



سنجش از دور

GIS ایران



سنجش از دور و GIS ایران
Iranian Remote Sensing & GIS

سال نهم، شماره سوم، پاییز ۱۳۹۶
Vol.9, No. 3, Autumn 2017

۱-۱۴

ارائه روشی جهت شناسایی تغییرات در زمین‌های کشاورزی، با استفاده از الگوریتم‌های شیء‌گرا و ترکیب رنگی لایه‌ها در تصاویر چندزمانه

فاروق محمودی^{۱*}، مهدی مختارزاده^۲، محمدجواد ولدان زوج^۳

۱. کارشناس ارشد فتوگرامتری و سنجش از دور، دانشگاه صنعتی خواجه نصیرالدین طوسی
۲. دانشیار گروه فتوگرامتری و سنجش از دور، دانشگاه صنعتی خواجه نصیرالدین طوسی
۳. استاد گروه فتوگرامتری و سنجش از دور، دانشگاه صنعتی خواجه نصیرالدین طوسی

تاریخ پذیرش مقاله: ۱۳۹۶/۶/۲۱

تاریخ دریافت مقاله: ۱۳۹۵/۳/۴

چکیده

در این تحقیق، طرح روشی مناسب جهت شناسایی تغییرات در زمین‌های کشاورزی، با استفاده هم‌زمان از روش شیء‌گرا و روش ترکیب رنگی به صورت نظارت‌شده، بررسی شده است. بدین‌منظور، از تصاویر چندزمانه سنجنده‌های LandsatV استفاده شده است. درواقع در این روش، برخلاف روش‌های رایج که تصاویر با هم مقایسه می‌شوند و سپس تغییرات شناسایی می‌شود، برای شناسایی تغییرات از ترکیب تصاویر و درنتیجه، آشکارشدن تغییرات با رنگ‌هایی متفاوت با رنگ اولیه استفاده شده و مقایسه‌ای جداگانه صورت نگرفته است. ایده اصلی عرضه روشی شیء‌گراست که در آن، با استفاده از دو تصویر، یک تصویر هم‌مرجع‌شده چندزمانه، شامل کل لایه‌های دو تصویر، تهیه شده است. سپس با انتخاب پارامترهای مناسب طبقه‌بندی، تک‌تصویر ایجادشده طبقه‌بندی و پس از آن، با استفاده هم‌زمان از روش ترکیب رنگی و روش‌های طبقه‌بندی شیء‌گرا، به نواحی تغییریافته و تغییرنیافته طبقه‌بندی شده است. درواقع، روش ترکیب رنگی با ایجاد نواحی رنگی متفاوت با تصاویر اولیه، قطعه‌های تغییریافته را به صورت بصری مشخص می‌کند و با انتخاب چند نمونه از آن قطعه‌ها از سوی کاربر خبره، با اعمال طبقه‌بندی شیء‌گرا، این قطعه‌ها در کل تصویر شناسایی می‌شوند. درنهایت، با انتخاب نمونه‌های آموزشی فقط از یک تصویر، نواحی برجسب‌خورده و نواحی تغییریافته نهایی به‌دست آمده است. نتایج بیانگر آن است که این روش به‌علت استفاده از اطلاعات مکانی افزون‌بر اطلاعات طیفی، از جهت کاهش نمونه‌های آموزشی، افزایش دقت (تقریباً ۳٪) و افزایش درصد اطمینان طبقه‌بندی بر روش‌های معمولی شناسایی تغییرات، که از مقایسه دو تصویر چندزمانه استفاده می‌کنند، برتری دارد.

کلیدواژه‌ها: شناسایی تغییرات، طبقه‌بندی نظارت‌شده، طبقه‌بندی شیء‌گرا، روش ترکیب رنگی جمعی.

* نویسنده عهده‌دار مکاتبات: کرمانشاه، شهرستان پاوه، جنب جهاد کشاورزی، خیابان ۱۶ خرداد، کدپستی ۱۴۶۹۶۹۵۶۱۳. تلفن: ۰۹۱۸۹۸۶۲۱۸۶

۱- مقدمه

تصاویر ماهواره‌ای و در کنار آنها الگوریتم‌های شناسایی تغییرات از جمله ابزارهای قدرتمندی‌اند که کاربردشان در بررسی تغییرات مناطق جغرافیایی و چشم‌اندازهای دست‌ساز انسان بر کسی پوشیده نیست و گاه حیات بسیاری از انسان‌ها را نیز تحت‌الشعاع خود قرار می‌دهند. برای نمونه، در برآورد میزان محصولات زمین‌های زیرکشت، یا پیشرفت آنها به نسبت سال‌های پیشین و یا میزان رشد جنگل در چند دهه و مواردی از این دست، چنانچه روش‌های مناسبی در شناسایی تغییرات با کمک اطلاعات ارسالی از ماهواره‌ها موجود باشد و به کار رود، قطعاً از جهات گوناگون، از جمله کاهش هزینه یا افزایش سرعت کار و خدمت‌رسانی، بسیار مفید و مطلوب خواهد بود. برای کشف تغییرات، روش‌های گوناگونی در سنجش از دور وجود دارد اما شاید بتوان گفت که هیچ‌یک به صورت مطلق در تمامی وجوه بهینه محسوب نمی‌شوند. انتخاب نوع روش کار چندان ساده‌ای نیست و به کاربرد، تعداد و تراکم عوارض مورد نظر، دقت لازم، دوره به‌هنگام‌رسانی، هزینه و پارامترهای بسیار دیگری ارتباط دارد. روش‌های شناسایی تغییرات، از یک نگاه، به دو دسته کلی روش‌های پیکسل‌مبنا و روش‌های شیء‌مبنا تقسیم می‌شوند. با نگاهی کلی به نتایج طبقه‌بندی پیکسل‌مبنا (Blaschke, 2009)، معمولاً مشاهده می‌شود که پیکسل‌های مجاور، با وجود اختلاف اندک در مقادیر شدت روشنایی، در یک کلاس قرار گرفته‌اند. این مسئله بیانگر این مطلب است که هنوز اطلاعاتی در داده‌ها وجود دارد که در روش‌های طبقه‌بندی پیکسل‌مبنا از آن‌ها استفاده نشده است. این اطلاعات مربوط به پیکسل‌های همسایه‌اند. استفاده از این نوع اطلاعات در روش‌های طبقه‌بندی به صورت کلی با عنوان طبقه‌بندی طیفی-مکانی شناخته می‌شود. در این حالت، طبقه‌بندی براساس مقادیر طیفی خود پیکسل و اطلاعات استخراج‌شده از همسایگی آن، با عنوان اطلاعات مکانی، انجام می‌شود. جهت طبقه‌بندی با

استفاده هم‌زمان از اطلاعات طیفی و مکانی، در حالت کلی، با دو مسئله روبه‌رویم: تعریف ساختارهای مکانی برای پیکسل‌ها و ترکیب اطلاعات طیفی و مکانی برای طبقه‌بندی. تفاوت روش‌های گوناگون به کاررفته در شیوه برخورد با این دو مسئله و حل آنهاست. افزون‌بر آن، اطلاعات بافت تصویر نیز از جمله ویژگی‌هایی است که، براساس توزیع درجات خاکستری در سطح تصویر، از تصویر به دست می‌آید. اصولاً در این حالت، از پارامترهایی مانند آنتروپی، همگرایی و کنتراست به‌منزله اطلاعات بافت برای افزودن اطلاعات به طبقه‌بندی‌کننده استفاده می‌شود. پیشینه تحقیقات دانشمندان سنجش از دور (Gang chen et al., 2012) نشان می‌دهد که کشف تغییرات تصاویر با استفاده از دو روش پیکسل‌مبنا و شیء‌مبنا نتایج متفاوتی را دربر دارد و روش‌های شیء‌مبنا، هرچند خود به چندین دسته طبقه‌بندی می‌شوند، نتایج مطلوب‌تر و دقت بیشتری دارند. کاروالیو^۱ (۲۰۰۵) اولین الگوریتم را در این زمینه مطرح کرد. الخدیری^۲ (۲۰۰۵) از الگوریتم PC و روش تفاضلی روی تصاویر با توان تفکیک بالا برای طبقه‌بندی پیکسل‌مبنا و از طبقه‌بندی شیء‌گرا برای شناسایی تغییرات استفاده کرد. لالیبرت^۳ (۲۰۰۵) یک روش طبقه‌بندی شیء‌مبنا را روی یازده تصویر هوایی و یک تصویر QuickBird ارائه کرد که در آن بیشتر به شناسایی تغییرات پوشش گیاهی توجه شده است. همچنین، افرادی مانند مک‌درمید^۴ (۲۰۰۸) و لینکه^۵ (۲۰۰۸)، با استفاده از این روش، روی تصاویر چندزمانه ایده‌هایی در زمینه شناسایی تغییرات عرضه کردند. والتر^۶ (۲۰۰۴) اهمیت استفاده از شاخص‌های گیاهی و طیفی و اطلاعات بافت را در روش‌های طبقه‌بندی شیء‌مبنا ارزیابی کرد. دوریه^۷ (۲۰۰۸) روشی شیء‌مبنا را، با استفاده از یک تابع تعلق فازی برای کلاسه‌بندی،

- | | |
|--------------|-----------------|
| 1. Carvalho | 2. Al-Khudhairi |
| 3. Laliberte | 4. McDermid |
| 5. Linke | 6. Walter |
| 7. Durieux | |

سوی کاربر خبره، بعد از طبقه‌بندی شیء‌گرا، این قطعه‌ها در کل تصویر شناسایی می‌شوند. پس از این مرحله، درنهایت، با استفاده از نمونه‌های آموزشی استخراج‌شده از تک‌تصویر و با استفاده از روش‌های رایج طبقه‌بندی، تغییرات کشف‌شده برچسب خوردند و با مشخص کردن کلاس آنها، نواحی نهایی تغییرات به‌دست آمد.

یادآور می‌شویم از جمله مزایایی که باعث شد این روش پیشنهاد شود این است که، نخست، با توجه به قانون انتشار خطاها کاملاً مشهود است که خطای طبقه‌بندی چندین تصویر به‌صورت مجزا، با استفاده از الگوریتمی یکسان، به‌مراتب بیشتر از خطای طبقه‌بندی تصویر هم‌مرجع‌شده است. همچنین، استفاده از روش‌های شیء‌گرا برای شناسایی تغییرات، در مقایسه با روش‌های معمولی و کلاسیک، به‌دلیل افزایش اطلاعات به‌کاررفته در آنها قطعاً نتایج بهتری را در پی خواهد داشت. افزون‌بر این، استفاده از نمونه‌های آموزشی فقط یک تصویر و در نتیجه، کاهش اطلاعات استفاده‌شده و روش ترکیب رنگ‌ها و تلفیق آن با روش‌های طبقه‌بندی شیء‌گرا ایده بسیار ساده و در عین حال، بسیار کارآمدی به‌شمار می‌رود که کمتر از آن استفاده شده است و به‌کاربردن آن نتایج مطلوبی خواهد داشت. بنابراین، هدف از این پژوهش را می‌توان چنین بیان کرد:

۱. بررسی تغییرات در زمین‌های کشاورزی، با تأکید بر استفاده از روش‌های طبقه‌بندی شیء‌گرا در تصویر چندزمانه، شامل کل لایه‌ها و در نتیجه، ایجاد اشیای تصویری مشابه مکانی.
۲. مطرح کردن ایده شناسایی تغییرات بدون مقایسه تصاویر چندزمانه با یکدیگر با تکیه بر ترکیب رنگی لایه‌ها و روش شیء‌گرا، به‌صورت هم‌زمان، در تک‌تصویر به‌دست‌آمده، شامل کل لایه‌های دو تصویر چندزمانه.
۳. کاهش داده آموزشی برای طبقه‌بندی، با تکیه بر انتخاب نمونه‌های آموزشی در نواحی بدون تغییر.

روی تصاویر ماهواره SPOT 5 پیشنهاد کرد. جمال و طاها^۱ (۲۰۱۴) الگوریتمی را مطرح کردند که در آن از روش‌های فازی و ترکیب آنها با معیارهای شهرسازی، به‌منظور کشف میزان تغییرات شهرنشینی در جزیره‌ای خاص، استفاده شد. یه و همکاران^۲ (۲۰۱۶) روشی را مطرح کردند که در آن، با استفاده از الگوریتم بردار پشتیبان^۳، تغییرات خاص مورد نظر کاربر را شناسایی کند. در واقع، هدف او شناسایی تغییرات مدنظر کاربر است. هائو و همکاران^۴ (۲۰۱۷) به روشی اشاره کردند که در آن از خوشه‌بندی فازی و استفاده هم‌زمان از اطلاعات محلی و جهانی برای شناسایی تغییرات استفاده کرده بود. گستردگی مطالب و الگوریتم‌های استفاده‌شده در روش‌های شیء‌گرا آن چنان وسیع است که در این مقاله مجال برای آن نیست. اما برای جمع‌بندی تحقیقات، می‌توان گفت که در کارهای محققان گذشته اگرچه از روش‌های شیء‌گرا و ترکیب رنگ به‌طور جداگانه استفاده شده؛ استفاده هم‌زمان از روش‌های شیء‌گرا و نیز روش ترکیب رنگی لایه‌ها جهت کشف تغییرات به چشم نمی‌خورد و همین باعث شد، در این مقاله، تحقیقاتی در این راستا صورت گیرد.

در این تحقیق، برخلاف روش‌های رایج کشف تغییرات که اصولاً از مقایسه دو تصویر چندزمانه استفاده می‌کنند، از ترکیب تصاویر استفاده شده و مقایسه‌ای مجزا صورت نگرفته است. روش کلی به این صورت است که ابتدا، پس از اعمال تصحیحات و هم‌مرجع‌سازی تصاویر، کل لایه‌های دو تصویر همراه با هم در نظر گرفته می‌شود و قطعه‌بندی روی تک‌تصویر، شامل کل لایه‌ها، اعمال می‌شود. بعد از قطعه‌بندی، تک‌تصویر هم‌مرجع‌شده حاصل از دو تصویر، با استفاده هم‌زمان از روش ترکیب رنگی جمعی و روش‌های طبقه‌بندی شیء‌گرا، به نواحی تغییریافته و تغییرنیافته طبقه‌بندی شده است. در واقع روش ترکیب رنگی جمعی، با ایجاد نواحی رنگی متفاوت با تصاویر اولیه، قطعه‌های تغییریافته را به‌صورت بصری مشخص می‌کند. سپس با انتخاب چند نمونه از آن قطعه‌ها از

1. Gamal and Taha
2. Ye et al.
3. support vector domain description
5. Hao et al.

۲- مروری بر مفاهیم نظری مورد نیاز

۲-۱- روش‌های کشف تغییرات شیء‌مبنا^۱

در تصاویر ماهواره‌ای، علاوه بر استخراج اطلاعات طیفی، می‌توانیم اطلاعات بافت، شکل، هندسه و دیگر موارد را از طریق اطلاعات مکانی پیکسل‌های همسایه استخراج کنیم؛ درحالی‌که در روش‌های متداول پیکسل‌پایه، طبقه‌بندی براساس ارزش عددی هر یک از پیکسل‌ها انجام می‌شود. توانایی روش‌های معمول یا کلاسیک در طبقه‌بندی تصاویر ماهواره‌ای، هنگامی‌که اشیای متفاوت اطلاعات طیفی مشابهی دارند، محدود است و این از صحت روش‌های طبقه‌بندی پیکسل‌پایه می‌کاهد. در نتیجه، روش‌های جدیدی با عنوان روش‌های شیء‌گرا مطرح شدند. در این روش‌ها، اطلاعات طیفی با اطلاعات مکانی ادغام می‌شوند و طبقه‌بندی پیکسل‌ها براساس شکل، بافت، تن خاکستری و موارد دیگر در سطح تصویر، با مقیاس مشخص، صورت می‌گیرد و تصویر براساس این طبقه‌بندی می‌شود. در این روش شناسایی تغییرات، از هر دو دسته اطلاعات استفاده می‌شود.

به‌طور کلی، روش‌های کشف تغییرات شیء‌مبنا به چهار دسته (Gang chen et al., 2012) تقسیم می‌شوند:

• روش‌های کشف تغییرات شیئی- تصویری^۲.

در این حالت، تصاویر چندزمانه یا براساس اطلاعات طیفی اشیای تصویری و یا براساس ویژگی‌های دیگری، مانند بافت و هندسه اشیاء، به‌صورت مجزا طبقه‌بندی می‌شوند. سپس به‌صورت مستقیم، با تعریف حد آستانه، اشیای تصویری را در تصاویر طبقه‌بندی‌شده با هم مقایسه و تغییرات را شناسایی می‌کنند.

• روش‌های کشف تغییرات شیئی- کلاسی^۳.

در شناسایی تغییرات براساس روش‌های شیئی- تصویری نمی‌توان نوع کلاس تغییرات را مستقیماً شناسایی کرد و این کار نیازمند اطلاعات اضافی برای طبقه‌بندی است. بر همین اساس، روش‌های شیئی-

کلاسی مطرح شد. در این حالت، چون نوع کلاس مشخص است، مشکلی چندانی وجود نخواهد داشت.

• روش‌های کشف تغییرات شیئی- چندزمانه^۴.

تصاویر به‌دست‌آمده در زمان‌های متفاوت به‌ندرت ویژگی‌های یکسانی دارند زیرا عوامل گوناگونی مانند روشنایی، زاویه دید و شرایط آب‌وهوایی در آنها تأثیر می‌گذارند. بنابراین، اشیای تصویری طبقه‌بندی‌شده در زمان‌های متفاوت، اگرچه از نظر ویژگی‌های جغرافیایی یکسان‌اند اغلب از نظر هندسی تغییر می‌کنند؛ بنابراین، چنانچه تصاویر چندزمانه را با یکدیگر ترکیب و آنها را با هم طبقه‌بندی کنیم، می‌توانیم اشیای تصویری مشابه مکانی را پدید آوریم و این خود یکی از مزایای اصلی این روش‌ها محسوب می‌شود.

• روش‌های کشف تغییرات ترکیبی^۵.


در این روش افزون‌بر اطلاعات پیکسلی، از اطلاعات اشیای تصویری مانند شکل، هندسه و اطلاعات بافت نیز استفاده می‌شود؛ یعنی در این الگوریتم، هم‌زمان هر دو دسته اطلاعات به کار می‌روند. این روش‌ها همان روش‌های شیء‌گرا به‌شمار می‌روند.

در این پژوهش، درواقع از هر دو روش کشف تغییرات شیئی- چندزمانه و روش کشف تغییرات ترکیبی هم‌زمان استفاده شده است؛ یعنی کل لایه‌های تصاویر چندزمانه با هم در نظر گرفته شده و سپس، طبقه‌بندی شده‌اند و درنهایت، با استفاده از روش‌های ترکیبی (شیء‌گرا)، طبقه‌بندی شده‌اند.

1. object-based change detection
2. image-object change detection
3. class-object change detection
4. multitemporal-object change detection
5. hybrid change detection

۲-۲- روش ترکیب رنگی جمعی

در این روش، یک ترکیب رنگی به کار می‌رود. این روش بسیار ساده است که در آن لایه‌های متفاوت تصاویر چندزمانه با یکدیگر ترکیب می‌شوند (رنگ‌ها با هم جمع می‌شوند) و نتیجه کار تصویری با رنگ‌هایی متفاوت از تصاویر اولیه خواهد بود. در تصویر نهایی حاصل از ترکیب لایه‌ها، مشاهده می‌شود نواحی دارای تغییرات و یا حتی نواحی بدون تغییر با رنگ‌هایی متفاوت از رنگ اولیه هر یک از تصاویر ظاهر می‌شوند. برای نمونه، ناحیه‌هایی که هم پیش‌تر و هم در این زمان کاربرد کشاورزی داشته‌اند با رنگ سیاه ظاهر می‌شوند و یا مناطقی که قبلاً بایر بودند و اکنون کاربرد کشاورزی دارند با رنگ قرمز ظاهر می‌شوند. این نکته در شکل ۱ مشهود است.



شکل ۱. قطعه‌ای از تصویر سال ۱۹۹۹ (a)؛ قطعه‌ای از تصویر سال ۲۰۰۲ (b)؛ تصویر حاصل از روش ترکیب رنگ لایه‌های دو تصویر دیگر (c)

آموزشی از تصویر اول به تصویر دوم استفاده شده است. ساختار کلی این الگوریتم به‌صورتی است که در شکل ۲ نشان داده شده است.

درواقع، این الگوریتم شامل سه مرحله اصلی است که می‌توان آنها را هسته اصلی روش مطرح‌شده دانست. برای تفهیم مدل، این سه مرحله را در ادامه توضیح داده‌ایم:

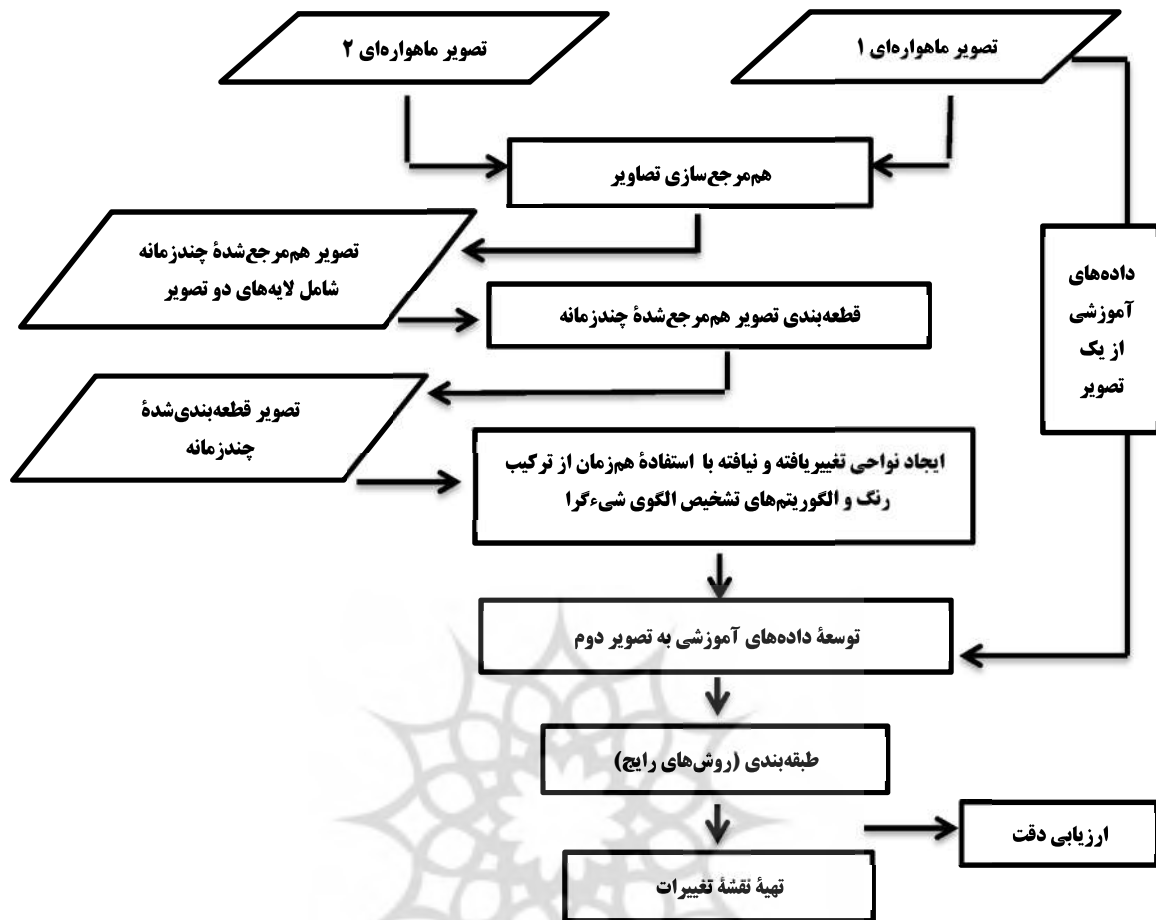
۱. در گام اول، بعد از هم‌مرجع‌سازی تصاویر، لایه‌های گوناگون تصاویر چندزمانه را هم‌زمان با هم در نظر می‌گیرند و تصاویر به یک تصویر، شامل کل لایه‌های دو تصویر دیگر، تبدیل می‌شوند.

۲. در گام دوم، تک‌تک تصاویر هم‌مرجع‌شده چندزمانه که از دو تصویر به‌دست آمده قطعه‌بندی شده است. سپس، با اعمال روش ترکیب رنگی جمعی در این قطعه‌ها، نواحی تغییر یافته و تغییر نیافته، که هر یک با رنگی متفاوت از رنگ اولیه ظاهر شده‌اند، تشخیص داده شدند. در نهایت، پس از به‌دست آمدن تصویر رنگی قطعه‌بندی‌شده حاصل از تلفیق لایه‌ها، کاربر خیره با شناسایی چند قطعه که در آن تغییرات رخ داده است، نمونه آموزشی مربوط به نواحی تغییر یافته و تغییر نیافته را انتخاب می‌کند. نواحی دیگر با توجه به نمونه‌های انتخاب‌شده براساس الگوریتم‌ها و روش‌های طبقه‌بندی شیء‌گرا شناسایی شده است. سادگی و افزایش سرعت عمل شناسایی تغییرات را می‌توان از مزایای این روش به حساب آورد.

۳. در گام سوم در توسعه داده‌های آموزشی به تصویر دوم ایده به‌کاررفته، از داده‌های آموزشی در نواحی بدون تغییر استفاده شده است و چنانچه داده آموزشی در نواحی تغییر یافته به‌کار می‌رفت حذف می‌شد. در واقع، چون داده‌های آموزشی که از یک تصویر انتخاب می‌شوند باید در هر دو تصویر استفاده شوند، این الزام ایجاد می‌شود که نمونه‌ها در نواحی یکسان به‌کار روند. پس از کشف نواحی تغییر یافته با هم‌پوشانی داده‌های آموزشی با تصویر مشتمل بر نواحی

۳- روش پیشنهادی

در این مدل، برخلاف روش‌های رایج شناسایی تغییرات که اصولاً در آنها از مقایسه دو تصویر چندزمانه با هم استفاده می‌شود، از تک‌تک تصاویر هم‌مرجع‌شده شامل کل لایه‌های دو تصویر و همچنین، اعمال قطعه‌بندی روی آن و استفاده از روش شیء‌گرا برای طبقه‌بندی آن به نواحی تغییر یافته و تغییر نیافته و نیز توسعه داده‌های



شکل ۲. نمودار جریان‌ی روش پیشنهادی

در ۵۰۰ برش داده شده‌اند و از ماهواره Landsat ۷، در اکتبر سال ۲۰۰۲ و ۱۹۹۹، از نواحی نیمه‌شهری جنوب غرب شهر تهران اخذ شده‌اند استفاده شده است. این شهر در ۵۱ درجه و ۶ دقیقه تا ۵۱ درجه و ۳۸ دقیقه طول شرقی و ۳۵ درجه و ۳۴ دقیقه تا ۳۵ درجه و ۵۱ دقیقه عرض شمالی واقع شده است. در این تصاویر، برای اعمال تصحیحات رادیومترکی، از روش نسبی^۲ از نوع آماری استفاده شده است.

تغییرات، نمونه‌هایی که در نواحی تغییر یافته قرار داشتند حذف شدند. در نهایت، با استفاده از داده‌های آموزشی و روش‌های رایج طبقه‌بندی، مانند SVM و شبکه عصبی، نوع کلاس‌ها مشخص و برچسب زده شد و دقت نهایی حاصل از آن نیز، با استفاده از ماتریس خطا و دو پارامتر بسیار رایج استخراج شده از آن (دقت کلی و ضریب کاپا)، ارزیابی شد. کل مراحل با استفاده از نرم‌افزارهای متلب ۲۰۱۱^۱، ENVI ۴.۷ و eCognition اجرا شده است.

۴- اجرا، نتایج و ارزیابی

۴-۱- داده‌های مورد استفاده

در این مقاله، از دو تصویر (شکل ۳ و ۴) که در ابعاد ۵۰۰

1. Matlab 2011

2. relative radiometric normalization

قطعه‌بندی از مهم‌ترین آن پارامترها محسوب می‌شوند. در این تحقیق، تعیین بهینه توصیفگرها بر مبنای آزمون و خطا بوده است و سعی بر آن بوده که پارامترهایی برای سطوح مورد نظر انتخاب شود که نتیجه بهینه را به دنبال داشته باشند؛ بنابراین الگوریتم پیشنهادی در سه سطح متفاوت عملی شد. طبق جدول ۱:

جدول ۱. پارامترهای مورد استفاده در قطعه‌بندی

| تعداد توصیفگرها | فشرده‌گی | شکل | مقیاس | سطح |
|-----------------|----------|-----|-------|-------|
| ۲۸ | ۵۰۰ | ۵۰۰ | ۵ | سطح ۱ |
| ۲۸ | ۶۰۰ | ۶۰۰ | ۷ | سطح ۲ |
| ۳۹ | ۸۰۰ | ۸۰۰ | ۸ | سطح ۳ |




شکل ۳. زیرتصویر Landsat ۷، سال ۱۹۹۹

توصیفگرهای استفاده شده برای طبقه‌بندی شیء‌گرا عبارت بودند از:

مساحت، زبری، فشرده‌گی، اندکس شکل، میانگین کل لایه‌های تصویر هم‌مرجع شده، مرز، شعاع بزرگ‌ترین بیضوی محاط، طول، نسبت طول بر عرض، فیت مستطیلی، شعاع کوچک‌ترین بیضوی محیط، شدت، ماکزیمم دیفرانسیل، عرض، طول مرز، عدم تقارن، فیت بیضوی، پارامتر همگنی کل لایه‌های تصویر.

شایان ذکر است که در طبقه‌بندی شیء‌گرا، برای اینکه دقت انتخاب قطعه‌های تصویری یکسان باشد، از قطعه‌های مشابه مکانی در تمامی سطوح استفاده شده است. در شکل ۵، برای نمونه، خروجی حاصل از قطعه‌بندی تصویر شامل کل لایه‌ها با پارامترهای مطرح شده در سطح ۱ نشان داده شده است.

پس از آن، بقیه مراحل الگوریتم اجرا شد. برای ارزیابی دقت نهایی شناسایی تغییرات، از دقت کلی حاصل از ماتریس خطا و ضریب کاپا استفاده شده است. مرحله اجرا با استفاده از دو مجموعه داده آموزشی و ارزیابی کاملاً متفاوت، که کاربر خبره آنها را انتخاب کرده بود، انجام شد.




شکل ۴. زیرتصویر Landsat ۷، سال ۲۰۰۲

۲-۴- اجرا و نتایج

نخستین گام، پس از اعمال تصحیحات و هم‌مرجع کردن، قطعه‌بندی تصویر است. حالت استاندارد برای انجام قطعه‌بندی وجود ندارد و با تغییر پارامترهای روش قطعه‌بندی، نتایج متفاوتی حاصل می‌شود. بنابراین، تعیین پارامترهای قطعه‌بندی یکی از مراحل قطعه‌بندی به‌منظور رسیدن به قطعات مناسب به‌شمار می‌رود. اصولاً پارامتر مقیاس، به کاربردن/ نبردن اطلاعات شکل، پارامتر فشرده‌گی و تعداد ویژگی‌های ورودی در مرحله

لازم است یادآوری کنیم برای اینکه دقت انتخاب داده‌های آموزشی در دو روش (روش پیشنهادی و روش معمولی) یکسان باشد و در نتایج نهایی تأثیر مشابه داشته باشد، در هر دو الگوریتم، برای طبقه‌بندی به‌منظور تهیه نقشه تغییرات، از نمونه‌های آموزشی و ارزیابی یکسانی (جدول‌های ۲ و ۳) استفاده شده است. بعد از اجرا، نتایج موجود در جدول‌های ۴ و ۵ حاصل شد.



شکل ۵. نمایش تصویر قطعه‌بندی‌شده شامل کل لایه‌ها در سطح ۱

جدول ۲. تعداد نمونه‌های آموزشی (مجموعه اول)

| تعداد داده‌های ارزیابی (پیکسل) | نوع کلاس تعریف‌شده تغییرات |
|--------------------------------|---|
| ۱۱۶ | قبلاً بایر بوده، اکنون دارای کاربرد کشاورزی است |
| ۲۱۳ | بدون تغییرات |
| ۱۷۰ | قبلاً کاربرد کشاورزی داشته، اکنون چنین نیست |

جدول ۳. تعداد نمونه‌های ارزیابی (مجموعه اول)

| تعداد نمونه‌های آموزشی در تصویر اول (پیکسل) | تعداد نمونه‌های آموزشی در تصویر دوم (پیکسل) | نوع کلاس تعریف‌شده |
|---|---|--------------------|
| ۱۴۳ | ۱۷۲ | کشاورزی |
| ۱۶۶ | ۱۸۹ | غیرکشاورزی |

جدول ۴. دقت نهایی شناسایی تغییرات روش معمولی (مجموعه اول)

| الگوریتم طبقه‌بندی‌کننده | دقت کلی برای مدل ۱ | ضریب کاپا برای مدل ۱ |
|--------------------------|--------------------|----------------------|
| SVM با تابع کرنل سهمی | ٪۹۷،۹۵ | ٪۹۶،۲۸ |
| SVM با تابع کرنل RBF | ٪۹۷،۳۹ | ٪۹۵،۹۶ |
| شبکه عصبی مصنوعی | ٪۹۶،۵۸ | ٪۹۴،۰۱ |

جدول ۵. دقت نهایی شناسایی تغییرات روش پیشنهادی (مجموعه اول)

| الگوریتم طبقه‌بندی‌کننده | دقت کلی | | ضریب کاپا | |
|--------------------------|---------|--------|-----------|--------|
| | سطح ۱ | سطح ۲ | سطح ۱ | سطح ۲ |
| SVM با تابع کرنل سهمی | ٪۹۸،۰۸ | ٪۹۸،۶۴ | ٪۹۶،۱۴ | ٪۹۷،۸۳ |
| SVM با تابع کرنل RBF | ٪۹۸،۱۷ | ٪۹۸،۷۳ | ٪۹۶،۲۰ | ٪۹۷،۹۲ |
| شبکه عصبی مصنوعی | ٪۹۷،۸۸ | ٪۹۸،۱۱ | ٪۹۶،۰۲ | ٪۹۷،۰۹ |

۳-۴- ارزیابی نتایج

با توجه به نتایج حاصل شده، مدل پیشنهادی در هر دو حالت نتایج بهتری را در پی داشت. این بهتر بودن نتایج مدل پیشنهادی را می‌توان به ویژگی‌های اصلی به کار رفته در الگوریتم، یعنی تلفیق کل لایه‌های دو تصویر و اعمال الگوریتم شیء‌گرا روی آن به منظور استخراج نواحی تغییر یافته و تغییر نیافته و در نتیجه، ایجاد اشیای تصویری مشابه مکانی مربوط دانست. علاوه بر آن، کاهش و حذف خطاهایی که در فرایند اجرای الگوریتم پیش می‌آیند نیز از جمله موارد بهتر بودن نتایج است زیرا در این مدل، نمونه آموزشی فقط از یک تصویر انتخاب شده است و تک تک تصاویر جداگانه طبقه‌بندی نشده‌اند بلکه کل لایه‌های تصاویر،

همان‌طور که از نتایج به دست آمده در جدول‌ها مشهود است، دقت کلی و ضریب کاپای حاصل از ارزیابی دقت نهایی شناسایی تغییرات مدل پیشنهادی در سطوح گوناگون، در مقایسه با روش معمولی (روشی که در آن پس از طبقه‌بندی تصاویر، از مقایسه دو تصویر با روش تفاضلی استفاده می‌کند)، بهتر است. در ادامه، برای مجموعه دوم داده‌های آموزشی و ارزیابی، الگوریتم‌های مذکور اجرا شده است. تعداد نمونه‌های آموزشی و ارزیابی به کار رفته برای این مجموعه و نتایج حاصل از اجرای آنها در جدول‌های ۶ تا ۹ مشاهده می‌شود. بار دیگر، مشاهده می‌شود که دقت کلی و ضریب کاپای حاصل در مدل پیشنهادی از دقت کلی و ضریب کاپای به دست آمده در بقیه نتایج بهتر است.

جدول ۶. تعداد نمونه‌های آموزشی (مجموعه دوم)

| نوع کلاس تعریف شده | تعداد نمونه‌های آموزشی در تصویر اول (پیکسل) | تعداد نمونه‌های آموزشی در تصویر دوم (پیکسل) |
|--------------------|---|---|
| کشاورزی | ۱۳۰ | ۱۱۷ |
| غیرکشاورزی | ۱۶۲ | ۱۶۶ |

جدول ۷. تعداد نمونه‌های ارزیابی (مجموعه دوم)

| نوع کلاس تعریف شده تغییرات | تعداد داده‌های ارزیابی (پیکسل) |
|---|--------------------------------|
| قبلاً بایر بوده، اکنون کاربرد کشاورزی دارد | ۱۲۵ |
| بدون تغییرات | ۲۲۴ |
| قبلاً کاربرد کشاورزی داشته، اکنون چنین نیست | ۱۱۴ |

جدول ۸. دقت نهایی شناسایی تغییرات روش معمولی (مجموعه دوم)

| ضریب کاپا برای مدل ۱ | دقت کلی برای مدل ۱ | الگوریتم طبقه‌بندی کننده |
|----------------------|--------------------|--------------------------|
| %۹۶,۴۸ | %۹۷,۸۰ | SVM با تابع کرنل سهمی |
| %۹۶,۱۲ | %۹۷,۵۸ | SVM با تابع کرنل RBF |
| %۹۶,۴۸ | %۹۷,۸۰ | شبکه عصبی مصنوعی |

جدول ۹. دقت نهایی شناسایی تغییرات روش پیشنهادی (مجموعه دوم)


| ضریب کاپا سطح ۳ | دقت کلی سطح ۳ | ضریب کاپا سطح ۲ | دقت کلی سطح ۲ | ضریب کاپا سطح ۱ | دقت کلی سطح ۱ | الگوریتم طبقه‌بندی کننده |
|-----------------|---------------|-----------------|---------------|-----------------|---------------|--------------------------|
| %۹۸,۲۲ | %۹۹,۱۳ | %۹۷,۹۰ | %۹۹,۰۰ | %۹۸,۱۸ | %۹۹,۰۹ | SVM با تابع کرنل سهمی |
| %۹۸,۲۲ | %۹۹,۱۳ | %۹۷,۹۰ | %۹۹,۰۰ | %۹۸,۲۴ | %۹۹,۱۸ | SVM با تابع کرنل RBF |
| %۹۷,۹۶ | %۹۸,۸۸ | %۹۷,۳۳ | %۹۸,۶۹ | %۹۷,۶۳ | %۹۸,۷۷ | شبکه عصبی مصنوعی |

۵- جمع‌بندی و نتیجه‌گیری

در این مقاله، از روش شیء‌گرا و در کنار آن، از الگوریتم‌های طبقه‌بندی‌کننده SVM و شبکه عصبی مصنوعی برای دو مدل متفاوت، با بهره‌گیری از روش ترکیب رنگ‌ها در مدل پیشنهادی و روش تفاضلی در مدل معمولی، به منظور شناسایی تغییرات موجود در تصاویر لندست ۷ استفاده شده است. تلفیق الگوریتم‌های طبقه‌بندی شیء‌گرا و روش‌های ترکیب رنگ با روش‌های شناسایی تغییرات و روش‌های پیشرفته سنجش از دور و موارد دیگر می‌تواند راهکاری مناسب برای شناسایی تغییرات در نظر گرفته شود. برای درک و مشاهده بهتر نتایج، سعی شد نتایج حاصل در قالب نمودارهای استوانه‌ای نمایش داده شود تا مقایسه بصری نتایج نیز امکان‌پذیر باشد. دقت کلی حاصل از نتایج در شکل‌های ۷ و ۸ دیده می‌شود.

نتایج به‌دست‌آمده نشان می‌دهند دقت کلی حاصل در مدل پیشنهادی از دقت کلی حاصل از روش معمولی بهتر است. از جمله نتایجی که در این تحقیق آشکار شد این است که، نخست، خطای طبقه‌بندی جداگانه چندین تصویر با استفاده از یک الگوریتم یکسان به مراتب بیشتر از خطای طبقه‌بندی یک تصویر هم‌مرجع شده است. دوم، استفاده از تلفیق کل لایه‌های دو تصویر و اعمال روش‌های شیء‌گرا روی آن برای شناسایی تغییرات، به دلیل افزایش اطلاعات استفاده‌شده و ایجاد اشیای تصویری مشابه مکانی در آنها، قطعاً نتایجی بهتر از روش‌های معمولی و کلاسیک به دنبال خواهد داشت. سوم، استفاده از نمونه‌های آموزشی فقط یک تصویر و در نتیجه، کاهش نمونه‌های آموزشی به کاررفته سبب کاهش دقت نخواهد شد. در حالت کلی، می‌توان گفت که دقت حاصل از روش پیشنهادی به‌طور میانگین ۲.۵ تا ۳ درصد بر روش معمولی برتری دارد. البته دقت حاصل شده در روش‌های نظارت‌شده به پارامترهای دیگری نیز ارتباط دارد؛ از جمله دقت داده‌های آموزشی و ارزیابی، که می‌توان این را یکی از ایرادهای روش‌های نظارت‌شده در نظر


هم‌زمان با هم، فقط یک‌بار طبقه‌بندی شده‌اند و این باعث کاهش و حذف خطاهایی است که در فرایند طبقه‌بندی پیش می‌آید. البته با توجه به اجرای الگوریتم‌ها با دو مجموعه متفاوت از نمونه‌های آموزشی و ارزیابی آنها، باید به این نکته توجه کرد که دقت نمونه‌های آموزشی تأثیر چشمگیری در نتایج خواهد داشت و باید نمونه‌ها با دقت بالایی انتخاب شوند. جهت تحلیل بصری از تغییرات کشف‌شده در مدل پیشنهادی، یکی از خروجی‌های نشان‌دهنده تغییرات با رنگ‌های کاذب در شکل ۶ نمایش داده شده است. همان‌طور که مشاهده می‌شود، در مدل پیشنهادی با حالت شیء‌گرا، تغییرات دارای نویز نیستند و تغییرات نامنظم، که گاه به‌اشتباه در روش‌های معمولی شناسایی می‌شوند، در آن دیده نمی‌شود؛ در حالی که برخلاف روش پیشنهادی، در روش‌های معمولی وجود چنین تغییرات نامنظمی باعث کاهش نسبت سیگنال به نویز و در نتیجه، کاهش دقت خواهد شد. علاوه بر آن، در مدل پیشنهادی تغییرات به‌صورت قطعه‌هایی مجزا و مشخص و فاقد تغییرات بسیار کوچک پیکسلی دیده می‌شوند؛ در حالی که در روش‌های معمولی، تغییرات کوچک پیکسلی به‌وفور پدید می‌آیند.




شکل ۶. تغییرات به‌دست‌آمده در مدل پیشنهادی سطح ۳

بنابراین، به دقت بهتری می‌رسد. ضریب کاپای حاصل شده نیز در روش پیشنهادی، به‌طور میانگین، ۲.۵ تا ۳ درصد بر روش معمولی برتری دارد. نتایج در شکل‌های ۹ و ۱۰ مشاهده می‌شود.


گرفت. در ادامه، ضریب کاپای حاصل از نتایج نیز با هم مقایسه شده است. شایان توجه است که ضریب کاپای این مزیت را بر دقت کلی دارد که از مقادیر غیرقطری ماتریس خطا نیز برای محاسبه دقت استفاده می‌کند و




شکل ۷. مقایسه دقت کلی حاصل از مدل‌های گوناگون برای مجموعه اول نمونه‌ها



شکل ۸. مقایسه دقت کلی حاصل از مدل‌های گوناگون برای مجموعه دوم نمونه‌ها



شکل ۹. مقایسه ضریب کاپای حاصل از مدل‌های گوناگون برای مجموعه اول نمونه‌ها



شکل ۱۰. مقایسه ضریب کاپای حاصل از مدل‌های گوناگون برای مجموعه دوم نمونه‌ها

اطلاعات استفاده شده محسوب می‌شود و چه بسا در روش‌های مطرح، با حفظ دقت، باعث کاهش هزینه نیز بشود.

۶- منابع

حاج احمدی، س.، ۱۳۹۲، به کارگیری توأمان تصاویر ماهواره‌ای و نقشه‌های رقومی موجود به منظور تهیه نقشه تغییرات در مناطق شهری، پایان‌نامه کارشناسی ارشد، دانشگاه خواجه نصیرالدین طوسی، دانشکده مهندسی نقشه‌برداری (ژئودزی و ژئوماتیک).

هداوند، ا.، ۱۳۹۰، استفاده از روش‌های شیء‌گرا در طبقه‌بندی تصاویر ابرطیفی، پایان‌نامه کارشناسی ارشد، دانشگاه صنعتی خواجه نصیرالدین طوسی، دانشکده مهندسی نقشه‌برداری (ژئودزی و ژئوماتیک).

Blaschke, T., 2009, **Object Based Image Analysis for Remote Sensing**, ISPRS Journal of Photogrammetry and Remote Sensing, Journal homepage: www.elsevier.com/locate/isprsjprs, PP.10-21.

Burges, C., 1998, **A Tutorial on Support Vector Machines for Pattern Recognition**, In: Data Mining and Knowledge Discovery, Vol. 2, PP. 121-167.

برای ارتقای دقت در مسیر کشف تغییرات برای الگوریتم مطرح‌شده، می‌توان به این پیشنهادها اشاره کرد:

- اجرای الگوریتم مذکور در تصاویر با قدرت تفکیک بیشتر و با قطعه‌بندی مطلوب، برای شناسایی تغییرات، به یقین نتایج بهتری را در پی خواهد داشت؛

- روش ترکیب رنگ‌ها و تلفیق آن با روش‌های طبقه‌بندی شیء‌گرا، با هدف شناسایی تغییرات، ایده‌ای بسیار ساده و در عین حال، بسیار کارآمد است که کمتر به کار رفته و استفاده از آن نتایج مطلوبی خواهد داشت.

- اینکه الگوریتم مذکور تا جایی که امکان دارد به‌طور خودکار به کار رود و از دخالت کاربر در اجرای فرایند آن و انتخاب نمونه‌های آموزشی و موارد دیگر صرف نظر شود قطعاً نتایج مطلوب‌تری خواهد داشت زیرا با این کار، بسیاری از خطاها حذف خواهند شد و یا دست کم کاهش می‌یابند.

- در روش‌های مطرح‌شده برای کشف تغییرات، سعی شود نمونه‌های آموزشی کمتری به کار رود چون در مدل پیشنهادی، در مقایسه با حالت معمولی آن، دقت با نتایج بهتری حاصل شد. اگرچه در این حالت، نمونه‌های آموزشی فقط در یک تصویر به کار رفت و این به نسبت مدل معمولی، مزیتی در زمینه کاهش

- Cacdac, J., 1998 **Application of Change Detection Algorithms for Mine Environmental Monitoring**. HYPERLINK "http://www.gisdevelopment.net/aars/acrs/1998/ts9006_shtml"
- Chen, G., Hay, G.J., Carvalho, L.M.T. & Wulder, M.A., 2012, **Object-Based Change Detection**, International Journal of Remote Sensing, Vol. 33, No. 14, PP. 4434–4457.
- Chen, M., Su, W., Li, L., Zhang, C., Yue, A. & Li, H., 2009, **Comparison of Pixel-Based and Object Oriented Knowledge-Based Classification Methods Using SPOT5 Imagery**, Wseas Transactions on Information Science and Applications, ISSN: 1790-0832, PP. 477–489.
- Cleve, C., Kelly, M., Kearns, F.R. & Moritz, M., 2008, **Classification of the Wildland–Urban Interface: A Comparison of Pixel and Object-Based Classifications Using High-Resolution Aerial Photography Computers**, Environment and Urban Systems, 32, 317–326.
- Doxani, D., Karantzalos, K. & Tsakiri- Strati, M., 2012, **Monitoring Urban Changes Based on Scale-Space Filtering and Object-Oriented Classification**, International Journal of Applied Earth Observation and Geoinformation, 15, PP. 38–48.
- Gamal, L. & Taha, E.L., 2014, **Assessment of Urbanization Encroachment over Al-Monib Island Using Fuzzy Post Classification Comparison and Urbanization Metrics**, The Egyptian Journal of Remote Sensing and Space Sciences, PP. 135–147.
- Gao, Y., Mas, J.F & Navarrete, A., 2009, **The Improvement of an Object-Oriented Classification Using Multi-Temporal MODIS EVI Satellite Data**, International Journal of Digital Earth, Vol. 2, Issue 3, September 2009 , PP. 219–236.
- Gomez-Chova, L., Camps-Valls, G., Mu Noz-Mar, J. & Calpe, J., 2007, **Semisupervised Image Classification with Laplacian Support Vector Machines**, IEEE Geoscience and Remote Sensing Letters, Vol. XX, No. Y, 1–5.
- Guo, B., Gunn, S.R., Damper, R.I. & Nelson, J.D.B., 2008, **Customizing Kernel Functions for SVM-Based Hyperspectral Image Classification**, IEEE Transactions on Image Processing, Vol. 17, No. 4, PP. 622–629.
- Hao, M., Zhang, H., Li, Z. & Chen, B., 2017, **Unsupervised Change Detection Using a Novel Fuzzy C-Means Clustering Simultaneously Incorporating Local and Global Information**, Multimedia Tools and Applications, PP. 118.
- Janalipour, M. & Mohammadzadeh, A., 2016, **Building Damage Detection Using Object-Based Image Analysis and ANFIS from High-Resolution Image (Case Study: BAM Earthquake, Iran)**, IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 9(5), PP. 1937–1945.
- Janalipour, M. & Taleai, M., 2017, **Building Change Detection after Earthquake Using Multi Criteria Decision Analysis Based on Extracted Information from High Spatial Resolution Satellite Image**, International Journal of Remote Sensing, Vol. 38, PP. 82–99.
- Li, X. & Yeh, A.G.O., 1998, **Principal Component Analysis of Stacked Multi-Temporal Images for the Monitoring of Rapid Urban Expansion in the Pearl River Delta**, International Journal of Remote Sensing, 19, 1501–1518.
- Mahesh Pal, 2005, **Multiclass Approaches for Support Vector Machine Based Land Cover Classification**, MapIndia 2005 Conference, 1–16.
- Malila, W.A., 1980, **Change Vector Analysis: An Approach for Detecting Forest Changes with Landsat**, In: LARS Symposia, P. 385.
- Martinez, J.A., Martha, T.R., Kerle, N., van Westen, C.J., Jetten, V.G. & Kumar, K.V., 2012, **Object-Oriented Analysis of Multi-Temporal Panchromatic Images for Creation of Historical Landslide Inventories**, ISPRS Journal of Photogrammetry and Remote Sensing, 67, PP. 105–119.
- Navulur, K., 2007, **Multispectral Image Analysis Using the Object-Oriented Paradigm**, United States of America, CRC Press.
- Singh, A., 1989, **Digital Change Detection Techniques Using Remotely-Sensed Data**, Int. J. Remote Sensing, 10, 989–1003.
- Weismiller, R.A., Kristof, S.J., Scholz, D.K., Anuta, P.E., & Momin, S.A., 1977, **Change Detection in Coastal Zone Environment**, Photogrammetric Engineering and Remote Sensing, 43, 1533–1539.

- Ye, S., Chen, D., Yu, J., 2016, **A Targeted Change Detection Procedure by Combining Change Vector Analysis and Post Classification Approach**, ISPRS Journal of Photogrammetry and Remote Sensing, PP. 115–124.
- Zhigao, Y., Qianqing, Q. & Qifeng, Z., 2006, **Change Detection in High Spatial Resolution Images Based on Support Vector Machine**, In: IEEE International Symposium on Geoscience and Remote Sensing, PP. 225–228.

