

ارزیابی مناسب‌ترین الگوریتم یادگیری ماشین در طبقه‌بندی تصاویر ماهواره‌ای و آشکارسازی تغییرات کاربری/ پوشش اراضی در حوضه آبخیز گرگان‌رود

ادیت عیشویی^۱، میرحسن میریعقوب‌زاده^{۲*}، کاکا شاهدی^۳

تاریخ دریافت: ۱۴۰۴/۰۹/۲۹

تاریخ پذیرش: ۱۴۰۴/۱۱/۲۷

چکیده

آگاهی از نسبت کاربری اراضی و نحوه تغییرات آن در گذر زمان یکی از مهم‌ترین مسائل برنامه‌ریزی زیست‌محیطی می‌باشد. در تحقیق حاضر به منظور ارزیابی مناسب‌ترین الگوریتم‌های یادگیری ماشین در طبقه‌بندی تصاویر ماهواره‌ای از تصاویر ماهواره‌ای لندست ۸ طی سال‌های ۲۰۱۳، ۲۰۱۷ و ۲۰۱۹ در حوضه گرگان‌رود استان گلستان استفاده شده است. به منظور آشکارسازی تغییرات کاربری/ پوشش اراضی از الگوریتم تفاضل تصویر استفاده گردید. همچنین به منظور ارزیابی دقت الگوریتم‌های طبقه‌بندی از نمونه‌های تعلیمی به روش پیمایش زمینی استفاده گردید. نتایج حاصل از ضریب کاپا در به‌کارگیری الگوریتم‌های طبقه‌بندی ماشین بردار پشتیبان و جنگل تصادفی به ترتیب ۰/۷۹ و ۰/۷۷ در سال ۲۰۱۹ و ۰/۷۹ و ۰/۸۱ در سال ۲۰۱۷ و ۰/۸۶ و ۰/۷۹ در سال ۲۰۱۳ به دست آمد که بیانگر دقت مناسب‌تر در طبقه‌بندی تصاویر ماهواره‌ای و همچنین کارایی تصاویر لندست ۸ در تهیه نقشه کاربری اراضی می‌باشد. نتایج حاصل از آشکارسازی تغییرات کاربری اراضی نشان می‌دهد که در طول سال‌های ۲۰۱۳ تا ۲۰۱۹ پوشش جنگلی در منطقه مورد مطالعه تغییرات اندکی داشته است. با توجه به وضعیت توپوگرافی منطقه و سکونت آبخیزنشینان در رقوم ارتفاعی مختلف، منطقه مورد مطالعه در معرض خطر کاهش پوشش جنگلی و افزایش اراضی دیم در اراضی شیب‌دار و متعاقباً وقوع سیلاب قرار دارد.

واژگان کلیدی: آشکارسازی تغییرات کاربری اراضی، لندست، جنگل تصادفی، ماشین بردار پشتیبان، گرگان‌رود.

۱- گروه مهندسی مرتع و آبخیزداری، دانشکده منابع طبیعی، دانشگاه ارومیه، ارومیه، ایران

۲- دانشگاه ارومیه، دانشکده منابع طبیعی، گروه مهندسی مرتع و آبخیزداری، ایمیل نویسنده مسئول: m.miryaghoubzadeh@urmia.ac.ir

۳- گروه مهندسی مرتع و آبخیزداری، دانشکده منابع طبیعی، دانشگاه علوم کشاورزی و منابع طبیعی ساری، ساری، ایران

مقدمه

پیکسل، آن را در کلاس یا طبقه‌ای که به رفتار طیفی پیکسل نزدیک‌تر است قرار می‌دهد (جهانبخشی و اختصاصی، ۲۰۱۹).

در سال‌های اخیر، الگوریتم‌های متنوعی برای طبقه‌بندی کاربری‌ها با استفاده از علم سنجش از دور توسعه یافته‌اند؛ بنابراین، انتخاب الگوریتم مناسب طبقه‌بندی جهت دستیابی به نتایج دقیق نقش مهمی را ایفا می‌کند. در بین الگوریتم‌های مبتنی بر احتمال الگوریتم حداکثر شدت احتمال رایج‌ترین و یکی از دقیق‌ترین نوع طبقه‌بندی شناخته شده است (دانشی و پناهی، ۲۰۱۶). الگوریتم ماشین بردار پشتیبان به پدیده‌های فضا‌های چندبعدي حساسیت کمتری دارد، به همین علت در طبقه‌بندی داده‌های چند طیفی و ابر طیفی روش مناسبی به شمار می‌رود. یکی از مزایای الگوریتم ماشین بردار پشتیبان این است که با نمونه‌های تعلیمی کوچک نیز می‌تواند دقت تصویر طبقه‌بندی شده خوبی را ارائه دهد. در نتیجه، هزینه‌ها کاهش یافته و سرعت طبقه‌بندی افزایش پیدا می‌کند (دانشی و پناهی، ۲۰۱۶). (متکان و حاجب، ۲۰۱۳)، سه روش طبقه‌بندی کننده ماشین بردار پشتیبان، شبکه عصبی مصنوعی و حداکثر شدت احتمال را در فیلترکردن عوارض دارای نویز مورد بررسی قرار دادند و بدین منظور داده‌های لیدار مورد استفاده قرار گرفتند. آن‌ها پنج کلاس را که فیلتر نشده بودند را با استفاده از روش‌های ذکر شده فیلتر نموده و نویزها را حذف کردند. ارزیابی آن‌ها نشان داد که روش شبکه عصبی مصنوعی در مقایسه با ماشین بردار پشتیبان و حداکثر شدت احتمال کارایی بهتری در حذف نویزها داشته و در مقابل، روش حداکثر شدت احتمال عملکرد ضعیف‌تری را نشان داده است. (زارع و همکاران، ۲۰۱۷)، تغییرات کاربری اراضی شهرستان نور را در بازه زمانی ۲۸ ساله از ۱۹۸۶ تا ۲۰۱۳ با استفاده از تصاویر ماهواره‌ای لندست ۵ TM بررسی نمودند. در این مطالعه از روش طبقه‌بندی حداکثر شدت احتمال استفاده نمودند. نتایج مطالعه آن‌ها نشان داد که بیشترین تغییرات مربوط به تبدیل اراضی کشاورزی به مسکونی بوده به طوری که ۵ برابر رشد در طی این ۲۸ سال

پدیده تغییر کاربری اراضی یکی از مخاطرات محیطی و بحران‌های اکولوژیکی است که امروزه جهان با آن روبه‌رو می‌باشد. کاربری اراضی، استفاده خاص انسان از زمین بوده و یکی از مهم‌ترین جنبه‌های بررسی مدیریت منابع طبیعی و بازنگری تغییرات محیطی است. در حال حاضر تغییر غیراصولی کاربری زمین از مهم‌ترین مسائل سرزمینی کشور است، چراکه تغییر اکثر کاربری‌ها غالباً بدون در نظر گرفتن محدودیت‌های زیست‌محیطی صورت می‌گیرد که از آن جمله می‌توان به رشد بی‌رویه شهرها و افزایش آلودگی منابع، از بین رفتن سطح وسیعی از جنگل‌ها، فرسایش زمین‌های کشاورزی، وقوع سیل‌های مخرب ناشی از تبدیل غیراصولی پوشش اراضی اکوسیستم‌های بیابانی و اعمال روش‌های نادرست بهره‌برداری از کاربری اشاره نمود (بنیادامیر و حاجی قادری، ۲۰۰۷؛ مظاهری و همکاران، ۲۰۱۳؛ موسوی و همکاران، ۲۰۱۵؛ کرمی و همکاران، ۲۰۱۵؛ رحمانی و همکاران، ۲۰۱۶؛ ساها و همکاران، ۲۰۲۴). استفاده از دانش سنجش از دور در مطالعات کاربری اراضی و تهیه نقشه‌های کاربری اراضی، باتوجه به اهمیت بررسی تغییرات کاربری و پوشش اراضی و تعیین برنامه‌های مدیریتی هماهنگ و یکپارچه، موفقیت‌های بسیاری را به دنبال داشته است (مظاهری و همکاران، ۲۰۱۳). نقشه‌های کاربری اراضی مهم‌ترین فاکتورهای مطالعات منابع طبیعی و محیط‌زیست و یکی از پرهزینه‌ترین بخش‌های پروژه‌های محیط‌زیست و منابع طبیعی می‌باشند (موسوی‌نژاد و همکاران، ۲۰۱۷) که اطلاعات پایه را برای مدیریت و پایش سیستم‌های محیطی فراهم می‌کنند. ارزش و قابلیت استفاده از هر نقشه تولید شده با استفاده از تصاویر ماهواره‌ای به درجه دقت و صحت و به فاکتورهای نظیر صحت داده‌های اولیه و روش طبقه‌بندی تصاویر ماهواره‌ای بستگی دارد. طبقه‌بندی اطلاعات ماهواره‌ای، ابتدا مجموعه‌های طیفی مشابه را جداسازی نموده و سپس رفتار طیفی مشابه را در طبقات مربوط تقسیم‌بندی می‌نماید. در طبقه‌بندی تصاویر ماهواره‌ای، الگوریتم طبقه‌بندی باتوجه به ارزش عددی هر

و چندجمله‌ای^۴ با پارامترهای بهینه با هدف تعیین کاربری اراضی مورد استفاده قرار گرفتند. نتایج آن‌ها نشان دادند که روش ماشین بردار پشتیبان به‌ویژه تابع رادیال کرنل در مقایسه با روش دیگر کارایی بهتری دارد. (کافی^۵ و همکاران، ۲۰۲۲)، اثرات تغییرات کاربری اراضی را بر روی ویژگی‌های دما با استفاده از الگوریتم یادگیری ماشین مورد بررسی قرار دادند. به این منظور تصاویر ماهواره‌ای TM و OLI بین سال‌های ۲۰۲۰-۱۹۹۵ و این داده‌ها به‌عنوان آموزش مدل جهت پیش‌بینی سال‌های ۲۰۳۰-۲۰۲۵ مورد استفاده قرار گرفتند. نتایج پیش‌بینی نشان دادند که احتمالاً در بین سال‌های ۲۰۳۰-۲۰۲۵ اراضی مسکونی تا ۴۲٪ افزایش مساحت خواهند داشت و در مقابل، ۲۲٪ اراضی سبز و ۲۱٪ اراضی بایر کاهش خواهند داشت. هدف از این مطالعه انتخاب مناسب‌ترین الگوریتم طبقه‌بندی داده‌های سنجنش از دوری در منطقه مورد مطالعه می‌باشد. بدین منظور آشکارسازی تغییرات کاربری اراضی و پوشش زمین در حوزه گرگان‌رود واقع در استان گلستان مورد تحلیل و بررسی قرار گرفت و سه روش ماشین بردار پشتیبان، جنگل تصادفی و حداکثر شدت احتمال مورد مقایسه قرار گرفتند.

مواد و روش‌ها

منطقه مورد مطالعه

حوزه آبخیز گرگان‌رود در محدوده جغرافیایی طول شرقی ۱۰° ۵۴' تا ۲۵° ۵۶' و عرض شمالی ۳۵° ۳۶' تا ۱۰° ۳۸' واقع شده است که مساحتی بالغ بر ۱۱ هزار کیلومترمربع شامل می‌گردد. این حوزه از جنوب مشرف به سلسله کوه‌های البرز، از شرق به کوه‌های آلاداغ و گلی داغ، از شمال به حوزه آبخیز اترک و از غرب به دریای خزر مشرف می‌باشد (عظیمی و همکاران، ۲۰۱۹). شکل ۱ موقعیت جغرافیایی منطقه را در کشور نشان می‌دهند. در پژوهش حاضر داده‌های سنجنده OLI ماهواره لندست مربوط به سال‌های ۲۰۱۳ و ۲۰۱۷ و ۲۰۱۹ مورد استفاده قرار گرفتند.

رخ داده است. (کاظمی و همکاران، ۲۰۱۷)، به بررسی و انتخاب بهترین روش طبقه‌بندی در تهیه نقشه کاربری اراضی با استفاده از داده‌های ماهواره‌ای لندست ۸ (OLI) در استان فارس پرداختند. در این مطالعه، آن‌ها ۸ الگوریتم و روش مختلف از جمله ماشین بردار پشتیبان، حداکثر شدت احتمال، حداقل فاصله از میانگین، سطوح موازی، فاصله ماهالانوبیس، نقشه بردار زاویه طیفی، واگرایی اطلاعات کیفی و کدهای باینری را مورد بررسی و مقایسه قرار دادند. نتایج آن‌ها حاکی از آن است که دو روش ماشین بردار پشتیبان و حداکثر شدت احتمال با صحت کلی ۹۸/۷ و ۹۸/۹ و ضریب کاپا ۹۸ و ۹۸/۴ به ترتیب، نسبت به دیگر روش‌ها دقت بالاتری داشته و عملکرد بهتری در تهیه کاربری اراضی نشان دادند. (تقدسی و حسنلو، ۲۰۱۹)، روش‌های طبقه‌بندی نظارت شده را در تهیه نقشه شوری خاک مورد ارزیابی و مقایسه قرار دادند. الگوریتم‌های مورد مطالعه شامل حداقل فاصله از میانگین، فاصله ماهالانوبیس، سطوح موازی، حداکثر شدت احتمال و ماشین بردار پشتیبان بودند. نتایج حاصل از طبقه‌بندی با استفاده از روش‌های مورد بررسی نشان داد که روش ماشین بردار پشتیبان با دقت کلی ۹۲٪ و ضریب کاپا ۰/۸۹ در مقایسه با سایر روش‌ها دقت بالاتری داشته است. (باقری‌فر و همکاران، ۲۰۲۳)، دو الگوریتم شبکه عصبی مصنوعی و حداکثر شدت احتمال را با استفاده از تصاویر ماهواره‌ای سنجنده‌های TM و ETM⁺ را بین سال‌های ۱۳۶۹ و ۱۳۹۰ در تغییرات کاربری اراضی جنگلی مورد ارزیابی قرار دادند. براساس نتایج حاصل از مطالعه آن‌ها، الگوریتم شبکه مصنوعی با داشتن ضریب کاپا ۰/۹۹ در تشخیص اراضی جنگلی و تغییرات کاربری در این منطقه، کارایی بهتری نسبت به روش حداکثر شدت احتمال ارائه کرده است. (کاواوزوغلوا^۱ و چولکسن^۲، ۲۰۰۹)، تابع کرنل را در روش ماشین بردار پشتیبان با هدف طبقه‌بندی کاربری اراضی و استفاده از تصاویر ماهواره‌ای ETM⁺ و Terra ASTER مورد استفاده قرار دادند. توابع کرنل شعاعی^۳

¹ Kavazoglu

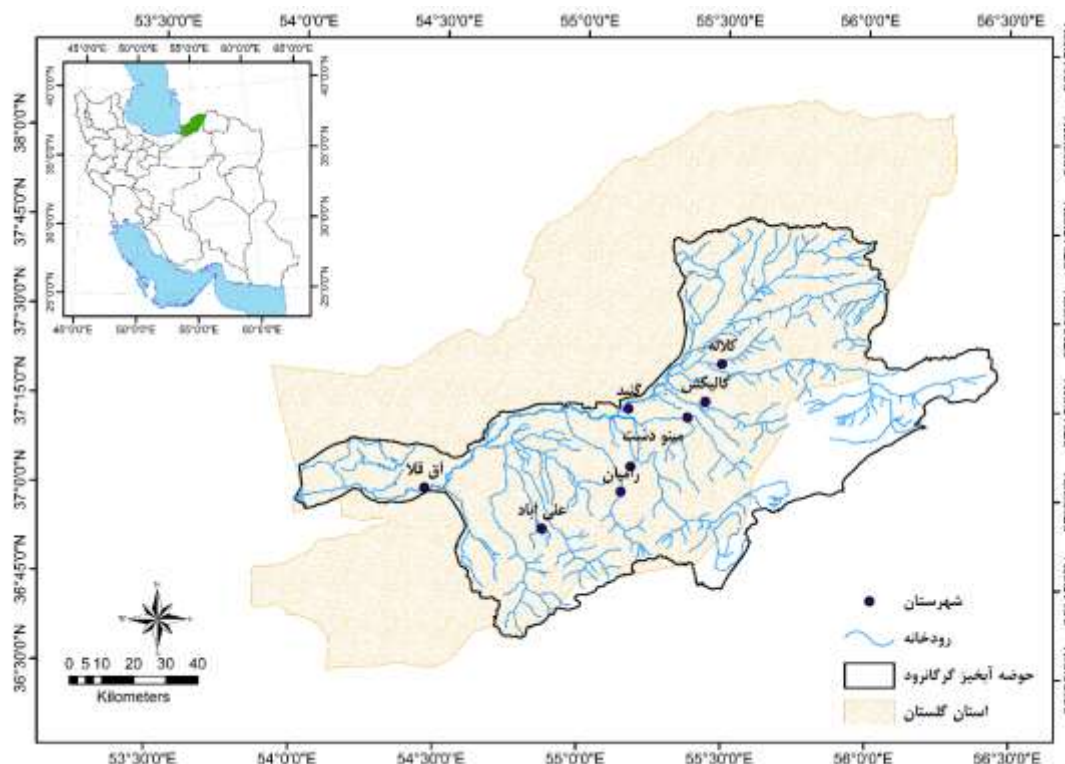
² Colkesen

³ Radial

⁴ Polynomial

⁵ Al-Kafy

تصاویر چند زمانه مورد استفاده در این مطالعه در جدول ۱ آورده شده است.



شکل (۱): موقعیت جغرافیایی حوضه آبخیز گرگانرود

Figure (1): location of Gorganroud basin

جدول (۱): تصاویر چند زمانه مورد استفاده

Table (1): Utilized multi temporal imagery

ماهواره	سنجنده	تاریخ گذر ماهواره
Landsat 8	OLI	2013.05.03
Landsat 8	OLI	2017.04.06
Landsat 8	OLI	2019.08.14

پیش پردازش تصاویر ماهواره‌ای

عموماً به منظور طبقه‌بندی و آشکارسازی تغییرات کاربری اراضی نیاز به انجام تصحیحات رادیومتریک و تصحیحات ارتفاع خورشید و فاصله زمین تا خورشید می‌باشد. طی این فرآیند، داده‌های تصویر مورد نیاز تحت زوایای مختلف خورشید با محاسبه تابش در هر پیکسل نرمال‌سازی می‌شوند و فرض بر این است که در لحظه تصویربرداری، خورشید در نقطه اوج نسبت به زمین قرار داشته است و با تقسیم مقدار

هر پیکسل تصویر به سینوس زاویه ارتفاع خورشید در زمان و مکان مشخص به دست می‌آید. تصحیحات فاصله زمین-خورشید جهت نرمال‌سازی تغییرات فصلی در فاصله بین زمین و خورشید انجام می‌شوند (لیلساند^۱ و همکاران، ۲۰۰۴). در این تحقیق، تصحیحات رادیومتریک با روش Chavez و Dark Subtraction انجام شد. همچنین سیگنال دریافتی ماهواره ممکن است تحت تأثیر گردوغبار، گازها،

¹ Lillesand

شاخص جینی^۷ اشاره کرد. الگوریتم جنگل تصادفی از شاخص جینی به‌عنوان محاسبه‌کننده و انتخاب پیکسل استفاده می‌کند. این کلاسه‌بندی نمونه‌های تعلیمی را برای تخمین مورد استفاده قرار می‌دهد. درخت‌ها در جنگل تصادفی با رسم نمونه تعلیمی به روش جایگزینی ایجاد می‌شوند بدین معنی که هر نمونه مشابه می‌تواند چندین بار توسط الگوریتم انتخاب گردد تا در نهایت در بهترین کلاس مدنظر تخصیص داده شود. در این روش تقریباً دوسوم نمونه‌ها برای تعلیم درخت‌ها و یک‌سوم باقیمانده برای اعتبارسنجی استفاده می‌شوند (رودریگز گالیانو و همکاران، ۲۰۱۲). در کلاسه‌بندی جنگل تصادفی به دلیل تصادفی بودن انتخاب نمونه‌های تعلیمی برخی داده‌ها چندین بار استفاده شده و برخی از آن‌ها هرگز استفاده نمی‌شوند. درحالی‌که پایداری کلاسه‌بندی‌کننده زمانی حاصل می‌شود که داده‌های ورودی با انجام تغییرات کوچک قوی‌تر شده و در نتیجه دقت طبقه‌بندی افزایش می‌یابد (رودریگز گالیانو و همکاران، ۲۰۱۲).

الگوریتم ماشین بردار پشتیبان (SVM)

الگوریتم ماشین بردار پشتیبان، براساس تئوری یادگیری آماری توسعه داده شده است و هدف آن تخمین مکان مرز تصمیم‌گیری است که کلاس‌ها در حالت بهینه تفکیک می‌شوند (واپنیک^۸، ۱۹۹۵). در موضوع تشخیص الگوی دو کلاس از هم تفکیک می‌شوند، بردار خطی مرزی را تعیین کرده و این دو کلاس را از هم جدا می‌کند. اندازه مرز جداکننده از حاصل جمع فاصله نقاط با ابرصفحه^۹ بردار پشتیبان به دست می‌آید (واپنیک^{۱۰}، ۱۹۹۵). تابع کرنل جهت کاهش هزینه محاسبه فضای پیکسلی مورد استفاده قرار می‌گیرد (واپنیک^{۱۱}، ۱۹۹۵؛ کریستیانتی^{۱۲} و تایلور^{۱۳}، ۲۰۰۰؛ پال، ۲۰۰۵؛ کائو و همکاران، ۲۰۰۹). ماشین‌های بردار

ابر، مواد جامد و مایع معلق در فضا قرار گرفته باشند و نتایج را مورد تأثیر خود قرار دهند. رادیانس محاسبه شده در نزدیکی سنجنده در بالای اتمسفر^۱ در نظر گرفته می‌شود که اثرات مواد معلق در فضا بر روی آن بایستی تصحیح گردند (لوپز-سرانو^۲ و همکاران، ۲۰۱۶؛ اسلام^۳ و همکاران، ۲۰۱۸). در تحقیق حاضر از روش FLAASH به‌منظور تصحیحات اتمسفریک استفاده گردید. همچنین به‌منظور آماده‌سازی تصاویر ماهواره‌ای جهت پردازش از الگوریتم همگام‌سازی هیستوگرام^۴ استفاده گردید. در این روش، داده‌های جدید پانکروماتیک با مؤلفه‌های شدت که از داده‌های RGB چندطیفی حاصل شده‌اند، از طریق هیستوگرام داده، همگام می‌شوند (لیلساند^۵ و همکاران، ۲۰۰۴). در روش همگام‌سازی هیستوگرام، توزیع مقدار پیکسل براساس فراوانی آن‌ها می‌باشد و عموماً به‌منظور افزایش کنتراست در پدیده‌هایی با تراکم و فراوانی بالا تأثیر بیشتری دارد (داودپور و ترنج‌زور، ۲۰۱۸).

الگوریتم جنگل تصادفی (RF)

الگوریتم جنگل تصادفی یکی دیگر از الگوریتم‌های یادگیری ماشین مبتنی بر ترکیب طبقه‌بندی درختی است که در آن هر کدام از کلاسه‌بندی‌ها با استفاده از وکتور تصادفی مستقل از وکتور ورودی ایجاد می‌شود و هر درخت برای هر وکتور یک گزینه کلاس را تعیین می‌کند که بیشترین تطابق را با هر کلاس داشته باشد و در آن کلاس قرار می‌گیرد (پال، ۲۰۰۵). در مطالعه (پال، ۲۰۰۵)، الگوریتم جنگل تصادفی در پیکسل‌هایی که به‌طور تصادفی انتخاب شده‌اند یا ترکیبی از پدیده‌هایی که هر گره نشان‌دهنده یک درخت است، به‌کاربرده شده است. روش‌های متعددی برای انتخاب پیکسل‌ها جهت استفاده در درخت تصمیم‌گیری وجود دارد. از پرکاربردترین روش‌ها می‌توان به ضریب معیار نسبی^۶ و

⁷ Gini Index

⁸ Vapnik

⁹ HyperPlane

¹⁰ Vapnik

¹¹ Vapnik

¹² Cristianti

¹³ Taylor

¹ Top Of Atmosphere

² López-Serrano

³ Islam

⁴ Histogram Matching

⁵ Lillesand

⁶ Gain Ratio Criterion

واریانس و کوواریانس آن تعریف می‌شوند. این تابع چگالی احتمال برای محاسبه حداکثر شدت احتمال پیکسل‌های هر کلاس طیفی مورد استفاده قرار می‌گیرند. پیکسل‌ها در کلاسی که بیشترین احتمال را به خود اختصاص دهند قرار می‌گیرند (بولشتاد^۵ و لیلساند^۶، ۱۹۹۱).

تعیین دقت نقشه‌های کاربری اراضی

به منظور تعیین دقت نقشه‌های طبقه‌بندی شده از روش تحلیل ماتریس خطا استفاده گردید. در ماتریس خطا داده‌های مرجع (ستون‌های ماتریس) با داده‌های طبقه‌بندی شده (ردیف‌های ماتریس) مقایسه می‌گردند (جدول ۴). در اغلب موارد شاخص کاپا برای تعیین دقت نتایج حاصل از روش-های مختلف طبقه‌بندی استفاده می‌شود (نظری سامانی و همکاران، ۲۰۱۰). دقت کلی و ضریب کاپا طبق معادلات زیر محاسبه می‌گردد (میریعیقوبزاده و قنبرپور، ۲۰۱۰).

$$OA = \frac{1}{N} \sum P_{ii}$$

که در آن، N: تعداد کل پیکسل‌های آزمایشی و $\sum P_{ii}$: جمع عناصر قطر اصلی ماتریس خطا می‌باشد.

$$K = \frac{\sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} \times x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} \times x_{+i})}$$

که در آن، x_{ii} : عناصر قطر اصلی، x_{+} : تعداد کلاس‌ها، x_{+i} : جمع ستون‌ها و x_{i+} : جمع ردیف‌ها می‌باشد.

نمونه‌های تعلیمی

در تعیین صحت نقشه‌های یاد شده نیاز به اطلاعات زمینی یا نمونه تعلیمی می‌باشد که طی بازدید میدانی و به صورت تصادفی در سال ۲۰۱۷ از منطقه مورد مطالعه به دست آمده است. نمونه‌های تعلیمی اساس طبقه‌بندی نظارت شده را تشکیل می‌دهند و پیکسل‌هایی هستند که به عنوان معرف هر طبقه انتخاب می‌شوند. پس از تعیین کلاس‌ها و می‌بایست نمونه‌های تعلیمی انتخاب شده و به الگوریتم مورد نظر کلاس‌بندی معرفی شوند و با این روش تشخیص پدیده‌ها و تفکیک آن‌ها از یکدیگر میسر خواهد شد

پشتیبان تکنیک نظارت شده غیر پارامتری یادگیری آماری هستند. به همین دلیل هیچ تخمینی بر توزیع داده‌ها وجود ندارد. طبق معادله اصلی این روش با نمونه سری داده‌های کدگذاری شده ارائه می‌شود و هدف الگوریتم یادگیری، یافتن یک ابرصفحه است که مجموعه داده‌ها را به تعداد از پیش تعریف شده مجزا مطابق با نمونه‌های تعلیمی تقسیم‌بندی کند. تفکیک پدیده‌ها با افزایش حاشیه بین ابرصفحه صورت می‌گیرد که این حاشیه در واقع فاصله بین نزدیک‌ترین نمونه تعلیمی یا بردار پشتیبان می‌باشد. در این روش، نمایش بردارها در یک فضای چندبعدی با استفاده از تابع کرنل صورت می‌پذیرد که ابرصفحه هر پدیده را تفکیک کرده و در کلاس مخصوص به خود قرار می‌دهد (پوتو^۱ و همکاران، ۲۰۱۱).

الگوریتم حداکثر شدت احتمال

کلاس‌بندی حداکثر شدت احتمال متداول‌ترین روش نظارت شده است که در اکثر مطالعات از آن به عنوان دقیق‌ترین روش کلاس‌بندی نام برده شده است (هوآنگ^۲ و همکاران، ۲۰۰۲؛ متکان و حاجب، ۲۰۱۳؛ کاظمی و همکاران، ۲۰۱۷؛ مددی و مظفری، ۲۰۱۹؛ ریچاردز^۳ و ریچاردز^۴، ۲۰۲۲). این کلاس‌بندی از توزیع گوسین پیروی می‌کند و در کلاس‌های چندطیفی نتایج بهتری را ارائه می‌دهد. در این روش با استفاده از شدت احتمال، پس از آزمون آماری با فرض نرمال بودن توزیع آماری، میزان تعلق هر یک از پیکسل‌های تصویر به کلاس مورد نظر محاسبه شده و هر پیکسل در کلاسی که بیشترین احتمال تعلق را به خود اختصاص دهد، قرار می‌گیرد (متکان و حاجب، ۲۰۱۳؛ کاظمی و همکاران، ۲۰۱۷؛ مددی و مظفری، ۲۰۱۹). در این روش نمونه‌های تعلیمی جهت تخمین پارامتر چگالی احتمال برای هر کلاس طیفی مورد استفاده قرار می‌گیرند. معمولاً مدل احتمال نرمال چندمتغیره برای این منظور به کار برده می‌شود و براساس نمونه‌های تعلیمی، وکتور میانگین،

¹ Pouteau

² Huang

³ Richards

⁴ Richards

⁵ Bolstad

⁶ Lillesand

(میریعیقوب‌زاده و قنبرپور، ۲۰۱۰). به لحاظ بالا بردن صحت کلاس‌بندی نیاز است تا تعداد نمونه‌های تعلیمی بیشتر در نظر گرفته شوند، چراکه هر قدر تعداد و تراکم آن‌ها بیشتر باشد، پوشش دادن تمامی نواحی پدیده طیفی مورد نظر آسان‌تر خواهد بود، به خصوص هر چه تعداد نمونه‌ها در نواحی غیرهمگن بیشتر باشند، نتیجه به دست آمده دقیق‌تر خواهد بود (میریعیقوب‌زاده و قنبرپور، ۲۰۱۰).

آشکارسازی تغییرات

به منظور شناسایی و تشخیص کاربری اراضی منطقه در ۶ کلاس پوشش گیاهی جنگلی، کشاورزی، دیم، پوشش گیاهی بدون پوشش و یا پوشش تنک، پیکره‌های آبی و مناطق مسکونی و جاده‌ها تقسیم‌بندی گردید و نقشه‌های پوشش گیاهی تولید شدند (جدول ۲). به منظور بررسی و آشکارسازی تغییرات ابتدا عملیات انطباق هیستوگرام طیفی تصاویر چند زمانه نسبت به سال پایه انجام و سپس روش تفاضل تصویر استفاده شد. در این روش، مناطقی که در آن‌ها تغییرات صورت نگرفته است، درجات روشنایی نزدیک به میانگین خواهد داشت. تغییرات با تفسیر دنباله‌های هیستوگرام آن نشان داده می‌شوند. این روش تنها حدود تغییرات را بیان می‌کند و نوع و ماهیت در این روش مورد بررسی قرار نمی‌گیرد. طبق رابطه زیر ارزش‌های رقومی تصویر در تاریخ دوم از ارزش‌های رقومی تصویر در تاریخ اول پیکسل به پیکسل کم می‌شود. نتیجه این روش تولید تصویری است که نشان‌دهنده تغییر بین دو تاریخ است (یوسفی و همکاران، ۲۰۱۱).

$$Dx = x(t_2) - x(t_1) + C \quad (3)$$

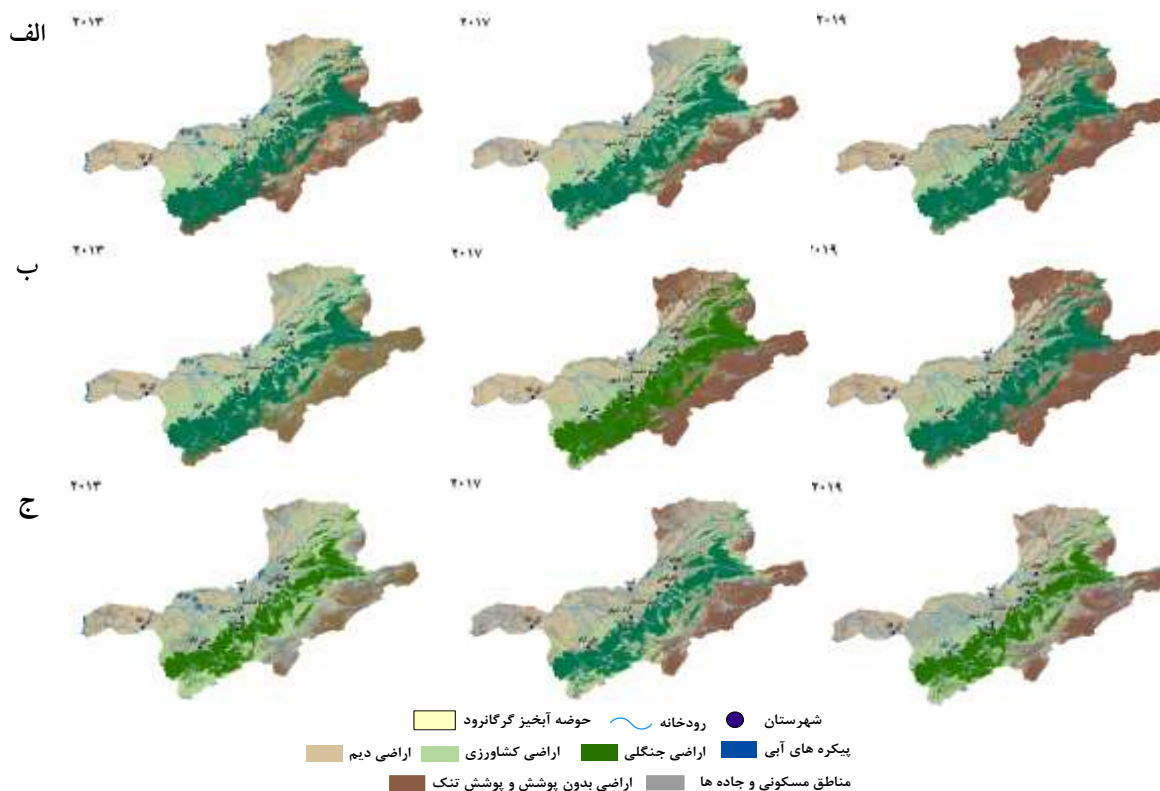
که در آن x ارزش پیکسل، t_1 تاریخ اول، t_2 تاریخ دوم و C عدد ثابت است. مزیت این روش، سادگی و آسانی تحلیل آن است و اجرای آن سریع می‌باشد.

نتایج

در این پژوهش به منظور مطالعه تغییرات کاربری اراضی در طی سال‌های مورد بررسی از تصاویر سنجنده OLI استفاده شد. به منظور ارزیابی مناسب‌ترین روش طبقه‌بندی پیکسل پایه از سه الگوریتم حداکثر شدت احتمال، جنگل تصادفی و ماشین بردار پشتیبان استفاده گردید. مطابق نتایج به دست آمده در روش حداکثر شدت احتمال، اراضی جنگلی ابتدا رشد داشته و سپس در فاصله سال‌های ۲۰۱۷ تا ۲۰۱۹ از مساحت اراضی جنگلی کاسته شده است اما در مقایسه با سال ۲۰۱۳ افزایش نسبی داشته‌اند. در مقابل، مساحت اراضی کشاورزی رشد نشان می‌دهد (جدول ۳). پوشش گیاهی پراکنده نیز ابتدا با افزایش چشمگیری روبه‌رو بوده اما سپس در دو سال از مساحت آن کاسته شده و کمی بیشتر از سال ۲۰۱۳ باقی‌مانده است که نشان‌دهنده از بین رفتن اراضی با پوشش گیاهی طبیعی است. اگر چنانچه این رویه ادامه یابد، کاهش جنگل‌ها و تبدیل شدن آن به اراضی دیم را در پی خواهد داشت (شکل ۲).

اراضی دیم، جنگلی و پوشش گیاهی پراکنده در روش حداکثر شدت احتمال، روند متفاوت‌تری را دنبال می‌کند. روند تغییرات اراضی جنگلی ثابت بوده و اراضی مسکونی، دیم و پوشش گیاهی پراکنده به‌طور کلی روند افزایشی روبه‌رو بوده است. با توجه به مقادیر دقت و صحت به دست آمده در دو روش جنگل تصادفی و ماشین بردار پشتیبان، می‌توان بیان داشت که در مقایسه با حداکثر شدت احتمال نتایج دقیق‌تر و با صحت بالاتری را ارائه می‌دهند. پیکره‌های آبی و اراضی جنگلی با روند کاهشی همراه می‌باشند.

مطابق نتایج به دست آمده نشان می‌دهد طبقه‌بندی دقت بالایی داشته اما روش‌های جنگل تصادفی و ماشین بردار پشتیبان در مقایسه با روش حداکثر شدت احتمال، روند منطقی‌تری را دنبال می‌کند.



شکل (۲): تغییرات کاربری اراضی به روش الف) جنگل تصادفی، ب) ماشین بردار پشتیبان و ج) حداکثر شدت احتمال در سه دوره مطالعاتی
 Figure (2): Landuse change detection by (a) Random Forest, (b) Support Vector Machine and (c): Maximum Likelihood methods in 3 study period time

جدول (۲): کلاس های طبقه بندی شده در پژوهش حاضر و تعریف آن ها براساس لیلساند و همکاران، ۲۰۰۴


Table (2): classes of the current study and their definition

تعریف کلاس کاربری اراضی	کلاس کاربری اراضی
پیکره های آبی مناطقی را شامل می شود که سطح تراز آب آن در سال های متوالی نزدیک و یا بالای سطح زمین است. پیکره های آبی شامل، باتلاق ها، مرداب ها و لجنزارهایی که در حاشیه عمق کم خلیج ها قرار دارند، دریاها و دریاچه ها و برکه ها، نهرها، رودها و رودخانه ها و برکه های مصنوعی همانند مخازن آب می باشند.	پیکره های آبی
اراضی جنگلی به مناطقی اطلاق می شود که دارای تاج پوشش درختی هوایی بیش از ۱۰٪ هستند و با درختان احاطه شده است. این اراضی تولیدکننده محصولات چوبی و الوار هستند.	اراضی جنگلی
اراضی کشاورزی به مناطقی گفته می شود که جهت تولید غذا و فیبر مورد بهره برداری قرار می گیرند. این کلاس شامل زمین زراعی و چراگاه، باغ ها و تاکستان ها، نهالستان ها و باغ های زینتی می باشند.	اراضی کشاورزی
اراضی دیم به اراضی شخم خورده خارج از محدوده کشاورزی اطلاق می شود.	اراضی دیم
مناطق مسکونی به اراضی گفته می شود که بیشترین مساحت آن را سازه ها تشکیل می دهند. این اراضی شامل کلان شهرها، شهرها، روستاها، اتوبان ها و زیرساخت های حمل و نقل همانند جاده و راه های ارتباطی و حمل و نقل، نیروگاه ها، مناطق دارای آسیاب های بادی و سایر آسیاب ها، مراکز خرید، شهرک های صنعتی و بخش های تجاری خارج از محدوده شهری هستند.	مناطق مسکونی و جاده ها
اراضی بدون پوشش و پوشش تنک به مناطقی گفته می شود که در آن ها کمتر از یک سوم منطقه دارای پوشش گیاهی است. این اراضی شامل اراضی خشک و شور، سواحل، زمین سنگلاخی بایر، مین نواری، معادن و گودال های شن و ماسه هستند.	اراضی بدون پوشش و پوشش تنک




شکل (۳): تغییرات کاربری اراضی به روش حداکثر شدت احتمال به (km²)

Figure (3): Landuse change detection by MLC method (km²)



شکل (۴): تغییرات کاربری اراضی به روش جنگل تصادفی به (km²)

Figure (4): Landuse change detection by RF method (km²)



شکل (۵): تغییرات کاربری اراضی به روش ماشین بردار پشتیبان به (km²)

Figure (5): Landuse change detection by MLC method (km²)

جدول (۳): تغییرات کاربری اراضی به روش حداکثر شدت احتمال به (km²)


	۲۰۱۳	۲۰۱۷	۲۰۱۹
پیکره‌های آبی	۱۸۹/۷۹	۵۸/۹۷	۱۸/۹۷
اراضی جنگلی	۲۴۱۴/۲۲	۲۴۲۴/۵۲	۲۴۳۸/۳۱
اراضی کشاورزی	۳۱۴۳/۶۱	۲۸۱۲/۱۳	۲۳۲۴/۲۶
اراضی دیم	۲۱۴۳/۹۴	۱۵۹۷/۱۶	۱۸۶۴/۴۳
پوشش گیاهی پراکنده	۱۱۳۹/۵۵	۱۹۹۷/۲۹	۱۵۷۲/۶
مناطق مسکونی و جاده‌ها	۲۰۱۲/۸۳	۲۱۵۳/۸۹	۲۸۲۵/۳۷
مجموع مساحت‌ها	۱۱۰۴۴	۱۱۰۴۴	۱۱۰۴۴

جدول (۴): تغییرات کاربری اراضی به روش جنگل تصادفی به (km²)

	۲۰۱۳	۲۰۱۷	۲۰۱۹
پیکره‌های آبی	۱۳۴/۹۵	۸۲/۱۸	۲۸
اراضی جنگلی	۲۹۲۳/۱۳	۲۸۹۱/۶	۲۸۵۷/۵۷
اراضی کشاورزی	۲۳۸۱/۱۹	۲۴۴۶/۰۸	۲۴۴۸/۵
اراضی دیم	۳۲۰۸/۳۴	۳۱۶۲/۲۷	۳۱۷۸/۷۳
پوشش گیاهی پراکنده	۲۰۶۵/۲۳	۲۰۰۲/۴۷	۲۰۶۵/۶
مناطق مسکونی و جاده‌ها	۳۳۱/۱۱	۴۵۹/۳۵	۴۶۵/۵۵
مجموع مساحت‌ها	۱۱۰۴۴	۱۱۰۴۴	۱۱۰۴۴


جدول (۵): تغییرات کاربری اراضی به روش ماشین بردار به (km²)

	۲۰۱۳	۲۰۱۷	۲۰۱۹
پیکره‌های آبی	۱۳۴/۳۹	۴۲/۹۷	۳۰
اراضی جنگلی	۲۸۵۵/۶۶	۲۸۵۰/۱۵	۲۸۴۷/۱۲
اراضی کشاورزی	۲۵۲۶/۱۷	۲۱۹۱/۷۴	۱۸۴۹/۸۶
اراضی دیم	۲۱۰۸/۳۴	۲۱۹۱/۰۷	۲۲۸۱/۰۵
پوشش گیاهی پراکنده	۲۸۶۱/۱۷	۳۱۹۴/۶۳	۳۳۹۸/۹۳
مناطق مسکونی و جاده‌ها	۵۸۸/۲۳	۵۷۳/۴	۶۳۷
مجموع مساحت‌ها	۱۱۰۴۴	۱۱۰۴۴	۱۱۰۴۴




شکل (۶): مقایسه کلاسه‌بندی پیکره‌های آبی

Figure (6): Water lands classification compares




شکل (۷): مقایسه کلاسه‌بندی اراضی جنگلی

Figure (7): Forest lands classification compares




شکل (۸): مقایسه کلاسه‌بندی اراضی دیم

Figure (8): Rainfed lands classification compares




شکل (۹): مقایسه کلاسه‌بندی پوشش گیاهی پراکنده

Figure (9): Bare lands classification compares



شکل (۱۰): مقایسه کلاسه‌بندی اراضی کشاورزی

Figure (10): Agriculture lands classification compares



شکل (۱۱): مقایسه کلاسه‌بندی مناطق مسکونی و جاده‌ها

Figure (11): residential lands classification compares

جدول (۶): میزان دقت و ضریب کاپا در تهیه نقشه‌های کاربری اراضی

Table (6): Accuracy and Kappa coefficient index in Landuse mapping

الگوریتم	۲۰۱۳		۲۰۱۷		۲۰۱۹	
	ضریب کاپا	درصد صحت	ضریب کاپا	درصد صحت	ضریب کاپا	درصد صحت
حداکثر شدت احتمال	۰/۸۴	۸۷/۳۹	۰/۵۵	۶۳/۰۳	۰/۵۰	۵۹/۰۵
جنگل تصادفی	۰/۷۹	۸۳/۴۰	۰/۸۱	۸۵/۱۹	۰/۷۷	۸۳/۰۱
ماشین بردار پشتیبان	۰/۸۶	۸۹/۳۷	۰/۷۹	۸۳/۰۵	۰/۷۹	۸۴/۲۶

جدول (۷): صحت کاربر و صحت تولیدکننده هر روش طبقه‌بندی کننده در سال ۲۰۱۳

Table (7): User accuracy and producer accuracy of each classifier in 2013

کلاس	۲۰۱۳		حداکثر شدت احتمال		ماشین بردار پشتیبان		جنگل تصادفی	
	صحت تولیدکننده	صحت کاربر	صحت تولیدکننده	صحت کاربر	صحت تولیدکننده	صحت کاربر	صحت تولیدکننده	صحت کاربر
پیکره‌های آبی	۹۹/۳۸	۹۹/۷۸	۱۰۰	۹۲/۷۲	۱۰۰	۹۲/۷۲	۱۰۰	۷۶/۰۲
اراضی جنگلی	۹۸/۸۱	۹۷/۸۵	۹۹/۷۵	۹۶/۰۹	۸۹/۴۴	۹۶/۰۹	۸۹/۴۴	۱۰۰
اراضی کشاورزی	۶۴/۲۵	۹۵/۸۱	۸۸/۰۳	۷۵/۳۴	۸۹/۱۳	۷۵/۳۴	۸۹/۱۳	۶۴/۵۹
اراضی دیم	۹۶/۰۵	۹۹/۰۳	۹۳/۳۱	۹۵/۴۷	۹۳/۳۵	۹۵/۴۷	۹۳/۳۵	۸۲/۸۱
پوشش گیاهی پراکنده	۷۸/۱۷	۷۸/۴۷	۶۷/۶۷	۹۹/۵۷	۵۷/۴۲	۹۹/۵۷	۵۷/۴۲	۹۷/۸۳
مناطق مسکونی و جاده‌ها	۴۸/۲۷	۲۴/۲۹	۱۰۰	۵۶/۶۹	۱۰۰	۵۶/۶۹	۱۰۰	۶۳/۱۴

جدول (۸): صحت کاربر و صحت تولیدکننده هر روش طبقه‌بندی کننده در سال ۲۰۱۷

Table (8): User accuracy and producer accuracy of each classifier in 2017

کلاس	۲۰۱۷		حداکثر شدت احتمال		ماشین بردار پشتیبان		جنگل تصادفی	
	صحت تولیدکننده	صحت کاربر	صحت تولیدکننده	صحت کاربر	صحت تولیدکننده	صحت کاربر	صحت تولیدکننده	صحت کاربر
پیکره‌های آبی	۹۸/۶۲	۹۹/۹۵	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰
اراضی جنگلی	۷۴/۴۲	۹۸/۰۲	۸۵/۱۶	۹۸/۸۶	۸۵/۷۴	۹۸/۸۶	۸۵/۷۴	۹۷/۹
اراضی کشاورزی	۶۱/۳۲	۵۷/۹۱	۶۲/۲۸	۶۶/۷۷	۶۲/۹۸	۶۶/۷۷	۶۲/۹۸	۷۳/۷۱
اراضی دیم	۷۱/۳۱	۷۷/۹۴	۹۴/۶۴	۷۳/۴۸	۹۶/۳۵	۷۳/۴۸	۹۶/۳۵	۷۳/۱۴
پوشش گیاهی پراکنده	۴۱/۱	۷۶/۹۸	۷۸/۷۱	۸۸/۹۹	۸۲/۶۴	۸۸/۹۹	۸۲/۶۴	۹۲/۹۸
مناطق مسکونی و جاده‌ها	۶۷/۵۴	۱۵/۶۸	۱۰۰	۸۴/۴۲	۱۰۰	۸۴/۴۲	۱۰۰	۸۲/۳۲

جدول (۹): صحت کاربر و صحت تولیدکننده هر روش طبقه‌بندی کننده در سال ۲۰۱۹

Table (9): User accuracy and producer accuracy of each classifier in 2019

کلاس	۲۰۱۹		حداکثر شدت احتمال		ماشین بردار پشتیبان		جنگل تصادفی	
	صحت تولیدکننده	صحت کاربر	صحت تولیدکننده	صحت کاربر	صحت تولیدکننده	صحت کاربر	صحت تولیدکننده	صحت کاربر
پیکره‌های آبی	۹۹/۷۸	۱۰۰	۱۰۰	۹۹/۷۱	۱۰۰	۹۹/۷۱	۱۰۰	۹۹/۷۱
اراضی جنگلی	۵۸/۸۸	۹۹/۴۸	۶۶/۷۱	۹۹/۹۳	۶۴/۸۷	۹۹/۹۳	۶۴/۸۷	۱۰۰
اراضی کشاورزی	۶۰/۶	۴۵/۴۱	۷۱/۳۸	۵۰/۷۵	۷۰/۹۷	۵۰/۷۵	۷۰/۹۷	۴۵/۴۷
اراضی دیم	۷۶/۷۱	۶۸/۹۴	۹۷/۹۲	۸۰/۴۹	۹۷/۹۹	۸۰/۴۹	۹۷/۹۹	۷۸/۳۲
پوشش گیاهی پراکنده	۳۹/۱۹	۹۰/۵۸	۹۰/۷۳	۸۹/۴۹	۸۸/۵۴	۸۹/۴۹	۸۸/۵۴	۹۱/۵
مناطق مسکونی و جاده‌ها	۸۴/۸۶	۱۲/۸۸	۱۰۰	۸۷/۱۶	۱۰۰	۸۷/۱۶	۱۰۰	۹۰/۱۳

نتیجه گیری

تخریب جنگل‌ها و تغییر کاربری آن به کشاورزی و دیم، که خود مصرف آب را توسط ساکنین منطقه افزایش داده و کاهش مساحت پیکره‌های آبی را در پی دارد. با کاهش منابع آبی، به مساحت اراضی بدون پوشش و بلااستفاده نیز افزوده می‌گردد چراکه تأمین آب برای کشت و زرع با مشکل روبه‌رو می‌شود. علاوه بر این، نتایج مشابهی از افزایش مساحت مناطق مسکونی و کاهش اراضی جنگلی در منطقه نور در تحقیق صورت گرفته توسط (زارع و همکاران، ۲۰۱۷)، مشاهده می‌شود و باتوجه به نزدیک بودن دو منطقه مورد مطالعه نور و گرگان‌رود در شمال کشور می‌توان بیان داشت که تغییرات کاربری جنگلی با روند منفی و اراضی مسکونی با روند مثبت در شمال کشور روبه‌رو هستند. نتایج حاصل از مقایسه سه روش حداکثر شدت احتمال، جنگل تصادفی و ماشین بردار پشتیبان نشان می‌دهد که دو روش ماشین بردار پشتیبان و جنگل تصادفی نتایج نزدیک‌تری به هم ارائه می‌دهند و نتایج حاصل از روش حداکثر شدت احتمال با دو روش دیگر تفاوت دارد. باتوجه به جدول ۶ و نقشه‌های ارائه شده، می‌توان بیان داشت که روش‌های ماشین بردار پشتیبان و جنگل تصادفی نتایج دقیق‌تر و نقشه‌های صحیح‌تری را ارائه می‌دهند (اشکال ۶ الی ۱۱).

نتایج نشان می‌دهد که با روند کنونی در آینده در منطقه مورد مطالعه با کاهش جنگل‌ها و افزایش اراضی شخم‌خورده، احتمال سیل‌خیزی در منطقه بالا خواهد رفت. همچنین، با کاهش اراضی جنگلی و افزایش اراضی کشاورزی و مناطق مسکونی، منابع آب رو به کاهش بوده که بحران آب تهدیدی برای ساکنین محسوب می‌شود.

باتوجه به جدول ۶ و مشاهده دقت کلاسه‌بندی صورت گرفته براساس ضریب کاپا می‌توان دریافت که دو روش جنگل تصادفی و ماشین بردار پشتیبان در مقایسه با روش حداکثر شدت احتمال عملکرد بهتری داشته و نتایج دقیق‌تری را ارائه نموده‌اند. در سال ۲۰۱۳ میزان ضریب کاپا در روش ماشین بردار پشتیبان بیشترین مقدار و ۰/۸۶ و صحت کلی ۸۹/۳۷ درصد بیان شده است و نسبت به دو روش دیگر نتیجه بهتری را ارائه نموده است. در سال ۲۰۱۷ روش جنگل تصادفی با مقدار ضریب کاپا ۰/۸۱ و دقت کلی ۸۵/۹ درصد در مقایسه با دو روش دیگر نتایج بهتری را ارائه نموده است ولی فاصله زیادی با نتایج روش ماشین بردار پشتیبان که ضریب کاپا آن ۰/۷۹ و صحت کلی آن ۸۳/۵ درصد به‌دست‌آمده است، ندارد و می‌توان گفت نسبت به روش حداکثر شدت احتمال با ضریب کاپا ۰/۵۵ نتایج بسیار بهتر و دقیق‌تری را دارد و دقت نقشه‌های تولید شده بسیار بهتر است (جداول ۷، ۸ و ۹). این مطلب که روش ماشین بردار پشتیبان در مقایسه با حداکثر شدت احتمال نتایج بهتری را ارائه می‌نماید با یافته‌های (متکان و حاجب، ۲۰۱۳) همخوانی دارد. در مطالعه صورت گرفته توسط (تقدسی و حسنلو، ۲۰۱۹) نیز مناسب بودن الگوریتم ماشین بردار پشتیبان در مقایسه با روش‌های حداکثر فاصله از میانگین، فاصله ماهالانویس، سطوح موازی، حداکثر شدت احتمال، نتایج دقیق‌تر و قابل اطمینان‌تری را ارائه نموده است. در مطالعه آن‌ها همچون تحقیق حاضر مقایسه دقت و صحت طبقه‌بندی‌های انجام گرفته، توسط ضریب کاپا صورت گرفته است. به‌طورکلی باتوجه به نتایج به‌دست‌آمده می‌توان بیان داشت که در طول سال‌های مورد بررسی مطالعه پوشش گیاهی منطقه تغییرات محسوس اما آرام داشته و تغییرات شدید و چشمگیری در آن مدت زمان کوتاه رخ نداده است (اشکال ۳، ۴ و ۵) (جداول ۳، ۴ و ۵). با ادامه روند کنونی خطر کاهش سطح جنگل‌ها و تبدیل آن به اراضی کشاورزی دور از انتظار نیست. افزایش مناطق مسکونی و اراضی کشاورزی هرچند آرام، گواهی است بر

منابع

1. Azimi, M., Rahbar, Gh., & Mansouri, Sh. (2019). Site selection and prioritization of the areas appropriate for floodwater spreading using GIS and AHP (Case study: Gorganrud river basin, Golestan). *Journal of Environmental Science and Technology*, 20 (4 (79)), 179-192. [In Persian].
2. Bagherifar, P., Basiri, R., Yosefi Khaneghah, Sh., & Pourkhabbaz, H. (2023). The comparison of Artificial Neural Network to and maximum likelihood algorithms for forest changes detection. *Journal of Environment Science and Technology*, Vol 25, No. 8. P75-88. [In Persian].
3. Bolstad, P., & Lillesand, T. M. (1991). Rapid maximum likelihood classification. *Photogrammetric engineering and remote sensing*, 57(1), 67-74.
4. Bonyad Amir, A., & Hajigaderi, T. (2007). Mapping Zanjan basin natural forests Using ETM+ Landsat 7 data. *Soil And Water Science Journal (Agriculture and Natural resources science and technology)*. 11 (42b), 627-638. [In Persian].
5. Cao, X., Chen, J., Imura, H., & Higashi, O. (2009). A SVM-based method to extract urban areas from DMSP-OLS and SPOT VGT data. *Remote Sensing of Environment*, 113 (10), 2205-2209.
6. Cristianini, N., & Shawe-Taylor, J. (2000). *An introduction to support vector machines and other kernel-based learning methods*. Cambridge university press.
7. Daneshi, A., & Panahi, M. (2016). Efficiency Comparison of Support Vector Machine and Maximum Likelihood Algorithms for Monitoring Land Use Changes. *Iranian Remote Sensing and GIS*. 8 (2), 73-86. [In Persian].
8. Davodpour, R., & Toranjzar, H. (2018). Preparation of Land Use Map Using ETM+ Landsat (A Case Study in Hendodar Watershed). *Journal of Environmental Science and Technology*. 22 (6). [In Persian].
9. Huang, C., Davis, L. S., & Townshend, J. R. G. (2002). An assessment of support vector machines for land cover classification. *International Journal of remote sensing*, 23 (4), 725-749.
10. Islam, K., Jashimuddin, M., Nath, B., & Nath, T. K. (2018). Land use classification and change detection by using multi-temporal remotely sensed imagery: The case of Chunati wildlife sanctuary, Bangladesh. *The Egyptian Journal of Remote Sensing and Space Science*, 21 (1), 37-47.
11. Jahanbakhshi, F., & Ekhtesasi, M. R. (2019). Performance evaluation of three image classification methods (Random Forest, Support Vector Machine and the Maximum Likelihood) in land use mapping. *Journal of Water and Soil Science*, 2019, Vol. 22, No. 4, p235-246. [In Persian].
12. Kafy, A.A., Saha, M., Rahaman, Z.A., Rahman, M.T., Liu, D., Fattah, M.A., Al Rakib, A., AlDousari, A.E., Rahaman, S.N., Hasan, M.Z. & Ahasan, M.A.K. (2022). Predicting the impacts of land use/land cover changes on seasonal urban thermal characteristics using machine learning algorithms. *Building and Environment*, 217, p.109066.
13. Karami, O., Hoseini Nasr, S.M., Jalijvand, H., Miryaghoubzadeh, M.H. (2015). Determination of Babolrood basin Capability for Various Land Uses Using Multi Criteria Decision Making Methods. *J Watershed Manage Res*. 6 (11), 171-181.
14. Kavzoglu, T., & Colkesen, I. (2009). A kernel functions analysis for support vector machines for land cover classification. *International Journal of Applied Earth Observation and Geoinformation*, 11 (5), 352-359.
15. Kazemi, M., Nohegar, A., & Mirdady, M. (2017). Best classification method choosing in landuse mapping using OLI sensor Landsat 8 satellite (Case study: Behesht-Gomshode watershed, Fars region). *Iran Natural Ecosystems*. 8 (1), 79-97. [In Persian].
16. Lillesand, T.M., Kiefer, R.W., & Chipman, J.W. (2004). *Remote Sensing and Image Interpretation*, fifth edition Wiley and Sons. New York, 763.
17. López-Serrano, P. M., Corral-Rivas, J. J., Díaz-Varela, R. A., Álvarez-González, J. G., & López-Sánchez, C. A. (2016). Evaluation of radiometric and atmospheric correction algorithms for aboveground forest biomass estimation using Landsat 5 TM data. *Remote sensing*, 8 (5), 369.
18. Madadi, A., & Mozaffari, H. (2019). Comparison and Evaluation of Supervised Classification Methods for Extraction and Detection of Changes in Geomorphologic Landforms of Sojasrood Basin. *Quantitative Geomorphological Research*. 7 (3), 71-90. [In Persian].
19. Mazaheri, M. R., Esfandiari, M., Masih Abadi, M. H., & Kamali, A. (2013). Detecting temporal land use changes using remote sensing and GIS techniques (Case study: Jiroft, Kerman Province). *Journal of Applied RS & GIS Techniques in Natural Resource Science*. 4 (2), 25-39. [In Persian].
20. Mir Yaghoobzadeh M H, Ghanbarpour M R. Investigation of Digital Detection Accuracy of Snow, Cloud and Earth Using MODIS Imagery. *jwmseir* 2010; 3 (9) :51-54
21. Mousavi, S.H., Ranjbar, A., & Haseli, M. (2015). Investigation and trend detection of Landuse change in Abarkouh basin using satellite data (1976-2014). *Scientific-Research Quaterly of Geographical Data (Sepehr)*. 25 (97), 129-146. [In Persian].
22. Mousavinejad, S.H., Habashi, H., Kiani, F., Shataee, Sh., & Abdi, O. (2017). evaluation of soil erosion using imagery spot5 satellite in chehel chi catchment of golestan province. *journal of wood and forest science and technology*, 24 (2), 73-86. [In Persian].
23. NazariSamani, A., Ghorbani, M., & Kouhbandani, H.R. (2010). Evaluation of LandUse change detection of Talegan Watershed between 1366

to 1380 study period. *Rangeland journal*. 4 (3) 442-451. [In Persian].

24. Pal, M. (2005). Random forest classifier for remote sensing classification. *International journal of remote sensing*, 26 (1), 217-222.

25. Pal, M., & Mather, P. M. (2003). An assessment of the effectiveness of decision tree methods for land cover classification. *Remote sensing of environment*, 86 (4), 554-565.

26. Pouteau, R., Meyer, J. Y., & Stoll, B. (2011). A SVM-based model for predicting distribution of the invasive tree *Miconia calvescens* in tropical rainforests. *Ecological modelling*, 222 (15), 2631-2641.

27. Richards, J. A., & Richards, J. A. (2022). *Remote sensing digital image analysis* (Vol. 5, pp. 256-258). Berlin/Heidelberg, Germany: Springer.

28. Rodriguez-Galiano, V. F., Ghimire, B., Rogan, J., Chica-Olmo, M., & Rigol-Sanchez, J. P. (2012). An assessment of the effectiveness of a random forest classifier for land-cover classification. *ISPRS journal of photogrammetry and remote sensing*, 67, 93-104.

29. Saha, J., Ria, S. S., Sultana, J., Shima, U. A., Seyam, M. M. H., & Rahman, M. M. (2024). Assessing seasonal dynamics of land surface temperature (LST) and land use land cover (LULC) in Bhairab, Kishoreganj, Bangladesh: A geospatial analysis from 2008 to 2023. *Case Studies in Chemical and Environmental Engineering*, 9, 100560.

30. Motakan, A., & Hajeb, M. (2013). Comparison of the ability of SVM, ANN and MLC

classifiers in optimizing the Lidar data filtering algorithms. *Iranian Remote Sensing and GIS*. 5 (2), 1-16. [In Persian].

31. Rahmani, N., Shahedi, K., Soleimani, K., Miryaghoubzadeh, M.H. (2016). Evaluation of the Land use Change Impact on Hydrologic Characteristics (Case Study: Kasilian Watershed). *J Watershed Manage Res*. 7 (13), 32-23. doi:10.18869/acadpub.jwmr.7.13.32

32. Singh, A. (1989). Digital change detection techniques using remotely sensed data. *International Journal of Remote Sensing* 10: 989-1003.

33. Taghadosi, M.M., Hasanlou, M., & Eftekhari, K. (2019). Evaluating and comparing supervised classification algorithms with the aim of mapping soil salinity levels using Sentinel-2 satellite imageries. *Scientific - Research Quarterly of Geographical Data (SEPEHR)*. Vo.28, No.110. p37-52. doi: 10.22131/sepehr.2019.36608. [In Persian].

34. Vapnik, V.N. (1995). *The Nature of Statistical Learning Theory* (New York: Springer-Verlag).

35. Yousefi, S., Moradi, H.R., Hosseini, S.H., & Mirzaee, S. (2011). Land use change detection using Landsat TM and ETM+ satellite images over Marivan. *Journal of Applied RS & GIS Techniques in Natural Resource Science* 2 (3), 97-105. [In Persian].

36. Zare, M., Teimourian, T., & Joory, M.H. (2017). Monitoring land use-land cover change detection using the change and stability index and comparing after classification. *Iran Natural Ecosystems*. 8 (1), 123-136. [In Persian].

Evaluating the Optimum Machine Learning Pattern for Satellite Imagery Classification and Land Use/Land Cover Change Detection in the Gorganroud Basin

Edith Eishoei^۱, Mirhassan Miryaghoubzadeh^{*۲}, Kaka Shahedi^۳

Received: 2025/12/20

Accepted: 2026/02/16

Extended Abstract

Introduction: Knowledge of land use/land cover (LULC) ratios and their temporal change trends constitutes a fundamental prerequisite for environmental planning. Understanding land use change is of particular importance in the context of land development processes. The application of remote sensing science to land use studies and the extraction of land use maps has proven successful in change detection and the formulation of associated management policies. In recent years, various algorithms have been developed for classifying different land use categories using remote sensing imagery. Consequently, identifying the optimal algorithm for a given classification approach is critical to obtaining accurate outputs. Among probability-based algorithms, Maximum Likelihood is the most common and accurate technique and is recognized as one of the most precise classification methods. The Support Vector Machine (SVM) algorithm is less sensitive to multidimensional phenomena. As a result, it is considered an appropriate method for the classification of multispectral and hyperspectral data. One of the advantages of the SVM algorithm is its ability to produce an optimally classified map using a limited number of training samples. Accordingly, this reduces costs and increases classification speed. Random Forest is another machine learning algorithm, based on a complex ensemble of decision trees. In this method, each classification is derived from a random vector that is independent of the input. Each tree assigns a separate class to every vector that exhibits the highest correspondence with that class.

Material and Methods: In this research, Landsat 8 (OLI) multitemporal image data from 2013, 2017, and 2019 were utilized to extract land use/land cover (LULC) change detection in the Gorganroud basin, located in Golestan Province. The Landsat 8 data within the study period represent the most stable images for extracting and mapping LULC change detection. Radiometric corrections were applied using the Chavez and Dark Subtraction methods. Furthermore, the Histogram Matching algorithm was employed to prepare satellite imagery for processing purposes. In this method, recent panchromatic data, along with intensity components extracted from RGB multispectral data, were matched using the histograms of the data. To assess the accuracy of the extracted maps, an error matrix was utilized. Accuracy assessment required ground truth images or regions of interest, which were obtained from a field survey conducted in 2017. In the error matrix, the raw data were compared with the classified data. In most studies, the Kappa coefficient is employed to evaluate the accuracy of results derived from different classification methods. To investigate and detect changes, the histogram matching method of multitemporal images was first applied based on a reference year, followed by the image difference method.

Results: Evaluation of the results derived from accuracy indices, along with comparison to the locally derived map obtained through in-person field monitoring, demonstrates the high accuracy of the algorithm applied in this study. Furthermore, it confirms the effectiveness of Landsat 8 imagery in extracting land use/land cover (LULC) maps. The results reveal that, between 2013 and 2019, forest lands experienced a slight decrease. Dry lands also underwent gradual changes. Bare soil areas increased significantly; however, after two years, their area expanded further, indicating a reduction in natural plant cover. Should this trend continue, the region will face forest loss and conversion to rainfed agricultural lands.

1. PhD, Rangeland and watershed management engineering. Faculty of Natural Resources, Urmia University, Urmia, Iran
2. Associate Professor, Rangeland and watershed management engineering. Faculty of Natural Resources, Urmia University, Urmia, Iran; Email: m.miryaghoubzadeh@urmia.ac.ir
3. Professor, Range and Watershed Management engineering, Faculty of Natural Resources, Sari Agricultural and Natural Resources University, Sari, Iran.

In the Maximum Likelihood method, rainfed lands, forests, and areas with scattered plant cover followed distinct trends. The forest change trend remained stable, whereas residential areas, rainfed lands, and scattered plant cover areas increased gradually. Based on the accuracy values obtained from the Random Forest and Support Vector Machine methods, it can be concluded that these methods are more accurate than the Maximum Likelihood method. In contrast, wetlands and forests exhibit a declining trend.

Discussion and Conclusion: The study area is facing forest destruction and an increase in dry lands at higher elevations. Consequently, land use/land cover change detection must be taken into account in the future to prevent and control flooding in the region. Accordingly, it can be stated that during the study years, land cover in the region has changed gradually; however, no pronounced or significant changes have occurred over the short term. If the current trend continues, it is predictable that forests may convert to agricultural or rainfed lands. Such a transformation could lead to increased water consumption and the decline of wetlands. As water resources diminish, unused lands are likely to expand due to a reduced capacity for water supply. The results of comparing the three classification methods—Random Forest, Support Vector Machine (SVM), and Maximum Likelihood—indicate that Random Forest and SVM yield more comparable results, whereas Maximum Likelihood produces different outputs relative to these two methods. Based on the extracted maps, it is evident that Random Forest and SVM provide more accurate and reliable results. From these findings, it can be concluded that in steeper areas, forests are decreasing while plowed lands are increasing, which may contribute to flooding in the region. Therefore, future water supply for the residents is likely to become a critical issue.

Keywords: LULC Change Detection, Landsat Imagery, Random Forest, Support Vector Machine, Gorganroud Basin