

ارزیابی عملکرد پردازش تک‌زمانه و چندزمانه تصاویر ماهواره لندست ۸ مبتنی بر طبقه‌بندی کننده‌های ماشین بردار پشتیبان و جنگل تصادفی در پایش آتش‌سوزی جنگل‌ها

نادیا عباس‌زاده طهرانی*

استادیار پژوهشگاه هوافضا، وزارت علوم، تحقیقات و فناوری، تهران، ایران
آذر مروتی

دانشجوی کارشناسی ارشد دانشگاه آزاد اسلامی واحد جنوب
سارا خانبنایی

دانشجوی دکتری فتوگرامتری دانشگاه تهران، تهران، ایران
میلاذ جانعلی‌پور

استادیار پژوهشگاه هوافضا، وزارت علوم، تحقیقات و فناوری، تهران، ایران

(تاریخ دریافت: ۱۴۰۰/۱/۱۶ - تاریخ پذیرش: ۱۴۰۰/۵/۲۲)

چکیده

پدیده آتش‌سوزی جنگل‌ها، از مخاطرات محیط زیستی مهم محسوب می‌شود. داده‌های ماهواره لندست ۸ با توان تفکیک مکانی متوسط و دسترسی آسان از منابع مهم در زمینه پایش آتش‌سوزی‌های گسترده است. هدف این مقاله ارزیابی رویکرد تک‌زمانه و دوزمانه مبتنی بر تصویر حین آتش‌سوزی و تصاویر قبل و بعد از آتش‌سوزی از ماهواره لندست ۸ و طبقه‌بندی کننده‌های ماشین بردار پشتیبان و جنگل تصادفی برای شناسایی آتش‌سوزی جنگل‌هاست. نتایج پردازش تصاویر ماهواره‌ای جنگل‌های پارادایز منطقه ساکرامنتو در ایالت کالیفرنیا، نشان داد که روش طبقه‌بندی جنگل تصادفی بر روی داده تک‌زمانه حین آتش‌سوزی با صحت کلی ۹۹/۸۳ درصد، در مقایسه با روش ماشین بردار پشتیبان با صحت کلی ۹۹/۵۳ درصد، توانایی بیشتری برای تفکیک آتش از غیر آتش دارد. البته در هر دو روش، صحت کلی زیاد است که مؤید مطلوبیت استفاده از هر دو روش برای تشخیص مخاطره آتش‌سوزی است. همچنین عملکرد طبقه‌بندی تصویر تک‌زمانه بعد از آتش‌سوزی، بهتر از تصاویر دوزمانه قبل و بعد از آتش‌سوزی بوده است.

واژه‌های کلیدی: طبقه‌بندی ماشین بردار پشتیبان، طبقه‌بندی جنگل تصادفی، ماهواره لندست ۸، مخاطره آتش‌سوزی.

مقدمه

ردیابی تغییرات^۱ در سنجش از دور به معنای شناسایی تغییرات طبیعی یا انسانی ایجاد شده در منطقه‌ای خاص توسط پردازش تصاویر سنجش از دور و در طی زمان است. مسئله شناسایی تغییرات با توجه به کاربردهای وسیع آن در حوزه‌های مختلف مانند مدیریت منابع سرزمین، پایش تغییرات محیط زیستی، رشد شهرها، تغییرات کاربری زمینی، پایش مخاطرات طبیعی، ارزیابی خسارات و غیره، از اهمیت زیادی برخوردار است [۲۷، ۴، ۱].

آتش‌سوزی جنگل‌ها از مخاطرات مهمی است که ممکن است عامل انسانی یا غیرانسانی داشته باشد و موجب اختلال‌های زیادی در چرخه اکوسیستم، تخریب زیرساخت‌های جنگل، فرسایش خاک و همچنین از بین رفتن حیات بسیاری از موجودات زنده می‌شود [۵-۳]. توجه و نظارت بیشتر بر مناطق مستعد آتش موجب جلوگیری از این مخاطره می‌شود [۶]. ماهواره‌های سنجش از دور قادر به تعیین موقعیت نقاط آتش با بهره‌گیری از آنالیز تصاویر چندزمانه هستند [۱۶].

ماهواره‌های با توان تفکیک زمانی زیاد، مانند ماهواره‌های نوآ^۲، ای وی اچ آر آر^۳ و مادیس^۴، می‌توانند به‌طور «تقریباً بهنگام» حدود تقریبی محل وقوع آتش را مشخص کنند. البته توان تفکیک مکانی نقشه‌های تولید شده کم است و نمی‌توان در حد متر محل آتش‌سوزی را مشخص کرد. از این‌رو، داده‌های ماهواره‌ای با قدرت تفکیک مکانی متوسط، به‌منظور پایش کلی یا ناحیه‌ای استفاده می‌شوند که نقشه محل مخاطره آتش را در مقیاس مناسب‌تری فراهم می‌کنند. دسترسی آسان به داده‌های لندست و تهیه نقشه تغییرات با جزئیات بهتر نسبت به ماهواره‌های ذکر شده در بالا، از دلایل استفاده از آنها برای پایش مناطق آتش‌سوزی است. روش‌های مختلفی برای شناسایی آتش از تصاویر ماهواره‌ای ارائه شده است که به سه دسته بصری، نیمه‌خودکار و خودکار تقسیم می‌شوند [۳۶]. در برخی تحقیقات، از تصاویر حرارتی برای شناسایی آتش استفاده شده است [۳۹، ۷]. به‌طور معمول توان تفکیک مکانی باندهای حرارتی کمتر از باندهای مرئی و مادون قرمز نزدیک است. از این‌رو در برخی آتش‌سوزی‌های کوچک، امکان شناسایی دقیق آتش در تصاویر حرارتی وجود ندارد [۳۳]. با توجه به این محدودیت، برخی محققان از باندهای چندطیفی برای شناسایی آتش استفاده کرده‌اند که موضوع این پژوهش نیز در همین زمینه است [۳۷، ۱۳].

-
1. Change Detection
 2. NOAA
 3. AVHRR
 4. MODIS

در بررسی مطالعات پیشین، الگوریتم‌های شناسایی مناطق آتش‌سوزی به دو دسته تقسیم شده‌اند [۱۷]. دسته اول روش‌های زنجیره‌ای پردازش تک‌فازه هستند که از تکنیک‌های طبقه‌بندی برای تمایز نهادن میان مناطق آتش و غیرآتش به صورت نظارت‌نشده یا نظارت‌شده استفاده می‌کنند. محققان در سال ۲۰۱۱ به بررسی روش طبقه‌بندی ماشین بردار پشتیبان بر روی تصاویر چندطیفی سنجنده TM ماهواره‌اندست پرداختند [۳۲]. در تحقیقی دیگر در سال ۲۰۱۱، بررسی مقایسه‌ای روش طبقه‌بندی ماشین بردار پشتیبان و روش نگاشت زاویه طیفی در تهیه نقشه آتش از تصاویر اندست صورت گرفت [۸]. در سال ۲۰۰۵، کرنل بافتی با استفاده از مشخصه‌های بافت و رادیومتریک برای طبقه‌بندی‌کننده ماشین بردار پشتیبان با هدف شناسایی دقیق‌تر مناطق آتش به کمک تصاویر سنجش از دور معرفی شد [۲۹].

در سال ۲۰۲۰، برای شناسایی مناطق آتش‌سوزی، از روش شناسایی تغییرات براساس ارائه شاخص طیفی جدید NBRSWIR و روش حد آستانه‌گذاری خودکار استفاده شد [۳۰] در مقاله‌ای در سال ۲۰۱۹، به منظور تهیه نقشه مناطق آتش‌گرفته از الگوریتم جنگل تصادفی به صورت شیء‌مبنا استفاده شد [۱۸]. در سال ۲۰۲۰ نقشه پیش و پس از آتش‌سوزی با استفاده از روش طبقه‌بندی ماشین بردار پشتیبان بهینه‌شده با الگوریتم بهینه‌سازی رقابت استعماری تهیه شد و مقایسه آن با روش طبقه‌بندی ماشین بردار پشتیبان متداول بر روی تصاویر سنتینل ۲ و اندست ۸ صورت گرفت [۳۸]. در سال ۲۰۱۹ نتایج پیش‌بینی ماشین بردار پشتیبانی و روش‌های جنگل تصادفی با استفاده از میانگین بیزی تلفیق شد. با توجه به نتایج، روش‌های SVM و RF و روش حاصل از تلفیق آنها عملکرد قابل قبولی داشتند [۲۲]. در سال ۲۰۱۶ عملکرد روش‌های طبقه‌بندی «جنگل تصادفی» و رگرسیون بردار پشتیبان^۱ (SVM)، در تشخیص تغییرات مخاطرات طبیعی ارزیابی شد. نتایج نشان داد که عملکرد SVM در مقایسه با جنگل تصادفی (RF) با دقت کلی ۳ تا ۴ درصد بیشتر بهتر است [۲۰]. جعفری و پورقاسمی در سال ۲۰۱۹، عوامل مؤثر بر احتمال آتش‌سوزی در ایران را براساس کاربرد روش جنگل تصادفی و ماشین بردار پشتیبان بررسی کردند. برای پیش‌بینی احتمال وقوع آتش‌سوزی، از مدل ماشین بردار پشتیبان استفاده شد و ثابت شد که این مدل با موفقیت ۰/۸۱ و پیش‌بینی ۰/۷۵، صحت رضایت‌بخشی دارد [۲۴]. در سال ۲۰۱۸ از دو روش جنگل تصادفی و ماشین بردار پشتیبان برای تولید نقشه از مناطق سوخته‌شده جنگل‌های آمازون استفاده شد [۱۹]. در تحقیقی دیگر، کارایی الگوریتم‌های جنگل تصادفی و ماشین بردار پشتیبان و درخت تصمیم‌گیری (CART) در شناسایی مناطق سوخته مقایسه شد. یافته‌ها نشان داد که الگوریتم‌های درخت تصمیم‌گیری و جنگل تصادفی تکه‌های مشابه آتش‌سوزی در

1. Support Vector Regression

جنگل را با دقت کلی ۹۷-۱۰۰ درصد شناسایی شده‌اند. درحالی که دقت طبقه‌بندی SVM به دلیل تخمین کمتر تکه‌های آتش‌سوزی جنگل، اندکی کمتر برآورد شد [۱۱]. با توجه به کارایی تصاویر لندست در شناسایی مناطق آتش و همچنین استفاده از تصاویر تک‌زمانه در بعضی مقالات و تصاویر چندزمانه (به‌صورت روش‌های شناسایی تغییرات) و همچنین روش‌های طبقه‌بندی ماشین بردار پشتیبان و جنگل تصادفی در مقالات پیشین، این تحقیق به بررسی امکان یافتن مناطق آتش‌سوزی با استفاده از روش‌های طبقه‌بندی ماشین بردار پشتیبان و جنگل تصادفی روی تصویر تک‌زمانه حین آتش‌سوزی و تصویر اختلاف محاسبه‌شده از تصاویر قبل و حین آتش در شمال ساکرامنتوی کالیفرنیا می‌پردازد.

روش‌ها

مدل مفهومی روش پیشنهادی در دو مرحله کلی مطابق شکل ۱ نمایش داده شده است. در مرحله اول تصاویر ورودی مربوط به زمان قبل از آتش‌سوزی و حین آن، پیش‌پردازش شده و تصویر اختلاف به‌منظور تمایز بهتر بین مناطق تغییر یافته و نیافته ایجاد می‌شود. سپس تصویر مذکور به‌منظور شناسایی مناطق آتش‌سوزی وارد الگوریتم‌های طبقه‌بندی‌کننده ماشین بردار پشتیبان و جنگل تصادفی می‌شود. آنالیز حساسیت روی پارامترهای طبقه‌بندی‌کننده انجام خواهد گرفت و در نهایت نقشه‌های مناطق آتش‌سوزی تولید خواهد شد [۱]. در مرحله دوم فقط تصویر حین آتش‌سوزی بررسی می‌شود و الگوریتم‌های طبقه‌بندی ذکر شده در مرحله اول و آنالیز حساسیت و دقت روی تک‌تصویر ورودی حین آتش‌سوزی انجام می‌گیرد و در نهایت، نتایج خروجی مراحل اول و دوم بررسی و تحلیل می‌شود.

پیش‌پردازش

یکی از گام‌های اصلی در استفاده از داده‌های سنجش از دوری برای شناسایی تغییرات ناشی از مخاطرات پیش‌پردازش تصاویر است. اخذ تصاویر با سنجنده‌های مختلف، در شرایط تصویربرداری متنوع از جمله شرایط فصلی و زمانی یا زاویه دید تصویربرداری مختلف سبب جابه‌جایی‌هایی در موقعیت نقاط متناظر در تصویر می‌شود که مقایسه آنها را با یکدیگر دشوار می‌کند و سبب ایجاد تغییرات مکانی و رادیومتریکی فاحش در تصاویر می‌شود. به‌منظور جلوگیری از شناسایی تغییرات اشتباه در مقایسه تصاویر دو یا چندزمانه باید تصاویر از لحاظ هندسی هم‌مرجع شوند و رفتار رادیومتریکی آنها نیز اصلاح شود [۳۴، ۳۱، ۲۸، ۲۵، ۲۳، ۹].

ایجاد تصویر اختلاف

فرض کنید تصاویر X_1 و X_2 به ترتیب نشان‌دهنده تصاویرهای قبل از آتش‌سوزی و حین آتش‌سوزی

مطابق رابطه‌های ۱ و ۲ بوده و هر دو با ابعاد یکسان $M \times N \times K$ از یک موقعیت جغرافیایی اخذ شده باشند؛ جایی که M نشان‌دهنده سطرها، N نشان‌دهنده ستون‌ها و K نشان‌دهنده تعداد باندهای تصویر است. تصویر اختلاف ساده DI به‌منظور ایجاد یک تصویر مقایسه‌ای که تمایز پیکسل‌ها را به‌خوبی نشان می‌دهد، مطابق با رابطه ۳ محاسبه می‌شود [۲۳، ۱۲].

$$X_1 = \{x_1(i, j) | 1 \leq i \leq M, 1 \leq j \leq N\} \quad (1)$$

$$X_2 = \{x_2(i, j) | 1 \leq i \leq M, 1 \leq j \leq N\} \quad (2)$$

$$DI^K = |X_2^K - X_1^K| \quad (3)$$

طبقه‌بندی‌کننده ماشین بردار پشتیبان (SVM)

روش طبقه‌بندی ماشین بردار پشتیبان (SVM)، روش طبقه‌بندی نظارت‌شده است که توسط واپنیک در سال ۱۹۹۵ معرفی شد. در روش طبقه‌بندی ماشین بردار پشتیبان از انواع توابع خطی و غیرخطی برای جداسازی طبقات از یکدیگر استفاده می‌شود. در روش ماشین بردار پشتیبان توابع جداساز در فضای ویژگی نمونه‌های طبقات را از یکدیگر تفکیک می‌کنند، به‌شکلی که بیشترین تفکیک‌پذیری میان آن طبقات ایجاد شود. این روش در طی فرایند بهینه‌سازی، ابرصفحه جداکننده میان نمونه‌ها را برآورد می‌کند [۲۶، ۱۴]. روابط ریاضی مورد استفاده در روش طبقه‌بندی‌کننده ماشین بردار پشتیبان به‌طور کامل ذکر شده است [۳۴].

طبقه‌بندی‌کننده جنگل تصادفی

طبقه‌بندی‌کننده جنگل تصادفی از مجموعه طبقه‌بندی‌کننده‌های درختی محسوب می‌شود. در این روش، چند درخت تصمیم‌گیری به‌صورت تصادفی تولید می‌شوند که به کمک آنها طبقه‌بندی تصاویر انجام خواهد گرفت. از تولید چند درخت، جنگل ایجاد می‌شود که به‌دلیل تصادفی بودن این فرایند به آن جنگل تصادفی اطلاق می‌شود. بنابراین مهم‌ترین متغیر روش طبقه‌بندی جنگل تصادفی، تعداد درختان است. در نتیجه چند تصویر طبقه‌بندی‌شده از منطقه تحقیق در اختیار خواهد بود. در مرحله بعد نتایج طبقه‌بندی‌کننده‌ها با رأی اکثریت تلفیق خواهند شد. بدیهی است تکرار روش و استفاده از نمونه‌های آموزشی متنوع می‌تواند به رسیدن نتایج مطلوب کمک کند [۳۵]. روابط ریاضی و مدل مفهومی اجرای روش طبقه‌بندی جنگل تصادفی ارائه شده‌اند [۲۱].

اعتبارسنجی

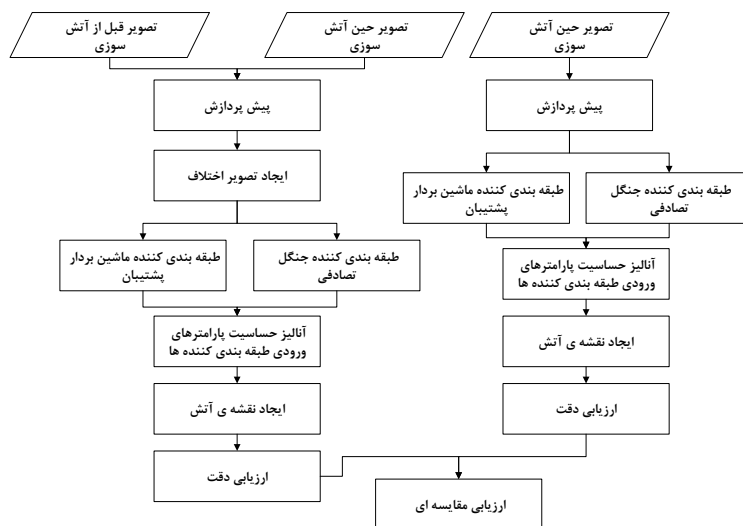
برای اعتبارسنجی نتایج روش‌های طبقه‌بندی از نمونه‌های ارزیابی که موقعیت پیکسل‌های

آتش و غیرآتش را مشخص می‌کنند استفاده می‌شود. داده‌های ارزیابی توسط عامل خبره به صورت دستی از تصاویر ماهواره‌ای قبل و بعد از آتش‌سوزی جمع‌آوری شده‌اند. نتایج به دست آمده از طبقه‌بندی کننده با نمونه‌های ارزیابی مقایسه می‌شود و چند نمونه صحیح و خطا دار به دست می‌آید. پس از آن آماره‌هایی نظیر ضریب کاپا، صحت کلی، کاربر و تولیدکننده برای هر طبقه‌بندی کننده محاسبه می‌شود [۲۸].

داده‌ها و بحث

منطقه تحقیق

به منظور بررسی عملکرد روش پیشنهادی، منطقه‌ای با ابعاد ۱۰۰۰ در ۱۰۰۰ پیکسل از شمال ساکرامنتوی کالیفرنیا انتخاب و از لندست ۸ که شامل ۱۱ باند طیفی است استفاده شد. منطقه در موقعیت جغرافیایی ۱۲۱ درجه و ۳۵ دقیقه شمالی و ۳۸ درجه و ۴۵ دقیقه غربی واقع است. داده مربوط به زمان قبل از آتش‌سوزی در تاریخ بیست و یکم اوت ۲۰۱۸ و داده حین آتش‌سوزی در تاریخ هشتم نوامبر ۲۰۱۸ اخذ شد (شکل ۱). آتش‌سوزی بزرگ رخ داده در این منطقه و زمان آن به گونه‌ای بود که ماهواره لندست ۸ حین آتش‌سوزی توانست تصاویر را از منطقه اخذ کند. بنابراین یکی از دلایل انتخاب منطقه هم‌زمانی اخذ تصویر لندست ۸ با مخاطره بوده است. همچنین این آتش‌سوزی توسط محققان مختلف بررسی شده است و می‌توان به عنوان مبنا نتایج آن را با نتایج این تحقیق مقایسه کرد.



شکل ۱. مدل مفهومی روش پیشنهادی برای شناسایی آتش

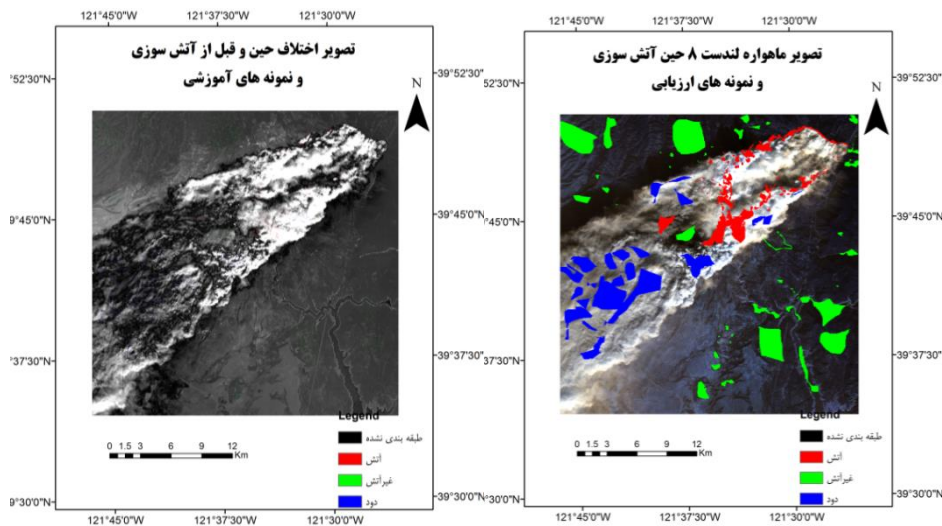
نتایج اجرا

به‌منظور بهبود و تصحیحات رادیومتریکی، هر دو تصویر ورودی با استفاده از فایل کالیبراسیون سنجنده کالیبره شد و برای بررسی صحت و تطابق هندسی دو تصویر با یکدیگر، از ۱۷ نقطه چک در منطقه استفاده شد. به‌دلیل تناظر حدود $0/31$ متر (به‌دست‌آمده از معیار RMSE) از مرحله تناظریابی چشم‌پوشی شد. به‌منظور آموزش الگوریتم، 402 پیکسل آموزشی برای منطقه آتش، 759 پیکسل آموزشی برای منطقه دود و 839 پیکسل غیرآتش انتخاب شد. همچنین به‌منظور ارزیابی دقت الگوریتم‌های طبقه‌بندی 25825 پیکسل آزمون برای منطقه آتش، 47118 پیکسل آزمون برای منطقه دود و 53616 پیکسل آزمون برای منطقه غیرآتش انتخاب شد. همان‌طور که مشاهده می‌شود، تعداد نمونه‌های آموزشی از تعداد نمونه‌های ارزیابی بسیار کمتر است، از این‌رو می‌توان انتظار داشت که اعتبارسنجی با دقت مناسب انجام گیرد. شکل ۲ نقشه منطقه تحقیق و همچنین تصاویر استفاده‌شده را نشان می‌دهد. نمونه‌ای از خروجی نقشه‌های آتش به‌دست‌آمده از دو روش طبقه‌بندی در شکل ۳ نشان داده شده است.

همان‌طور که در جدول ۱ و شکل ۴ نشان داده شده است، مقادیر پارامتر گاما برای کرنل تابع پایه شعاعی الگوریتم طبقه‌بندی ماشین بردار پشتیبان از $0/31$ تا ۱۶ و مقادیر پارامتر پنالتی نیز از مقدار $0/31$ تا ۱۲۸ تغییر داده شده که براساس تحقیقات پیشین انتخاب شده است [۲۱]. مطابق با نتایج جدول ۱، با افزایش مقدار پارامتر پنالتی، صحت کلی افزایش یافت. مطابق با مقادیر دقت خروجی‌های اخذشده بدیهی است که پارامتر تأثیرگذار در این مورد مقدار پنالتی است، زیرا با تغییر مقدار پنالتی صحت کلی تغییر می‌یابد، اما تغییر صحت نتایج با تغییر مقدار گاما در ستون مربوط به پارامتر پنالتی مقداری ثابت است. مطابق با جدول ۱، بیشترین مقدار صحت کلی مربوط به مقدار پارامتر پنالتی ۱۲۸ به‌ازای همه مقادیر گاما است که معادل $97/18$ درصد است و کمترین مقدار نیز مربوط به پارامتر پنالتی معادل $0/31$ برای همه پارامترهای گاما و معادل $94/50$ درصد است.

براساس شکل ۴ با افزایش مقدار پارامترهای پنالتی، صحت کلی افزایش می‌یابد و مقادیر صحت خروجی‌ها وابسته به مقدار پارامتر پنالتی است، زیرا با تغییر مقدار پنالتی صحت کلی تغییر می‌یابد، ولی تغییر مقدار گاما در ستون مربوط به پارامترهای پنالتی مقداری ثابت است. بیشترین مقدار صحت کلی مربوط به مقدار پارامتر پنالتی ۱۲۸ به‌ازای همه مقادیر گاما است که $99/53$ درصد است و کمترین مقدار نیز مربوط به پارامتر پنالتی معادل $0/31$ برای همه پارامترهای گاما و معادل $97/68$ درصد است. با توجه به نتایج خروجی، روش طبقه‌بندی ماشین بردار پشتیبان برای ورودی تک‌تصویر حین آتش‌سوزی صحت کلی

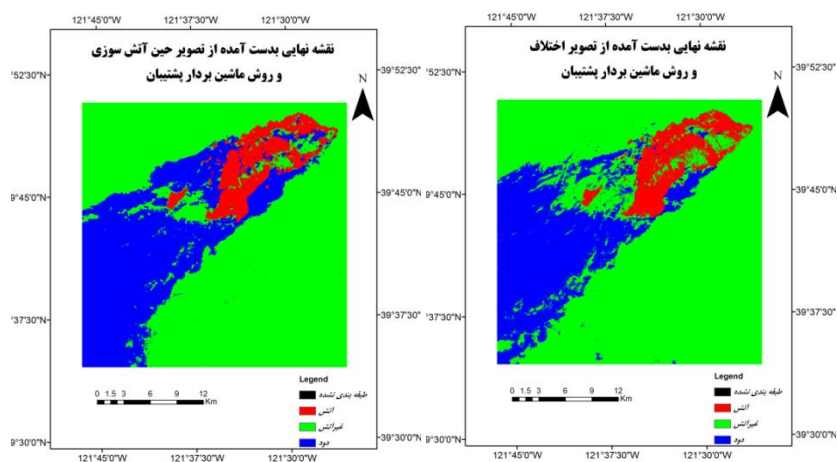
بیشتری را در همه پارامترهای مختلف پنالتی نسبت به ورودی تصویر اختلاف نشان می‌دهد. بیشترین صحت ورودی تصویر حین آتش‌سوزی ۹۹/۵۳ درصد است که نسبت به بیشترین صحت کلی تصویر اختلاف که ۹۷/۱۸ درصد است افزایش ۲/۳۵ درصدی را نشان می‌دهد.



(ب)

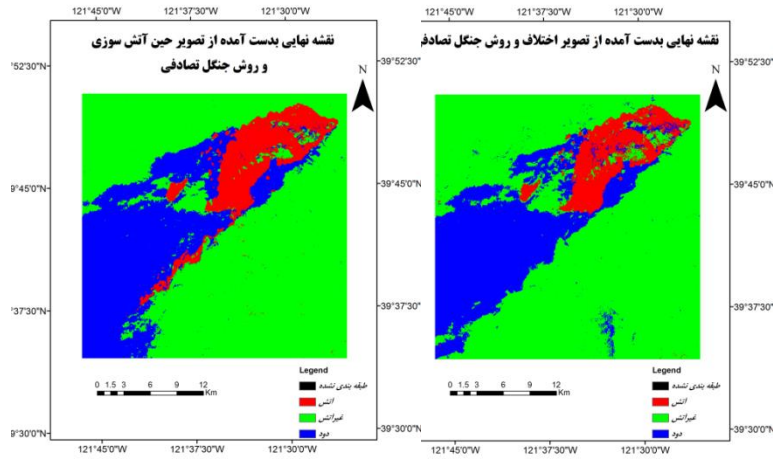
(الف)

شکل ۲. (الف) نمونه پیکسل‌های آموزشی؛ (ب) نمونه پیکسل‌های آزمون یا همان تصویر صحت زمینی. در هر دو تصویر رنگ قرمز نشان‌دهنده محل آتش، رنگ سبز نشان‌دهنده غیر آتش و رنگ آبی نشان‌دهنده دود است.



(ب)

(الف)



(د)

(ج)

شکل ۳. نتایج طبقه‌بندی‌کننده‌های ماشین بردار پشتیبان و جنگل تصادفی، الف) ماشین بردار پشتیبان پیاده‌شده بر تصویر اختلاف؛ ب) ماشین بردار پشتیبان پیاده‌شده بر تصویر بعد از آتش؛ ج) جنگل تصادفی پیاده‌شده بر تصویر اختلاف؛ د) جنگل تصادفی پیاده‌شده بر تصویر بعد از آتش

جدول ۱. مقادیر صحت کلی برحسب درصد و ضریب کاپا حاصل از خروجی روش طبقه‌بندی ماشین بردار پشتیبان با مقادیر مختلف پارامترهای پنالتی و گاما برای ورودی تصویر اختلاف

پنالتی/گاما	۰/۰۳۱	۰/۱۲۵	۰/۵	۲	۸	۳۲	۱۲۸
۱۶	O	۹۴/۵۰	۹۴/۸۷	۹۴/۴۶	۹۴/۷۵	۹۵/۵۴	۹۶/۱۳
	K	۰/۹۱۴	۰/۹۱۹	۰/۹۱۳	۰/۹۱۷	۰/۹۳۰	۰/۹۳۹
۸	O	۹۴/۵۰	۹۴/۸۷	۹۴/۴۶	۹۴/۷۵	۹۵/۵۴	۹۶/۱۳
	K	۰/۹۱۴	۰/۹۱۹	۰/۹۱۳	۰/۹۱۷	۰/۹۳۰	۰/۹۳۹
۲	O	۹۴/۵۰	۹۴/۸۷	۹۴/۴۶	۹۴/۷۵	۹۵/۵۴	۹۶/۱۳
	K	۰/۹۱۴	۰/۹۱۹	۰/۹۱۳	۰/۹۱۷	۰/۹۳۰	۰/۹۳۹
۰/۵	O	۹۴/۵۰	۹۴/۸۷	۹۴/۴۶	۹۴/۷۵	۹۵/۵۴	۹۶/۱۳
	K	۰/۹۱۴	۰/۹۱۹	۰/۹۱۳	۰/۹۱۷	۰/۹۳۰	۰/۹۳۹
۰/۱۲۵	O	۹۴/۵۰	۹۴/۸۷	۹۴/۴۶	۹۴/۷۵	۹۵/۵۴	۹۶/۱۳
	K	۰/۹۱۴	۰/۹۱۹	۰/۹۱۳	۰/۹۱۷	۰/۹۳۰	۰/۹۳۹
۰/۰۳۱	O	۹۴/۵۰	۹۴/۸۷	۹۴/۴۶	۹۴/۷۵	۹۵/۵۴	۹۶/۱۳
	K	۰/۹۱۴	۰/۹۱۹	۰/۹۱۳	۰/۹۱۷	۰/۹۳۰	۰/۹۳۹

مطابق با جدول ۲، مقادیر صحت کلی و ضرایب کاپا با تغییر تعداد درختان ورودی تغییر

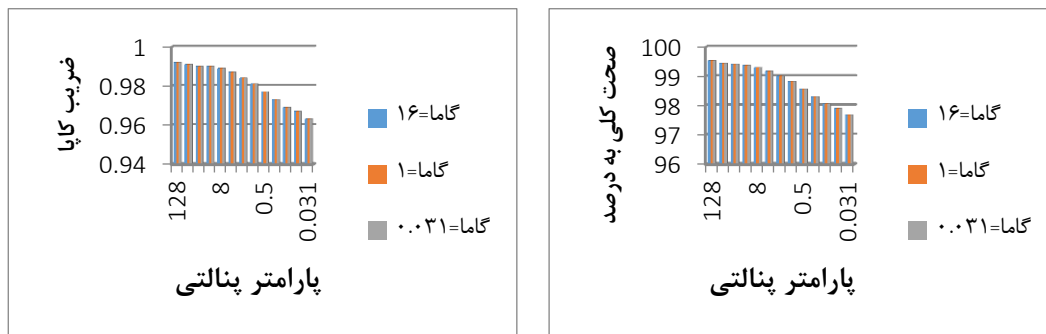
می‌یابد. به عبارتی این عامل گاهی موجب افزایش و گاهی موجب کاهش این مقادیر می‌شود. با توجه به نتایج خروجی، این تغییر کمتر از ۰/۰۵ درصد در مورد صحت کلی و کمتر از ۰/۰۰۵ در مورد ضریب کاپا است. بیشترین دقت حاصل از الگوریتم جنگل تصادفی برای ورودی تصویر اختلاف ۹۹/۲۸ درصد بوده که با تعداد درخت ۲۰۰ ایجاد شد و به تبع آن بیشترین ضریب کاپا با ۰/۹۸۸۸ ایجاد شد. در مورد ورودی تصویر حین آتش‌سوزی بیشترین دقت ۹۹/۸۳ درصد نشان داده شد که با تعداد ۳۰۰ درخت اتفاق افتاد. بیشترین ضریب کاپا نیز ۰/۹۹۷۴ است.

با توجه به نتایج حاصل‌شده، روش جنگل تصادفی و ماشین بردار پشتیبان دقت بیشتری را در حالت تک‌تصویر نسبت به حالت تصویر اختلاف نشان می‌دهند. مطابق با نتایج شکل ۴، روش جنگل تصادفی در حالت ورودی تک‌تصویر حین آتش‌سوزی بیشترین صحت کلی معادل ۹۹/۸۳ درصد و روش ماشین بردار پشتیبان در حالت ورودی تک‌تصویر حین آتش‌سوزی صحت کلی ۹۹/۵۳ درصد را نشان می‌دهند.

با توجه به ماتریس خطای به‌دست‌آمده، طبقه آتش در مورد تصویر تک‌زمانه حین آتش‌سوزی بیشترین صحت کاربر (۱۰۰ درصد) را نشان داد که در مقایسه با صحت کاربری طبقه آتش در مورد ورودی تصویر اختلاف، افزایش ۰/۰۶ درصدی دارد. این ۰/۰۶ درصد خود معادل حدود ۲۵۰ پیکسل است. طبقات دود و مناطق غیرآتش نیز به ترتیب صحت کاربری ۹۹/۳۷ و ۹۹/۴۵ درصد دارند که در مقایسه با ورودی تصویر اختلاف افزایش ۲/۶ و ۳/۲ درصدی را نشان می‌دهند. طبقه دود نیز بیشترین صحت تولیدکننده معادل با ۹۹/۷۹ درصد را در مورد ورودی تک‌زمانه حین آتش‌سوزی دارد که نسبت به طبقه دود در ورودی تصویر اختلاف، افزایش ۳/۲ درصدی را نشان می‌دهد. به لحاظ صحت کلی، روش ماشین بردار پشتیبان در حالت تصویر تک‌زمانه حین آتش‌سوزی دقت ۹۹/۵۳ درصدی دارد که در مقایسه با ورودی تصویر اختلاف، افزایش ۲/۳۵ درصدی را نشان می‌دهد که از لحاظ تعداد پیکسل این تفاوت دقت معادل ۲۹۷۶ پیکسل است.

پیش از این نیز دو تحقیق در منطقه با استفاده از تصاویر سنجش از دور صورت گرفته است [۱۰، ۱۵]. در این دو تحقیق نتایج به صورت بصری و کمی ارائه شدند، اما اعتبارسنجی نشدند. در تحقیق نخست در سال ۲۰۲۰ از تصاویر ماهواره‌های لندست ۸ و سنتینل ۲، قبل و بعد از آتش‌سوزی و از روش‌های طبقه‌بندی‌کننده ماشین بردار پشتیبان بهینه‌شده و متداول استفاده شد [۳۸]. در این پژوهش، طبقه‌های پوششی قبل و بعد از آتش‌سوزی استخراج شد. صحت کلی استخراج طبقات ماشین بردار پشتیبان بهینه‌شده و متداول به ترتیب در حدود ۸۳ و ۸۰ درصد برآورد شد. مقایسه مستقیم صحت کلی به‌دست‌آمده در آن تحقیق با پژوهش پیش رو دشوار است، اما به نظر روش پیشنهادی چهار مزیت عمده دارد: ۱. در تحقیق سال ۲۰۲۰ از

سه باند طیفی استفاده شد، اما در تحقیق پیش رو از همه باندهای لندست ۸ بهره گرفته شد؛ ۲. در پژوهش پیش رو، برخلاف تحقیق قبلی از تصویر حین آتش‌سوزی استفاده شد؛ ۳. استفاده از روش طبقه‌بندی جنگل تصادفی و نتایج بهتر آن نسبت به ماشین بردار پشتیبان، از دیگر مزایای این پژوهش است؛ ۴. در این تحقیق از سه طبقه آتش، غیرآتش و دود استفاده شد، درحالی که محققان قبلی این طبقات را در نظر نگرفتند. براساس این توضیحات، به نظر می‌رسد که روش پیشنهادی در این پژوهش با صحت کلی حدود ۹۹ درصد در شناسایی طبقات، نتایج قابل قبولی در پایش آتش‌سوزی جنگل‌ها خواهد داشت.



(ب)

(الف)

شکل ۴. مقادیر صحت کلی برحسب درصد و ضریب کاپا حاصل از خروجی روش طبقه‌بندی ماشین بردار پشتیبان با مقادیر مختلف پارامترهای پنالتی و گاما برای ورودی تصویر حین آتش‌سوزی، الف) صحت کلی، ب) ضریب کاپا.

جدول ۲. مقادیر صحت کلی و ضریب کاپا برای ورودی تصویر اختلاف و تصویر حین آتش در الگوریتم طبقه‌بندی جنگل تصادفی

تعداد درختان	ورودی تصویر اختلاف		ورودی تصویر حین آتش	
	صحت کلی (%)	ضریب کاپا	صحت کلی (%)	ضریب کاپا
۱۰	۹۹/۱۲	۰/۹۸۶۴	۹۹/۷۲	۰/۹۹۵۷
۵۰	۹۹/۱۸	۰/۹۸۷۲	۹۹/۸۱	۰/۹۹۷۱
۱۰۰	۹۹/۲۴	۰/۹۸۸۱	۹۹/۸۲	۰/۹۹۷۳
۲۰۰	۹۹/۲۸	۰/۹۸۸۸	۹۹/۸۰	۰/۹۹۷۰
۳۰۰	۹۹/۲۳	۰/۹۸۸۱	۹۹/۸۳	۰/۹۹۷۴
۴۰۰	۹۹/۲۵	۰/۹۸۸۳	۹۹/۸۱	۰/۹۹۷۱

ورودی تصویر حین آتش		ورودی تصویر اختلاف	
ضریب کاپا	صحت کلی (%)	ضریب کاپا	صحت کلی (%)
۰/۹۹۷۲	۹۹/۸۲	۰/۹۸۸۵	۹۹/۲۶
۰/۹۹۷۰	۹۹/۸۰	۰/۹۸۸۱	۹۹/۲۳
۰/۹۹۷۱	۹۹/۸۱	۰/۹۸۸۴	۹۹/۲۵
۰/۹۷۷۴	۹۹/۸۲	۰/۹۸۸۳	۹۹/۲۵
۰/۹۹۷۰	۹۹/۸۰	۰/۹۸۸۰	۹۹/۲۳
۰/۹۹۷۱	۹۹/۸۱	۰/۹۸۸۵	۹۹/۲۶

نتیجه‌گیری

در این مقاله، آتش‌سوزی در منطقه ساکرامنتوی ایالت کالیفرنیا با استفاده از داده سنجنده نلدست شناسایی و پایش شد. هدف از این کار، بررسی دو روش طبقه‌بندی جنگل تصادفی و ماشین بردار پشتیبان در دو حالت تصویر تک‌زمانه بعد از مخاطره و تصاویر دوزمانه قبل و بعد از مخاطره بوده است. براساس نتایج خروجی افزایش پارامتر پنالتی سبب افزایش صحت کلی شده و بهترین صحت در پارامتر پنالتی ۱۲۸ مشاهده شد. در روش جنگل تصادفی نیز صحت کلی و ضریب کاپا تحت تأثیر تعداد درختان است، ولی افزایش تعداد درخت، لزوماً افزایش صحت را نتیجه نمی‌دهد و نتایج با تغییر تعداد درختان تغییر می‌کند. تحلیل نتایج حاصل از ورودی‌ها نشان داد که روش ارائه‌شده با ورودی تک‌تصویر حین آتش‌سوزی در هر دو حالت جنگل تصادفی و ماشین بردار پشتیبان، صحت بیشتری از روش ارائه‌شده در حالت ورودی تصویر اختلاف نشان می‌دهد. در مقایسه الگوریتم‌های طبقه‌بندی نیز روش جنگل تصادفی صحت بیشتری از روش ماشین بردار پشتیبان نشان می‌دهد. روش جنگل تصادفی در حالت ورودی تک‌تصویر حین آتش‌سوزی بیشترین صحت کلی یعنی ۹۹/۸۳ درصد را نشان می‌دهد. سپس روش جنگل تصادفی در حالت ورودی تک‌تصویر حین آتش‌سوزی صحت کلی ۹۹/۵۳ درصد را نشان می‌دهد. روش‌های بررسی‌شده، صحت زیادی را نسبت به پارامترهای ارزیابی صحت بررسی‌شده نشان می‌دهند و می‌توان عملکردشان را روی داده‌های آتش غیر از جنگل نیز بررسی کرد. همچنین خودکار کردن انتخاب پارامترهای بهینه در هر الگوریتم را نیز می‌توان در پژوهش‌های آینده مدنظر قرار داد.

تقدیر و تشکر

از حمایت پژوهشگاه هوافضای وزارت علوم، تحقیقات و فناوری؛ و نیز دانشگاه آزاد واحد تهران جنوب در به انجام رسیدن این پژوهش تشکر می‌شود.

منابع

- [۱] جانعلی‌پور، میلاد؛ عباس‌زاده طهرانی، نادیا؛ محمدخانلو، حکمت‌الله؛ خصالی، الهه؛ و عنایتی، حمید. (۱۳۹۸). «شناسایی سریع مناطق آسیب‌دیده پس از وقوع زلزله با استفاده از تصاویر ماهواره‌ای Sentinel-2 (مطالعه موردی: زلزله سرپل ذهاب)»، *مدیریت مخاطرات محیطی*، دوره ۶، شماره ۲، ص ۱۴۸-۱۳۱.
- [۲] جدی، علی؛ مقیمی، ابراهیم؛ احمدی، سیدعباس؛ و زارع، مهدی (۱۳۹۸). «راهبرد کاهش مخاطرات طبیعی در ایران برمبنای حقوق و روابط بین‌الملل»، *مدیریت مخاطرات محیطی*، دوره ۶، شماره ۱، ص ۱۶-۱.
- [۳] شاه‌حیدری‌پور، علی؛ پهلوانی، پرهام؛ و بیگدلی، بهناز. (۱۳۹۷). «تهیه نقشه ریسک وقوع آتش‌سوزی مناطق جنگلی با استفاده از روش رگرسیون انطباقی چندمتغیره اسپیلاین (مطالعه موردی: استان گلستان)»، *مدیریت مخاطرات محیطی*، دوره ۵، شماره ۳، ص ۲۷۷-۲۵۶.
- [4] Abbaszadeh Tehrani, Nadia; & Janalipour, Milad. (2020). "Predicting ecosystem shift in a Salt Lake by using remote sensing indicators and spatial statistics methods (case study: Lake Urmia basin)", *Environmental Engineering Research*, no. 26 (4):30-40.
- [5] Abbaszadeh Tehrani, Nadia; Shafri, Helmi Zulhaidi Mohd; Salehi, Sara; Chanussot, Jocelyn; & Janalipour, Milad (2021). "Remotely-Sensed Ecosystem Health Assessment (RSEHA) model for assessing the changes of ecosystem health of Lake Urmia Basin", *International Journal of Image and Data Fusion*:1-26.
- [6] Alkhatib, Ahmad A.A. (2014). "A review on forest fire detection techniques", *International Journal of Distributed Sensor Networks*, no. 10 (3).
- [7] Allison, Robert S.; Johnston, Joshua M.; Craig, Gregory; & Jennings, Sion (2016). "Airborne optical and thermal remote sensing for wildfire detection and monitoring", *Sensors* no. 16 (8).
- [8] Anggraeni, Ajeng; & Chinsu, Lin. (2011). "Application of SAM and SVM Techniques to Burned Area Detection for Landsat TM Images in Forests of South Sumatra", Paper read at International Conference on Environmental Science and Technology.
- [9] Babaei, Hadiseh; Janalipour, Milad; & Abbaszadeh Tehrani, Nadia. (2019). "A simple, robust, and automatic approach to extract water body

- from Landsat images (case study: Lake Urmia, Iran)", *Journal of Water and Climate Change*.
- [10] Ban, Yifang; Zhang, Puzhao; Nascetti, Andrea; Bevington, Alexandre R.; & Wulder, Michael A. (2020). "Near real-time wildfire progression monitoring with Sentinel-1 SAR time series and deep learning", *Scientific Reports* no. 10 (1):1-15.
- [11] Bar, Somnath; Parida, Bikash Ranjan; & Pandey, Arvind Chandra (2020). "Landsat-8 and Sentinel-2 based Forest fire burn area mapping using machine learning algorithms on GEE cloud platform over Uttarakhand, Western Himalaya", *Remote Sensing Applications: Society and Environment*.
- [12] Bruzzone, Lorenzo, & Prieto, Diego F. (2000). "Automatic analysis of the difference image for unsupervised change detection", *IEEE Transactions on Geoscience and Remote sensing*, no. 38(3):1171-1182.
- [13] Calle, A, JL Casanova, & Romo, A. (2006). "Fire detection and monitoring using MSG Spinning Enhanced Visible and Infrared Imager (SEVIRI) data", *Journal of Geophysical Research: Biogeosciences*, no. 111 (G4).
- [14] Cervantes, Jair; Farid, Garcia-Lamont; , Lisbeth, Rodriguez-Mazahua; & Asdrubal, Lopez (2020). "A comprehensive survey on support vector machine classification: Applications, challenges and trends", *Neurocomputing*, no. 408:189-215.
- [15] Chambers, Jeffrey; Gorman, Caralyn; Feng, Yanlei; Torn, Margaret; & Stapp, Jared (2019). "Rapid remote sensing assessment of landscape-scale impacts from the California Camp Fire",
- [16] Chu, Thuan; & Guo, Xulin (2014). "Remote sensing techniques in monitoring post-fire effects and patterns of forest recovery in boreal forest regions: A review", *Remote Sensing*, no. 6 (1):470-520.
- [17] Chuvieco, Emilio; Aguado, Inmaculada; Salas, Javier; García, Mariano; Yebra, Marta; & Oliva, Patricia (2020). "Satellite remote sensing contributions to wildland fire science and management", *Current Forestry Reports*, no. 6 (2):81-96.
- [18] Çömert, Resul; MATCI, Dilek Küçük; & Avdan, Uğur (2019). "Object Based Burned Area Mapping with Random Forest Algorithm", *International Journal of Engineering and Geosciences*, no. 4 (2):78-87.
- [19] de Carvalho, Nathália Silva; Ferreira, Igor José M; Korting, T.S.; Eduardo, L.; Aragao, C.D.; & Anderson, L.O. (2018). "Random forest

and support vector machine applied for mapping burned areas in Amazon. Paper read at Proceedings of XIX Brazilian Symposium on Remote Sensing”.

- [20] Eisavi, Vahid; & Homayouni, Saeid (2016). “Performance evaluation of random forest and support vector regressions in natural hazard change detection”, *Journal of Applied Remote Sensing*, no. 10 (4):046030.
- [21] Ghavami, Zinat; Arefi, Hossein; Bigdeli, Behnaz; & Janalipour, Milad (2017). “Comprehensive investigation on non-parametric classification methods in order to separate urban objects using the integration of very high spatial resolution LiDAR and aerial data”.
- [22] Gigović, Ljubomir; Pourghasemi, Hamid Reza; Drobnjak, Siniša & Bai, Shibiao. (2019). “Testing a new ensemble model based on SVM and random forest in forest fire susceptibility assessment and its mapping in Serbia’s Tara National Park”, *Forests*, no. 10 (5):408.
- [23] Hussain, Masroor; Chen, Dongmei; Cheng, Angela; Wei, Hui; & Stanley, David (2013). “Change detection from remotely sensed images: From pixel-based to object-based approaches”, *ISPRS Journal of Photogrammetry and Remote Sensing*, no. 80:91-106.
- [24] Jaafari, Abolfazl; & Pourghasemi, Hamid Reza (2019). “Factors influencing regional-scale wildfire probability in Iran: an application of random forest and support vector machine”, In *Spatial modeling in GIS and R for Earth and environmental sciences*, 607-619. Elsevier.
- [25] Jianya, Gong, Haigang, Sui; Guorui, Ma; & Qiming. Zhou (2008). “A review of multi-temporal remote sensing data change detection algorithms”, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, no. 37 (B7):757-762.
- [26] Joachims, Thorsten (1999). “Svmlight: Support vector machine”, SVM-Light Support Vector Machine <http://svmlight.joachims.org/>, University of Dortmund, no. 19 (4).
- [27] Khanbani, Sara, Mohammadzadeh, Ali; & Janalipour, Milad (2020). “A novel unsupervised change detection method from remotely sensed imagery based on an improved thresholding algorithm”, *Applied Geomatics*:1-17.
- [28] Khanbani, Sara; Mohammadzadeh, Ali; & Janalipour, Milad (2020). “Unsupervised change detection of remotely sensed images from rural areas based on using the hybrid of improved Thresholding techniques and particle swarm optimization”, *Earth Science Informatics*:1-14.

- [29] Lafarge, Florent; Descombes, Xavier; & Zerubia, Josiane (2005). "Textural kernel for SVM classification in remote sensing: Application to forest fire detection and urban area extraction", Paper read at IEEE International Conference on Image Processing 2005.
- [30] Liu, Sicong; Zheng, Yongjie; Dalponte, Michele; & Tong, Xiaohua (2020). "A novel fire index-based burned area change detection approach using Landsat-8 OLI data", *European journal of remote sensing*, no. 53 (1):104-112.
- [31] Lu, Dengsheng; Mausel, Paul; Brondizio, Eduardo; & Moran, Emilio (2004). "Change detection techniques", *International journal of remote sensing*, no. 25 (12):2365-2401.
- [32] Petropoulos, George P.; Charalambos, Kontoes; & Iphigenia, Keramitsoglou; (2011). "Burnt area delineation from a uni-temporal perspective based on Landsat TM imagery classification using support vector machines", *International Journal of Applied Earth Observation and Geoinformation*, no. 13 (1):70-80.
- [33] Prakash, Anupma (2000). "Thermal remote sensing: concepts, issues and applications", *International Archives of Photogrammetry and Remote Sensing*, no. 33 (B1; PART 1):239-243.
- [34] Richards, John Alan; & Richards, J.A. (1999). *Remote sensing digital image analysis*. Vol. 3: Springer.
- [35] Sabat-Tomala, Anita; Raczko, Edwin; & Zagajewski, Bogdan (2020). "Comparison of Support Vector Machine and Random Forest Algorithms for Invasive and Expansive Species Classification Using Airborne Hyperspectral Data", *Remote Sensing*, no. 12 (3):516.
- [36] Schroeder, Wilfrid; Oliva, Patricia; Giglio, Louis; Quayle, Brad; Lorenz, Eckehard; & Morelli, Fabiano (2016). "Active fire detection using Landsat-8/OLI data", "Remote sensing of environment", no. 185:210-220.
- [37] Slonecker, Terrence; Fisher, Gary B.; Aiello, Danielle P.; & Haack, Barry. (2010). "Visible and infrared remote imaging of hazardous waste: a review", *Remote Sensing*, no. 2 (11):2474-2508.
- [38] Syifa, Mutiara; Panahi, Mahdi; & Lee, Chang-Wook. (2020). "Mapping of post-wildfire burned area using a hybrid algorithm and satellite data: the case of the camp fire wildfire in California, USA", *Remote Sensing*, no. 12 (4).
- [39] Wooster, Martin J.; Roberts, Gareth; Alistair MS Smith; Johnston,

Joshua; Freeborn, Patrick; Amici, Stefania; & Hudak; Andrew T. (2013).
“Thermal remote sensing of active vegetation fires and biomass burning
events”, In *Thermal Infrared Remote Sensing*, 347-390, Springer.