۵۵۸	۹۳/۹۸	۰/۷۲۱۱	۸۶/۵۱	۲۰۲۳



شکل (۲) نقشه کاربری اراضی مرتع جیرانسو بر اساس روش حداکثر احتمال



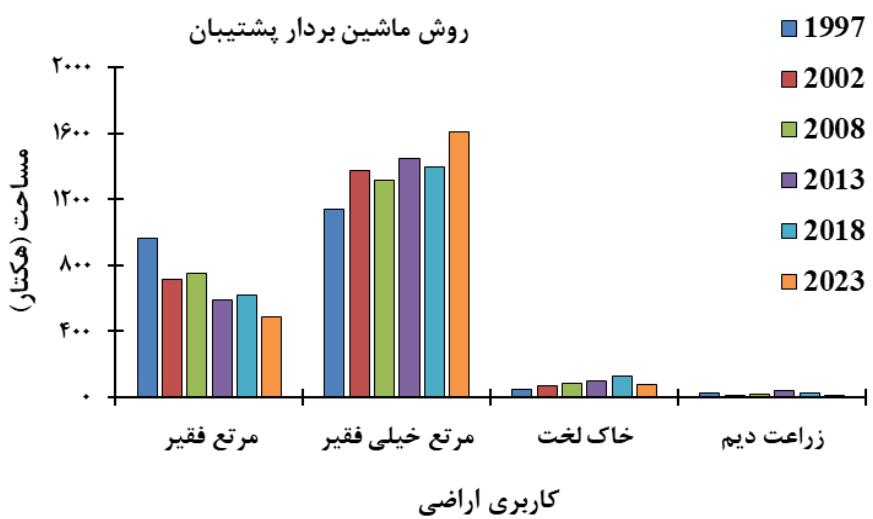
شکل (۳) نقشه کاربری اراضی مرتع جیرانسو بر اساس روش ماشین بردار پشتیبان



شکل (۴) نقشه کاربری اراضی مرتع جیرانسو بر اساس روش شیء‌گرا

روند تغییرات کاربری اراضی

بر اساس نتایج، مرتع با وضعیت فقیر دارای روند کلی کاهشی و کاربری‌های مرتع خیلی فقیر، اراضی بدون پوشش و زراعت دیم دارای روندهای افزایشی بودند. برای مثال، مساحت اراضی مرتعی فقیر از ۹۶۲ هکتار (۴۴/۳۶ درصد) در سال ۱۹۹۷ به ۴۸۹ هکتار (۲۲/۵۷ درصد) در سال ۲۰۲۳ کاهش یافتند در حالی که مرتع خیلی فقیر در مدت مشابه از ۱۱۳۸ هکتار (۵۲/۴۸ درصد) به ۱۶۰۶ هکتار (۷۴/۰۵ درصد) افزایش یافتند (شکل ۵). همچنین، در خلال سال‌های ۱۹۹۷ تا ۲۰۲۳ اراضی بدون پوشش از ۴۵ هکتار (۲/۰۸ درصد) به ۷۲ هکتار (۳/۳۳ درصد) افزایش یافت.

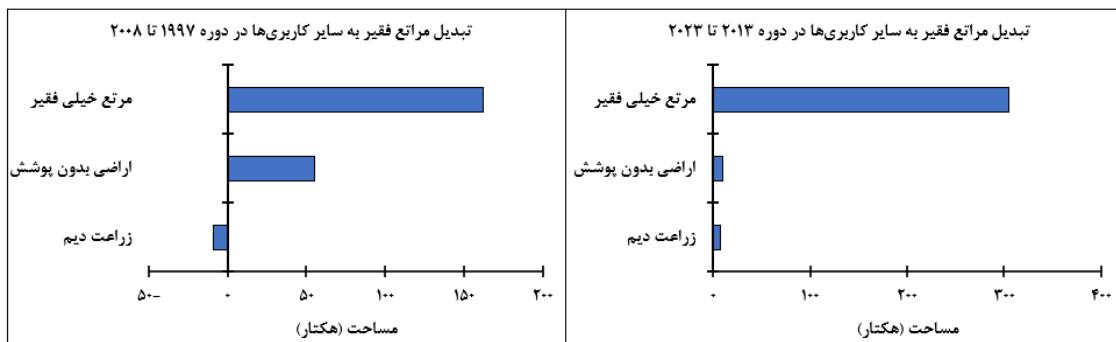


شکل (۵) بررسی تغییرات سطح کاربری‌های اراضی مختلف در مرتع جیرانسو با روش ماشین بردار پشتیبان

بررسی تغییرات کاربری اراضی مرتع فقیر به سایر کاربری‌ها

بر اساس نتایج بدست آمده، در دوره ۱۹۹۷-۲۰۰۸، به ترتیب ۱۶۲ و ۵۵ هکتار از اراضی مرتعی فقیر کاهش و به اراضی مرتعی

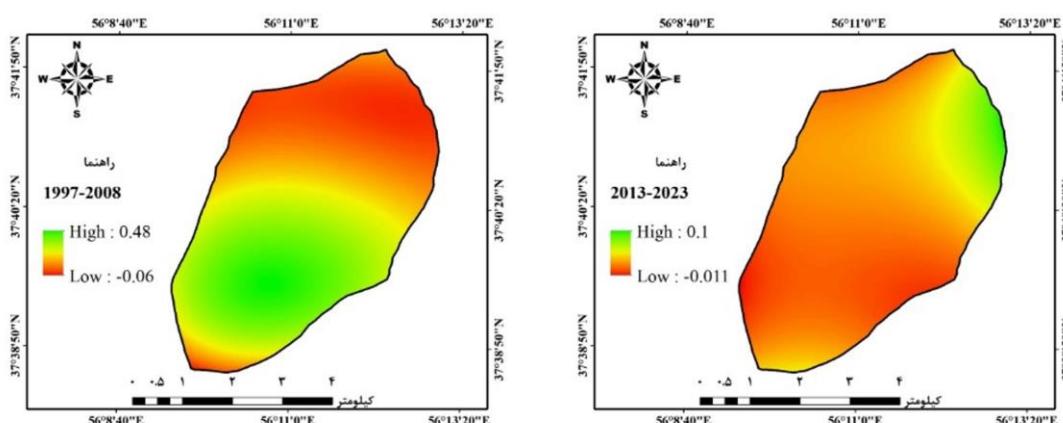
خیلی فقیر و اراضی بدون پوشش تبدیل شده است. همچنین، در این دوره، حدود ۹ هکتار از اراضی زراعت دیم کاسته و به اراضی مرتعی فقیر اضافه شده است (شکل ۶). بررسی میزان تبدیل اراضی مرتعی فقیر به سایر کاربری‌ها در دوره ۲۰۲۳-۲۰۱۳ نیز مشابه با دوره قبل نشان داد که بیشترین میزان از اراضی مرتعی فقیر کاهش یافته (از بین رفته) به اراضی مرتعی خیلی فقیر تبدیل شده‌اند. بر اساس نتایج، در این دوره در مجموع ۳۲۳ هکتار از اراضی مرتعی فقیر کاهش یافته که به ترتیب ۳۰۵، ۱۰ و ۸ هکتار از آن به اراضی مرتعی خیلی فقیر، اراضی بدون پوشش و زراعت دیم تبدیل شده است (شکل ۶).



شکل (۶) بررسی تبدیل اراضی مرتعی فقیر به سایر کاربری‌ها در دوره ۱۹۹۷-۲۰۰۸ و دوره ۲۰۱۳-۲۰۲۳

بررسی الگوی مکانی تغییرات کاربری اراضی

بر اساس نتایج بدست آمده، بیشترین میزان تغییرات در دوره ۱۹۹۷-۲۰۰۸ مربوط به نواحی مرکزی تا جنوبی مرتع جیرانسو بود (شکل ۷). در حالی که کمترین میزان تغییرات در نواحی شمالی، شمال شرق و شمال غرب مرتع جیرانسو مشاهده شد. بررسی الگوی مکانی تغییرات در دوره ۲۰۱۳-۲۰۲۳ نشان داد که بر اساس ضرایب بدست آمده، شدت تغییرات در این دوره از دوره قبلی (۱۹۹۷-۲۰۰۸) کمتر بود (شکل ۷). بر اساس نتایج، در این دوره، بیشتر تغییرات در منطقه شمال شرق مرتع جیرانسو اتفاق افتاده است در حالی که در سایر مناطق تغییر کاربری اراضی از شدت کمتری برخودار بود (شکل ۷).

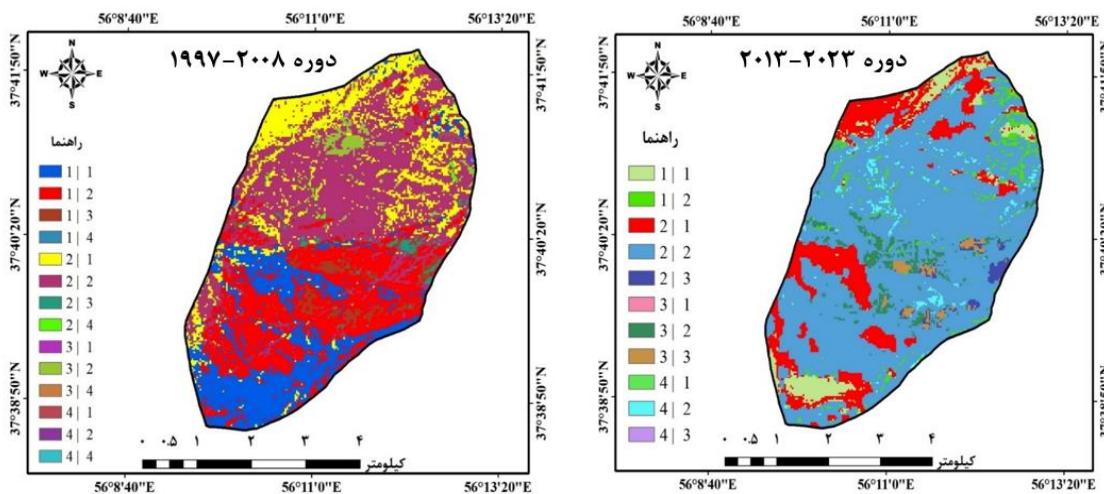


شکل (۷) الگوی مکانی تغییرات کاربری‌ها در دوره ۱۹۹۷-۲۰۰۸ و دوره ۲۰۱۳-۲۰۲۳

ارزیابی متقارن تغییرات کاربری اراضی

بر اساس نتایج، در دوره اول بیشترین مساحت از کلاس بدون تغییر مربوط به اراضی مرتعی خیلی فقیر (۵۱۳/۳۶ هکتار) و

فقیر (۳۸۷/۰۹ هکتار) بود. همچنین بیشترین میزان تغییرات مربوط به تبدیل اراضی مرتعی فقیر به خیلی فقیر (کد ۱ به ۲) بود که دارای مساحت ۵۱۳/۳۶ هکتار بودند (شکل ۸). در دوره دوم نتایج برخلاف دوره اول بدست آمد بطوری که در این دوره بیشترین تغییرات مربوط به تبدیل اراضی مرتعی خیلی فقیر به مراعع فقیر (کد ۲ به ۱) بود که دارای مساحتی ۳۶۲/۴۳ هکتار بودند. بر اساس نتایج، در دوره اول بیشترین مساحت از کلاس بدون تغییر مربوط به اراضی مرتعی خیلی فقیر (کد ۱ به ۲) و فقیر (۳۸۷/۰۹ هکتار) بود. همچنین، بیشترین میزان تغییرات مربوط به تبدیل اراضی مرتعی فقیر به خیلی فقیر (کد ۱ به ۲) بود که دارای مساحت ۵۱۳/۳۶ هکتار بودند (شکل ۸). به علاوه، در حدود ۳۰/۵۱ هکتار از اراضی مرتعی خیلی فقیر به اراضی بدون پوشش (کد ۲ به ۳) تبدیل شده‌اند.



شکل (۸) ارزیابی متقاطع تغییرات کاربری‌ها در دوره ۱۹۹۷-۲۰۰۸ و دوره ۲۰۱۳-۲۰۲۳. کدهای ۱، ۲، ۳ و ۴ به ترتیب بیانگر مرتع فقیر، مرتع خیلی فقیر، خاک لخت و زراعت دیم هستند.

بحث و نتیجه‌گیری

در این تحقیق برای تهیه نقشه کاربری اراضی مرتع جیرانسو از سه روش طبقه‌بندی حداکثر احتمال، ماشین بردار پشتیبان و شیءگرا استفاده شد. نتایج نشان داد که روش‌های پیکسل پایه از قبیل روش طبقه‌بندی حداکثر احتمال دارای دقت به مراتب کمتری نسبت به روش‌های یادگیری ماشینی (ماشین بردار پشتیبان) و روش طبقه‌بندی شیءگرا است در حالی که در دو روش طبقه‌بندی ماشین بردار پشتیبان و روش طبقه‌بندی شیءگرا دقت بالایی مشاهده شد. در همین راستا، بسیاری از تحقیقات بر کارائی بالاتر روش‌های نوین طبقه‌بندی تصاویر ماهواره‌ای از قبیل طبقه‌بندی شیءگرا (امیدی‌پور و همکاران، ۱۳۹۲) و نیز روش‌های یادگیری ماشینی (جوzdani et al., ۲۰۱۹؛ شیخ‌موسی و همکاران، ۲۰۲۰؛ ریمال و همکاران، ۲۰۲۰؛ ها و همکاران، ۲۰۲۰) نسبت به روش‌های سنتی و مرسوم از قبیل روش حداکثر احتمال دارند. بطور کلی، اختلاف اصلی بین دو روش طبقه‌بندی پیکسل پایه و شیءگرا، در این است که روش طبقه‌بندی پیکسل پایه منجر به نتیجه‌های موضعی می‌شود که علت آن علامت‌گذاری پیکسل‌ها و یا نواحی است که با معیارهای معرفی شده مطابقت داشته‌اند. در حالی که، در روش شیءگرا تمامی تصویر به واحدهای مجزا تبدیل می‌شود (امیدی‌پور و همکاران، ۱۳۹۲). به عبارت دیگر، در روش طبقه-

^۱ Jozdani et al.,

بندی پیکسل پایه، کاربر ابتدا مناطق را به عنوان معرف برای سیستم تعریف می‌کند و در ادامه سیستم بر اساس اطلاعات مناطق معرفی شده، در مورد تعلق هر پیکسل از تصویر ماهواره‌ای تصمیم می‌گیرد (مارتینز و همکاران، ۲۰۲۰). به همین دلیل، نتایج این روش وابستگی بسیار زیادی به انتخاب صحیح نمونه‌های معرف (نمونه تعلیمی) دارد در حالی که در روش طبقه‌بندی شیءگرا بر اساس اطلاعاتی از قبل شامل (متغیر پنهانی پنجره، تشابه، فاکتور میانگین وزن و فاکتور واریانس وزن) ابتدا تصویر به مناطق همگن تبدیل می‌شود و سپس در مرحله بعد باید نمونه تعلیمی از میان این مناطق همگن انتخاب شود. به همین دلیل در روش شیءگرا میزان خطا به دلیل ایجاد مناطق همگن بسیار کمتر خواهد شد (جين و همکاران، ۲۰۱۹؛ زانگ و همکاران،^۳ ۲۰۲۰). هر چند در روش طبقه‌بندی شیءگرا صحت نتایج وابستگی زیادی به انتخاب صحیح پارامترهای قطعه‌بندی دارد و بطور معمول هیچ روش خاصی برای تعیین پارامترها وجود ندارد و تنها کاربر با آزمون و خطا به اعداد صحیح خواهد رسید به همین دلیل ممکن این عامل موجب کاهش دقیق اطلاعات بدست آمده شود (امیدی‌پور و همکاران، ۱۳۹۲؛ رضایی و همکاران، ۱۴۰۱). از طرفی دیگر، در قطعه‌بندی ممکن است مناطق کوچک حذف شده یا در سایر کاربری‌های اطراف ادغام شوند. به همین دلیل در مناطقی که دارای کاربری‌های با مساحت کوچک هستند استفاده از روش طبقه‌بندی شیءگرا نتایج چندان مناسبی ارائه نخواهد کرد. برای مثال در این تحقیق مشخص شد که اراضی زراعت دیم در سال ۲۰۰۲ دارای مساحت بسیار کمی (کمتر از ۵۰ هکتار) هستند در حالی که در روش طبقه‌بندی شیءگرا این کاربری‌های لکه‌ای و با متناظر در آن سال کاملاً حذف شده است و این تاییدی بر عدم دقیق این روش در طبقه‌بندی و تفکیک کاربری‌های لکه‌ای و با مساحت کوچک است. علاوه بر دو روش مذکور، در تحقیق حاضر از روش طبقه‌بندی ماشین بردار پشتیبان نیز برای طبقه‌بندی تصاویر ماهواره‌ای و استخراج نقشه کاربری اراضی استفاده شد. بر اساس نتایج، این روش دارای دقیق‌تر بالایی در طبقه‌بندی تصاویر ماهواره‌ای بود بطوریکه صحت کلی آنها بین ۸۶ تا ۹۹ درصد و ضریب کاپای آنها بین ۰/۷۱ تا ۰/۹۸ متغیر بود و در مجموع به عنوان بهترین روش طبقه‌بندی در این تحقیق مشخص گردید. بطور کلی، ماشین بردار پشتیبان یکی از الگوریتم‌های نظارت‌شده یادگیری ماشین است (شیخ‌موسی و همکاران، ۲۰۲۰). تاکنون بسیاری از تحقیقات بر دقیق‌تر بالای و قابلیت مناسب این روش برای طبقه‌بندی تصاویر ماهواره‌ای تاکید کرده‌اند (جوزدانی و همکاران، ۲۰۱۹).

بررسی روند تغییرات کاربری اراضی موجود در مرتع جیرانسو در سه روش مورد بررسی مشابه بود به طوری که بر اساس آن در دوره مورد بررسی، مراتع فقیر کاهش و به ازای آن، مراتع خیلی فقیر، اراضی بدون پوشش و زراعت دیم افزایش یافته بود. برای مثال، بر اساس نتایج بدست آمده از روش طبقه‌بندی ماشین بردار پشتیبان، مساحت اراضی مرتعی فقیر از ۹۶۲ هکتار (۴۴/۳۶ درصد) در سال ۱۹۹۷ به ۴۸۹ هکتار (۲۲/۵۷ درصد) در سال ۲۰۲۳ کاهش یافتند در حالی که مراتع خیلی فقیر در مدت مشابه از ۱۱۳۸ هکتار (۵۲/۴۸ درصد) به ۱۶۰۶ هکتار (۷۴/۰۵ درصد) افزایش یافتند. بررسی زمانی تغییرات کاربری اراضی در دوره ۱۹۹۷-۲۰۰۸ نشان داد که ۲۲۶ هکتار از اراضی مرتعی با وضعیت فقیر کاهش یافته است که به ترتیب ۱۶۲ و ۵۵ هکتار از این کاربری به اراضی مرتعی خیلی فقیر و اراضی بدون پوشش تبدیل شده است. همچنین در این دوره حدود ۹ هکتار از اراضی زراعت دیم کاسته و به اراضی مرتعی فقیر اضافه شده است. بررسی مکانی این تغییرات نیز نشان داد که عملده تغییرات انجام شده در نواحی مرکزی تا جنوبی مرتع جیرانسو بود. در حالی که کمترین میزان تغییرات در نواحی شمالی، شمال شرق و شمال غرب مرتع جیرانسو مشاهده شد. این در حالی بود که میزان تغییرات در دوره دوم به مراتب بیشتر

¹-Martins et al.,

²-Jin et al.,

³-Zhang et al.,

از دوره اول بود بطوریکه در این دوره در مجموع ۳۲۳ هکتار از اراضی مرتعی فقیر کاهش یافته که به ترتیب ۱۰، ۳۰۵ و ۸ هکتار از آن به اراضی مرتعی خیلی فقیر، اراضی بدون پوشش و زراعت دیم تبدیل شده است. بر اساس نتایج، در این دوره، بیشتر تغییرات در منطقه شمال شرق مرتع جیرانسو اتفاق افتاده است. بطور کلی، چرای دام با شدت زیاد و بیش از مدت زمان مجاز برای استفاده (دوره سه تا چهار ماهه) از مهمترین دلایل تخریب مرتع در ایران و بخصوص مناطق گرم و خشک است. بررسی میدانی در این منطقه نشان داد که نبود مرتع یالاقی باعث شده است تا دامداران تمام طول سال در این منطقه حضور داشته باشد و این عامل موجب ایجاد فشار بسیار زیادی بر مرتع شده و تخریب آن با سرعت بسیار زیادی در حال اتفاق فتدن است. به عبارت دیگر، وجود مرتع یالاقی و قشلاقی و همچنین کوچ در فصول مختلف، به نوعی یک سیستم چرای استراحتی است (زارع چاهوکی و آذرنیوند، ۱۴۰۱) و به مرتع این فرصت را می‌دهد که در مدتی از سال اتسارحت نموده و خدمات ناشی از چرای دارم را ترمیم کنند.

در تحقیق حاضر، رویکردهای مختلف طبقه‌بندی تصاویر ماهواره‌ای مورد مقایسه و بررسی قرار گرفت. بر اساس نتایج، دقت روش طبقه‌بندی مبتنی بر یادگیری ماشینی (ماشین بردار پشتیبان) بیش از سایر روش‌های مورد بررسی بود. بررسی روند تغییرات کاربری اراضی نشان داد که عمدۀ تغییرات در کلاس‌های وضعیت مختلف مرتع (مرتع فقیر و مرتع خیلی فقیر) اتفاق افتاد است. با توجه به کاهش مرتع فقیر و افزایش مرتع خیلی فقیر، می‌توان نتیجه‌گیری کرد که روند تغییرات پوشش گیاهی در مرتع جیرانسو در طول زمان قهقهرا و فراینده بوده و در حال تشدید می‌باشد. به همین دلیل استفاده از روش‌های مختلف احیا و اصلاح مرتع به منظور بهبود وضعیت اکوسیستمی در این منطقه ضروری است. همچنین، نتایج این بخش نشان می‌دهد که بکارگیری روش‌های استخراج نقشه کاربری اراضی دارای قابلیت بالای برای بررسی و پایش مداوم تغییرات کاربری اراضی و تعیین روند تغییرات آن‌هاست که این امر زمانی دقیق خواهد بود که از روش‌های طبقه‌بندی یادگیری ماشینی استفاده شود. بنابراین، توصیه می‌شود هم برای بررسی شرایط فعلی و هم برای بررسی و پایش اثرات عملیات‌های اصلاحی در مرتع از سنجش از دور و ابزارهای آن استفاده شود.

سپاسگزاری

پژوهش حاضر برگفته از طرح پژوهشی اداره کل امور عشاپری استان خراسان شمالی با عنوان "بررسی روند فرآینده تخریب پوشش گیاهی در استان خراسان شمالی" به شماره ۲۰۷/۱۲/۱۲۳۶۵ می‌باشد. نویسنده‌گان برخود لازم می‌دانند از زحمات و همکاری همه کارکنان این اداره تشکر و قدردانی نمایند.

منابع

- امیدی‌پور، رضا؛ مرادی، حمیدرضا؛ و آرخی، صالح (۱۳۹۲). مقایسه روش‌های طبقه‌بندی پیسکل پایه و شیء‌گرا در تهیه نقشه کاربری اراضی با استفاده از تصاویر ماهواره‌ای. مجله سنجش از دور و GIS/یران، ۳(۵)، ۹۹-۱۱۰.
- برهانی، ف.، احسانی، ا.، حسینی‌شکرابی، ح.س. (۱۴۰۲). پیش‌بینی و تحلیل مکانی‌زمانی ذرات ریز جوی و اثرپذیری آن از دما و پوشش گیاهی در سطح ایران با استفاده از رویکرد هموارسازی نمایی در پایتون. نشریه محیط زیست طبیعی، ۲(۷۶)، ۳۴۴-۳۲۵.
- برهانی، فائزه؛ احسانی، امیر هوشنگ؛ حسینی‌شکرابی، حلیا سادات (۱۳۹۵). بررسی تغییرات کاربری اراضی طی دو دهه دوره زمانی (مطالعه موردی: حوزه آبخیز ابوالعباس). پژوهشنامه مدیریت حوزه آبخیز، ۱۴(۷)، ۲۳۷-۲۴۴.

- رضایی، مجتبی؛ امیدی پور، رضا؛ رضایی، اشکان؛ نداف، محبت (۱۴۰۱). مقایسه تأثیر تغییرات روند کاربری اراضی و بارش بر دبی سالانه (مطالعه موردی حوزه آبخیز کیار). مدیریت جامع حوزه‌های آبخیز، ۲(۲)، ۷۴-۶۲.
- زارع گاریزی، آرش؛ شیخ، واحدبردی؛ سعدالدین، امیر؛ سلمان ماهینی، عبدالرسول (۱۳۹۱). شبیه‌سازی مکانی‌زمانی تغییرات گستره جنگل در آبخیز چهل چای استان گلستان با استفاده از مدل تلفیقی سلول‌های خودکار و زنجیره مارکوف. *فصلنامه علمی-پژوهشی تحقیقات جنگل و صنوبر ایران*، ۲۰(۲)، ۲۷۳-۲۸۵.
- زارع چاهوکی، محمدعلی و آذرنيوند، حسين (۱۴۰۱). اصلاح مرتع. *انتشارات دانشگاه تهران*، ۳۶۷ صفحه.
- فتاحی، محمد (۱۳۷۳). بررسی جنگل‌های بلوط زاگرس و مهمترین عوامل تخریب آن. موسسه تحقیقات جنگل‌ها و مرتع، چاپ اول، ۶۳ صفحه.
- منابع طبیعی و آبخیزداری استان خراسان شمالی (۱۳۸۸). بهبود و اصلاح مرتع/ کپه‌کاری-نهال‌کاری، شناسنامه طرح مرتعداری عشاپری جیرانسو، ۳۱ صفحه.
- Asad, M. H., & Bais, A. (2020). Weed detection in canola fields using maximum likelihood classification and deep convolutional neural network. *Information Processing in Agriculture*, 7(4), 535-545.
- Cavender-Bares, J., Gamon, J.A., & Townsend, P.A. (2020). *Remote sensing of plant biodiversity*. Springer Nature. 581 P.
- Choate, M., Rengarajan, R., Micijevic, E., & Lubke, M. (2021). Comparing geometric differences between Landsat Collection 1 to Collection 2 level-1 products. In *Earth Observing Systems XXVI*. (11829), 114-124.
- Dhingra, S., & Kumar, D. (2019). A review of remotely sensed satellite image classification. *International Journal of Electrical and Computer Engineering*, 9(3), 1720.
- Ha, N. T., Manley-Harris, M., Pham, T. D., & Hawes, I. (2020). A comparative assessment of ensemble-based machine learning and maximum likelihood methods for mapping seagrass using sentinel-2 imagery in Tauranga Harbor, New Zealand. *Remote Sensing*, 12(3), 355.
- Jin, B., Ye, P., Zhang, X., Song, W., & Li, S. (2019). Object-oriented method combined with deep convolutional neural networks for land-use-type classification of remote sensing images. *Journal of the Indian Society of Remote Sensing*, 47, 951-965.
- Jozdani, S. E., Johnson, B. A., & Chen, D. (2019). Comparing deep neural networks, ensemble classifiers, and support vector machine algorithms for object-based urban land use/land cover classification. *Remote Sensing*, 11(14), 1713.
- Kaur, S., Bansal, R. K., Mittal, M., Goyal, L. M., Kaur, I., Verma, A., & Son, L. H. (2019). Mixed pixel decomposition based on extended fuzzy clustering for single spectral value remote sensing images. *Journal of the Indian Society of Remote Sensing*, 47(3), 427-437.
- Kumar, N., Yamaç, S. S., & Velmurugan, A. (2015). Applications of remote sensing and GIS in natural resource management. *Journal of the Andaman Science Association*, 20(1), 1-6.
- Li, J., Pei, Y., Zhao, S., Xiao, R., Sang, X., & Zhang, C. (2020). A review of remote sensing for environmental monitoring in China. *Remote Sensing*, 12(7), 1130.
- Lohse, J., Doulgeris, A. P., & Dierking, W. (2019). An optimal decision-tree design strategy and its application to sea ice classification from SAR imagery. *Remote Sensing*, 11(13), 1574.
- Long, H., & Qu, Y. (2018). Land use transitions and land management: A mutual feedback perspective. *Land use policy*, 74, 111-120.
- Luo, L., Ma, W., Zhuang, Y., Zhang, Y., Yi, S., Xu, J., Long, Y., Ma, D. and Zhang, Z. (2018). The impacts of climate change and human activities on alpine vegetation and permafrost in the Qinghai-Tibet Engineering Corridor. *Ecological Indicators*, 93, 24-35.

- Martins, V. S., Kaleita, A. L., Gelder, B. K., da Silveira, H. L., & Abe, C. A. (2020). Exploring multiscale object-based convolutional neural network (multi-OCNN) for remote sensing image classification at high spatial resolution. *ISPRS Journal of Photogrammetry and Remote Sensing*, 168, 56-73.
- Mirzaei, J., Mohamadi, A., Heidarizadi, Z., Noorolahi, H., & Omidipour, R. (2015). Assessment of land cover changes using RS and GIS (case study: Zagros forests, Iran). *Journal of Materials and Environmental Science*, 6, 2565-2572.
- Ramezan, C. A., Warner, T. A., Maxwell, A. E., & Price, B. S. (2021). Effects of training set size on supervised machine-learning land-cover classification of large-area high-resolution remotely sensed data. *Remote Sensing*, 13(3), 368.
- Rimal, B., Rijal, S., & Kunwar, R. (2020). Comparing support vector machines and maximum likelihood classifiers for mapping of urbanization. *Journal of the Indian Society of Remote Sensing*, 48, 71-79.
- Schnebele, E., Tanyu, B. F., Cervone, G., & Waters, N. J. E. T. R. R. (2015). Review of remote sensing methodologies for pavement management and assessment. *European Transport Research Review*, 7(2), 1-19.
- Senekane, M. (2019). Differentially private image classification using support vector machine and differential privacy. *Machine Learning and Knowledge Extraction*, 1(1), 483-491.
- Sheykhmousa, M., Mahdianpari, M., Ghanbari, H., Mohammadimanesh, F., Ghamisi, P., & Homayouni, S. (2020). Support vector machine versus random forest for remote sensing image classification: A meta-analysis and systematic review. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 6308-6325.
- Sisodia, P. S., Tiwari, V., & Kumar, A. (2014). Analysis of supervised maximum likelihood classification for remote sensing image. In *International conference on recent advances and innovations in engineering (ICRAIE-2014) (1-4)*. IEEE.
- Smith, P., House, J.I., Bustamante, M., Sobocká, J., Harper, R., Pan, G., West, P.C., Clark, J.M., Adhya, T., Rumpel, C. & Paustian, K. (2016). Global change pressures on soils from land use and management. *Global change biology*, 22(3), 1008-1028.
- Sun, L., Li, H., Wang, J., Chen, Y., Xiong, N., Wang, Z., Wang, J. & Xu, J. (2023). Impacts of Climate Change and Human Activities on NDVI in the Qinghai-Tibet Plateau. *Remote Sensing*, 15(3), 587.
- Sun, X., Liu, L., Li, C., Yin, J., Zhao, J., & Si, W. (2019). Classification for remote sensing data with improved CNN-SVM method. *IEEE Access*, 7, 164507-164516.
- Thakkar, A., Desai, V., Patel, A., & Potdar, M. (2015). Land use/land cover classification using remote sensing data and derived indices in a heterogeneous landscape of a khan-kali watershed, Gujarat. *Asian Journal of Geoinformatics*, 14(4), 1-12.
- Verbyla, D.L. (2022). *Satellite remote sensing of natural resources*. CRC Press.
- Yang, J., Weisberg, P. J., & Bristow, N. A. (2012). Landsat remote sensing approaches for monitoring long-term tree cover dynamics in semi-arid woodlands: Comparison of vegetation indices and spectral mixture analysis. *Remote sensing of environment*, 119, 62-71.
- Zhang, C., Yue, P., Tapete, D., Shangguan, B., Wang, M., & Wu, Z. (2020). A multi-level context-guided classification method with object-based convolutional neural network for land cover classification using very high-resolution remote sensing images. *International Journal of Applied Earth Observation and Geoinformation*, 88, 102086.

Zhou, L., Tian, Y., Myneni, R.B., Ciais, P., Saatchi, S., Liu, Y.Y., Piao, S., Chen, H., Vermote, E.F., Song, C. & Hwang, T. (2014). Widespread decline of Congo rainforest greenness in the past decade. *Nature*, 509(7498), 86-90.

Zhu, L., Huang, L., Fan, L., Huang, J., Huang, F., Chen, J., Zhang, Z. and Wang, Y., 2020. Landslide susceptibility prediction modeling based on remote sensing and a novel deep learning algorithm of a cascade-parallel recurrent neural network. *Sensors*, 20(6), 1576.