

آنالیز خودکار آشکارسازی تغییرات بر مبنای تصویر اختلاف با استفاده از ترکیب مدل آمیخته‌ی گاوسی و میدان‌های تصادفی مارکوف

حمید قنبری^۱، صفا خزائی^{۲*}

^۱ کارشناس ارشد سنجش از دور - دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی - پردیس دانشکده‌های فنی -

دانشگاه تهران

hamid.ghanbari@ut.ac.ir

^۲ استادیار دانشگاه جامع امام حسین(ع)

skhazai@ihu.ac.ir

(تاریخ دریافت شهریور ۱۳۹۶، تاریخ تصویب آذر ۱۳۹۶)

چکیده

نبود یک روش خودکار مناسب برای جداکردن پیکسل‌های تغییریافته و تغییرنیافته، از اصلی‌ترین مشکلات مربوط به آشکارسازی تغییرات بر مبنای تصویر اختلاف است. این جدایی معمولاً به وسیله روش‌های مبتنی بر آزمون و خطا صورت می‌گیرد که بر روی دقت و درجه اعتمادپذیری فرآیند آشکارسازی تغییرات تأثیر گذار است. برای فائق آمدن بر این مشکل، در این تحقیق، در ابتدا بر مبنای قضیه بیز و با استفاده از مدل آمیخته‌ی گاوسی روشی خودکار برای آنالیز تصویر اختلاف ارائه شده است که می‌تواند به انتخاب نقطه‌ی تغییر (حد آستانه) دو کلاس تغییریافته و تغییرنیافته، کمک کند. در این روش حد آستانه‌ای انتخاب می‌شود که احتمال خطای کلی آشکارسازی تغییرات را با فرض اینکه پیکسل‌های موجود در تصویر اختلاف از یکدیگر مستقل هستند، کمینه کند. در گام بعد بر مبنای استفاده از اطلاعات مکانی و همسایگی، از میدان‌های تصادفی مارکوف برای بررسی وابستگی بین پیکسل‌ها استفاده شده است. روش پیشنهادی بر روی تصاویر ماهواره‌ای لندست ۸ از شهر حلب سوریه اعمال شده است. نتایج حاصل از این تحقیق نشان داده است که استفاده از اطلاعات مکانی به عنوان منبع اطلاعاتی مکمل، سبب بهبود نتایج شناسایی تغییرات می‌شود. همچنین بر اساس نتایج تجربی به‌دست آمده، تکنیک پیشنهادی در مقایسه با روش مدل آمیخته گاوسی و استفاده از حد آستانه تجربی (که نتایج نسبتاً مشابهی داشتند) از کارایی و دقت بالاتری برخوردار است.

واژگان کلیدی: آشکارسازی تغییرات، تصویر اختلاف، مدل آمیخته‌ی گاوسی، میدان‌های تصادفی مارکوف

* نویسنده رابط

۱- مقدمه

در دهه گذشته، رشد فزاینده‌ای در توسعه روش‌های خودکار آشکارسازی تغییرات برای آنالیز تصاویر سنجش از دوری چند طیفی صورت گرفته است. منشا این رشد فزاینده به بازه‌ی گسترده‌ای از کاربردها که روش‌های آشکارسازی تغییرات می‌توانند مورد استفاده قرار بگیرند، بر می‌گردد. آشکارسازی تغییرات طیف وسیعی از کاربردها را در بر می‌گیرد؛ از جمله‌ی این کاربردها می‌توان به پایش گسترش شهرها، آشکارسازی تغییرات کاربری و پوشش اراضی، پایش کیفیت و کمیت پوشش گیاهی منطقه، پایش خطوط ساحلی، پایش کیفیت سطح آب دریاها، پایش آلودگی هوا و گرد و غبار معلق در هوا، پایش یخچال‌های طبیعی و تخمین جمعیت اشاره نمود. اصولاً آشکارسازی تغییرات به آنالیز دو تصویر ثبت شده که از یک ناحیه جغرافیایی در دو زمان مختلف اخذ شده‌اند، تعبیر می‌شود [۱-۵].

روش‌های آشکارسازی تغییرات را به صورت کلی می‌توان به دو دسته نظارت شده و بدون نظارت دسته بندی کرد [۶-۸]. روش‌های آشکارسازی تغییرات با نظارت مبتنی بر طبقه‌بندی بر اساس مقایسه بین دو نقشه طبقه‌بندی شده مربوط به تاریخ‌های مختلف عمل می‌کنند. عواملی که از منظر کاربردی باعث ایجاد محدودیت در استفاده از روش آشکارسازی مبتنی بر طبقه‌بندی می‌شوند، عبارتند از: (۱) هزینه محاسباتی، (۲) قابلیت اطمینان نتایج، (۳) انتشار خطا [۹]. با توجه به حجم بالای تصاویر سنجش از دوری، طبقه‌بندی کل تصاویر یک منطقه در دوره‌های زمانی مختلف دارای هزینه محاسباتی بالایی است. عدم استحکام نتایج به‌دست‌آمده از این روش‌ها، به علت تفاوت در مفسرین نتایج طبقه‌بندی و محدودیت آنهاست، به گونه‌ای که نتایج یک مفسر می‌تواند با مفسر دیگر متفاوت باشد [۱۰]. دسته دوم، آن دسته از روش‌هایی هستند که بدون اطلاعات اضافی سعی در آشکارسازی تغییرات بین دو تصویر دارند. گرچه روش‌های نظارت شده برتری‌هایی نسبت به روش‌ها بدون نظارت دارند (قابلیت تشخیص واضح نوع تغییرات بین پوشش‌های زمینی)، ولی تهیه داده واقعیتهای زمینی اغلب کاری دشوار و پرهزینه است. بنابراین نیاز به استفاده از روش‌های آشکارسازی تغییرات بدون نظارت در بسیاری از موارد که

داده واقعیتهای زمینی وجود ندارد، احساس می‌شود [۱۱]. تکنیک‌های آشکارسازی تغییرات بدون نظارت به الگوهای آموزشی برای آشکارسازی تغییرات نیازی ندارند [۸]. به همین دلیل قابلیت اتوماسیون بالایی داشته و در سالهای اخیر محبوبیت زیادی پیدا کرده‌اند. این روش‌ها عموماً مبتنی بر تشخیص تغییرات طیفی، بر مبنای محاسبه فاصله طیفی بین پیکسل‌ها (روش‌های تفاضلی) و یا شباهت بین پیکسلی (روش‌های تقسیم تصاویر، ضرب داخلی تصاویر و یا همبستگی بین تصاویر) و استفاده از عملیات جبری روی تصاویر دو زمانه و استفاده از یک حد‌آستانه به منظور جداسازی پیکسل‌های تغییر یافته از پیکسل‌های بدون تغییر عمل می‌کنند [۱۲] و [۱۳]. حد آستانه‌گذاری تصویر اختلاف قدر مطلق به منظور تفکیک مناطق تغییر یافته و تغییر نیافته، یکی از متداول‌ترین و ساده‌ترین روش‌های آشکارسازی بدون نظارت می‌باشد که به تکنیک حد‌آستانه‌گذاری معروف هستند. این تکنیک اگرچه از فرو و فرا آشکارسازی رنج می‌برند، در عین حال انتخاب یک حد آستانه‌گذاری مناسب سخت است. حد آستانه خیلی پایین مناطق تغییرات را بیرون خواهد گذاشت و حد آستانه خیلی بالا شامل مناطق تغییرات خواهد شد [۱]، [۳] و [۱۴].

در سال ۱۹۷۵ اتسو^۱ روشی برای یافتن حد آستانه بهینه ارائه نمود. این روش حد آستانه‌ای را انتخاب می‌کند که بیشینه مقدار مجموع واریانس‌های بخش‌های قبل و بعد از آن حد آستانه را دارد [۱۵]. اگرچه تاکنون این روش به عنوان روشی با کارایی بالا برای شناسایی حد آستانه شناخته می‌شود، اما از زمان محاسبه برای شناسایی بهترین حد آستانه در بین تمامی مقادیر نمی‌توان چشم‌پوشی نمود. پو^۲ و همکارانش متوجه این امر شدند که صحت آشکارسازی تغییرات به وسیله جایگذاری حد آستانه‌گذاری‌های متفاوت برای تغییرات مثبت و منفی بهبود می‌یابد [۱۶]. حد آستانه‌گذاری بهینه با استفاده از یک روش آزمون و خطای دستی یا در طی خودکار سازی و آزمودن آن شناسایی می‌شوند. محدودیت‌های اولین روش شامل این موارد می‌شود: پرهزمت و زمان‌بر بودن، فقط از یک تصویر در آنالیز استفاده می‌کند، تعداد حد آستانه-

^۱ Otsu
^۲ Pu

گذاری‌های گسسته کمتری را برای تست کردن استفاده می‌کند [۱۷] و همبستگی مکانی بین پیکسل‌های همسایه را در نظر نمی‌گیرد [۱۸]. در دسته دوم الگوریتم‌های انتخاب حد آستانه‌گذاری خودکار متنوعی طرح‌ریزی شده است که از جمله آن‌ها می‌توان به کمینه‌سازی جمع واریانس داخل کلاسی^۱ (MSICV) [۱۹]، مبتنی بر آنتروپی [۱۹] و فیشر [۲۰] اشاره نمود.

یکی از متداولترین آنالیزهای تحلیلی برای تعیین حدآستانه، آنالیز هیستوگرام نقشه تغییر است. پیکسل‌هایی که دارای تغییرات قابل ملاحظه‌ای هستند، معمولاً در انتهای منحنی توزیع هیستوگرام قرار دارند و پیکسل‌های بدون تغییر در اطراف میانگین توزیع قرار می‌گیرند [۱۲]. پس از تعیین حدآستانه، با مقایسه مقادیر عددی هریک از پیکسل‌ها در نقشه تغییر با حدآستانه، پیکسل‌های تغییر یافته از پیکسل‌های بدون تغییر تمییز داده می‌شوند. با طبقه‌بندی تصویر تغییر به دست آمده بر مبنای کلاس‌های طیفی می‌توان نقشه تغییر را به دست آورد [۲۱]. با این حال به دلیل وجود عوامل مختلف، استفاده از روش‌های متداول کشف تغییرات در مناطق شهری عملکرد قابل قبول ندارند. یکی از این موارد پیچیدگی بین کلاس‌های مختلف پوشش زمین در مناطق شهری است [۲۲]. سنجش از دور در مناطق شهری به دلیل تلفیق شدن طیفی کاربری‌های ساخته شده دست بشر و کاربری‌های طبیعی همواره با مشکلات اساسی روبرو است. از طرفی دیگر ماهیت تغییرات در روش‌های متداول کشف تغییر، بصورت خطی در نظر گرفته می‌شود و فضای بین پیکسل‌های بدون تغییر به صورت خطی از یکدیگر جدا می‌شوند. این در حالیست که در برخی موارد از جمله زمانی که تصاویر با نویز یا تغییرات رادیومتریکی نرمالایز نشده تخریب می‌شوند و یا کلاس‌های طیفی در مناطق شهری با یکدیگر تلفیق شوند، ماهیت تغییرات به صورت غیر خطی باشد [۱۱]. در پژوهشی شاه-حسینی و همکاران [۱۳] یک روش آشکارسازی خودکار مبتنی بر کرنل و با قابلیت استفاده همزمان از اطلاعات طیفی و شاخص‌های طیفی مختلف در مناطق شهری با استفاده از تصاویر چندطیفی ماهواره لندست، پیشنهاد کردند. در این روش در مرحله اول شاخص‌های مناسب از تصاویر چندزمانه استخراج می‌شود. در ادامه به کمک آنالیز

مولفه بردار تغییر در فضای اولیه طیف و فضای هیلبرت و تعیین خودکار حدآستانه، نمونه‌های شبه آموزشی غیر دقیق مربوط به کلاس‌های تغییر یافته و تغییر نیافته استخراج و به عنوان ورودی به الگوریتم خوشه‌بندی وارد شده و به طور همزمان با بهینه‌سازی یک تابع هزینه، مقادیر دقیق پارامترهای الگوریتم خوشه‌بندی و نمونه‌های آموزشی دقیق برای آموزش طبقه‌بندی کننده حداقل فاصله مبتنی بر کرنل استفاده می‌شوند. در مرحله آخر هریک از پیکسل‌های مجهول به طبقه‌بندی کننده وارد شده و کلاس هریک از این پیکسل‌ها مشخص می‌شوند. بازی و همکاران در سال ۲۰۰۷ با فرض گوسی بودن توزیع کلاس‌های تغییر یافته و تغییر نیافته یک روش آستانه‌گذاری با استفاده از الگوریتم EM پیشنهاد کردند که پارامترهای آماری هریک از توزیع‌ها توسط الگوریتم ژنتیک تخمین زده شده است [۲۳]. در تحقیقی دیگر جانعلی‌پور و همکاران در سال ۲۰۱۷ الگوریتمی را به منظور آشکارسازی تغییرات مناطق تخریب شده حاصل از زلزله بم با استفاده از تصاویر با قدرت تفکیک مکانی بالا پیشنهاد دادند. ایشان از یک چارچوب آنالیز تصمیم چند ضابطه‌ای که از اطلاعات طیفی، بافت و ویژگی‌های انتقال یافته استفاده کردند. در این روش ابتدا اطلاعات طیفی، بافت و ویژگی‌های انتقال یافته از تصاویر دو زمانه استخراج و نقشه‌های فاکتور با استفاده از ورود هریک از ویژگی‌های مربوطه به مدل ANFIS ایجاد شدند. در ادامه با استفاده از مدل ANFIS و با ترکیب نقشه‌های فاکتور، نقشه تغییر ابتدایی تولید شد. در نهایت با انجام آنالیز حساسیت و تعیین پارامترهای بهینه مدل ANFIS نقشه تغییر نهایی حاصل شد [۲۴]. در پژوهشی دیگر، کلیک در سال ۲۰۱۰ روشی بدون نظارت برای آشکارسازی تغییرات با استفاده از مدل آمیخته گاوسی و الگوریتم ژنتیک ارائه داد [۲۵]. ایشان روش پیشنهادی خود را بر روی نسبت تصاویر چندزمانه SAR پیاده‌سازی کردند. برای تخمین پارامترهای مدل آمیخته گاوسی از الگوریتم ژنتیک با مینیم کردن تابع هزینه پیکسل‌های کلاس تغییر یافته و تغییر نیافته، استفاده کردند.

با توجه به نتایج قابل قبول مدل آمیخته گاوسی برای آشکارسازی تغییرات در تصاویر SAR، در این تحقیق برآنیم تا علاوه بر استفاده از مدل آمیخته گاوسی به منظور آشکارسازی تغییرات در تصاویر چندطیفی، به آنالیز پارامترهای این الگوریتم و بررسی ابعاد مختلف استفاده از

^۱ Minimizing Sum of Inter-Class Variance (MSICV)

این روش پردازیم. پیش‌نیاز استفاده از این الگوریتم، تخمین احتمالات پیشین و توابع چگالی شرطی برای پیکسل‌های مربوط به کلاس‌های تغییر یافته و تغییر نیافته می‌باشد. علاوه بر این به منظور بهبود نتایج، اطلاعات حاصل از مدل آمیخته گاوسی با اطلاعات همسایگی به وسیله میدان‌های تصادفی مارکوف تلفیق شده است. فرض اولیه در این مسئله مستقل بودن پیکسل‌های تصویر اختلاف از یکدیگر می‌باشد. با استفاده از این فرضیه و قانون بیز می‌توان حد آستانه‌ای را انتخاب کرد که احتمال خطای کلی در فرآیند آشکارسازی تغییرات را کمینه کند. در گام بعد از اطلاعات مکانی بین پیکسل‌های مجاور در تصویر اختلاف به منظور افزایش دقت نقشه تغییرات نهایی استفاده می‌شود. بدین منظور استفاده از میدان‌های تصادفی مارکوف پیشنهاد شده است که وابستگی کلاسی بین پیکسلی را استخراج می‌کند و از آن برای مدل کردن احتمالات هریک از کلاس‌های تغییر یافته و تغییر نیافته بهره می‌برد.

۲- مبانی نظری پژوهش

۲-۱- پیش پردازش تصاویر جهت آشکارسازی تغییرات

جهت آشکارسازی تغییرات در تصاویر ماهواره‌ای چندزمانه در صورتی که از روشهای مبتنی بر آنالیز تغییرات پاسخ طیفی عوارض استفاده شود، لازم است تا تصحیح رادیومتریکی در مورد آنها صورت گیرد. دو روش کلی برای تصحیح رادیومتریکی وجود دارد: روش مطلق و روش نسبی [۲۶]. روش مطلق به اندازه‌گیری‌های زمینی از منطقه مربوطه در لحظه‌ای اخذ تصویر نیازمند است. این اندازه‌گیری‌ها علاوه بر هزینه زیاد گاه‌ها در مواقعی که از تصاویر آرشیو ماهواره استفاده می‌شود، غیرعملی است [۲۷]. روش نسبی برای تصحیح رادیومتریکی که به نرمالیزاسیون رادیومتریکی نسبی^۱ معروف است، نسبت به روش مطلق برتری‌هایی دارد چرا که در سطح DN تصاویر انجام گرفته و به داده‌های اتمسفری سایت در لحظه‌ای اخذ تصویر، نیاز ندارد [۳]، [۲۸] و [۲۹]. در این پژوهش از روش ارائه شده توسط مقیمی و همکارانش [۲۸] استفاده شده است. در روش مذکور از نرمالیزاسیون رادیومتریکی

نسبی استفاده شده است که یکی از تصاویر را به عنوان داده مرجع مورد استفاده قرار داده و سپس خصوصیات رادیومتریکی تصویر هدف را طوری تعدیل می‌کند تا به تصویر مرجع مطابق شود. در این فرایند، دو مرحله اساسی لازم است که به درستی صورت گیرد تا موفقیت فرآیند در تصحیح رادیومتریکی تضمین شود. اولین مرحله آشکارسازی صحیح پیکسل‌های تغییر نیافته در دو تصویر مرجع و هدف می‌باشد تا این پیکسل‌های تغییر نیافته که در واقع نقاط کنترل رادیومتریکی هستند در برآورد پارامترهای مجهول روابط بکار برده شده برای نرمالیزاسیون مورد استفاده قرار گیرند. در روش مذکور از تبدیل آشکارسازی تغییرات چند متغیره وزن‌دار^۲ (IR-MAD) استفاده شده است. مرحله دوم فرآیند نرمالیزاسیون رادیومتریکی تصاویر ماهواره‌ای چندزمانه، نحوه مدلسازی و ارتباط بین پیکسل‌های کنترل رادیومتریکی در دو تصویر مرجع و رفرنس می‌باشد که از شبکه عصبی مصنوعی^۳ جهت برآورد این ارتباط استفاده شد. معمولاً ارتباط بین درجات خاکستری پیکسل‌های تغییر نیافته در تصویر هدف و مرجع از مدل خطی تبعیت نمی‌کند و این فرض تنها به خاطر ساده کردن مرحله مدلسازی مورد استفاده قرار می‌گیرد.

۲-۲- قضیه بیز

برخلاف روش‌های کلاسیک آشکارسازی تغییرات بدون نظارت، روشی که در این پژوهش ارائه شده است بر پایه فرموله بندی کردن مسئله آنالیز تصویر اختلاف در چارچوب بیز است. بدین منظور فرض شده است که پیکسل‌های تصویر اختلاف از توزیعی آمیخته متشکل از دو توزیع است. چنانچه این توزیع‌ها گوسین فرض شوند (فرضی که در بیشتر کاربردهای تصاویر اپتیک استفاده می‌شود)، لذا مسئله ما به تولید نقشه تغییرات با استفاده از مدل آمیخته گاوسی^۴ تبدیل می‌شود [۳۰]. مدل آمیخته‌ی گاوسی به میزان قابل توجهی در مدلسازی تراکم و خوشه‌بندی مورد استفاده قرار می‌گیرد. این مدل‌ها قابلیت تخمین کاملی می‌باشند، چرا که آنها می‌توانند هر نوع تابع تراکم را به

^۲ Iteratively Reweighted Multivariate Alteration Detection

^۳ Artificial neural network

^۴ Gaussian Mixture Model (GMM)

^۱ Relative Radiometric Normalization

صورت دقیقی با تعداد کافی تابع گاوسی مدل سازی نمایند. مدل آمیخته گاوسی به صورت زیر تعریف می شود:

$$P(x; \theta) = \sum_{i=1}^K \alpha_i N(x; \mu_i, \sigma_i^2) \quad (1)$$

از آنجایی که در مسئله ما هدف به دست آوردن توزیع های مربوط به کلاس های تغییر یافته و تغییر نیافته است، تعداد کلاس ها در رابطه بالا برابر دو در نظر گرفته می شود ($K=2$). در رابطه فوق (μ_1, μ_2) و $\sigma = (\sigma_1, \sigma_2)$ به ترتیب میانگین و انحراف معیار توزیع های گاوسین کلاس های هستند. α_i ضریب وزنی یا ضریب آمیخته ی^۱ نام است که در شرایط $\sum_{i=1}^K \alpha_i = 1$ و $0 \leq \alpha_i \leq 1$ صدق می کند و $N(x; \mu_i, \sigma_i^2)$ تابع چگالی گاوسی با پارامترهای μ_i و σ_i^2 مربوط به مؤلفه نام می باشد که از رابطه زیر به دست می آید:

$$N(x; \mu_i, \sigma_i^2) = \frac{1}{\sqrt{2\pi\sigma_i^2}} \exp\left[-\frac{(x_i - \mu_i)^2}{2\sigma_i^2}\right] \quad (2)$$

رابطه (۱) تابع چگالی احتمال متغیرهای مشاهده شده را با استفاده از چگالی های آمیخته گاوسی مدل می کند. به منظور برآورد پارامترهای مدل آمیخته گاوسی تاکنون روش های گوناگونی بصورت نظارت شده و بدون نظارت ارائه شده است. یکی از روش های بدون نظارت به منظور تخمین پارامترهای مدل آمیخته ی گاوسی الگوریتم امید ریاضی-بیشینه سازی (EM) می باشد که مورد توجه بسیاری از محققین قرار گرفته است.

۲-۳- الگوریتم EM

روش های مختلفی برای تخمین پارامترهای مدل آمیخته ی گاوسی پیشنهاد شده اند [۳۱]. یکی از این روش ها الگوریتم EM است. این روش یک روش کلی برای بهینه سازی توابع درست نمایی است، هنگامی که داده ی گمشده وجود داشته باشد یا روش های ساده بهینه سازی با شکست مواجه شوند [۳۰] و [۳۲]. این روش توسط دمپستر و همکاران در سال ۱۹۹۷ ارائه شد [۳۳] و در سال ۱۹۸۴ توسط رندر و واکر برای برآورد پارامترهای مدل های آمیخته به کار گرفته شد [۳۴]. لازمه این الگوریتم اطلاع در مورد تعداد مؤلفه های آمیخته می باشد. تعداد مؤلفه های آمیخته

نشان دهنده تعداد کلاس های طبقه بندی است که می توان آن را با دانش قبلی از مسئله، روش های گرافیکی آنالیز دیتا و یا سایر روش های تخمین تعداد مؤلفه ها مانند Adaptive Mixture به دست آورد [۳۵]. با توجه به مسئله مورد بحث در این پژوهش، تعداد کلاس ها معلوم و برابر دو در نظر گرفته شده است. علاوه بر تعداد مؤلفه های آمیخته، می بایست تخمین اولیه ای برای مقادیر پارامترهای بردار میانگین، ماتریس کواریانس و ضرایب اختلاط تولید کرد. الگوریتم EM با استفاده از تخمین های اولیه و با در نظر گرفتن متغیرهای پنهان از چرخه مکرر برای برآورد پارامترها استفاده می کند. این الگوریتم با در نظر گرفتن مقدار اولیه برای پارامترهای مدل شروع و در گام بعد که مرحله ی تکرار نامیده می شود، این پارامترها به روز می شوند و چرخه تا جایی تکرار می شود که الگوریتم همگرا شود. مرحله ی تکرار از دو گام محاسبه امید ریاضی و بیشینه سازی تشکیل می شود. در گام اول احتمالات پسین توسط رابطه (۳) محاسبه می گردد.

$$\hat{t}_{ij} = \frac{\hat{\alpha}_i N(x_j; \hat{\mu}_i, \hat{\sigma}_i^2)}{\hat{P}(x_j; \theta)} \quad (3)$$

در رابطه بالا $\hat{t}_{ij}$ احتمال پسین برای عنصر j ام است و نشان دهنده ی میزان احتمال عنصر x_j نسبت به تابع چگالی آمیخته ی نام است. $N(x_j; \hat{\mu}_i, \hat{\sigma}_i^2)$ چگالی نرمال مؤلفه ی نام و $\hat{P}(x; \theta)$ نیز تخمین آمیخته ی گاوسی برای عنصر x_j است که رابطه آن در زیر آمده است.

$$\hat{P}(x_j; \theta) = \sum_{i=1}^K \hat{\alpha}_i N(x_j; \hat{\mu}_i, \hat{\sigma}_i^2) \quad (4)$$

در گام بعد پارامترهایی انتخاب می شوند که بر اساس آن ها امید ریاضی به دست آمده از مرحله قبل بیشینه مقدار شود. در این مرحله پارامترهای مدل برحسب $\hat{t}_{ij}$ که از گام قبل به دست آمده، محاسبه می شوند.

$$\hat{\alpha}_i = \frac{1}{n} \sum_{j=1}^n \hat{t}_{ij} \quad (5)$$

$$\hat{\mu}_i = \frac{1}{n} \sum_{j=1}^n \frac{\hat{t}_{ij} x_j}{\hat{\alpha}_i} \quad (6)$$

$$\hat{\Sigma}_i = \frac{1}{n} \sum_{j=1}^n \frac{\hat{t}_{ij} (x_j - \hat{\mu}_i)(x_j - \hat{\mu}_i)^T}{\hat{\alpha}_i} \quad (7)$$

این روند تکراری تا جایی ادامه پیدا می کند که پارامترهای مدل همگرا شوند.

^۱ Mixing coefficient

۲-۴- آنالیز نقطه‌ی تغییر با استفاده از قضیه بیز

زمانی که پارامترهای میانگین، انحراف معیار و ضرایب آمیخته هر توزیع تخمین زده می‌شود حد آستانه از طریق نقطه برخورد توزیع‌ها به دست می‌آید که پیکسل‌های قبل از حد آستانه به عنوان پیکسل‌های تغییرنیافته و پیکسل‌های بعد از حد آستانه به عنوان پیکسل‌های تغییر یافته آشکارسازی می‌شوند. پارامترهای μ_c, σ_c^2 و α_c به ترتیب واریانس، میانگین و ضریب آمیخته برای توزیع کلاس تغییر یافته و پارامترهای μ_n, σ_n^2 و α_n به ترتیب واریانس، میانگین و ضریب آمیخته برای توزیع کلاس تغییر نیافته می‌باشند. به منظور به دست آوردن حد آستانه توزیع‌های مربوط به کلاس‌های تغییر یافته و تغییر نیافته، طبق رابطه زیر با یکدیگر طلاق داده می‌شوند.

$$\alpha_c N(x; \mu_c, \sigma_c^2) = \alpha_n N(x; \mu_n, \sigma_n^2) \quad (۸)$$

رابطه (۸) معادل رابطه زیر می‌باشد:

$$-\frac{(x - \mu_c)^2}{2\sigma_c^2} + \frac{(x - \mu_n)^2}{2\sigma_n^2} = \ln \left(\frac{\alpha_n \sqrt{\sigma_c^2}}{\alpha_c \sqrt{\sigma_n^2}} \right) \quad (۹)$$

رابطه فوق، یک معادله درجه دوم به صورت رابطه (۱۰) می‌باشد که مقادیر ضرایب این معادله در رابطه‌های (۱۱)، (۱۲) و (۱۳) آورده شده است.

$$Ax^2 + Bx + C = 0 \quad (۱۰)$$

$$A = (\sigma_c^2 - \sigma_n^2) \quad (۱۱)$$

$$B = 2(\sigma_n^2 \mu_c - \sigma_c^2 \mu_n) \quad (۱۲)$$

$$C = (\sigma_c^2 \mu_n^2 - \sigma_n^2 \mu_c^2) - 2\sigma_c^2 \sigma_n^2 \ln \left(\frac{\alpha_n \sqrt{\sigma_c^2}}{\alpha_c \sqrt{\sigma_n^2}} \right) \quad (۱۳)$$

ریشه معادله (۱۰) به عنوان حد آستانه به دست آمده از فرآیند آنالیز هیستوگرام ($\hat{T}$) در نظر گرفته می‌شود. اکنون با استفاده از حد آستانه به دست آمده از روابط بالا و تصویر اختلاف موجود، نقشه تغییرات اولیه به دست می‌آید. مقادیر کوچکتر از $\hat{T}$ به عنوان پیکسل‌های تغییر نیافته و مقادیر بزرگتر از $\hat{T}$ به عنوان پیکسل‌های تغییر یافته برچسب می‌خورند. خروجی نقشه تغییر در این مرحله با عنوان GMM شناخته می‌شود.

۲-۵- میدان تصادفی مارکوف

یکی از روش‌های استفاده از اطلاعات مکانی تصویر در طبقه‌بندی و خوشه‌بندی، مفهوم میدان‌های تصادفی مارکوف^۱ است که از اطلاعات همسایگی برای برآورد احتمال برچسب‌دهی استفاده می‌کند [۳۶]. مدل‌سازی تصویر با استفاده از میدان‌های تصادفی مارکوف از موضوعاتی است که در سال‌های اخیر مورد توجه محققان و پژوهشگران قرار گرفته است [۳۷]. از جمله می‌توان به کاربرد میدان‌های تصادفی مارکوف در بازیابی تصاویر، حذف نویز و قطعه‌بندی اشاره نمود. در روش میدان‌های تصادفی مارکوف از مفهوم دسته (یک دسته شامل یک پیکسل و مجموعه همسایگان آن است) و توزیع گیبس برای قطعه‌بندی تصویر استفاده می‌شود. در روش‌های مبتنی بر میدان‌های تصادفی مارکوف هدف کمینه کردن تابع انرژی است تا بتوان به یک قطعه‌بندی مطلوب دست یافت. پروسه آشکارسازی شامل برچسب زدن هریک از پیکسل‌های تصویر اختلاف به هریک از کلاس‌های تغییر یافته و تغییر نیافته می‌باشد. طبق قضیه بیز، احتمال پسین برچسب L برای تصویر اختلاف به صورت زیر می‌باشد:

$$P(L|X_D) = \frac{P(X_D|L) P(L)}{P(X_D)} \quad (۱۴)$$

که $L = \{l_1, l_2, \dots, l_n\} \in \{1, 2\}$ به ازای مجموعه n پیکسل می‌باشد. در رابطه بالا $P(X_D)$ مقداری ثابت است و در نتیجه نهایی تاثیری ندارد. $P(L)$ را می‌توان تعبیری از احتمال پیشین مربوط به مکان و $P(X_D|L)$ تابع احتمال مربوط به توزیع داده‌ها می‌باشد. مقدار L ی که مقدار $P(L|X_D)$ را در رابطه (۱۵) کمینه کند، تحت عنوان برآوردگر بیشینه احتمال پسین^۲ شناخته می‌شود و از رابطه زیر به دست می‌آید.

$$\hat{L} = \arg \min_L \sum_{i=1}^n ((-\log P(X_i|L_i)) - \log P(L_i)) \quad (۱۵)$$

بخش‌های اول و دوم رابطه بالا به ترتیب تحت عنوان انرژی طیفی و انرژی مکانی شناخته شده‌اند. رابطه (۱۵) یک مسئله بهینه‌سازی ترکیبی است که محاسبه آن کاری

^۱ Markov Random Field (MRF)

^۲ Maximum a posteriori (MAP) estimation

قبلی را می‌گیرد. خروجی نقشه با استفاده از اطلاعات مکانی را تحت عنوان GMM-MRF نام‌گذاری می‌کنیم.

۳- روش پیشنهادی

فرض شود دو تصویر چندطیفی X_1 و X_2 با ابعاد $I \times J$ از یک مکان در دو زمان مختلف t_1 و t_2 اخذ شده‌اند. روش آشکارسازی بدون نظارت یک ماسک تغییرات باینری $CM = \{cm(i, j), 1 \leq i \leq I, 1 \leq j \leq J\}$ تولید می‌کند، به گونه‌ای که عناصر آن مجموعه‌ای از برچسب‌های تغییر یافته و تغییر نیافته است. تصویر اختلاف $X_D = \{X_D(i, j), 1 \leq i \leq I, 1 \leq j \leq J\}$ با توجه به نوع تصویر ورودی محاسبه می‌گردد. برای تصاویر ایتیک X_D را می‌توان به صورت قدر مطلق تفاضل مقادیر شدت درجه خاکستری تعریف کرد [۴۳].

$$X_D(i, j) = |X_2(i, j) - X_1(i, j)| \quad (19)$$

در شکل (۱) فلوچارت روش پیشنهادی جهت آشکارسازی تغییرات با استفاده از تصاویر ماهواره‌ای دوزمانه ارائه شده است. داده‌های ورودی شامل دو تصویر ماهواره‌ای مربوط به دو زمان مختلف از یک منطقه می‌باشد. مطابق شکل روش پیشنهادی از سه مرحله اصلی تشکیل شده است. مرحله اول شامل پیش‌پردازش می‌باشد. از آنجایی که تصاویر قبلاً نسبت به یکدیگر هم‌مرجع شده‌اند، در این قسمت به تصحیح رادیومتریکی دو تصویر پرداخته می‌شود. طبق روش ارائه شده در [۲۸]، در این پژوهش از تبدیل IR-MAD به عنوان یک روش کارآمد در تصحیح رادیومتریکی نسبی تصاویر ماهواره‌ای چندزمانه استفاده شد. در این روش پیکسل‌هایی که با احتمال ۹۵ درصد در تصاویر ماهواره‌ای چندزمانه تغییر نیافته‌اند، به عنوان پیکسل‌های کنترل رادیومتریکی مشخص شده و در ادامه نحوه مدلسازی و ارتباط بین پیکسل‌های کنترل رادیومتریکی در دو تصویر مرجع و رفرنس با استفاده از شبکه عصبی مصنوعی^۶ مشخص شود. در استفاده از شبکه عصبی مصنوعی با توجه به ماهیت مسئله، یک لایه پنهان در معماری شبکه عصبی با تعداد نورون‌های متغیر در این لایه در نظر گرفته شد و هر دو لایه ورودی و خروجی از یک نورون که به ترتیب درجه خاکستری پیکسل‌های تغییر نیافته در تصویر هدف و تصویر

دشوار است. تاکنون الگوریتم‌های زیادی بدین منظور پیشنهاد شده‌اند که از جمله آنها می‌توان به روش‌های تکراری شرطی^۱ [۳۸]، برش گراف^۲ [۳۹]، خط گذر درختی بازبینی‌شده^۳ [۴۰] و بسط α بر مبنای برش گراف^۴ [۴۱] اشاره نمود. در این مقاله از روش متروپلیس^۵ [۴۲] استفاده کردیم. این روش علاوه بر تضمین همگرایی به مقدار کمینه کلی، می‌تواند به طور قابل ملاحظه‌ای بر مسئله کمینه‌های محلی چیره شود. این روش بر پایه چارچوب بیز است و هدف آن کمینه کردن انرژی‌های طیفی و مکانی در یک روند تکراری می‌باشد. انرژی مربوط به یک پیکسل x_j را می‌توان به صورت زیر نوشت.

$$E(x_j) = E_{\text{spectral}}(x_j) + E_{\text{spatial}}(x_j) \quad (16)$$

که $E_{\text{spectral}}(x_j)$ انرژی طیفی و $E_{\text{spatial}}(x_j)$ انرژی مکانی برای همسایگی N_j پیکسل x_j می‌باشد. انرژی طیفی از طریق رابطه زیر محاسبه می‌شود.

$$E_{\text{spectral}}(x_j) = -\log P(x_j | L_j) \quad (17)$$

که $P(x_j | L_j)$ احتمال تعلق پیکسل x_j به کلاس L_j می‌باشد. انرژی مکانی نیز از طریق رابطه زیر به دست می‌آید.

$$E_{\text{spatial}}(x_j) = \sum_{x_j \in N_j} \beta (1 - \delta(L_i - L_j)) \quad (18)$$

در رابطه بالا $\delta(L)$ تابع دلتای کروکنر است. خروجی این تابع اگر آرگومان‌های آن با هم مساوی باشند یک و در غیر اینصورت صفر خواهد بود و پارامتر $\beta \in [1, 2]$ اثر همسایگان را کنترل می‌کند. الگوریتم متروپلیس به این صورت است که در هر تکرار یک پیکسل به صورت تصادفی انتخاب می‌شود و سپس انرژی محلی $E(x_j)$ طبق رابطه (۱۶) برای آن محاسبه می‌شود. سپس برچسب پیکسل مرکزی تغییر می‌کند و دوباره مقدار انرژی محلی $E^{new}(x_i)$ به ازای برچسب جدید محاسبه می‌شود. چنانچه شرط $\Delta E = E^{new}(x_i) - E(x_i) < 0$ برقرار شود برچسب جدید جای برچسب قبلی را می‌گیرد، در غیر اینصورت برچسب جدید با احتمال $p = \exp(-\Delta E)$ جای برچسب

^۱ iterated conditional modes

^۲ graph cuts


^۳ tree-reweighted message passing

^۴ α -Expansion graph-cut-based

^۵ Metropolis

^۶ Artificial neural network

مرجع می‌باشد تشکیل شده است. در مرحله بعد تصویر اختلاف با استفاده از تصاویر دو زمانه بدست می‌آید. در بدست آوردن تصویر اختلاف، از باندهای آبی، سبز و قرمز که با استفاده از رابطه زیر به تصویر تک باند خاکستری تبدیل شده‌اند، استفاده شده است.



شکل ۱- فلوجارت روش پیشنهادی

$$E = 0.2989 \times R + 0.5870 \times G + 0.1140 \times B \quad (20)$$

در رابطه فوق R ، G ، B و E به ترتیب باندهای قرمز، سبز، آبی و باند خاکستری می‌باشد. در ادامه تصویر اختلاف با استفاده از قضیه بیز حد آستانه گذاری می‌شود. در این قسمت مسئله آنالیز تصویر اختلاف با استفاده از مدل آمیخته گاوسی صورت می‌گیرد. بدین منظور فرض شده است که پیکسل‌های تصویر اختلاف از توزیعی آمیخته متشکل از دو توزیع گاوسین است. به منظور تخمین پارامترهای مدل نیز از الگوریتم EM استفاده شد. بعد از تخمین پارامترهای مدل حد آستانه مورد نظر از آنالیز نقطه برخورد دو توزیع بدست می‌آید که منجر به تولید نقشه تغییرات اولیه می‌شود. در نهایت با استفاده از اطلاعات مکانی و بهره‌گیری از میدان‌های تصادفی مارکوف دقت نقشه تغییرات به دست آمده از مرحله قبل بهبود می‌یابد.

۴- پیاده‌سازی و ارزیابی نتایج

۴-۱- تصاویر سنجش از دوری مورد استفاده

جهت بررسی دقت و کارایی الگوریتم پیشنهادی، دو دسته داده واقعی (تصویر ماهواره‌ای از شهر حلب واقع در سوریه) و شبیه‌سازی شده مورد استفاده قرار گرفت. در ادامه توضیحات مربوط به دو داده‌ی مورد استفاده آورده شده است.

۴-۱-۱- داده‌ی واقعی شهر حلب

داده اول مورد استفاده، مربوط به شهر حلب می‌باشد. شهر حلب در ۳۵۵ کیلومتری شمال دمشق، پایتخت سوریه، قرار دارد و پایتخت تجاری این کشور به‌شمار می‌رود. شهر حلب از نیمه سال ۲۰۱۲ میلادی به جبهه اصلی جنگ سوریه با گروه‌های تروریستی تبدیل و به مناطقی تحت کنترل نیروهای دولتی و تروریستها تقسیم شده بود. در سال ۲۰۱۶ این شهر از کنترل تروریستها خارج و کنترل شهر به دست دولت قانونی بشار اسد بازگشت. در مدت حضور گروه‌های تروریستی در این شهر، ویرانی‌های گسترده‌ای در سطح شهر حاصل شد که از جمله آنها تخریب ساختمان‌های دولتی و شخصی و تاسیسات شهری می‌باشند. لذا در این پژوهش ما بدنال آشکارسازی ساختمان‌ها و تاسیسات شهری تخریب شده در سطح شهر هستیم. بدین منظور از تصویر چندطیفی لندست ۸ که در سالهای ۲۰۱۴ و ۲۰۱۷ اخذ شده‌اند، استفاده شد. این تصاویر در اواسط فصل تابستان اخذ شده‌اند. بنابراین اثر تغییرات فصلی در آن به حداقل ممکن رسیده است. قدرت تفکیک مکانی این سنجنده برای باندهای طیفی ۳۰ متر و برای باند Pan ۱۵ متر است. الگوریتم‌های پیشنهادی در یک زیر صحنه از تصویر اصلی با ابعاد ۹۲۴×۷۸۲ پیکسل اجرا شد. نمایش ترکیب رنگی واقعی از تصاویر ماهواره لندست ۸ مربوط به سال‌های ۲۰۱۴ و ۲۰۱۷ به ترتیب در شکل‌های (۲-الف) و (۲-ب) نشان داده شده است.



(الف) (ب)




(ج)

شکل ۳- ترکیب رنگی داده‌ی شبیه‌سازی شده (الف) تصویر t_1 (ب) تصویر t_2 (به ازای $SNR=1$) (ج) نقشه مناطق تغییر یافته مصنوعی مرجع


بر طبق روش توضیح داده شده، ما پنج جفت تصویر به دست آوردیم که در هر جفت تصویر زمان اول ثابت و تصویر زمان دوم با مشخصه‌های متفاوت SNR تشکیل شدند. به عنوان نمونه، شکل (۳-الف) و (۳-ب) به ترتیب تصاویر t_1 و t_2 برای $SNR=1$ را نشان می‌دهد. نقشه منطقه با تغییرات شبیه‌سازی شده نیز در شکل (۳-ج) نشان داده شده است.

۴-۲- روش اعتبارسنجی

سه سری آزمایش متفاوت به منظور اعتبارسنجی و بررسی دقت الگوریتم پیشنهادی انجام شد. اولین آزمایش به ارزیابی دقت و استحکام روش پیشنهادی با روش GMM به منظور برآورد پارامترهای آماری در رابطه (۲) می‌پردازد. بدین منظور مقادیر واقعی ضرایب آمیخته، مقادیر میانگین و انحراف معیار برای توزیع‌های پیشین کلاس‌های تغییر یافته و تغییر نیافته با استفاده از نقشه تغییرات واقعی محاسبه شد. سپس این مقادیر با برآوردهای به دست آمده از الگوریتم GMM مقایسه شدند. در آزمایش دوم، عملکرد روش پیشنهادی آنالیز تصویر اختلاف با فرض پیکسل‌های مستقل، مورد ارزیابی قرار گرفته است. برای ارزیابی کمی نتایج آشکارسازی تغییرات، نقشه‌ی باینری تولید شده با داده‌های واقعیت زمینی مقایسه و سه پارامتر FA^1 (درصد پیکسل‌های تغییر نکرده-



(الف) (ب)



(ج)


شکل ۲- نمایش ترکیب رنگی واقعی از تصویر ماهواره لندست ۸ مربوط به (الف) سال ۲۰۱۴، (ب) سال ۲۰۱۷ در منطقه حلب و (ج) نقشه مناطق تغییر یافته

۴-۱-۲- داده‌ی شبیه‌سازی شده

داده‌ی شبیه‌سازی شده به این دلیل به کار گرفته شد که دارای یک نقشه مرجع و صد در صد دقیق است که ارزیابی دقت را با اطمینان بالا ممکن می‌سازد. علاوه بر این روند ایجاد آن تحت کنترل است و می‌توان کارایی الگوریتم پیشنهادی را در برابر سطوح مختلف نویز بررسی کرد. بدین منظور از یک تصویر ماهواره لندست ۸ و سنجنده OLI به عنوان تصویر مرجع t_1 استفاده شد. تصویر مورد نظر از شهر حلب در سال ۲۰۱۴ اخذ شده است و یک زیر صحنه با ابعاد 241×291 از آن در نظر گرفته شده است. تصویر دوم با ایجاد تغییراتی در مناطقی از تصویر اول به منظور شبیه سازی تغییرات پوشش زمینی ایجاد شد. بدین منظور مناطقی از تصویر اول انتخاب و مقادیر درجه خاکستری تغییر داده شدند. سپس به منظور شبیه‌سازی شرایط نوری متفاوت در زمان اخذ تصویر دوم، هیستوگرام تصویر خروجی انتقال داده شد. در نهایت با اضافه نمودن نویز گاوسی با میانگین صفر با پنج مقدار متفاوت نسبت سیگنال به نویز ($SNR = 1, 2, 3, 5, 10db$)، پنج ورژن متفاوت از تصویر در زمان t_2 ایجاد کردیم.


¹ False Alarm

است که هیستوگرام تصویر اختلاف و توابع چگالی مربوط به کلاس‌های تغییر یافته و تغییر نیافته را نمایش می‌دهد. مقدار حد آستانه بدست آمده در این مرحله برابر ۳۴ در نظر گرفته شده است. توابع چگالی کلاس‌های تغییر یافته و تغییر نیافته یک تقریب منطقی از توزیع تصویر اختلاف را نشان می‌دهند که عملکرد خوب روش پیشنهادی را تایید می‌کند. به منظور بررسی روند همگرایی الگوریتم GMM،



شکل ۴- هیستوگرام (نرمالیزه شده) تصویر اختلاف داده‌ی لندست ۸ (شهر حلب) به همراه توزیع‌های مربوط به کلاس‌های تغییر یافته و تغییر نیافته

رفتار پارامترهای برآورد شده بر مبنای تعداد تکرار الگوریتم برای کلاس‌های بدون تغییر، در شکل (۵) آورده شده است. همان‌طور که مشخص است، با افزایش تعداد تکرار الگوریتم، برآوردها از یک مقدار اولیه غیر دقیق به سمت تخمینی دقیق‌تر پیش رفته‌اند که در نهایت با شش تکرار مقادیر برآوردهای نهایی با توجه به عدم تغییر قابل ملاحظه، به‌دست آمده‌اند.



(الف)

ای که الگوریتم آنها را اشتباهاً به عنوان تغییرات آشکارسازی کرده)، MA^1 (درصد پیکسل‌های تغییر کرده- ای که الگوریتم موفق به آشکارسازی آنها نشده است) و خطای کلی آشکارسازی تغییرات (OE^2) که کل پیکسل- های اشتباه آشکارسازی شده است، گزارش شده است. در این آزمایش پارامترهای FA، MA و OE به ازای مقادیر مختلف حد آستانه محاسبه و با حد آستانه به‌دست آمده از الگوریتم EM مقایسه می‌شود. در آزمایش سوم نیز عملکرد استفاده از اطلاعات مکانی و همسایگی بررسی می‌شود. در این بخش علاوه بر سه پارامتر ذکر شده دو معیار ارزیابی دقت، یعنی دقت کلی (OA^3) و ضریب کاپا^۴ و نیز گزارش شده‌اند.

۳-۴- نتایج آزمایش‌ها بر روی داده لندست ۸

۳-۴-۱- آنالیز برآوردهای آماری مرتبط با کلاس‌های تغییر یافته و تغییر نیافته

نتایج برآوردهای ضرایب آمیخته، میانگین و انحراف معیار در جدول (۱) آورده شده است. در این جدول مقادیر محاسبه شده با مقادیر واقعی به‌دست آمده از داده واقعیت زمینی آورده شده است. همان‌طور که مشاهده می‌شود، برآوردهای بدست آمده از روش GMM تقریب نسبتاً دقیقی از پارامترهای آماری ارائه داده است. علیرغم برآوردهای μ_c و σ_c که مقدار اندکی با مقادیر واقعی فاصله دارند و مقادیر α_c و α_n و همچنین مقادیر μ_n و σ_n به مقادیر واقعی بسیار نزدیک هستند.


جدول ۱- مقادیر واقعی و برآورد شده با استفاده از الگوریتم GMM

	GMM Algorithm	True value
α_n	۰٫۹۲	۰٫۹۲
μ_n	۱۳٫۳۲	۱۳٫۲۵
σ_n	۶۱٫۱۱	۶۱٫۳۳
α_c	۰٫۰۸	۰٫۰۸
μ_c	۴۱٫۷۲	۴۲٫۸۵
σ_c	۳۴۲٫۲۲	۳۴۴٫۵۵


اطلاعات بیشتر در مورد دقت پارامترهای به‌دست آمده از الگوریتم GMM از طریق آنالیز شکل (۴) قابل استخراج

^۱ Missed Alarm
^۲ Overall Error
^۳ Overall Accuracy
^۴ Kappa coefficient


مقدار حد آستانه بهینه به صورت سعی و خطا به ازای مقادیر مختلف حد آستانه بدست آمده است و بهترین نتیجه (کمترین میزان خطا) به عنوان مقدار حد آستانه بهینه در نظر گرفته شده است. همان طور که در شکل (۶) مشاهده می شود، حد آستانه به دست آمده از الگوریتم GMM به مقدار کمینه آن بر روی منحنی OE خیلی نزدیک است. مقادیر FA و MA به دست آمده از الگوریتم GMM به ترتیب برابر با ۹۸ و ۹۱ و این مقادیر برای حد آستانه بهینه ای که به صورت تجربی به دست آمده است برابر ۹۲ و ۸۸ می باشند.



شکل ۶- رفتار خطاهای آشکارسازی تغییرات (FA, MA و OE) به ازای مقادیر مختلف حد آستانه برای داده لندست. مقدار بهینه حد آستانه T_c برابر ۳۲ به دست آمد



(ب)



(ج)


شکل ۵- رفتار پارامترهای برآورد شده بر مبنای تعداد تکرار الگوریتم برای کلاس های بدون تغییر

۴-۳-۲- آنالیز تصویر اختلاف با مقادیر مختلف حد آستانه

در این بخش، مقدار حد آستانه به دست آمده با استفاده از GMM با مقادیر مختلف حد آستانه مقایسه شده است. به منظور ارزیابی دقیق تر حد آستانه، سه پارامتر FA, MA و OE به عنوان معیار مقایسه، مورد استفاده قرار گرفتند.

جدول ۲- مقادیر FA, MA, OE و kappa به دست آمده از روش GMM-MRF به ازای مقادیر مختلف β و مقایسه نتایج با روش GMM

الگوریتم آشکارسازی	β	FA	MA	OE	kappa	OA (%)
GMM	-	۹۸	۹۱	۱۸۹	۰,۷۲	۷۷
استفاده از حد آستانه بهینه	-	۹۵	۸۵	۱۸۰	۰,۷۳	۷۸
GMM-MRF	۱,۶	۶۵	۵۱	۱۱۶	۰,۷۹	۸۰,۱۰
	۱,۷	۶۴	۴۷	۱۱۱	۰,۸۰	۸۱,۱۱
	۱,۸	۷۲	۵۳	۱۲۱	۰,۷۹	۸۰,۰۲



شکل ۷- نقشه تغییر داده‌ی لندست ۸ مربوط به شهر حلب به دست آمده از روش (الف) GMM (ب) حدآستانه بهینه (ج) GMM-MRF

نقشه تغییرات به دست آمده از الگوریتم GMM و حدآستانه بهینه به دست آمده به ترتیب در شکل (الف) و (ب) نشان داده شده‌اند. مقایسه دو نقشه تغییرات نشان می‌دهد خروجی روش خودکار بر مبنای الگوریتم GMM تا میزان نسبتاً بالایی به زمانی که از حدآستانه بهینه که به صورت غیر خودکار به دست آمده است، نزدیک است.

۳-۳-۴ آنالیز تصویر اختلاف با استفاده از اطلاعات مکانی

در این بخش آنالیز روش پیشنهادی با در نظر گرفتن اطلاعات مکانی استخراج شده به وسیله‌ی میدان‌های تصادفی مارکوف، صورت گرفته است. جدول (۲) مقادیر

FA، MA و OE را به ازای مقادیر مختلف β نشان می‌دهد. به منظور آنالیز بهتر عملکرد روش پیشنهادی، مقادیر دقت کلی (OA) و ضریب کاپا نیز در جدول (۲) آورده شده‌اند. همان‌طور که مشاهده می‌شود استفاده از میدان‌های تصادفی مارکوف به ازای مقادیر مختلف β ، در مقایسه با استفاده تنها از الگوریتم GMM و همچنین حدآستانه بهینه، کاهش مقدار OE را در پی دارد (به عنوان نمونه مقدار OE برای روش GMM-MRF به ازای $\beta=1,6$ برابر ۱۱۶ و برای الگوریتم GMM برابر ۱۸۹ است). همچنین پارامترهای MA و FA در روش GMM-MRF کاهش داشتند. به عنوان نمونه به ازای $\beta=1,6$ مقدار MA از ۹۱ به ۵۱ و مقدار FA از ۹۸ به ۶۵ کاهش پیدا کرده‌اند. نقشه تغییرات به دست آمده از روش GMM-MRF با مقدار $\beta=1,6$ در شکل (۷-ج) نشان داده شده است. مقایسه نقشه تغییرات نمایش داده شده در شکل (۷)، برتری روش GMM-MRF را نسبت به دو روش قبل نشان می‌دهد.

۴-۴-۴ نتایج آزمایش‌های بر روی داده‌ی شبیه‌سازی شده

در این بخش آزمایش‌های صورت گرفته در بخش ۴-۳، بر روی داده‌ی شبیه‌سازی شده تکرار شدند تا عملکرد روش پیشنهادی به ازای سطوح مختلف نویز سنجیده شود. بدین منظور پنج جفت تصویر مختلف شبیه‌سازی شده با سطوح مختلف نویز (SNR = 1, 2, 3, 5, 10db) مورد استفاده قرار گرفتند.

جدول ۳- مقادیر واقعی پارامترهای آماری به دست آمده از نقشه تغییر مرجع و با استفاده از الگوریتم GMM برای داده‌ی شبیه‌سازی شده برای (الف) کلاس تغییر نیافته و (ب) کلاس تغییر یافته

SNR (db)	α_n		μ_n		σ_n	
	مقدار تخمین زده شده	مقدار واقعی	مقدار تخمین زده شده	مقدار واقعی	مقدار تخمین زده شده	مقدار واقعی
۱۰	۰,۶۹	۰,۶۹	۱۷,۴۸	۱۷,۳۲	۹۷,۱۲	۹۷,۳۳
۵	۰,۶۹	۰,۶۹	۱۹,۷۸	۱۹,۲۳	۹۹,۳۱	۹۹,۲۱
۳	۰,۶۹	۰,۶۹	۲۱,۶۸	۲۱,۴۳	۱۰۰,۴۵	۱۰۰,۳۱
۲	۰,۶۹	۰,۶۹	۱۹,۱۱	۱۸,۵۴	۱۰۱,۲۱	۱۰۱,۵۴
۱	۰,۶۸	۰,۶۹	۲۶,۱۷	۲۵,۳۱	۱۰۵,۸۹	۱۰۵,۶۷

(الف)


SNR (db)	α_c		μ_c		σ_c	
	مقدار تخمین زده شده	مقدار واقعی	مقدار تخمین زده شده	مقدار واقعی	مقدار تخمین زده شده	مقدار واقعی
۱۰	۰,۳۱	۰,۳۱	۴۷,۴۲	۴۷,۷۱	۴۹۳,۵۷	۴۹۳,۲۵
۵	۰,۳۱	۰,۳۱	۴۸,۳۲	۴۹,۴۶	۴۹۱,۱۲	۴۹۲,۱۴
۳	۰,۳۱	۰,۳۱	۵۰,۷۴	۵۲,۸۷	۴۹۵,۳۲	۴۹۴,۲۱
۲	۰,۳۱	۰,۳۱	۵۲,۹۳	۵۴,۱۲	۴۹۷,۴۵	۴۹۵,۱۶
۱	۰,۳۲	۰,۳۱	۵۳,۶۵	۵۶,۸۳	۴۹۸,۶۵	۵۰۱,۲۱

(ب)


۴-۴-۱- آنالیز برآوردهای آماری مرتبط با کلاس‌های تغییر یافته و تغییر نیافته

جدول (۳) نتایج به‌دست‌آمده در این قسمت را برای پنج مقدار مختلف SNR نشان می‌دهد. همان‌طور که مشاهده می‌شود، به ازای مقادیر مختلف SNR، پارامترهای به‌دست‌آمده از الگوریتم GMM به صورت دقیقی پارامترهای واقعی را تخمین می‌زنند. این تخمین دقیق در مورد تصویر با نویز بالا ($SNR = 1$) نیز مشاهده می‌شود (بیشترین مقدار خطا در برآوردها به μ_c با $SNR=1$ مربوط می‌شود که مقدار برآورد شده برابر ۵۳,۶۵ است و مقدار واقعی آن برابر ۵۶,۸۳ می‌باشد). در شکل (۸) هیستوگرام تصویر اختلاف و توزیع‌های نرمال تخمین زده شده به وسیله الگوریتم GMM برای کلاس‌های تغییر یافته و تغییر نیافته به ازای $SNR = 1$ ، مقایسه شده‌اند. همان‌طور که مشاهده می‌شود، علیرغم پیچیدگی مسئله (توابع چگالی کلاس‌های تغییر یافته و تغییر نیافته در تصویر اختلاف قابل تمایز نیستند)، تخمین‌های به‌دست‌آمده با استفاده از الگوریتم GMM یک تقریب دقیق از تابع چگالی هیستوگرام تصویر اختلاف هستند. این آزمایش همچنین اطلاعات بیشتری در مورد همگرایی الگوریتم GMM می‌دهد. همان‌طور که از شکل (۹) پیداست، با

افزایش میزان نویز در تصویر تعداد تکرارهای لازم برای رسیدن به همگرایی افزایش پیدا می‌کند.



شکل ۸- هیستوگرام (نرمالیزه شده) تصویر اختلاف داده‌ی شبیه‌سازی شده (به ازای $SNR=1$) به همراه توزیع‌های مربوط به کلاس‌های تغییر یافته و تغییر نیافته




شکل ۹- تعداد تکرارها لازم برای رسیدن همگرایی در مقابل مقادیر مختلف SNR

جدول ۴- مقادیر دقت نقشه تغییر بدست آمده از روش GMM-MRF به ازای مقادیر مختلف β و مقایسه نتایج با روش GMM و استفاده از حد آستانه بهینه برای داده‌ی شبیه‌سازی شده ($SNR=1$)

الگوریتم آشکارسازی	β	FA	MA	OE	kappa	OA (%)
GMM	-	۳۹	۴۴	۸۳	۰,۷۹	۸۱,۰۵
استفاده از حد آستانه بهینه	-	۳۷	۴۱	۷۸	۰,۷۹	۸۱,۴۳
GMM-MRF	۱,۶	۲۴	۲۷	۵۱	۰,۸۱	۸۳,۰۴
	۱,۷	۲۲	۲۵	۴۷	۰,۸۱	۸۳,۹۴
	۱,۸	۲۴	۲۹	۵۳	۰,۸۱	۸۲,۲۳

۴-۴-۲- آنالیز تصویر اختلاف با مقادیر مختلف حد آستانه

در این بخش تمامی آزمایش‌های به ازای مقادیر مختلف SNR انجام شد که مقادیر حد آستانه از الگوریتم پیشنهادی به حد آستانه بهینه نزدیک بود. به عنوان نمونه، بیشترین خطای کلی مربوط به داده‌ی شبیه‌سازی شده با $SNR=1$ بود. در این حالت میزان حد آستانه به-دست آمده برابر 42.50 است، در صورتی که تفاوت چندان با میزان حد آستانه بهینه که برابر 43.6 است، ندارد. شکل (۱۰-الف) و (۱۰-ب) به ترتیب نقشه تغییرات به‌دست‌آمده با استفاده از الگوریتم GMM و نقشه تغییرات به‌دست‌آمده با استفاده از حد آستانه بهینه را نشان می‌دهد. یک آنالیز جامع از این تصاویر نشان می‌دهد همانند تصویر لندست ۸ در اینجا نیز نقشه تغییرات به‌دست‌آمده از دو روش ذکر شده نزدیک به یکدیگرند که این نشان-دهنده عملکرد خوب الگوریتم GMM است و اعتمادپذیری این الگوریتم را تایید می‌کند.



شکل ۱۰- نقشه تغییر داده‌ی شبیه‌سازی شده به‌دست آمده از روش (الف) GMM (ب) حد آستانه بهینه (ج) GMM-MRF

۴-۴-۳- آنالیز تصویر اختلاف با استفاده از اطلاعات مکانی

نتایج به‌دست‌آمده در این حالت در جدول (۴) آورده شده است. همان‌طور که پیداست نتایج نشان از افزایش دقت آشکارسازی تغییرات با استفاده از اطلاعات مکانی می‌دهد. از سوی دیگر، مقدار OE به‌دست‌آمده از روش

GMM-MRF در مقایسه با حد آستانه بهینه و الگوریتم GMM کاهش یافته است. به عنوان مثال مقدار OE برای روش GMM-MRF به ازای $SNR=1$ و $\beta=1.7$ برابر 47 است در صورتیکه این مقدار با استفاده از حد آستانه بهینه 78 و با استفاده از الگوریتم GMM برابر 83 است. همچنین در مقایسه روش GMM-MRF و GMM مقدار MA از 44 به 25 و FA از 39 به 22 کاهش یافت. شکل (۱۰-ج) نقشه تغییرات به‌دست‌آمده با استفاده از روش GMM-MRF به ازای $SNR=1$ نشان می‌دهد. مقایسه سه نقشه تغییرات در شکل (۱۰) برتری روش GMM-MRF را در مقایسه با دو روش الگوریتم GMM و حد آستانه بهینه نشان می‌دهد. خروجی حاصل از روش GMM-MRF دقیقتر و با نویز کمتری نسبت به دو تصویر دیگر است.

۵- نتیجه‌گیری

در این تحقیق دو روش آنالیز تصویر اختلاف برای آشکارسازی تغییرات خودکار و بدون نظارت ارائه گردید. نوآوری اصلی این تحقیق به فرموله بندی مسئله آشکارسازی تغییرات بر پایه تئوری تصمیم بیز مربوط می‌شود به‌طوری‌که یک روش تکراری (بر اساس الگوریتم EM) به منظور تخمین بدون نظارت توزیع‌ها و احتمالات پیشین توزیع‌های مرتبط با کلاس‌های تغییر یافته و تغییر نیافته را ارائه می‌دهد. در این چارچوب دو روش به منظور آنالیز تصویر اختلاف پیشنهاد شد. روش اول (GMM)، مبتنی بر این فرض که پیکسل‌های تصویر اختلاف مستقل از یکدیگرند، می‌باشد. با این فرض، امکان انتخاب خودکار حد آستانه‌ای که احتمال خطای کلی را کمینه کند، فراهم شد. در روش دوم (GMM-MRF) که بهینه‌شده روش اول است، با استفاده از میدان‌های تصادفی مارکوف که از اطلاعات مکانی و همسایگی پیکسل‌ها استفاده می‌کند، دقت نقشه تغییرات نهایی بهبود داده شد. نتایج آزمایش‌های گزارش شده در مقاله، نشان‌دهنده عملکرد بهتر روش GMM-MRF می‌باشد. این عملکرد بهتر به دقت و استحکام مهیا شده به‌وسیله‌ی الگوریتم EM بستگی دارد. بر اساس نتایج تجربی به‌دست آمده، مقدار حد آستانه به‌دست‌آمده از الگوریتم EM به مقدار بهینه‌ی آن بسیار نزدیک است. بهبود بیشتر نیز زمانی اتفاق افتاد که از اطلاعات مکانی در چارچوب

دورافتاده آسیب‌پذیر سازد. لذا در سال‌های اخیر تحقیقات زیادی بر جایگزین کردن توزیع‌های متقارن دم سنگین و حالت‌های چوله آن‌ها به جای توزیع نرمال صورت گرفته است. این توزیع‌ها زمانی کاربرد دارند که داده‌ها دارای تغییرات شدیدی باشند. همچنین در صورتی که داده‌ها دارای تغییرات شدیدی نباشند می‌توان به جای توزیع نرمال از توزیع‌های پایدار مانند توزیع لاپلاس و یا توزیع کشی که واریانس محدود دارند و توسعه‌یافته توزیع نرمال هستند، استفاده نمود.

میدان‌های تصادفی مارکوف استفاده شد. استفاده از این روش علاوه بر اینکه دقت بالایی نسبت به روش GMM داشت، قابلیت بالایی را نیز در مواجهه با تصاویر با نویز بالا از خود نشان داد. به عنوان نمونه، در مورد داده‌ی شبیه‌سازی شده به ترتیب میزان ۲٪ و ۳٪ افزایش دقت و در مورد داده‌ی لندست-۸ به ترتیب مقدار ۴٪ و ۸٪ افزایش دقت در پارامترهای ضریب کاپا و صحت کلی حاصل شده است. در پایان، همان‌طور که توضیح داده شد فرض اولیه در مدل آمیخته گاوسی، هم‌توزیع بودن مشاهدات بود. این فرض ممکن است استنباط را در صورت وجود داده‌های

مراجع

- [1] Lu, D., Mausel, P., Brondizio, E., & Moran, E. (2004). Change detection techniques. *International journal of remote sensing*, 25(12), 2365-2401.
- [2] Argany M. (2006) "Monitoring the development of urban areas using satellite imagery by spectral composition analysis and comparison after classification". M.Sc thesis, University of Tehran.
- [3] Moghimi A., Ebadi H., Sadeghi V. (2016) "Review of Change Detection Methods from Multitemporal Satellite Images by Pixel-Based and Object-Based Approach, *Geomatics Engineering Journal*, 7 (2), 99-110.
- [4] Moghimi A. (2012) "Integration of textual and spectral information for change detection in urban areas from satellite imagery with direct comparison and after classification methods". M.Sc thesis, KN Toosi University of Technology.
- [5] Singh A (1989) Review article digital change detection techniques using remotely-sensed data. *Int J Remote Sens* 10:989–1003
- [6] L. Bruzzone and S. B. Serpico, "An iterative technique for the detection of land-cover transitions in multitemporal remote-sensing images," *IEEE Trans. Geosci. Remote Sensing*, vol. 35, pp. 858–867, July 1997.
- [7] Ghanbari M., Akbari V., Abkar A.A., Sahebi M.R. (2015) "A test statistic based on wishart distribution for unsupervised change detection in multilook polarimetric radar data". *Journal of RADAR*, 2 (4).
- [8] Moghimi A., khazai S., Ebadi H. (2016) "Unsupervised Change Detection Using Multi-temporal SAR Images Based on Improvement of Level Set Methods", *Journal of Radar*, 4 (1).
- [9] M. Guorui, S. Haigang, L. Pingxiang, and Q. Qianqing, "A kernel change detection algorithm in remote sense imagery," in *Geoscience and Remote Sensing Symposium*, 2006. IGARSS 2006. IEEE International Conference on, 2006, pp. 220–224.
- [10] J. Muñoz-Marí, F. Bovolo, L. Gómez-Chova, L. Bruzzone, and G. Camp-Valls, "Semisupervised One-Class Support Vector Machines for Classification of Remote Sensing Data," *IEEE Trans. Geosci. Remote Sens.*, vol. 48, no. 8, pp. 3188–3197, Aug. 2010.
- [11] M. Volpi, D. Tuia, G. Camps-Valls, and M. Kanevski, "Unsupervised change detection by kernel clustering," in *Remote Sensing*, 2010, p. 78300V–78300V.
- [12] Bovolo, L. Bruzzone, and M. Marconcini, "A Novel Approach to Unsupervised Change Detection Based on a Semisupervised SVM and a Similarity Measure," *IEEE Trans. Geosci. Remote Sens.*, vol. 46, no. 7, pp. 2070–2082, Jul. 2008.
- [13] Shah-Hoseini R., Safari A., Homayouni S. (2016) "An Automated Kernel-based Change Detection Method in Urban Area Using Landsat Multispectral Images, Case Study: City of Karaj". *JGST*, 5 (3), 15-34.
- [14] Hussain, M., Chen, D., Cheng, A., Wei, H., & Stanley, D. (2013). Change detection from remotely sensed images: From pixel-based to object-based approaches. *ISPRS Journal of Photogrammetry and Remote Sensing*, 80, 91-106.
- [15] N. Otsu, "A threshold selection method from gray-level histograms," *Automatica*, vol. 11, pp. 23-27, 1975.
- [16] Rosin, P.L., 2002. Thresholding for change detection. *Computer Vision and Image Understanding* 86, 79– 95.

- [17] Im, J., Jensen, J.R., Hodgson, M.E., 2008a. Optimizing the binary discriminant function in change detection applications. *Remote Sensing of Environment* 112, 2776-2761.
- [18] Ghosh, A., Mishra, N.S., Ghosh, S., 2011. Fuzzy clustering algorithms for unsupervised change detection in remote sensing images. *Information Sciences* 181, 699-715.
- [19] M., Sezgin. and B., Sankur,(2004), "Survey over image thresholding techniques and quantitative performance evaluation", *Journal of Electronic Imaging*, Vol. 13, No. 1, pp. 146-165.
- [20] B., Zhang, K., Chen,Y., Zhou, M., Xie, H., Zhang, (2010), "Research on Change Detection in Remote Sensing Images by using 2D-Fisher Criterion Function Method", *ISPRS TC VII Symposium – 100 Years ISPRS*, Vienna, Austria, July 5-7, Vol. XXXVIII, Part 7B.
- [21] A. P. Tewkesbury, A. J. Comber, N. J. Tate, A. Lamb, and P. F. Fisher, "A critical synthesis of remotely sensed optical image change detection techniques," *Remote Sens. Environ.*, vol. 160, pp. 1-14, Apr. 2015.
- [22] H. Xu, "Extraction of urban built-up land features from Landsat imagery using a thematic-oriented index combination technique," *Photogramm. Eng. Remote Sens.*, vol. 73, no. 12, p. 1381, 2007.
- [23] Y. Bazi, L. Bruzzone, and F. Melgani, "Image thresholding based on the EM algorithm and the generalized Gaussian distribution," *Pattern Recognition*, vol. 40, pp. 619-634, 2007.
- [24] Milad Janalipour & Mohammad Taleai , Building change detection after earthquake using multi-criteria decision analysis based on extracted information from high spatial resolution satellite images *International Journal of Remote Sensing* Vol. 38 , Iss. 1, 2017.
- [25] T. Celik, "Unsupervised change detection in satellite images using principal component analysis and means clustering," *IEEE Geoscience and Remote Sensing Letters*, vol. 6, pp. 772-776, 2009.
- [26] C. P. Lo, and X. Yang.(1998) "Some practical considerations of relative radiometric normalization of multirate Landsat MSS data for land use change detection,Tampa,Florida," *Proceedings of ASPRS/RTI 1998 Annual Convention*, pp. 1184-1193.
- [27] R. J. Radke, S. Andra, O. Al-Kofahi, and B. Roysam, (2005) "Image change detection algorithms: a systematic survey," *Image Processing, IEEE Transactions on*, vol. 14, pp. 294-307.
- [28] Moghimi A., badi H., Sadeghi V. (2015) "Automatic Radiometric Normalization of Multi-Temporal Satellite Image based on IR-MAD ". *Transformation and Artificial Neural. JGST*. 4 (4), 209-222.
- [29] Sadeghi V., Ebadi H. , Ahmadi F. (2014) "Automatic Normalization of Multitemporal Satellite Images using Artificial Neural Network and Unchanged Pixels , *JGIT*, 2 (1) :17-39.
- [30] M. A. T. Figueiredo and A. K. Jain, "Unsupervised learning of finite mixture models," in *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 24, no. 3, pp. 381-396, March 2002.
- [31] Everitt, B. S. and D. J. Hand. 1981. *Finite Mixture Distributions*, London: Chapman and Hall.
- [32] B. A. S. Hasan, and Q. J. Gan, "Sequential EM for unsupervised adaptive Gaussian mixture model based classifier," in *Proc. 6th Int. Conf. Machine Learning and Data Mining in Pattern Recognition*, Leipzig, Germany, 2009, pp. 96-106.
- [33] Dempster, A. P., Laird, N. M., and Rubin, D. B. 1977. "Maximum likelihood from incomplete data via the EM algorithm (with discussion)," *Journal of the Royal Statistical Society: B*, 39: pp. 1-38.
- [34] Redner, A. R. and H. F. Walker. 1984. "Mixture densities, maximum likelihood and the EM algorithm," *SIAM Review*, 26: pp. 195-239.
- [35] Preibe, C. E. 1994. "Adaptive mixture density estimation," *Journal of the American Statistical Association*, 89: pp. 796-806.
- [36] Makrogiannis S., Economou G., Fotopoulos S. (2005). "A Region Dissimilarity Relation That Combines Feature-Space and Spatial Information for Color Image Segmentation." *IEEE TRANSACTIONS ON SYSTEMS, MAN, AND CYBERNETICS—PART B: CYBERNETICS*, VOL. 35, NO. 1, February 2005.
- [37] Richards J.A. (2006). "Remote Sensing Digital Image Analysis: An Introduction." 4th ed, ISBN-10 3-540-25128-6 , New Yourk, Springer.
- [38] Besag, "On the Statistical Analysis of Dirty Pictures", *J. Royal Statistical Soc. B*, vol. 48, no. 3, pp. 259-302, 1986.
- [39] Y. Boykov and V. Kolmogorov, "An experimental comparison of mincut/max- flow algorithms for energy minimization in vision," in *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 26, no. 9, pp. 1124-1137, Sept. 2004.
- [40] V. Kolmogorov, "Convergent Tree-Reweighted Message Passing for Energy Minimization," in *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 28, no. 10, pp. 1568-1583, Oct. 2006.

- [41] J. Li, J. M. Bioucas-Dias and A. Plaza, "Spectral-Spatial Hyperspectral Image Segmentation Using Subspace Multinomial Logistic Regression and Markov Random Fields," in IEEE Transactions on Geoscience and Remote Sensing, vol. 50, no. 3, pp. 809-823, March 2012.
- [42] S. Geman and D. Geman, "Stochastic Relaxation, Gibbs Distributions, and the Bayesian Restoration of Images," in IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. PAMI-6, no. 6, pp. 721-741, Nov. 1984.
- [43] T. Celik, "Change detection in satellite images using a genetic algorithm approach," IEEE Geoscience and Remote Sensing Letters, vol. 7, pp. 386-390, 2010.