

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

ادیت عیشویی، میرحسن میریعقوب زاده*، 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 زیست محیطی 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 بکارگیری الگوریتم‌های طبقه‌بندی ماشین بردار پشتیبان و جنگل تصادفی به ترتیب ۰/۷۹ و ۰/۷۷ در سال ۲۰۱۹ و ۰/۸۱ و ۰/۸۶ در سال ۲۰۱۳ بدست 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.

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

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

۲. دانشیار، گروه مهندسی مرتع و آبخیزداری، دانشکده منابع طبیعی، دانشگاه ارومیه، ارومیه، ایران، m.miryaghoubzadeh@urmia.ac.ir

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

مقدمه

پدیده تغییر کاربری اراضی یکی از مخاطرات محیطی و بحرانهای اکولوژیکی است که امروزه جهان با آن روبرو 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 غیر اصولی کاربری زمین از مهمترین مسائل سرزمینی کشور است، چرا که تغییر اکثر کاربری‌ها غالباً بدون در نظر گرفتن محدودیت‌های زیست محیطی 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 غیر اصولی 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 محیط زیست و یکی از پرهزینه‌ترین بخش‌های پروژه‌های محیط زیست 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 فاکتورهایی 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 پیکسل، آن‌را 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 چندبعدی حساسیت کمتری دارد، به همین علت در طبقه‌بندی داده‌های چندطیفی و ابرطیفی 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

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^۲ و چندجمله‌ای^۳ با پارامترهای بهینه با هدف تعیین کاربری اراضی مورد استفاده قرار گرفتند. نتایج آن‌ها نشان دادند که روش ماشین بردار پشتیبان به ویژه تابع رادیال کرنل در مقایسه با روش دیگر کارایی بهتری دارد. کافی^۴ 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 به عنوان 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

مشخصات منطقه مورد مطالعه

حوزه آبخیز گرگانرود در محدوده جغرافیایی طول شرقی ۳۸° ۱۰' تا ۳۶° ۳۵' شمالی و عرض شمالی ۵۴° ۱۰' تا ۵۶° ۲۵' واقع شده است که مساحتی بالغ بر ۱۱ هزار کیلومتر مربع 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 در یای خزر مشرف

بیشترین تغییرات مربوط به تبدیل اراضی کشاورزی به مسکونی بوده به طوریکه ۵ برابر رشد در طی این ۲۸ سال 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 مایلانویس، 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 حسنیلو، (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 مایلانویس، 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. بر اساس 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. کاوازوغلو^۱ و چولکسن^۲، (۲۰۰۹)، تابع کرنل

4 Polynomial

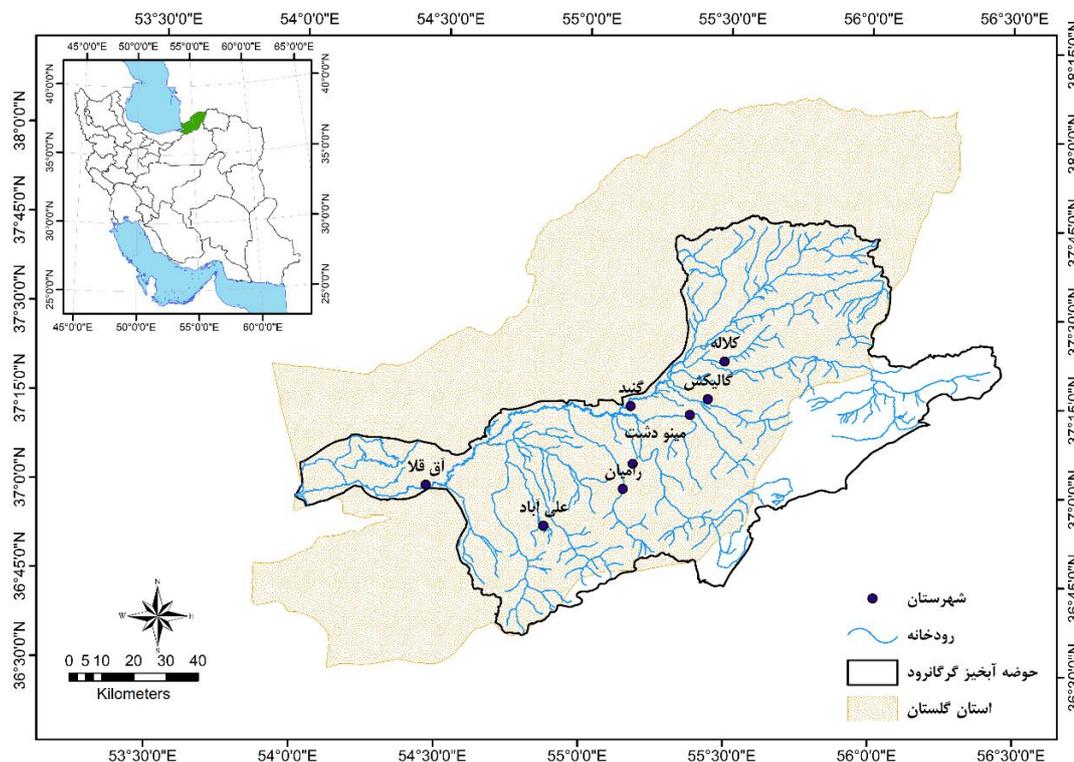
5 AI-Kafy

1 Kavazoglu

2 Colkesen

۳Radial

می باشد (عظیمی و همکاران، ۲۰۱۹). شکل ۱ موقعیت جغرافیایی منطقه را در کشور نشان می دهد. در پژوهش حاضر داده های سنجنده OLI ماهواره لندست مربوط به سال های ۲۰۱۳ و ۲۰۱۷ و ۲۰۱۹ مورد استفاده قرار گرفتند. تصاویر چند زمانه مورد استفاده در این مطالعه در جدول ۱ آورده شده است.



شکل (۱): موقعیت منطقه مورد مطالعه

Figure (1): Location of the study area

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

روش تحقیق

۲-۲- پیش پردازش تصاویر ماهواره ای

عموماً بمنظور طبقه بندی و آشکارسازی تغییرات کاربری اراضی نیاز به انجام تصحیحات رادیومتریک و تصحیحات ارتفاع خورشید و فاصله زمین تا خورشید می باشد. طی این فرآیند، داده های تصویر مورد نیاز تحت

زوایای مختلف خورشید با محاسبه تابش در هر پیکسل نرمال سازی می شوند 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 زاویه ارتفاع خورشید در زمان و مکان مشخص بدست می آید. تصحیحات فاصله زمین-خورشید جهت

الگوریتم جنگل تصادفی در پیکسل‌هایی که به طور تصادفی انتخاب شده‌اند یا ترکیبی از پدیده‌هایی که هر گره نشان‌دهنده یک درخت است، به کار برده شده است. روش‌های متعددی برای انتخاب پیکسل‌ها جهت استفاده در درخت تصمیم‌گیری وجود دارد. از پرکاربردترین روش‌ها می‌توان به ضریب معیار نسبی^۱ و شاخص جینی^۲ اشاره کرد. الگوریتم جنگل تصادفی از شاخص جینی به عنوان 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 دو سوم نمونه‌ها برای تعلیم درخت‌ها و یک سوم 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).

۲-۲-۲- الگوریتم ماشین بردار پشتیبان

(SVM)

الگوریتم ماشین بردار پشتیبان، بر اساس تئوری یادگیری آماری توسعه داده شده است و هدف آن تخمین مکان مرز تصمیم‌گیری است که کلاس‌ها در حالت بهینه تفکیک می‌شوند (واپنیک، ۱۹۹۵). در موضوع تشخیص الگوی دو کلاس از هم تفکیک می‌شوند، بردار خطی

نرمال‌سازی تغییرات فصلی در فاصله بین زمین و خورشید انجام می‌شوند (لیلساند^۹ و همکاران، ۲۰۰۴). در این تحقیق، تصحیحات رادیومتریک با روش Chavez و Dark Subtraction انجام شد. همچنین سیگنال دریافتی ماهواره ممکن است تحت تاثیر گرد و غبار، گازها، ابر، مواد جامد و مایع معلق در فضا قرار گرفته باشند و نتایج را مورد تاثیر خود قرار دهند. رادیانس محاسبه شده در نزدیکی سنجنده در بالای اتمسفر^{۱۰} در نظر گرفته می‌شود که اثرات مواد معلق در فضا بر روی آن بایستی تصحیح گردند (لوپز-سرانو^{۱۱} و همکاران، ۲۰۱۶؛ اسلام^{۱۲} و همکاران، ۲۰۱۸). در تحقیق حاضر از روش FLAASH بمنظور تصحیحات اتمسفریک استفاده گردید. همچنین بمنظور آماده‌سازی تصاویر ماهواره‌ای جهت پردازش از الگوریتم همگام سازی هیستوگرام^{۱۳} استفاده گردید. در این روش، داده‌های جدید پانکروماتیک با مولفه‌های شدت که از داده‌های RGB چندطیفی حاصل شده‌اند، از طریق هیستوگرام داده، همگام می‌شوند (لیلساند^۹ و همکاران، ۲۰۰۴). در روش همگام‌سازی هیستوگرام، توزیع مقدار پیکسل بر اساس فراوانی آن‌ها می‌باشد و عموماً به منظور افزایش کنتراست در پدیده‌هایی با تراکم و فراوانی بالا تاثیر بیشتری دارد (داودپور و ترنج‌زر، ۲۰۱۸).

۲-۲-۱- 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)،

1 Lillesand 4
1 Gain Ratio Criterion 5
1 Gini Index 6
1 Vapnik 7

9 Lillesand
1 Top Of Atmosphere 0
1 López-Serrano 1
1 Islam 2
1 Histogram Matching 3

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. معمولا مدل احتمال نرمال چندمتغیره برای این منظور به کار برده می‌شود و بر اساس نمونه‌های تعلیمی، وکتور میانگین، 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 و لیلساند، ۱۹۹۱).

۴-۲-۲- تعیین دقت نقشه‌های کاربری اراضی

بمنظور 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 روش‌های مختلف طبقه‌بندی استفاده می‌شود (نظری سامانی و همکاران، ۲۰۱۰). دقت کلی و ضریب کاپا طبق معادلات زیر محاسبه می‌گردد (میریعیوبزاده و قنبرپور، ۲۰۱۰).

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

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

مرزی را تعیین کرده و این دو کلاس را از هم جدا می‌کند. اندازه مرز جداکننده از حاصل جمع فاصله نقاط با ابرصفحه^{۱۸} بردار پشتیبان بدست می‌آید (واپنیک^{۱۹}، ۱۹۹۵). تابع کرنل جهت کاهش هزینه محاسبه فضای پیکسلی مورد استفاده قرار می‌گیرد (واپنیک^{۲۰}، ۱۹۹۵؛ کریستیانتی^{۲۱} و تیلور^{۲۲}، ۲۰۰۰؛ پال، ۲۰۰۵؛ کائو و همکاران، ۲۰۰۹). ماشین‌های بردار 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^{۲۳} و همکاران، ۲۰۱۱).

۳-۲-۲- الگوریتم حداکثر شدت احتمال

کلاس‌بندی حداکثر شدت احتمال متداول‌ترین روش نظارت شده است که در اکثر مطالعات از آن به عنوان دقیق‌ترین روش کلاسه‌بندی نام برده شده است (هوآنگ^{۲۴} و همکاران، ۲۰۰۲؛ متکان و حاجب، ۲۰۱۳؛ کاظمی و همکاران، ۲۰۱۷؛ مددی و مظفری، ۲۰۱۹؛ ریچاردز^{۲۵} و ریچاردز^{۲۶}، ۲۰۲۲). این کلاسه‌بندی 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،

2	Huang	4
2	Richards	5
2	Richards	6
2	Bolstad	7
2	Lillesand	8

1	HyperPlane	8
1	Vapnik	9
2	Vapnik	0
2	Cristianti	1
2	Taylor	2
2	Pouteau	3

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 بمنظور مطالعه تغییرات کاربری اراضی در طی سالهای مورد بررسی از تصاویر سنجنده OLI استفاده شد. بمنظور ارزیابی مناسبترین روش طبقه‌بندی پیکسل پایه از سه الگوریتم حداکثر شدت احتمال، جنگل تصادفی و ماشین بردار پشتیبان استفاده گردید. مطابق نتایج بدست 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 روبرو بوده اما سپس در دو سال از مساحت آن کاسته شده و کمی بیشتر از سال ۲۰۱۳ باقی مانده 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

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

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

۱-۴-۲-۲- 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 بدست 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 موردنظر کلاس‌بندی معرفی شوند و با این روش تشخیص پدیده‌ها و تفکیک آن‌ها از یکدیگر میسر خواهد شد (میریعقوب‌زاده 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 موردنظر آسان‌تر خواهد بود، به خصوص هر چه تعداد نمونه‌ها در نواحی غیرهمگن بیشتر باشند، نتیجه بدست آمده دقیق‌تر خواهد بود (میریعقوب‌زاده و قنبرپور، ۲۰۱۰).

۲-۴-۲-۲- آشکارسازی تغییرات

بمنظور 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 تقسیم بندی گردید و نقشه‌های پوشش گیاهی تولید شدند (جدول ۲). بمنظور 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

پیکره‌های آبی و اراضی جنگلی با روند کاهشی همراه می‌باشند. مطابق نتایج بدست 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 می‌کنند.

روند تغییرات اراضی جنگلی ثابت بوده و اراضی مسکونی، دیم و پوشش گیاهی پراکنده به طور کلی روند افزایشی روبرو بوده است با توجه به مقادیر دقت و صحت بدست 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.

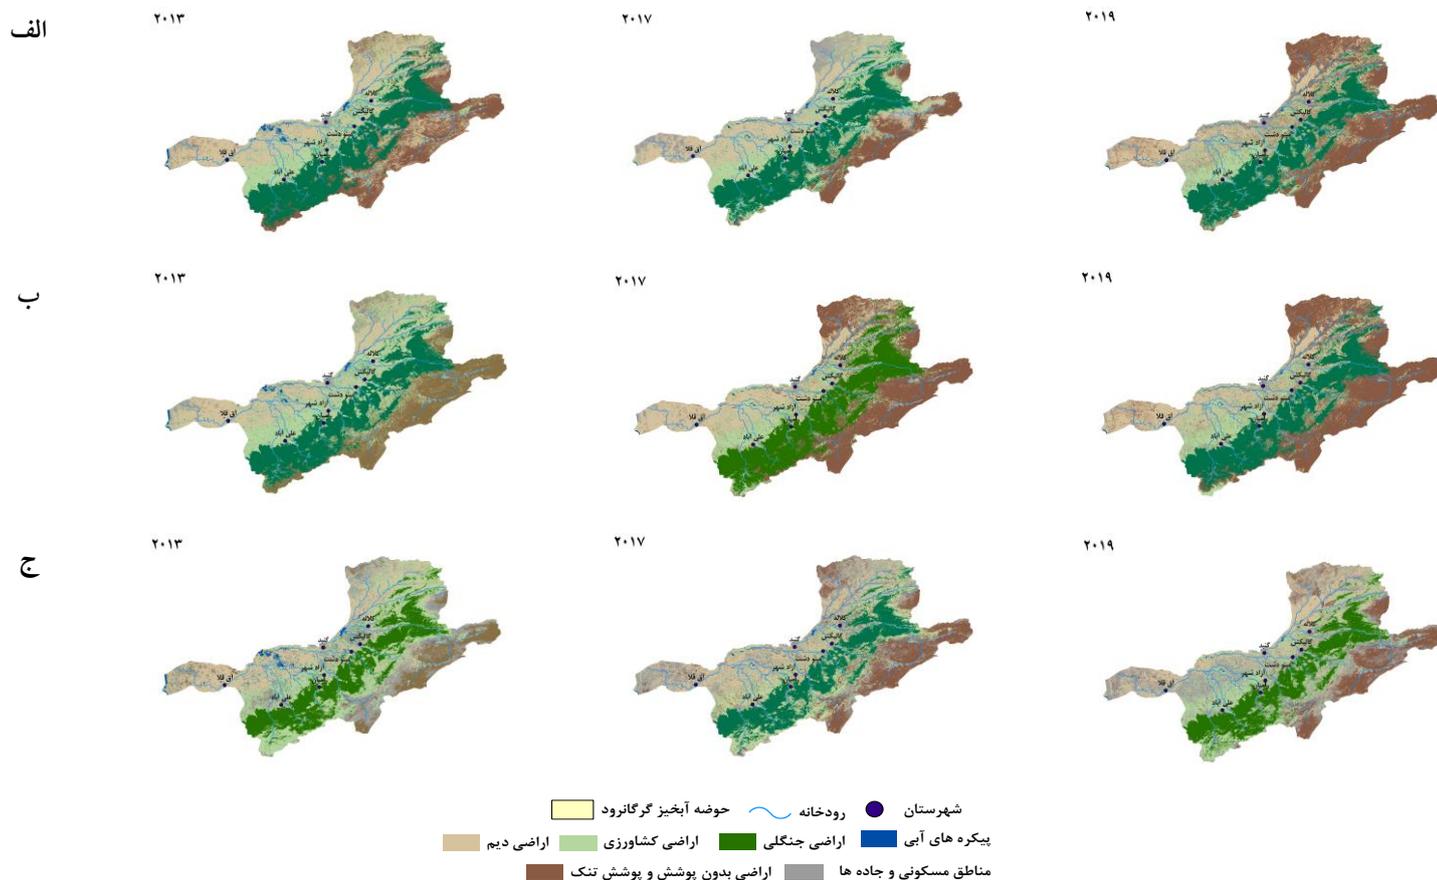


Figure (2): Landuse change detection by (a) Random Forest, (b) Support Vector Machine and (c): Maximum Likelihood methods in 3 study period time

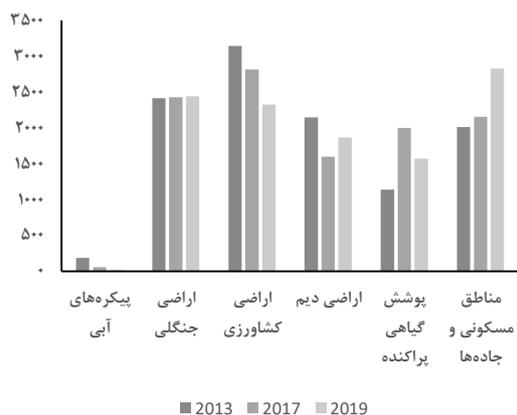
شکل (۲): تغییرات کاربری اراضی به روش (الف) جنگل تصادفی، (ب) ماشین بردار پشتیبان و (ج) حداکثر شدت احتمال در سه دوره مطالعاتی

جدول (۲): کلاس‌های طبقه‌بندی شده در پژوهش حاضر و تعریف آن‌ها بر اساس لپساند و همکاران، ۲۰۰۴

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

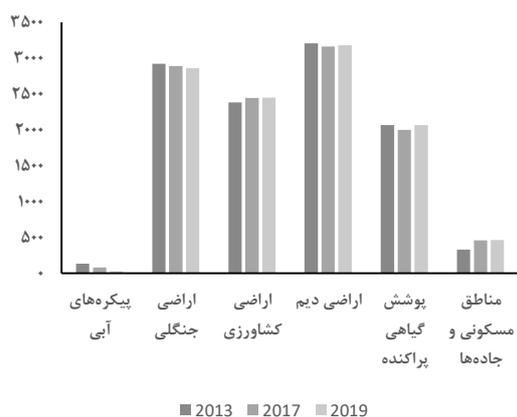
تعریف کلاس کاربری اراضی	کلاس کاربری اراضی
پیکره‌های آبی مناطقی را شامل می‌شود که سطح تراز آب آن در سال‌های متوالی نزدیک و یا بالای سطح زمین است. پیکره‌های آبی شامل، باتلاق‌ها، مرداب‌ها و لجنزارهایی که در حاشیه عمق کم خلیج‌ها قرار دارند، دریاها و دریاچه‌ها و برکه‌ها، نهرها، رودها و رودخانه‌ها و برکه‌های مصنوعی همانند مخازن آب می‌باشند.	پیکره‌های آبی

اراضی جنگلی	اراضی جنگلی به مناطقی اطلاق می‌شود که دارای تاج پوشش درختی هوایی بیش از ۱۰٪ هستند و با درختان احاطه شده است. این اراضی تولید کننده محصولات چوبی و الوار هستند.
اراضی کشاورزی	اراضی کشاورزی به مناطقی گفته می‌شود که جهت تولید غذا و فیبر مورد بهره‌برداری قرار می‌گیرند. این کلاس شامل زمین زراعی و چراگاه، باغ‌ها و تاکستان‌ها، نهالستان‌ها و باغ‌های زینتی می‌باشند.
اراضی دیم	اراضی دیم به اراضی شخم خورده خارج از محدوده کشاورزی اطلاق می‌شود.
مناطق مسکونی و جاده‌ها	مناطق مسکونی به اراضی گفته می‌شود که بیشترین مساحت آن را سازه‌ها تشکیل می‌دهند. این اراضی شامل کلان شهرها، شهرها، روستاها، اتوبان‌ها و زیرساخت‌های حمل و نقل همانند جاده و راه‌های ارتباطی و حمل و نقل، نیروگاه‌ها، مناطق دارای آسیاب‌های بادی و سایر آسیاب‌ها، مراکز خرید، شهرک‌های صنعتی و بخش‌های تجاری خارج از محدوده شهری هستند.
اراضی بدون پوشش و پوشش تنک	اراضی که قابلیت محدودی در تامین زندگی مردم را دارند تعریف می‌شوند. در آن‌ها کمتر از یک سوم منطقه دارای پوشش گیاهی است. این اراضی شامل اراضی خشک و شور، سواحل، زمین سنگلاخی بایر، مین نواری، معادن و گودال‌های شن و ماسه هستند.



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)

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

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

	۲۰۱۳	۲۰۱۷	۲۰۱۹
های آبی پیکره	۱۸۹/۷۹	۵۸/۹۷	۱۸/۹۷
اراضی جنگلی	۲۴۱۴/۲۲	۲۴۲۴/۵۲	۲۴۳۸/۳۱
اراضی کشاورزی	۳۱۴۳/۶۱	۲۸۱۲/۱۳	۲۳۳۴/۲۶
اراضی دیم	۲۱۴۳/۹۴	۱۵۹۷/۱۶	۱۸۶۴/۴۳
پوشش گیاهی پراکنده	۱۱۳۹/۵۵	۱۹۹۷/۲۹	۱۵۷۲/۶
همانطور مسکونی و جاده	۲۰۱۲/۸۳	۲۱۵۳/۸۹	۲۸۲۵/۳۷
مجموع مساحت ها	۱۱۰۴۴	۱۱۰۴۴	۱۱۰۴۴

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

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

	۲۰۱۳	۲۰۱۷	۲۰۱۹
های آبی پیکره	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
همانطور مسکونی و جاده	۳۳۱/۱۱	۴۵۹/۳۵	۴۶۵/۵۵
مجموع مساحت ها	۱۱۰۴۴	۱۱۰۴۴	۱۱۰۴۴

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

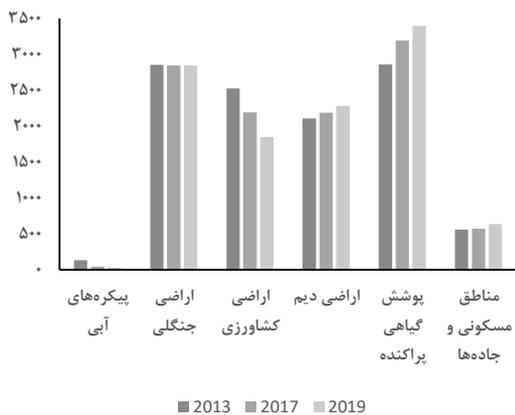
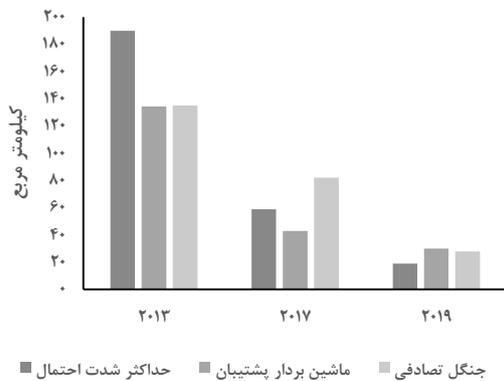


Table (5): Landuse change detection by SVM method (km²)

	۲۰۱۳	۲۰۱۷	۲۰۱۹
های آبی پیکره	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
هامناطق مسکونی و جاده	۵۸۸/۲۳	۵۷۳/۴	۶۳۷
مجموع مساحت ها	۱۱۰۴۴	۱۱۰۴۴	۱۱۰۴۴

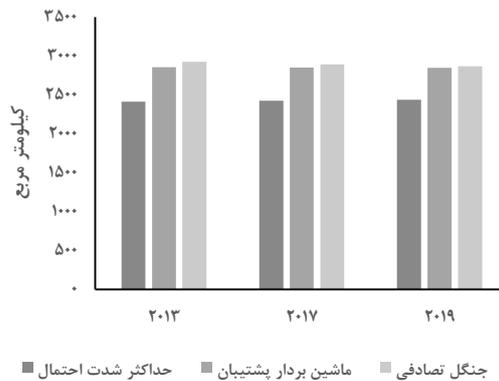
شکل (۵): تغییرات کاربری اراضی به روش ماشین بردار پشتیبان به (km²)

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



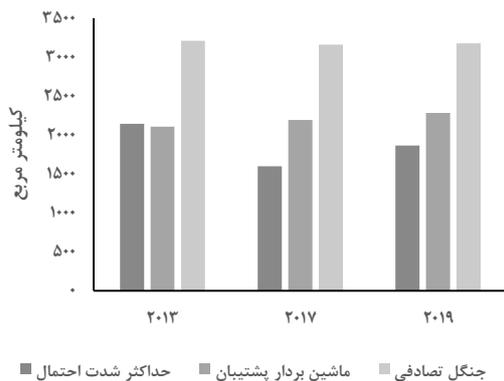
شکل (۶): مقایسه کلاسه‌بندی پیکره‌های آبی

Figure (6): Water lands classification compares



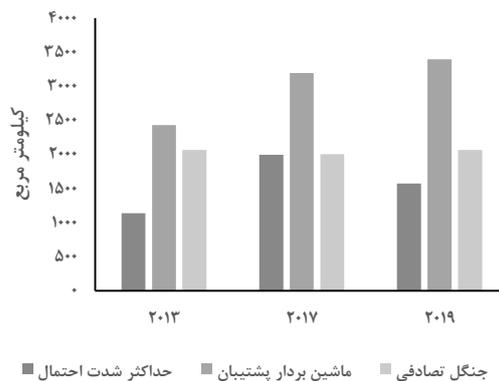
شکل (۷): مقایسه کلاسه‌بندی اراضی جنگلی

Figure (7): Forest lands classification compares



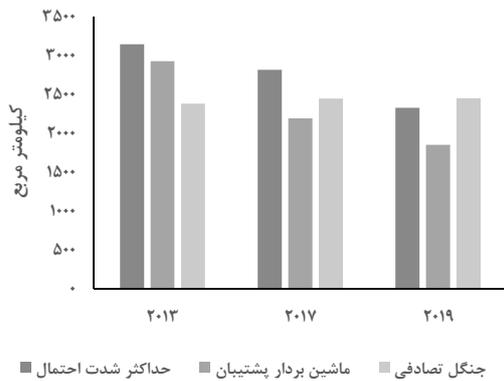
شکل (۸): مقایسه کلاسه‌بندی اراضی دیم

Figure (8): Rainfed lands classification compares



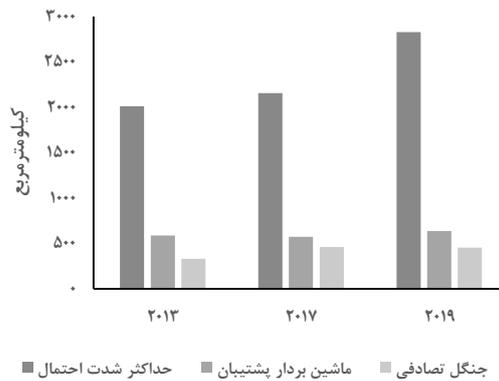
شکل (۹): مقایسه کلاسه‌بندی پوشش گیاهی پراکنده

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 تولید کننده هر روش طبقه‌بندی کننده در سال ۲۰۱۳

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

نگل تصادفی	ماشین بردار پشتیبان		حداکثر شدت احتمال		۲۰۱۳	
	صحت کاربر	صحت تولید کننده	صحت کاربر	صحت تولید کننده	صحت کاربر	صحت تولید کننده
کلاس	۷۶/۰۲	۱۰۰	۹۲/۷۲	۱۰۰	۹۹/۷۸	۹۹/۳۸
های آبی پیکره	۱۰۰	۸۹/۴۴	۹۶/۰۹	۹۹/۷۵	۹۷/۸۵	۹۸/۸۱
اراضی جنگلی	۶۴/۵۹	۸۹/۱۳	۷۵/۳۴	۸۸/۰۳	۹۵/۸۱	۶۴/۲۵
اراضی کشاورزی	۸۲/۸۱	۹۳/۳۵	۹۵/۴۷	۹۳/۳۱	۹۹/۳	۹۶/۵
اراضی دیم	۹۷/۸۳	۵۷/۴۲	۹۹/۵۷	۶۷/۶۷	۷۸/۴۷	۷۸/۱۷
پوشش گیاهی پراکنده	۶۳/۱۴	۱۰۰	۵۶/۶۹	۱۰۰	۲۴/۲۹	۴۸/۲۷
مناطق مسکونی و جاده‌ها						

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

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

جنگل تصادفی	ماشین بردار پشتیبان		حداکثر شدت احتمال		۲۰۱۷	
	صحت کاربر	صحت تولید کننده	صحت کاربر	صحت تولید کننده	صحت کاربر	صحت تولید کننده
کلاس	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۹۹/۹۵	۹۸/۶۲
های آبی پیکره	۹۷/۹	۸۵/۷۴	۹۸/۸۶	۸۵/۱۶	۹۸/۰۲	۷۴/۴۲
اراضی جنگلی	۷۳/۸۱	۶۲/۹۸	۶۶/۷۷	۶۲/۲۸	۵۷/۹۱	۶۱/۳۲
اراضی کشاورزی	۷۳/۱۴	۹۶/۳۵	۷۳/۴۸	۹۴/۶۴	۷۷/۹۴	۷۱/۳۱
اراضی دیم						

پوشش گیاهی پراکنده	۴۱/۱	۷۶/۹۸	۷۸/۷۱	۸۸/۹۹	۸۲/۶۴	۹۲/۹۸
مناطق مسکونی و جاده‌ها	۶۷/۵۴	۱۵/۶۸	۱۰۰	۸۴/۴۲	۱۰۰	۸۲/۳۲

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

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

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

نتیجه گیری

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 حداقل 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. بطور کلی با توجه به نتایج بدست آمده 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

باتوجه به جدول ۶ و مشاهده دقت کلاسه‌بندی صورت گرفته بر اساس 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 بدست آمده 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

دور از انتظار نیست. افزایش مناطق مسکونی و اراضی کشاورزی هرچند آرام، گواهی است بر 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 چرا که تامین آب برای کشت و زرع با مشکل روبرو 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 روبرو 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 شخم خورده، 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.

منابع

- 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].
- 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].
- Bolstad, P., & Lillesand, T. M. (1991). Rapid maximum likelihood classification. *Photogrammetric engineering and remote sensing*, 57(1), 67-74.
- Bonyad Amir, A., & Hajjaderi, 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].
- 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.
- Cristianini, N., & Shawe-Taylor, J. (2000). *An introduction to support vector machines and other kernel-based learning methods*. Cambridge university press.
- 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].
- 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].
- 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.
- 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.
- 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*

- 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
- 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].
- 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 goleslan province. *journal of wood and forest science and technology*, 24(2), 73-86. [In Persian].
- 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].
- Pal, M. (2005). Random forest classifier for remote sensing classification. *International journal of remote sensing*, 26(1), 217-222.
- 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.
- 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.
- Richards, J. A., & Richards, J. A. (2022). *Remote sensing digital image analysis* (Vol. 5, pp. 256-258). Berlin/Heidelberg, Germany: springer.
- 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.
- Saha, J., Ria, S. S., Sultana, J., Shima, U. A., Seyam, M. M. H., & Rahman, M. M. (2024). *Science*, 2019, Vol. 22, No. 4, p235-246. [In Persian].
- 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.
- Karami, O., Hoseini Nasr, S.M., Jalijvand, H., Miryaghoobzadeh, 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.
- 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.
- 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].
- Lillesand, T.M., Kiefer, R.W., & Chipman, J.W. (2004). *Remote Sensing and Image Interpretation*, fifth edition Wiley and Sons. New York, 763.
- 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.
- 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].
- 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].

Evaluation of Optimal Machine Learning Models for Satellite Image Classification and Land Use/Land Cover Change Detection in the Gorganroud Basin

Edith Eishoei, ¹ Miryaghoubzadeh, Mirhassan ^{2*}, Kaka Shahedi³

Received: 20/12/2025

Accepted: 16/02/2026

Extended Abstract

Introduction: Knowledge of land-use distribution and its temporal change trends constitutes one of the fundamental requirements in environmental planning and management. Understanding land-use change plays a critical role in analyzing land development processes and supporting sustainable resource management. The application of remote sensing technology in land-use studies, particularly for the extraction of land-use maps, has achieved significant success in change detection and the formulation of effective management policies. In recent years, numerous algorithms have been developed for land-use classification using remotely sensed imagery. Therefore, selecting the most appropriate classification algorithm is essential for achieving accurate and reliable results. Among probabilistic classification methods, the Maximum Likelihood algorithm is one of the most widely used techniques and is recognized as a highly accurate approach for image classification. The Support Vector Machine (SVM) algorithm is relatively insensitive to high-dimensional data characteristics and is therefore considered an effective method for the classification of multispectral and hyperspectral datasets. One of the main advantages of SVM is its ability to produce optimal classification results using relatively small training samples, which reduces operational costs while increasing classification efficiency. The Random Forest algorithm represents another powerful machine learning approach based on an ensemble of decision trees. In this method, each tree is constructed using randomly generated subsets of input data and features. Each tree independently assigns a class label, and the final classification is determined based on the class receiving the highest level of agreement among the trees.

Materials and Methods: In this study, multitemporal Landsat 8 Operational Land Imager (OLI) imagery acquired in 2013, 2017, and 2019 was used to extract and analyze land use/land cover (LULC) changes in the Gorganroud Basin, located in Golestan Province. Landsat 8 imagery during the study period provided stable and reliable data for mapping and detecting LULC changes. Radiometric corrections were performed using the Chavez atmospheric correction method and the Dark Object Subtraction (DOS) technique to reduce atmospheric effects and improve image quality. Furthermore, to prepare satellite imagery for processing and ensure radiometric consistency between multitemporal datasets, the histogram matching algorithm was applied. In this approach, the histogram of each image was adjusted relative to a reference image to minimize radiometric differences. Panchromatic data, together with intensity components derived from RGB multispectral imagery, were normalized through histogram matching to improve comparability among datasets. To evaluate the accuracy of the classified maps, an error (confusion) matrix was employed. Accuracy assessment requires reference data or regions of interest (ROIs), which were obtained through field surveys conducted in 2017. Within the error matrix framework, classified data were compared with reference (ground truth) data to quantify classification performance. The Kappa coefficient, widely used in remote sensing studies, was calculated to assess and compare the accuracy of different classification methods. For change detection analysis, multitemporal images were first normalized using histogram matching based on a selected base year. Subsequently, the image differencing technique was applied to identify and quantify land-use changes over time.

Results: Evaluation of the classification results based on accuracy assessment indices, together with comparisons against locally derived maps obtained through field surveys, demonstrates the high accuracy of the algorithms

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

DOI: 10.22052/deej.2026.258129.1131

applied in this study. The findings also confirm the effectiveness of Landsat 8 imagery for extracting reliable land use/land cover (LULC) maps. The results indicate that between 2013 and 2019 forest areas experienced a slight decrease. Dryland areas showed gradual and relatively minor changes over the study period. In contrast, bare soil areas increased significantly, particularly after the initial two-year interval, suggesting a reduction in natural vegetation cover. If this trend continues, the region may face substantial forest degradation and potential conversion of forested areas into rainfed agricultural lands. The Maximum Likelihood classification method exhibited different change patterns for rainfed lands, forests, and areas with scattered vegetation cover. Under this method, forest changes appeared relatively stable, while residential areas, rainfed lands, and scattered vegetation areas showed gradual increases over time. Comparison of classification accuracy metrics among the applied algorithms indicates that the Random Forest and Support Vector Machine methods achieved higher accuracy than the Maximum Likelihood approach. Additionally, the analysis reveals a declining trend in both wetland and forest areas throughout the study period.

Discussion and conclusion: The results indicate that the study area is experiencing forest degradation accompanied by an expansion of dryland areas, particularly in higher elevations. These land-use changes should be carefully considered in future land management and planning strategies, as they may increase flood susceptibility in the region. Although land-cover changes during the study period occurred gradually, no abrupt or large-scale transformations were observed within the relatively short time frame analyzed. However, if the current trend continues, forested areas are likely to be converted into agricultural or rainfed lands. Such transitions may lead to increased water consumption, contributing to the degradation and shrinkage of wetland ecosystems. The reduction of water resources may further result in the expansion of unused or abandoned lands due to limited water availability for cultivation and other human activities. Comparison of the three classification methods—Random Forest, Support Vector Machine (SVM), and Maximum Likelihood—demonstrates that Random Forest and SVM produced highly consistent results, whereas the Maximum Likelihood method generated comparatively different outputs. Accuracy assessments derived from the classified maps clearly indicate that Random Forest and SVM provide more reliable and accurate classification performance. The analysis further reveals that forest cover has decreased in steep terrain, while cultivated and plowed lands have expanded. Such land-use transformations may intensify surface runoff and increase flood risk in the basin. Consequently, continued land-cover change may pose significant challenges for future water resource availability and sustainable water supply for local residents.

Keywords: LULC Change detection, Landsat imagery, Random Forest, Support Vector Machine, Gorganroud basin.