



سنجش از دور

GIS ایران



سنجش از دور و GIS ایران  
Iranian Remote Sensing & GIS

سال نهم، شماره دوم، تابستان ۱۳۹۶  
Vol.9, No. 2, Summer 2017

۴۰-۲۱

## بهبود الگوریتم میدان تصادفی مارکوف با هدف آشکارسازی نظارت نشده تغییرات تصاویر SAR چندکاناله

سارا صالحی<sup>۱</sup>، محمدجواد ولدان زوج<sup>۲</sup>، محمودرضا صاحبی<sup>۳\*</sup>

۱. کارشناس ارشد مهندسی فتوگرامتری و سنجش از دور، دانشگاه صنعتی خواجه نصیرالدین طوسی

۲. استاد گروه سنجش از دور و فتوگرامتری، دانشگاه صنعتی خواجه نصیرالدین طوسی

۳. دانشیار گروه سنجش از دور و فتوگرامتری، دانشگاه صنعتی خواجه نصیرالدین طوسی

تاریخ پذیرش مقاله: ۱۳۹۶/۶/۲۷

تاریخ دریافت مقاله: ۱۳۹۵/۷/۷

### چکیده

استفاده از داده‌های چندکاناله<sup>۱</sup> سنجنده‌های رادار با روزه مجازی (SAR)<sup>۲</sup>، به دلیل مستقل بودن از شرایط جوی و نور خورشید و نیز دارا بودن قابلیت بالا در استخراج تغییرات، در مقایسه با حالت تک کاناله، در کاربردهای متفاوتی مانند نظارت بر محیط زیست و مدیریت بلایای طبیعی بسیار توجیه پذیر است. با این حال، بهره‌برداری از این قابلیت‌ها به استفاده از روش‌های دقیق و اتوماتیک برای تولید نقشه‌های تغییرات از تصاویر اخذ شده از منطقه جغرافیایی یکسان، در پلاریزاسیون‌ها یا فرکانس‌های گوناگون مربوط به زمان‌های متفاوت، نیاز دارد. از سوی دیگر، حساسیت به بافت صحیح برای یک پیکسل می‌تواند به حذف خطاهای برجسته‌گذاری پیکسل‌های منفرد کمک کند و نقشه تغییرات را بهبود بخشد. حذف نویز لکه‌ای و ماهیت ایزوتروپیک مدل‌سازی میدان‌های تصادفی مارکوف موجب نرم شدن مرزهای مکانی بین مناطق تغییر یافته و تغییر نیافته در نقشه تغییرات نهایی می‌شود. به منظور حذف یا دست کم کاهش این اثر نامطلوب، استفاده از مدل مارکوف با هدف دخیل کردن اطلاعات لبه‌ها در فرایند برجسته‌گذاری پیشنهاد می‌شود. این روند دقت لبه‌ها در محل مرزهای مکانی را بهبود می‌بخشد و دقت آشکارسازی تغییرات را ارتقا می‌دهد. در این تحقیق، یک مدل مارکوف به منظور تشخیص نظارت نشده تغییرات، از طریق ترکیب اطلاعات موجود در هر یک از کانال‌های SAR، اطلاعات بافت مکانی و نیز اطلاعات لبه، معرفی شده و با استفاده از «توابع انرژی» فرموله شده است. به منظور برآورد پارامترهای مدل، الگوریتم بیشینه‌سازی امید ریاضی (EM)<sup>۳</sup> با روش مشتقات لگاریتمی (MoLC)<sup>۴</sup> ترکیب شده است. الگوریتم پیشنهادی با استفاده از تصاویر ASAR-ENVISAT به روش شبه‌سازی ارزیابی شده است. براساس نتایج، روش پیشنهادی دقت کلی را، در مقایسه با روش‌های موجود آشکارسازی تغییرات (با میانگین ۱۲٪)، افزایش داده و قابلیت شناسایی هر سه نوع تغییرات (اندک-متوسط-زیاد) را داراست. این در حالی است که، با در نظر گرفتن اطلاعات باندها و بافت مکانی، قدرت شناسایی تغییرات اندک و متوسط بسیار پایین برآورد شده است. همچنین، با توجه به تعداد دفعات تکرار پایین، زمان اجرای الگوریتم بسیار کاهش یافته است. به طور کلی، بیشترین دقت الگوریتم، براساس روش پیشنهادی، ۹۹/۶۷٪ برآورد شد.

کلیدواژه‌ها: میدان‌های تصادفی مارکوف، اطلاعات بافت مکانی، اطلاعات لبه، سنجنده‌های رادار با گشودگی مصنوعی، مینیمم‌سازی انرژی.

1. multichannel
2. synthetic aperture radar
3. Expectation-Maximization Algorithm
4. Method of Log-Cumulants

\* نویسنده عهده‌دار مکاتبات: گروه مهندسی سنجش از دور و فتوگرامتری، دانشکده مهندسی نقشه‌برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، خیابان ولی عصر، تقاطع میرداماد، کدپستی ۱۵۴۳۳-۱۹۹۶۷، تلفن: ۰۲۱۸ ۸۸۷۷ (۲۱ ۹۸+).

## ۱- مقدمه

در سال‌های اخیر، تصاویر چندزمانه<sup>۱</sup> دریافتی از طریق سنجنده‌های رادار با روزه مجازی (SAR)، به دلیل مستقل بودن از شرایط جوی و نور خورشید و نیز دارا بودن داده‌های با قدرت تفکیک مکانی بالا (تا ۱ متر) و امکان مشاهده دوباره در بازه زمانی کوتاه (تا ۱۲ ساعت)، به منظور آشکارسازی تغییرات و به قصد پایش محیط و مدیریت بحران، بیش از تصاویر نوری مورد توجه قرار گرفته‌اند (Fransson et al., 2002; Moser and Serpico, 2010). با وجود این، در بیشتر موارد، SAR فقط امکان یک مشاهده دامنه/ شدت را فراهم می‌آورد و در تمیزدادن مناطق تغییر یافته و بدون تغییر ضعیف عمل می‌کند. بنابراین، انتظار می‌رود در SAR چندکاناله (چندپلاریزاسیونه/ چندفرکانسه)، در مقایسه با SAR تک‌کانال، قابلیت تمیزدادن تفاوت‌ها با حفظ ویژگی نداشتن حساسیت به شرایط جوی و نور خورشید افزایش یابد. گستره وسیعی از روش‌های آشکارسازی تغییرات تصاویر SAR از طبقه‌بندی پیکسل پایه<sup>۲</sup> استفاده می‌کنند. در روش‌های پیکسل پایه، توزیع احتمالات معرف تغییر یا ثبات، با یکدیگر هم‌پوشانی چشمگیری دارند و در نتیجه، نتایج حاصل از آشکارسازی تغییرات نویز بسیار زیادی دارد و تعیین دقیق مرزهای تغییرات دشوار خواهد بود (Vaccaro et al., 2000). یک راهکار ممکن برای غلبه بر این مشکل دخیل کردن قیود همگن بودن (قیود بافت مکانی)، به صورت محلی، در مدل است (Aanæs et al., 2009). این قیود در تفسیر تصاویر بسیار مهم‌اند و از ویژگی‌های طیفی، مکانی و زمانی قابل استخراج محسوب می‌شوند (Solberg et al., 1996; Tso and Mather, 2001). این اطلاعات نتایج طبقه‌بندی بهتری تولید می‌کند، از ابهام اطلاعات می‌کاهد و اطلاعات از دست‌رفته را بازیابی می‌کند (Bruzzone and Prieto, 2000). یکی از مدل‌های کاربردی، برای دخیل کردن این قیود، میدان‌های تصادفی مارکوف (MRF)<sup>۳</sup> است. این میدان‌ها، طی فرایندی تکرار شونده، اطلاعات مکانی

و دارای چند منبع را، با کمینه کردن توابع انرژی مناسب، مدل‌سازی می‌کنند (Aanæs et al., 2009; Li, 2007; Liming et al., 2009). این مدل‌ها، از مدت‌ها پیش، برای کاربردهای سطح پایین همچون فیلترینگ، قطعه‌بندی، طبقه‌بندی، حل مشکلات ترمیم تصاویر و بازسازی آن‌ها مورد استفاده گسترده قرار گرفته‌اند (Jackson and Landgrebe, 2002; Solberg et al., 1996; Besag, 1974; Geman and Geman, 1984). یکی از کاربردهای سطح بالای میدان‌های تصادفی مارکوف اعمال آن‌ها روی گراف‌های مربوط به نواحی، به منظور تفسیر کلی تصاویر SAR، محسوب می‌شود. به دلیل توانایی MRF در استخراج اطلاعات بافت مکانی در فرایند طبقه‌بندی، پیش از به کار بستن این روش، نیازی به حذف نویز نقطه‌ای نیست و این مدل‌ها، به‌ازای تصاویر SAR چندزمانه<sup>۳</sup> بسیار نویزی نیز، ثبات<sup>۴</sup> بالایی دارند (Moser and Serpico, 2009). با این حال، مطالعات انجام‌شده<sup>۴</sup> پیشین نشان داده است که مرزهای مکانی بین مناطق تغییر یافته و تغییر نیافته در نقشه تغییرات تولید شده<sup>۴</sup> نهایی، به دلیل اثر نرم‌کنندگی حذف نویز لکه‌ای و نیز فرمول‌بندی ایزوتروپیک مدل‌های مارکوف، بیش از اندازه نرم می‌شوند (Angiati et al., 2010). از دیگر سو، زمانی که موقعیت پیکسل‌ها از لحاظ مکانی (در صفحه<sup>۴</sup> x-y) گسسته‌سازی<sup>۴</sup> شدند، مقادیر پیکسل‌ها نویزی می‌شود. این نکته سبب ایجاد اشکال در تعیین دقیق مرزهای مکانی بین مناطق تغییر یافته و تغییر نیافته می‌شود و به بروز مشکلاتی در زمینه تشخیص لبه می‌انجامد (Li, 2009). به منظور حذف یا دست‌کم کاهش این اثر نامطلوب، استفاده از مدل مارکوف در راستای احیای لبه‌ها پیشنهاد می‌شود. این روند موجب بهبود دقت لبه در محل مرزهای مکانی می‌شود و دقت آشکارسازی تغییرات را ارتقا می‌دهد.

1. pixel-wise classification
2. Markov random fields
3. robust
4. quantization

پیاده‌سازی الگوریتم بیان شده است. در نهایت، در بخش ۴، دستاوردهای تحقیق بررسی و نتیجه‌گیری می‌شود.

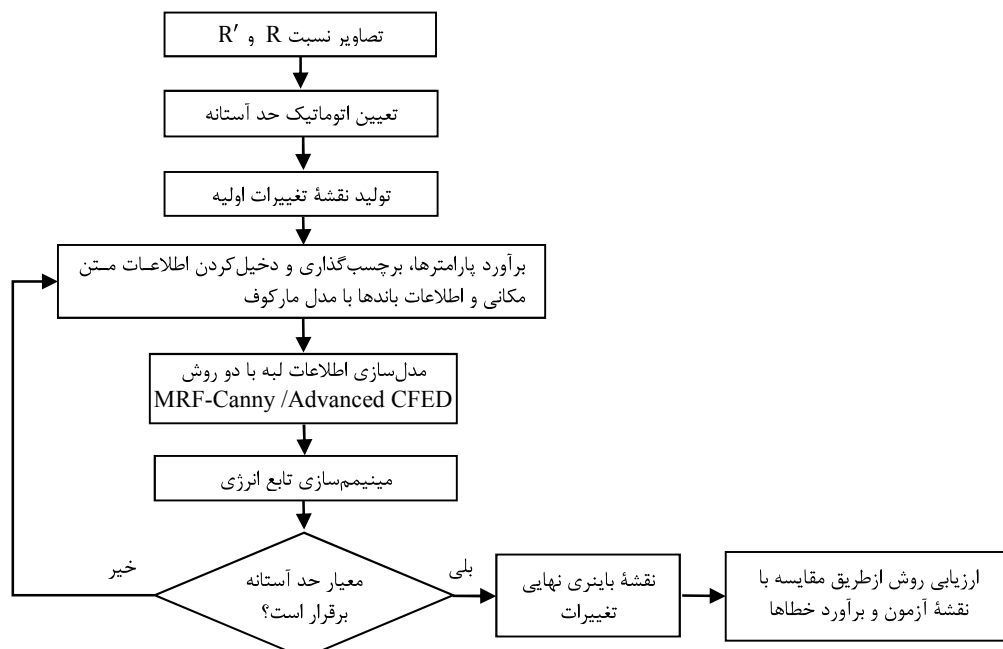
## ۲- متدولوژی

روش پیشنهادی طی روندی دومرحله‌ای پیاده‌سازی شده است. در مرحله نخست، اطلاعات لبه با استفاده از الگوریتم توسعه‌داده‌شده CFED و Canny استخراج شده است. خروجی این مرحله نقشه‌ای باینری (پیکسل‌های لبه/ غیرلبه) است. اطلاعات لبه، در مرحله دوم، با تعریف پارامتری جدید ( $n$ ) در مدل‌سازی مارکوف دخیل شده و میزان تأثیر این اطلاعات در فرایند برجسبدهی با ضریب اعتمادپذیری ( $\gamma$ ) تعیین شده است. همچنین، اطلاعات مربوط به پیکسل‌های همسایه و اطلاعات موجود در پلاریزاسیون‌های گوناگون تصاویر SAR، به منزله دو منبع اطلاعاتی دیگر، طی فرایند برجسبگذاری استفاده شده‌اند.

شکل ۱ روند پیشنهادی برای تهیه نقشه نهایی تغییرات با استفاده از تلفیق اطلاعات لبه، اطلاعات متن مکانی و اطلاعات موجود در دو پلاریزاسیون متفاوت را ارائه می‌دهد.

در این تحقیق، برای برجسبدهی به پیکسل‌ها، به اطلاعات تک‌پیکسل اکتفا نشده و با استفاده از مدل‌سازی مارکوف، اطلاعات پیکسل‌های همسایه (اطلاعات بافت مکانی) نیز مدنظر قرار می‌گیرند. اطلاعات موجود در باندهای مجزا منبع اطلاعاتی دیگری است که در این تحقیق به کار رفته است. همچنین به‌منظور تشخیص لبه‌ها، از الگوریتم شناخته‌شده Canny و طبقه‌بندی‌کننده فازی ویژه‌ای، با عنوان الگوریتم فازی رقابتی تشخیص لبه (CFED)<sup>۱</sup> که به آموزش نیاز ندارد، استفاده شده است. پس از آن، اطلاعات لبه از طریق مدل میدان‌های تصادفی مارکوف پیشنهادی در روند تشخیص تغییرات دخیل شده‌اند.


در بخش ۲، الگوریتم فازی رقابتی تشخیص لبه و مفاهیم مورد استفاده برای پیاده‌سازی آن تشریح می‌شود. در ادامه، روش احیای لبه‌ها و تلفیق آن با اطلاعات باندهای گوناگون و اطلاعات متن مکانی، از طریق مدل‌سازی مارکوف، بحث و بررسی خواهد شد. در بخش ۳، منطقه مورد مطالعه، داده‌های مورد استفاده و شیوه ارزیابی دقت الگوریتم معرفی شده و نتایج



شکل ۱. روند کلی تهیه نقشه نهایی تغییرات با استفاده از تلفیق اطلاعات لبه، متن مکانی و اطلاعات موجود در دو پلاریزاسیون متفاوت

### 1. competitive fuzzy edge detection

برای هر کلاس، یک بردار ویژگی چهاربعدی  $x = (d_1, d_2, d_3, d_4)$  در همسایگی  $3 \times 3$  هر پیکسل، غیرواقع در مرزهای بیرونی تصویر، بر مبنای حاصل جمع مقدار اختلاف شدت روشنایی در چهار جهت  $d_j$  ( $j=1, 2, 3, 4$ ) مطابق شکل ۳ و روابط (۱) محاسبه می‌شود.



شکل ۳. پیکسل‌ها و جهات در یک همسایگی  $3 \times 3$  (Liang and Looney, 2003)

رابطه (۱)

$$\begin{aligned} d_1 &= |P_1 - P_5| + |P_9 - P_5| && \text{جهت ۱} \\ d_2 &= |P_2 - P_5| + |P_8 - P_5| && \text{جهت ۲} \\ d_3 &= |P_3 - P_5| + |P_7 - P_5| && \text{جهت ۳} \\ d_4 &= |P_4 - P_5| + |P_6 - P_5| && \text{جهت ۴} \end{aligned}$$


شش بردار نمونه اولیه  $c_0, \dots, c_5$  را به‌منزله مراکز مربوط به شش کلاس در نظر می‌گیریم (جدول ۱). این مراکز (نمونه‌های اولیه) مقادیر "lo" و "hi" را، که نشان‌دهنده مقادیر  $d_j$  کم و زیاد در جهات جهت

## ۲-۱- توسعه الگوریتم CFED به منظور تشخیص لبه‌های تصویر SAR

طبقه‌بندی‌کننده فازی مورد استفاده در این تحقیق، بر اساس تنوع شدت روشنایی در جهات متفاوت و محاسبه بردار ویژگی، کلاس پیکسل‌های تصویر را مشخص می‌کند. پس از طبقه‌بندی و تعیین توابع عضویت، قوانین رقابتی برای نازک کردن لبه‌ها اجرا می‌شود. در نهایت، پیکسل‌های نویزی منفرد یا دوتایی حذف می‌شوند. روند کلی این الگوریتم مشابه مدل لیانگ و لونی<sup>۱</sup> (۲۰۰۳) است؛ با این تفاوت که در این تحقیق تصاویر SAR چندکاناله جایگزین تصاویر نوری شده و مدل برای تصاویر SAR توسعه یافته است. همچنین، به‌هدف برآورد میزان کارایی روش پیشنهادی برای استخراج اطلاعات لبه، از مقایسه آن با روش شناخته‌شده Canny استفاده شده است.

### • کلاس‌های پیکسل‌های تصویر

الگوریتم Advanced CFED پیکسل‌ها را به چهار کلاس لبه‌متمايز، یک کلاس پس‌زمینه و یک کلاس لبه‌لکه‌ای دسته‌بندی می‌کند. چهار موقعیت همسایگی معمولی برای هر کلاس لبه استفاده می‌شود: هر همسایگی لبه جهت‌دار نشان‌دهنده در شکل (۲ الف) چرخش  $180^\circ$  آن (۲-ج) و اختلاف پیکسل‌های تیره‌تر و روشن‌تر در هریک از این دو مورد (۲-ب و د).



شکل ۲. کلاس‌های لبه: (الف) کلاس ۱؛ (ب) کلاس ۲؛ (ج) کلاس ۳؛ (د) کلاس ۴

• توابع عضویت مجموعه فازی (FSMFs)<sup>1</sup>

توابع عضویت، برای هر بردار ویژگی  $x$  و به ازای هر کلاس در فضای ویژگی چهاربعدی، با توسعه توابع Epanechnikov محاسبه می‌شوند (Looney, 2001) (رابطه (۲)).

$$\mu_i(x) = \max \left\{ 0, \frac{1 - \|x - c_i\|^2}{w^2} \right\} \quad \text{رابطه (۲)}$$

در این رابطه،  $i$  معادل شماره کلاس است ( $i=0, 1, \dots, 5$ ). به ازای ( $i=0$ ) پیکسل متعلق به کلاس پس‌زمینه، به ازای ( $i=5$ ) پیکسل متعلق به کلاس لبه نقطه‌ای و به ازای ( $i=1, 2, 3, 4$ ) پیکسل متعلق به کلاس لبه متمایز است. پارامتر عرض  $w$  شعاع این FSMFs است. کیفیت تشخیص لبه با توجه به پارامترهای  $w$  و  $lo$ ,  $hi$  تعریف می‌شود. در عمل، این توابع با یکدیگر هم‌پوشانی دارند؛ به نحوی که هر بردار ویژگی ورودی، در یک یا چند تابع عضویت، صدق می‌کند.


در ابتدا، الگوریتم Advanced CFED تمامی پیکسل‌های داخلی غیرواقع در مرز تصویر را به یکی از کلاس‌های ۰ تا ۵ نسبت می‌دهد. طبقه‌بندی برای هر پیکسل، با قراردادن بردار ویژگی  $x = (d_1, d_2, d_3, d_4)$  در هریک از شش تابع توسعه‌یافته Epanechnikov انجام می‌گیرد. در نهایت، بزرگ‌ترین تابع عضویت معرف کلاس بهینه پیکسل خواهد بود. پیش از اینکه یک پیکسل لبه در تصویر خروجی با یکی از دو رنگ سفید

یادشده‌اند، اختیار می‌کنند. پارامترهای  $lo$  و  $hi$  را کاربر تنظیم می‌کند و به کنتراست نواحی تصویر و حساسیت مورد نظر ارتباط دارند. برای نمونه، می‌توان  $lo$  را به اختلاف درجه خاکستری نزدیک به ۰ نسبت داد و  $hi$  می‌تواند مقادیر نزدیک به ۱ را اختیار کند.

جدول ۱. کلاس‌ها و بردارهای نمونه اولیه آن‌ها

$c_0=(lo, lo, lo, lo)$	کلاس ۰ (پس‌زمینه)
$c_1=(lo, hi, hi, hi)$	کلاس ۱ (لبه)
$c_2=(hi, lo, hi, hi)$	کلاس ۲ (لبه)
$c_3=(hi, hi, lo, hi)$	کلاس ۳ (لبه)
$c_4=(hi, hi, hi, lo)$	کلاس ۴ (لبه)
$c_5=(hi, hi, hi, hi)$	کلاس ۵ (لبه نقطه‌ای)

کلاس پس‌زمینه مربوط به پیکسلی است که همسایگی‌هایش، در چهار جهت، اختلاف مقادیر اندکی دارند و کلاس لبه‌لکه‌ای به پیکسلی مربوط می‌شود که همسایگی‌هایش، در چهار جهت، دارای اختلاف مقادیر زیادند. همسایگی‌های دیگر، مانند آن‌هایی که در شکل ۴ نشان داده شده است، ممکن است نشان‌دهنده این باشند که پیکسل مرکزی پیکسل لبه محسوب می‌شود یا در کنار پیکسل لبه قرار دارد. در بخش‌های (الف) و (ب)، پیکسل  $P_5$  متعلق به کلاس لبه‌لکه‌ای است اما، در ابتدا، لبه در نظر گرفته شده است. قسمت‌های (ج) و (د) همسایگی‌های لبه‌های منظم را نمایش می‌دهند.



شکل ۴. دیگر همسایگی‌ها: (الف) کلاس لبه نقطه‌ای؛ (ب) کلاس لبه نقطه‌ای؛ (ج) کلاس لبه منظم؛ (د) کلاس لبه منظم

1. fuzzy set membership function

اگر برنده شد، آن گاه آن را به سفید تغییر بده (لبه)؛ در غیر این صورت، به رنگ سیاه تغییر بده.

- اگر  $x$  کلاس ۴ است (لبه)، آن گاه  $d_2$  را با پیکسل‌های همسایه در جهت ۲ رقابت بده؛

اگر برنده شد، آن گاه آن را به سفید تغییر بده (لبه)؛ در غیر این صورت، به رنگ سیاه تغییر بده.

- اگر  $x$  کلاس ۵ است (لبه نقطه‌ای)، آن گاه پیکسل را به سفید تغییر بده (لبه).

برای این سه پیکسل، تنها پیکسلی که بزرگ‌ترین مقدار  $d_j$  را دارد با عنوان لبه سفید ثبت می‌شود و دو پیکسل دیگر، به منزلهٔ پس‌زمینه، سیاه می‌شوند. در مرحلهٔ بعد با شمارش پیکسل‌های لبه در همسایگی  $3 \times 3$  و  $5 \times 5$ ، پیکسل‌های لبه‌دوتایی یا منفرد حذف و لبه‌ها نازک می‌شوند (شکل ۵).

یا سیاه تصویر شود، با دو پیکسل لبهٔ واقع در دو سمت خود، در راستای عرض لبه، رقابت می‌کند. این قوانین رقابتی بدین شرح‌اند:

- اگر  $x$  کلاس ۰ است (پس‌زمینه)، آن گاه پیکسل را به سیاه تغییر بده.

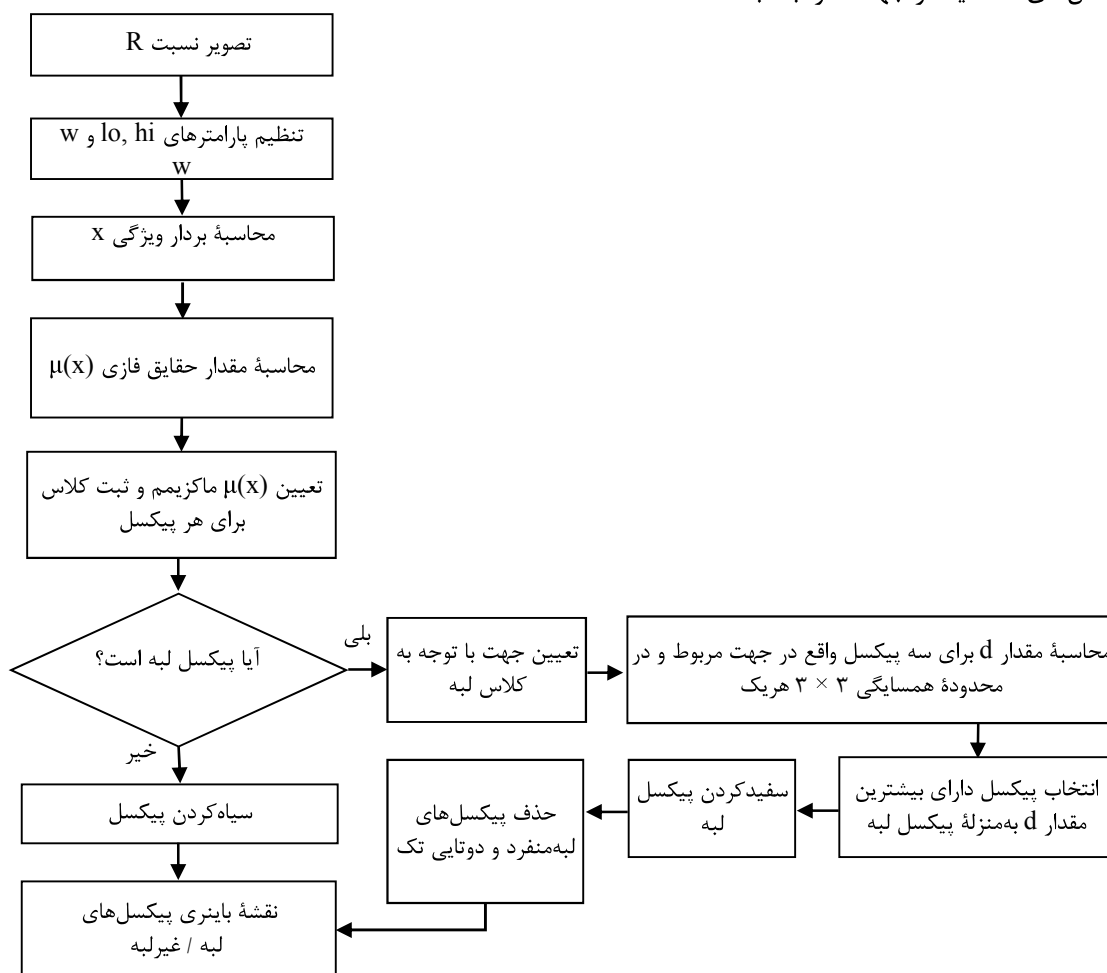
- اگر  $x$  کلاس ۱ است (لبه)، آن گاه  $d_3$  را با پیکسل‌های همسایه در جهت ۳ رقابت بده؛

اگر برنده شد، آن گاه آن را به سفید تغییر بده (لبه)؛ در غیر این صورت، به رنگ سیاه تغییر بده.

- اگر  $x$  کلاس ۲ است (لبه)، آن گاه  $d_4$  را با پیکسل‌های همسایه در جهت ۴ رقابت بده؛

اگر برنده شد، آن گاه آن را به سفید تغییر بده (لبه)؛ در غیر این صورت، به رنگ سیاه تغییر بده.

- اگر  $x$  کلاس ۳ است (لبه)، آن گاه  $d_1$  را با پیکسل‌های همسایه در جهت ۱ رقابت بده؛



شکل ۵. روند کلی الگوریتم Advanced CFED برای تهیهٔ نقشهٔ باینری پیکسل‌های لبه / غیر لبه

## ۲-۲ تلفیق اطلاعات با استفاده از مدل میدان

### تصادفی مارکوف پیشنهادی

در این تحقیق، آشکارسازی تغییرات را به صورت یک مسئله آزمون فرضیه دودویی در نظر می‌گیریم.  $H_0$  و  $H_1$ ، به ترتیب، بر دو فرضیه «تغییر» و «عدم تغییر» دلالت دارند و  $L_0$  و  $L_1$  نمایانگر دو تصویر دامنه هم‌مرجع شده متشکل از  $n$  کانال، دریافت از منطقه جغرافیایی یکسان، در دو زمان  $T_0$  و  $T_1$  ( $T_1 > T_0$ )، هستند. تصویر نسبت  $R$  از تقسیم دامنه‌های  $L_0$  به  $L_1$  به دست می‌آید و  $n$  کانال دارد (Dierking and Skriver, 2002). به صورت مجموعه‌ای  $\{U_1, U_2, \dots, U_N\}$  متشکل از  $n$  بردار تصادفی به صورت همسان توزیع شده، تعریف می‌شود ( $N$  تعداد پیکسل‌هاست). با توجه به تغییرات زمین در فاصله زمانی  $T_0$  و  $T_1$ ، می‌توان از تصویر نسبت  $R$  برای تشخیص «کاهش» دامنه‌های تصویر  $n$  کاناله SAR استفاده کرد. در صورتی که تغییرات زمین معادل «افزایش» دامنه‌های SAR باشد، می‌توان  $R$  را از طریق تقسیم (پیکسل به پیکسل و کانال به کانال) دامنه‌های  $L_1$  به  $L_0$  تعریف کرد. در صورت وجود هر دو نوع «افزایش» و «کاهش» در دامنه‌های SAR، می‌توان از دو فرمولاسیون جداگانه برای تصویر نسبت چندکاناله استفاده کرد (Moser and Serpico, 2006). همچنین، می‌توان با محاسبه پیکسل به پیکسل و باند به باند مقدار کمینه دو نسبت یادشده، این دو فرمولاسیون را ترکیب و آن را به یک «تصویر نسبت نرمال شده» تبدیل کرد (Bujor et al., 2004). شایان ذکر است که  $L_0$  و  $L_1$  باید از طریق سنجنده‌ای، با تنظیمات مشابه، دریافت شده باشند تا تفاوت بین مقادیر پیکسل‌ها در تصویر نسبت ناشی از اختلاف در فرایند دریافت تصاویر در دو زمان مشاهداتی نباشد.

در تحقیق حاضر، افزون بر اطلاعات موجود در هر کانال  $R$ ، اطلاعات مربوط به لبه‌ها نیز به منزله منبع اطلاعاتی جداگانه، با استفاده از پارامتر  $n$  و ضریب اعتمادپذیری ( $\gamma$ )، مدل سازی شده و الگوریتم مارکوف تلفیق داده‌های این منابع اطلاعاتی گوناگون را

امکان پذیر ساخته است. با توجه به قضیه هامرزل و کلیفورد<sup>۱</sup> (Geman and Geman, 1984)، می‌توان به جای قاعده تصمیم‌گیری «بیشینه خلفی»<sup>۲</sup>، از مینیمم سازی یک تابع انرژی محلی استفاده کرد (رابطه (۳)) (Dubes and Jain, 1989). با در نظر گرفتن  $\{H_0, H_1\}$  به منزله برچسب احتمالی  $k$  امین پیکسل ( $k=1, 2, \dots, N$ )، فرض می‌شود عناصر  $\{I_1, I_2, \dots, I_N\}$  یک MRF باشند (Dubes and Jain, 1989).

رابطه (۳)

$$P\{I_k = H_i | u_k, C_k\} = \frac{\exp[-U(H_i | u_k, C_k)]}{\sum_{j=0}^1 \exp[-U(H_j | u_k, C_k)]}$$

$C_k$  مجموعه‌ای از برچسب‌های همسایگی  $k$  امین پیکسل (اطلاعات بافت مکانی و لبه‌ها) و  $U(H_i | u_k, C_k)$  «تابع انرژی» مدل MRF محسوب می‌شود ( $k=1, 2, \dots, N$ ;  $i=0, 1$ ). با هدف تلفیق داده‌ها بر اساس رویکرد مبتنی بر MRF، این تابع انرژی به صورت ترکیبی خطی از سهم انرژی‌های مربوط به منابع اطلاعاتی گوناگون بیان می‌شود (رابطه (۴)). انرژی مربوط به اطلاعات بافت مکانی با استفاده از تابع چگالی احتمال (pdf)<sup>۳</sup> تک‌متغیره (مشروط به «تغییر» و «بدون تغییر») و اطلاعات موجود در هر یک از کانال‌های تصویر به نسبت صورت یک مدل ایزوتروپیک پاتس درجه دو<sup>۴</sup> فرموله شده است (Dubes and Jain, 1989; Solberg et al., 1996). اطلاعات مربوط به لبه‌ها به صورت ترکیبی خطی از برچسب‌های «لبه» و «غیرلبه» محاسبه می‌شوند.

رابطه (۴)

$$U(H_i | u_k, C_k, \theta) = \sum_{r=1}^n \alpha_r [-\ln p_{ir}(u_{kr} | \xi_{ir})] - \beta m_{ik} - \gamma n_{ik}$$

1. Hammersley-Clifford
2. maximum a posteriori
3. probability density function
4. second-order isotropic Potts model

توزیع NR برای  $u_{kr}$  مشروط به

$$(\xi_{ir} = (L_{ir}, \gamma_{ir}), L_{ir}, \gamma_{ir} > 0) H_i$$

رابطه (۶)

$$p_{ir}(u_{kr} | \xi_{ir}) = \frac{2\Gamma(2L_{ir})}{\Gamma^2(L_{ir})} \frac{\gamma_{ir}^{L_{ir}} u_{kr}^{2L_{ir}-1}}{(\gamma_{ir} + u_{kr}^2)^{2L_{ir}}},$$

$$u_{kr} > 0$$

$\Gamma(\cdot)$  تابع گامای رایج است.

توزیع WR برای  $u_{kr}$  مشروط به

$$(\xi_{ir} = (\eta_{ir}, \lambda_{ir}), \eta_{ir}, \lambda_{ir} > 0) H_i$$

رابطه (۷)

$$p_{ir}(u_{kr} | \xi_{ir}) = \eta_{ir} \lambda_{ir}^{\eta_{ir}} \frac{u_{kr}^{\eta_{ir}-1}}{(\lambda_{ir}^{\eta_{ir}} + u_{kr}^{\eta_{ir}})^2},$$

$$u_{kr} > 0$$

#### • تخمین پارامترهای مدل مارکوف

روش پیشنهادی، در این تحقیق، با مبنای قرار دادن مدل‌های MRF (۳) و (۴) و مینیما سازی تابع انرژی مربوط، نقشه تغییرات را تولید می‌کند. برآورد پارامترها و طبقه‌بندی نیازمند تعریف استراتژی‌های مناسب است. در این زمینه، از تلفیق دو روش LJ-EM<sup>۴</sup> و MoLC<sup>۵</sup> استفاده شده است.

LJ-EM تکنیکی تکرارشونده برای برآورد پارامترهاست. این روش برای تخمین شباهت حداکثر (ML)<sup>۶</sup>، به منظور حل مشکلات مربوط به داده‌های ناقص، به کار می‌رود (Jackson and Landgrebe, 2001). استفاده از LJ-EM برای مدل MRF، که با روابط (۳) و (۴) تعریف شده است، دو محدودیت دارد. نخست اینکه ترکیب الگوریتم‌های نوع EM و مدل‌های متنی تصویر نیازمند حجم زیادی از محاسبات است (Celeux et al., 2003). برای غلبه بر این مشکل، از روشی میان‌حوزه‌ای<sup>۷</sup> بر مبنای تخمین

$p_{ir}(\cdot | \xi_{ir})$  مدلی پارامتریک برای pdf مربوط به  $r$

آمین نسبت دامنه  $u_{kr}$  (مشروط به  $H_i$ ) است.  $\xi_{ir}$  بردار پارامترهای این pdf،  $m_{ik}$  و  $n_{ik}$  تعداد برجسب‌های معادل با  $H_i$  در همسایگی  $k$  آمین پیکسل (به ترتیب، مربوط به اطلاعات بافت مکانی و اطلاعات لبه) به شمار می‌روند. قابلیت اعتمادپذیری هر یک از کانال‌های تصویر با ضرایب  $\alpha_1, \alpha_2, \dots, \alpha_n$  تعیین می‌شود. همچنین، میزان تأثیر اطلاعات بافت مکانی (اطلاعات پیکسل‌های همسایه) و اطلاعات لبه از طریق ضرایب  $\beta$  و  $\gamma$  مشخص شده است.

$$\theta = (\gamma, \beta, \alpha_1, \alpha_2, \dots, \alpha_n, \xi_{01}, \xi_{11}, \xi_{02}, \xi_{12}, \dots, \xi_{0n}, \xi_{1n})$$

برداری شامل پارامترهای مدل است که باید تخمین زده شوند. با توجه به قاعده تصمیم‌گیری مینیما سازی تابع انرژی مذکور، سهم انرژی مکانی ( $-m_{ik}$ ) منجر به ایجاد مناطق همگن می‌شود و در نتیجه، تأثیر ناشی از نویز نقطه‌ای در نتایج طبقه‌بندی کاهش می‌یابد. همچنین، با تعریف انرژی جدید  $(-\gamma n_{ik})$ ، اطلاعات لبه نیز هنگام برجسب‌دهی به هر پیکسل در نظر گرفته شده و به کاهش خطا در محل مرزهای مکانی بین مناطق تغییر یافته و بدون تغییر انجامیده است. دخیل کردن این اطلاعات، در مدل سازی مارکوف، مستلزم استفاده از مدل‌های پارامتریک دقیق برای توصیف توزیع حاشیه‌ای هر عنصر  $u_{k1}, u_{k2}, \dots, u_{kn}$  مشروط به  $(k=1, 2, \dots, N; r=1, 2, \dots, n; i=1, 2, H_i)$  به منظور تخمین پارامترهاست (روابط (۵)، (۶)، (۷)). برای نمونه، می‌توان به مدل‌های لگاریتم-نرمال (LN)<sup>۱</sup>، نسبت ناکاگامی (NR)<sup>۲</sup> و نسبت ویبول (WR)<sup>۳</sup> اشاره کرد (Moser and Serpico, 2006).

توزیع LN برای  $u_{kr}$  مشروط به

$$(\xi_{ir} = (\mu_{ir}, \sigma_{ir}), \mu_{ir} \in R, \sigma_{ir} > 0) H_i$$

رابطه (۵)

$$p_{ir}(u_{kr} | \xi_{ir}) = \frac{1}{\sigma_{ir} u_{kr} \sqrt{2\pi}} \exp \left[ -\frac{(\ln u_{kr} - \mu_{ir})^2}{2\sigma_{ir}^2} \right],$$

$$u_{kr} > 0$$

1. log-normal
2. Nakagami-ratio
3. Weibull-ratio
4. expectation maximization algorithm with semilabeled samples developed by Landgrebe and Jackson
5. method of log-cumulants
6. maximum-likelihood



حد آستانه بهینه را برای تصویر تک کاناله نسبت دامنه (به منظور تمایز بین مناطق تغییر یافته و بدون تغییر) محاسبه می کند (Moser and Serpico, 2006). تابع  $J_r(\cdot)$  تابع معیار محاسبه شده برای کانال  $r$ ام در  $R$  است و حد آستانه بهینه از طریق  $\tau_r^* = \arg \min_{\tau} J_r(\tau)$  ( $r=1,2, \dots, n$ ) برآورد می شود. با در نظر گرفتن این مقدار و آستانه گذاری  $r$ امین کانال در  $R$ ، نقشه تغییرات  $M_r^*$  ( $r=1,2, \dots, n$ ) به دست آمده است.  $M_r^*$  مربوط به کوچک ترین مقدار بهینه تابع معیار  $J_r(\tau_r^*)$  ( $r=1,2, \dots, n$ ) به منزله نقشه تغییرات اولیه روش پیشنهادی تعریف می شود (Moser and Serpico, 2006). انتظار می رود این نقشه، با توجه به رابطه بین تابع معیار و احتمال خطا (Moser and Serpico, 2006)، انتخابی بهینه از میان نقشه های تک کاناله باشد. این نقشه به منظور مقداردهی اولیه  $C_k^0$  پیکسل  $k$ ام ( $k=1,2, \dots, N$ ) و برآورد ابتدایی پارامترهای pdf به کار می رود. با توجه به این نقشه، میانگین  $k_{1ir}^0$  به مثابه برآورد اولیه ای از  $k_{1ir}$  و واریانس  $k_{2ir}^0$  به منزله برآوردی ابتدایی از  $k_{2ir}$  در نظر گرفته شده است ( $r=1,2, \dots, n; i=1,2$ ). پس از آن، طی فرآیند تکرار، پارامترهای مدل بهینه سازی می شوند.

شایان ذکر است که، به دلیل توانایی میدان های تصادفی مارکوف در استخراج اطلاعات بافت مکانی طی فرآیند طبقه بندی، پیش از به کار بستن این روش، حذف نویز نقطه ای ضرورتی ندارد و الگوریتم، به ازای تصاویر SAR بسیار نویزی، نیز دارای ثبات بلایی است. با وجود این، اگر پیکسل های تغییر یافته و بدون تغییر را نتوان در نقشه های تغییرات اولیه به دست آمده از یکدیگر تمییز داد، اجرای عملیات مقداردهی اولیه به میدان تصادفی مارکوف امکان پذیر نخواهد بود. در چنین شرایطی، استفاده از میانگین نسبت های محلی  $\hat{C}_k^0$  (Touzi et al., 1988) یا حذف نویز لکه ای (Moser and Serpico, 2006) (دست کم در مرحله نخست مقداردهی) الزامی است.

تابع لگاریتمی استفاده می شود. این تخمین سبب کاهش شدید زمان محاسبات می شود و تعادل مناسبی بین زمان محاسبه و دقت طبقه بندی برقرار می کند (Celeux et al., 2003). دوم اینکه، هنگام استفاده از LJ-EM برای مدل های WR و NR، فرایند پیشینه سازی هیچ راهکار صریحی نخواهد داشت (Moser and Serpico, 2006). برای غلبه بر این مشکل از تلفیق LJ-EM و MoLC، که روشی جدید برای تخمین پارامترهاست، استفاده می شود (Nicolas, 2002). MoLC در زمینه تحلیل تصویر SAR کاربرد دارد. این روش برای بسیاری از مدل های خاص SAR، از لحاظ عددی، عملی و سریع است و خواص برآورد نظری خوبی در اختیار می گذارد (Nicolas, 2002). افزون بر این، مشخص شده است که با در نظر گرفتن  $k_{1ir} = E\{\ln u_{kr} | l_k = H_i\}$  و  $k_{2ir} = Var\{\ln u_{kr} | l_k = H_i\}$  واریانس لگاریتمی  $u_{kr}$  استفاده از آن برای تخمین پارامترهای توزیع LN، NR و WR عملی است (Moser and Serpico, 2006) (رابطه (۸)).

$$WR: \begin{cases} k_{1ir} = \ln \lambda_{ir} \\ k_{2ir} = 2\psi(1,1)\eta_{ir}^2 \end{cases} \quad \text{رابطه (۸)}$$

$$NR: \begin{cases} 2k_{1ir} = \ln \gamma_{ir} \\ 2k_{2ir} = \psi(1, L_{ir}) \end{cases}$$

$$LN: \begin{cases} k_{1ir} = \mu_{ir} \\ k_{2ir} = \sigma_{ir}^2 \end{cases}$$

$\psi(1, \cdot)$  تابع مرتبه اول پلی گاما (مشق دوم لگاریتمی  $\Gamma(\cdot)$ ) است (Sneddon, 1972).

#### • مقداردهی اولیه با الگوریتم GKIT

در این تحقیق، برای محاسبه نقشه تغییرات اولیه مربوط به توزیع پارامتریک مدنظر (LN، NR یا WR)، از تکنیک GKIT استفاده شده است که موزر و سرپیکو<sup>۲</sup> (۲۰۰۶) آن را مطرح کردند. GKIT با به حداقل رساندن «تابع معیار» مربوط به احتمال خطای طبقه بندی کننده باینری بیژین<sup>۳</sup>، به صورت خودکار،

1. Generalized Kittler and Illingworth
2. Moser and Serpico
3. Bayesian binary classifier
4. local mean ratios

## ۲-۳- روند ارزیابی دقت

برای ارزیابی الگوریتم، با در نظر گرفتن نقشه آزمون<sup>۱</sup>، نتایج هریک از نقشه‌های تغییرات به دست آمده نهایی از نظر کمی بررسی می‌شود. بدین منظور، دقت آشکارسازی<sup>۲</sup> (درصد به درستی طبقه‌بندی شدن پیکسل‌های آزمایش «تغییر یافته»)، نرخ هشدار اشتباه<sup>۳</sup> (درصد پیکسل‌های آزمایش «تغییر یافته» که به اشتباه با نام «تغییر یافته» طبقه‌بندی شده‌اند) و نرخ خطای کل<sup>۴</sup> (درصد پیکسل‌هایی که به اشتباه طبقه‌بندی شده‌اند) بدین صورت برآورد می‌شود (Moser and Serpico, 2009):

$$\text{Detection Accuracy} = (TP) / (\text{real change}) \quad (9)$$

$$\text{False Alarm Rate} = FN / (\text{real change})$$

$$\text{Overall Error Rate} = (FN + FP) / (\text{real change})$$

$TP$  تعداد پیکسل‌های تغییر یافته است که به درستی برچسب تغییر دریافت داشته‌اند.  $TN$  تعداد پیکسل‌های تغییر نیافته است که به درستی برچسب دهی شده‌اند.  $FN$  تعداد پیکسل‌های تغییر یافته است که، به اشتباه، پیکسل‌های تغییر نیافته در نظر گرفته شده‌اند.  $FP$  تعداد پیکسل‌های تغییر نیافته است که، به اشتباه، برچسب «تغییر یافته» دریافت کرده‌اند. تعیین تغییرات واقعی<sup>۵</sup> با استفاده از یک نقشه آزمون صورت می‌پذیرد.

## ۳- پیاده‌سازی و نتایج

روش پیشنهادی با استفاده از سه تابع چگالی احتمال  $LN$ ،  $NR$  و  $WR$  (روابط (۵)، (۶)، (۷)) پیاده‌سازی شده و نتایج حاصل از این سه تابع چگالی احتمال برای داده‌های نیمه شبیه‌سازی شده ارزیابی شده است. برای مقادیردهی اولیه، در تمامی حالات  $\alpha$ ،  $\beta$  و  $\gamma$  واحد در نظر گرفته شده و دقت نقشه‌های تغییرات، در سه حالت متفاوت، ارزیابی شده است:

- نقشه‌های تغییرات به دست آمده برای هریک از باندها (به صورت جداگانه) و استفاده از الگوریتم مقداردهی اولیه GKIT؛
- نقشه‌های تغییرات حاصل از تلفیق اطلاعات دو باند و در نظر گرفتن اطلاعات بافت مکانی؛

- نقشه‌های تغییرات حاصل، پس از دخیل کردن اطلاعات لبه، با استفاده از توسعه روش‌های آشکارسازی لبه CFED و Canny.

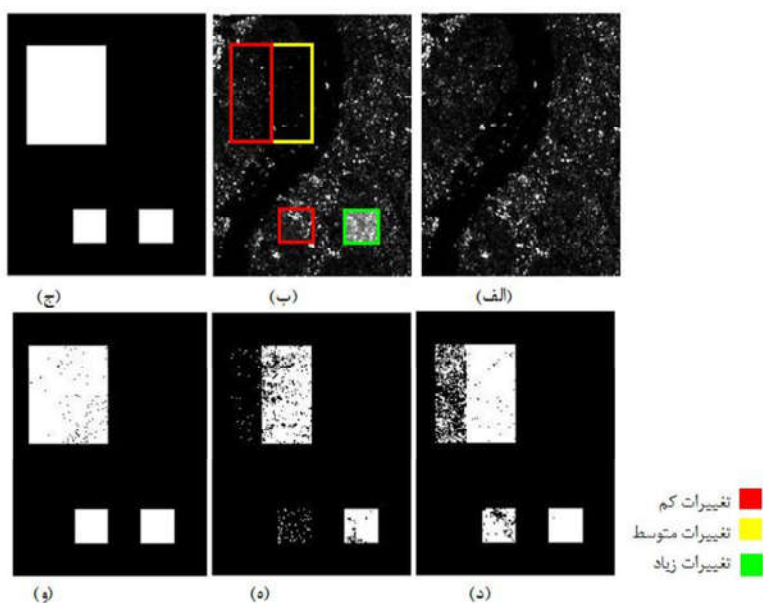
### ۳-۱- منطقه مورد مطالعه و داده‌های مورد نیاز

در تحقیق حاضر، از تصویر ماهواره‌ای ENVISAT اخذ شده از سنجنده ASAR، دارای دو پلاریزاسیون HH و HV، مربوط به سیل بانکوک در ۲۴ جولای ۲۰۱۱، استفاده شده است. منطقه مورد نظر در مختصات جغرافیایی ۱۰۰ درجه و ۳۲ دقیقه و ۲۶/۰۶ ثانیه طول مرکزی و ۱۳ درجه و ۴۶ دقیقه و ۵۱/۶ ثانیه عرض مرکزی واقع شده و ابعاد تصویر ۳۰۰×۴۰۰ پیکسل انتخاب شده است. روش پیشنهادی با مجموعه داده‌های نیمه شبیه‌سازی شده ارزیابی شده است. تغییرات با تغییر دادن تصادفی مقادیر دامنه در چهار ناحیه از تصویر اولیه (به صورت تغییرات اندک، متوسط و زیاد) شبیه‌سازی شده و تصویر دوم ایجاد شده است. با توجه به اینکه تغییرات شبیه‌سازی شده‌اند، نقشه آزمون برای این مجموعه داده را می‌توان برآورد کرد. به عبارت دیگر، با آگاهی از اینکه نواحی تغییر در چه بازه‌ای واقع شده‌اند، می‌توان نقشه‌ای باینری، شامل اطلاعات پیکسل‌های تغییر یافته و بدون تغییر، ایجاد کرد و آن را برای ارزیابی دقت الگوریتم به کار برد. نقشه آزمون مورد استفاده در این تحقیق شامل ۴۷۳ ۲۳ پیکسل تغییر یافته و ۵۲۷ ۹۶ پیکسل بدون تغییر است. از آنجاکه روش مورد استفاده نظارت نشده است، نقشه آزمون فقط برای برآورد دقت نقشه‌های تغییرات حاصل شده به کار می‌رود.


1. test map
2. detection accuracy
3. false alarm rate
4. overall error rate
5. real change

۳-۲- نتایج تجربی آشکارسازی تغییرات برای حالت تک‌باند (پلاریزاسیون HH و HV) در ابتدا، حد آستانهٔ بهینه مطابق با روش GKIT، برای هریک از پلاریزاسیون‌ها، انتخاب شده است. با استفاده

از این حد آستانه، آشکارسازی تغییرات برای دو پلاریزاسیون HH و HV و با استفاده از مدل‌های LN، NR و WR (روابط (۵)، (۶)، (۷)) انجام شده است (شکل‌های ۶ و ۷).



شکل ۶. (الف) تصویر ماهواره‌ای ASAR-HH، ۲۴ جولای سال ۲۰۱۱؛ (ب) تصویر ماهواره‌ای نیمه‌شبیه‌سازی شده در تاریخ دوم؛ (ج) نقشهٔ آزمون؛ (د) نقشه‌های تغییرات حاصل شده، با مقداری اولیهٔ GKIT و تابع توزیع احتمال LN؛ (ه) NR؛ (و) WR



شکل ۷. (الف) تصویر ماهواره‌ای ASAR-HV، ۲۴ جولای ۲۰۱۱؛ (ب) تصویر ماهواره‌ای نیمه‌شبیه‌سازی شده در تاریخ دوم؛ (ج) نقشهٔ آزمون؛ (د) نقشه‌های تغییرات حاصل از مقداری اولیهٔ GKIT و تابع توزیع احتمال LN؛ (ه) NR؛ (و) WR

و برآورد اولیه پارامترهای pdf استفاده شده است (رابطه (۸)). مقداردهی اولیه یکبار براساس نقشه تغییرات حاصل شده برای پلاریزاسیون HH و بار دیگر، برای پلاریزاسیون HV انجام گرفته است. به منظور دخیل کردن اطلاعات بافت مکانی، میدان تصادفی مارکوف، هنگام برچسبدهی به هر پیکسل، پیکسل‌های همسایه را نیز مدنظر قرار می‌دهد.

با ملاک قراردادن نقشه آزمون برای ارزیابی، دقت تشخیص نقشه‌های تغییرات حاصل از الگوریتم GKIT (درصد پیکسل‌های آزمون که به درستی برچسب «تغییر» دریافت کرده‌اند، نرخ تشخیص اشتباه (درصد پیکسل‌های آزمون که به اشتباه برچسب «تغییر نیافته» گرفته‌اند) و نرخ خطای کل (درصد پیکسل‌های آزمون که برچسب اشتباه گرفته‌اند) محاسبه شده است (جدول ۲).

جدول ۲. شیوه عملکرد الگوریتم GKIT

نرخ خطای کل	نرخ تشخیص اشتباه	دقت تشخیص	تعداد پیکسل‌های تغییر نیافته	تعداد پیکسل‌های تغییر یافته	حد آستانه بهینه	تابع چگالی احتمال	روش
٪۲۰/۵۵	٪۲۰/۵۵	٪۷۹/۴۵	۱۰۱۳۵۱	۱۸۶۴۹	۰/۸۲	LN	مقداردهی اولیه (GKIT-)
٪۴۸/۱۲	٪۴۸/۱۲	٪۵۱/۸۸	۱۰۷۸۲۲	۱۲۱۷۸	۰/۵۱	NR	(HH)
٪۱۱/۳۵	٪۱۱/۳۵	٪۹۸/۶۵	۹۶۸۴۴	۲۳۱۵۶	۰/۹۱	WR	
٪۵۳/۴۳	٪۵۳/۴۳	٪۴۶/۵۷	۱۰۹۰۶۹	۱۰۹۳۱	۰/۳۳	LN	مقداردهی اولیه (GKIT-)
٪۵۹/۶۶	٪۵۹/۶۶	٪۴۰/۳۴	۱۱۰۵۳۱	۹۴۶۹	۰/۲۴	NR	(HH)
٪۵۰/۶۰	٪۵۰/۶۰	٪۴۹/۴۰	۱۰۸۴۰۵	۱۱۵۹۵	۰/۴۷	WR	(HV)

بنابراین،  $m_{ik}$  (رابطه (۴)) برای هر پیکسل مرکزی در همسایگی  $3 \times 3$  آن محاسبه شده است. میزان تأثیر این پارامتر، در هر تکرار، با بهینه‌سازی ضریب  $\beta$  تعیین شده است. همچنین، اطلاعات موجود در هر یک از کانال‌های تصویر با استفاده از چارچوب مارکوف و ضریب اعتمادپذیری  $\alpha_n$  در فرایند برچسبدهی دخیل شده‌اند. پس از آن، برچسب هر پیکسل، از طریق مینیمم‌سازی انرژی (۴) و طی روندی تکرارشونده، بهینه می‌شود تا در نهایت، اختلاف به دست آمده برای پارامترهای مارکوف، در دو تکرار متوالی در معیار حد آستانه، صدق کند (برابر با ۰/۰۰۱). نقشه‌های تغییرات حاصل با استفاده از تلفیق اطلاعات دو باند در بخش‌های (الف)، (ب) و (ج) در شکل‌های ۶ و ۷ آورده شده است (در این حالت، ضریب  $\gamma$  برابر با صفر در نظر گرفته شده است).

برای بررسی میزان تأثیر دخیل کردن اطلاعات لبه

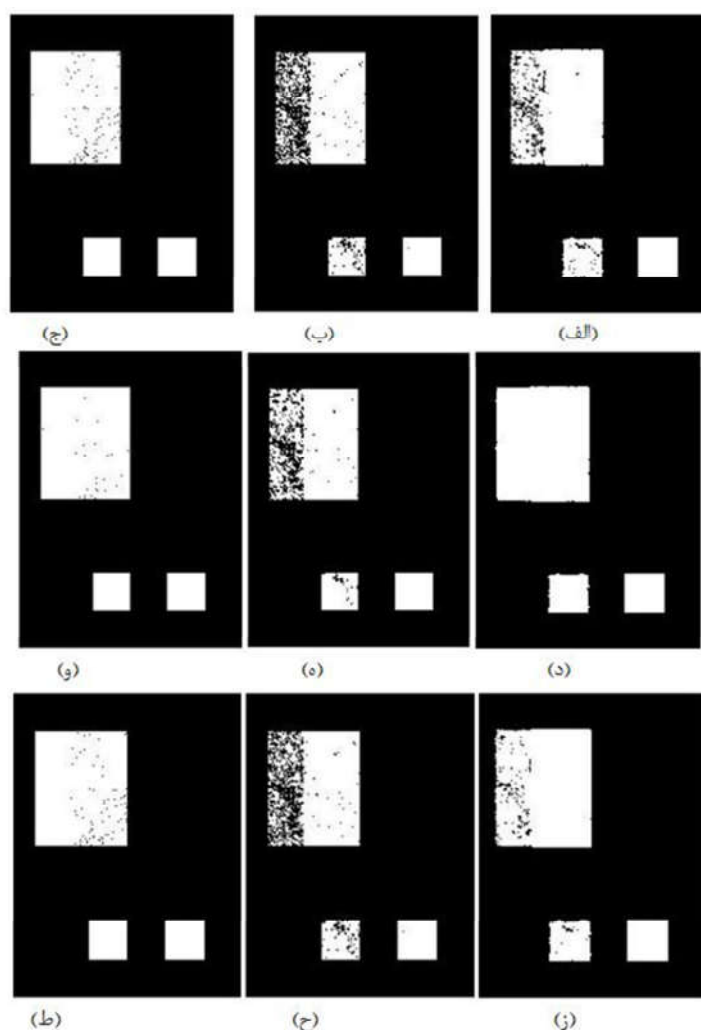
مطابق نتایج به دست آمده، پلاریزاسیون HH دقت بالاتری در برآورد تغییرات داشته است. همچنین، تابع چگالی احتمال WR بهترین دقت آشکارسازی تغییرات را به خود اختصاص داده است. از نظرگاه دقت، LN و NR، به ترتیب، دومین و سومین توابع چگالی احتمال محسوب می‌شوند.

### ۳-۳- نتایج تجربی آشکارسازی تغییرات با رویکرد تلفیق اطلاعات


در این مرحله، سه نوع اطلاعات از تصاویر موجود استخراج شده و از طریق چارچوب مارکوف، در فرایند برچسبدهی دخیل شده است. این اطلاعات شامل اطلاعات بافت مکانی، اطلاعات موجود در تصاویر مربوط به هر یک از پلاریزاسیون‌های HH، HV و اطلاعات است. نخست، از نقشه‌های تغییرات به دست آمده از مرحله قبل، به منظور مقداردهی اولیه پیکسل  $k$ ام ( $k=1,2,\dots,N$ )

بخش ۲-۲، با استفاده از مدل MRF و مینیمم‌سازی تابع انرژی مربوط، نقشه‌های تغییرات نهایی با استفاده از pdfهای مطرح‌شده تولید شده‌اند. نتایج حاصل، با استفاده از مدل آشکارسازی لبه Advanced CFED در بخش‌های (د)، (ه)، (و) و شکل‌های ۸ و ۹ آورده شده است. بخش‌های (ز)، (ح) و (ط) نتایج استفاده از مدل آشکارسازی لبه Canny را نشان می‌دهند.

در نتایج نهایی آشکارسازی تغییرات، از دو مدل Advanced CFED و Canny به‌منظور تشخیص و آشکارسازی لبه‌ها استفاده شده است. تعداد پیکسل‌های لبه در همسایگی  $3 \times 3$  هر پیکسل مرکزی شمارش شده و با استفاده از  $n_{ik}$  در مدل‌سازی مارکوف و فرایند تصمیم‌گیری دخیل شده است. همچنین، میزان تأثیر اطلاعات لبه استخراج‌شده از تصاویر با پارامتر  $\gamma$  تعیین شده است (رابطه (۴)). پس از آن، مطابق توضیحات



شکل ۸. نقشه‌های تغییرات حاصل از: (الف) تلفیق اطلاعات دو باند، با ملاک قراردادن باند HH و استفاده از تابع توزیع احتمال LN؛ (ب) NR؛ (ج) WR؛ (د) تلفیق اطلاعات لبه حاصل از روش Advanced CFED و استفاده از تابع توزیع احتمال LN؛ (ه) NR؛ (و) WR؛ (ز) تلفیق اطلاعات لبه حاصل از روش Canny و استفاده از تابع توزیع احتمال LN؛ (ح) NR؛ (ط) WR



شکل ۹. نقشه‌های تغییرات حاصل از: (الف) تلفیق اطلاعات دو باند، با ملاک قرار دادن باند HV و استفاده از تابع توزیع احتمال LN؛ (ب) NR؛ (ج) WR؛ (د) تلفیق اطلاعات لبه حاصل از روش Advanced CFED و استفاده از تابع توزیع احتمال LN؛ (ه) NR؛ (و) WR؛ (ز) تلفیق اطلاعات لبه حاصل از روش Canny و استفاده از تابع توزیع احتمال LN؛ (ح) NR؛ (ط) WR

همگرایی طی حداکثر چند دقیقه انجام گرفته است. عملکرد الگوریتم Advanced CFED تا حدودی شبیه به الگوریتم Canny است اما سرعت بسیار بیشتری دارد. به منظور دستیابی به بهترین نتایج برای هر دو الگوریتم، کاربر سطح مناسب حساسیت را تعیین کرده است.

دقت کلی الگوریتم با استفاده از نقشه آزمون برآورد شده است (جدول ۳). نتایج حاصل همگرایی روش پیشنهادی، با تعداد دفعات تکرار پایین به‌ازای استفاده از هر سه مدل pdf، را بیان می‌کند. مدل NR، به‌دلیل نیاز به حل معادلات غیرخطی در هر تکرار، به زمان محاسباتی بیشتری نیاز دارد. با این حال، زمان محاسباتی در تمامی حالات کم است و رسیدن به

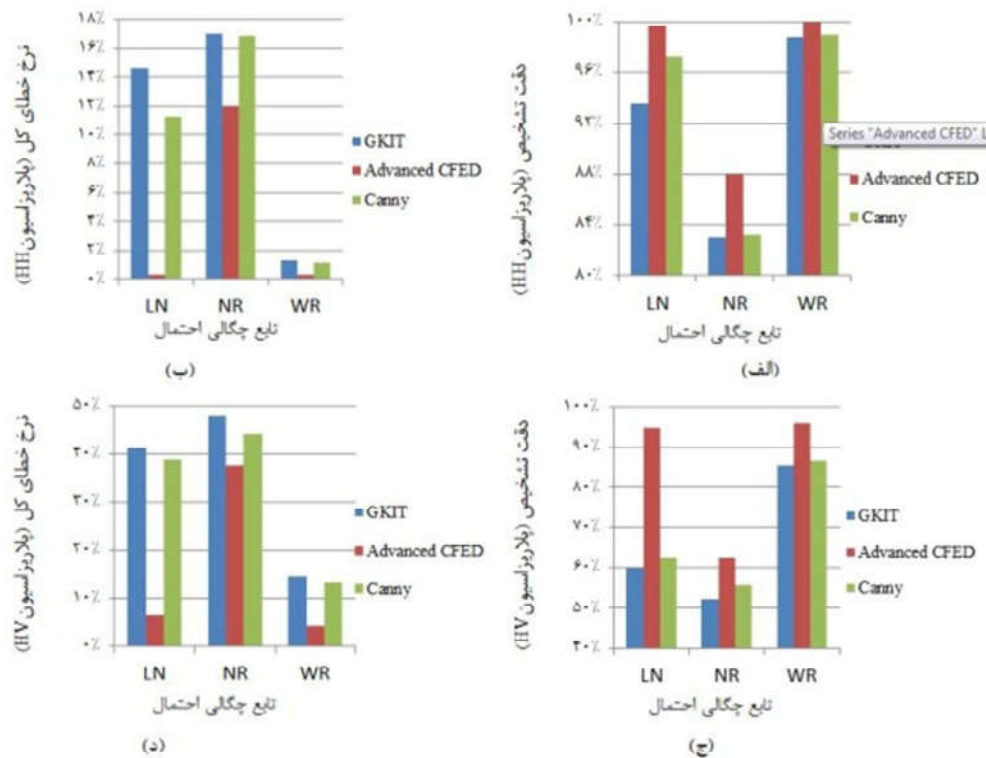
جدول ۳. چگونگی عملکرد الگوریتم‌های آشکارسازی تغییرات: ۱. با استفاده از مقداردهی اولیه GKIT و تلفیق اطلاعات باندها؛ ۲. تلفیق

اطلاعات لبه با استفاده از آشکارساز لبه Advanced CFED؛ ۳. تلفیق اطلاعات لبه با استفاده از آشکارساز لبه Canny

پلاریزاسیون HV				پلاریزاسیون HH				تلفیق اطلاعات	تابع چگالی احتمال
تعداد تکرار	نرخ خطای کل	نرخ تشخیص اشتباه	دقت تشخیص	تعداد تکرار	نرخ خطای کل	نرخ تشخیص اشتباه	دقت تشخیص		
۱۱	%۴۱/۲۹	%۴۰/۰۷	%۵۹/۹۳	۱۲	%۱۴/۶۱	%۶/۴۲	%۹۳/۵۸	LN	باندها (GKIT)
۲	%۴۷/۷۴	%۴۷/۷۲	%۵۲/۲۸	۲	%۱۶/۹۹	%۱۶/۹۹	%۸۳/۰۱	NR	
۶	%۱۴/۵۵	%۱۴/۵۵	%۸۵/۴۵	۲	%۱/۲۶	%۱/۲۶	%۹۸/۷۴	WR	
۳	%۶/۴۹	%۵/۲۷	%۹۴/۷۳	۲	%۰/۳۳	%۰/۳۳	%۹۹/۶۷	LN	لبه (Advanced CFED)
۲	%۳۷/۶۷	%۳۷/۶۵	%۶۲/۳۵	۲	%۱۲/۰۴	%۱۲/۰۴	%۸۷/۹۶	NR	
۲	%۴/۱۱	%۴/۱۱	%۹۵/۸۸	۴	%۰/۳۱	%۰/۰۶	%۹۹/۹۴	WR	
۵	%۳۸/۸۹	%۳۷/۶۶	%۶۲/۳۴	۵	%۱۱/۳۰	%۲/۷۷	%۹۷/۲۳	LN	لبه (Canny)
۲	%۴۴/۱۲	%۴۴/۱۱	%۵۵/۸۹	۲	%۱۶/۷۹	%۱۶/۷۹	%۸۳/۲۱	NR	
۲	%۱۳/۳۱	%۱۳/۳۱	%۸۶/۶۹	۲	%۱/۱۰	%۱/۱۰	%۹۸/۹۰	WR	

برابر با ۹۰٪ و با استفاده از آشکارساز Canny، ۸۰٪ برآورد شده است. بنابراین، ترکیب پیشنهادی MRF-Advanced CFED دقتی بالاتر (۱۰٪) از MRF-Canny به دست می‌دهد و بسیار سریع‌تر است. همچنین، با ملاک‌قراردادن پلاریزاسیون HH به‌منزله باند بهینه برای برآورد اولیه پارامترها، میانگین دقت تشخیص روش MRF-Advanced CFED برابر با ۸۵٪ و برای پلاریزاسیون HV، ۹۵٪ محاسبه شده است (شکل ۱۰).

نتایج حاصل از توابع چگالی احتمال LN و WR تقریباً مشابه است و در بهترین حالت، به ۹۹/۹۴٪ رسیده است. بیشترین دقت به‌دست‌آمده مربوط به تابع چگالی احتمال WR، به‌ازای پلاریزاسیون HV، است. دقت برآوردشده برای تابع چگالی احتمال NR کمتر از دو مدل دیگر است و در بهترین حالت، به ۸۷/۹۶٪ رسیده است. طبق نتایج به‌دست‌آمده، میانگین دقت تشخیص با استفاده از آشکارساز Advanced CFED



شکل ۱۰. نمودار مقایسه چگونگی عملکرد الگوریتم‌های GKIT, Advanced CFED و Canny به‌ازای توابع توزیع احتمال LN, NR و WR: (الف) دقت تشخیص پلاریزاسیون HH؛ (ب) نرخ خطای کل پلاریزاسیون HH؛ (ج) دقت تشخیص پلاریزاسیون HV؛ (د) نرخ خطای کل پلاریزاسیون HV

است. این روش از قابلیت میدان‌های تصادفی مارکوف، برای تلفیق منابع اطلاعاتی گوناگون مستخرج از تصویر، بهره می‌گیرد. به‌منظور برآورد پارامترهای مدل، الگوریتم پیشینه‌سازی امید ریاضی (EM) با روش مشتقات لگاریتمی (MoLC) ترکیب شده است. الگوریتم پیشنهادی با داده‌های نیمه‌شبیه‌سازی شده ASAR-ENVISAT ارزیابی شده است. در این تحقیق، به دو دلیل مهم، از میدان‌های تصادفی مارکوف استفاده شده است: نخست اینکه هندسه خاص تصویربرداری سنجنده‌های SAR، خطاهای هندسی موجود در این تصاویر و نیز وجود نویز نقطه‌ای در آن‌ها تفسیر این نوع تصاویر را دشوار و ما را از بهره‌بردن از مزایای استفاده از آن‌ها محروم می‌کند. دخیل کردن اطلاعات بافت مکانی،

نتایج حاصل از دخیل کردن اطلاعات لبه حاکی از عملکرد قوی این روش، به‌ازای هر سه نوع تغییرات (اندک، متوسط، زیاد)، است. درحالی‌که فقط با در نظر گرفتن اطلاعات باندها و بافت مکانی، قدرت شناسایی تغییرات اندک و متوسط بسیار پایین برآورد شده است. همچنین، مشخص شد روش پیشنهادی حتی به‌ازای نقشه اولیه تغییرات کم‌دقت، با تعداد دفعات تکرار پایین، درنهایت، به نقشه‌ای از تغییرات دقیق همگرا می‌شود.

#### ۴- نتیجه‌گیری

در این تحقیق، روشی نظارت‌نشده برای آشکارسازی تغییرات تصاویر SAR چندپلاریزاسیونی پیشنهاد شده



استفاده از ترکیبات گوناگون از پارامترها، نیاز داشته باشد. برخلاف آشکارساز لبه Canny، Advanced CFED ردیابی کانتور را، که گاه منجر به اتصال خطوط و تبدیل آن به کانتور بسته جدا می‌شود، انجام نمی‌دهد. این الگوریتم، در مقایسه با الگوریتم Canny وقت بسیار کمتری برای محاسبه نیاز دارد که می‌تواند اهمیت چشمگیری برای عکس‌های بزرگ داشته باشد. مزایای استفاده از مدل Advanced CFED به‌منظور آشکارسازی لبه عبارت‌اند از:

۱. حساسیت اندک به نویز: حتی زمانی که لبه در تصویر ورودی پخش شده است، خطوط تقریباً نازک سفیدی ارائه می‌دهد.
  ۲. مدل‌سازی آسان: فقط شش مجموعه توابع عضویت فازی ساده دارد و سریع است.
  ۳. محاسبه کارآمد: توابع Epanechnikov توسعه‌یافته حجم محاسبات را کاهش می‌دهند.
  ۴. این روش، حتی زمانی که پارامترهای بصری تا حدودی سخت<sup>۱</sup> تنظیم شده‌اند، به‌خوبی کار می‌کند.
  ۵. روند آن همسانگرد (ایزوتروپیک) است و خطوط در تمامی جهات، به‌طور مساوی، تشخیص داده می‌شوند.
- نتایج حاصل حاکی از آن است که دخیل کردن اطلاعات لبه موجب بهبود دقت در محل مرزهای مکانی شده و میانگین دقت آشکارسازی تغییرات را ۱۲٪ بهبود بخشیده است. این ارتقا در دقت سبب آسان شدن تصمیم‌گیری‌های درست می‌شود. همچنین، مشخص شد که روش پیشنهادی حتی به‌ازای نقشه اولیه تغییرات کم دقت، با تعداد دفعات تکرار پایین، در نهایت، به نقشه تغییرات دقیقی همگرا می‌شود. طبق نتایج به‌دست آمده، بهترین دقت (میانگین ۹۰٪) مربوط به روش پیشنهادی مبنی بر دخیل کردن اطلاعات لبه، با استفاده از MRF-Advanced CFED، است. با استفاده

با استفاده از مدل‌های میدان‌های تصادفی مارکوف، ممکن است چاره‌ساز این مسئله باشد و نه تنها منجر به تسهیل تفسیر شود بلکه، در نهایت، حصول نقشه تغییراتی دقیق و سازگار از دیدگاه طیفی و مکانی را امکان‌پذیر کند. دوم اینکه تصاویر SAR تک‌کاناله فقط امکان مشاهده دامنه/ شدت را فراهم می‌آورند و در تمییز دادن مناطق تغییر یافته و بدون تغییر ضعیف عمل می‌کنند. بنابراین در این تحقیق، با استفاده از مدل‌سازی مارکوف، اطلاعات موجود در هر یک از کانال‌ها (پلاریزاسیون‌های HH و HV) طی فرایند برجسب‌گذاری در نظر گرفته شده و میزان تمییز دادن تفاوت‌ها افزایش یافته است. این روش فقط به مدل‌سازی و تخمین اطلاعات هر تک‌باند، با استفاده از pdfهای حاشیه‌ای، نیاز دارد. بنابراین، در مقایسه با دیگر روش‌های موجود، از لحاظ آماری آسان‌تر و اثبات‌تر است. میزان تأثیر هر یک از باندها در مدل با استفاده از ضرایب اطمینان تعدیل شده است.

با وجود این، میدان‌های تصادفی مارکوف، به دلیل فرمول‌بندی ایزوتروپیک خود، به نرم‌شدن بیش از حد لبه‌ها منجر می‌شوند و تعیین دقیق مرزهای مکانی بین نواحی تغییر یافته و تغییر نیافته را دچار مشکل می‌کنند. به‌منظور حذف یا دست‌کم کاهش این اثر نامطلوب، اطلاعات لبه‌های استخراجی از تصویر، با استفاده از مدل مارکوف و با تعریف پارامتر جدید  $n_{ik}$  و ضریب اعتمادپذیری  $\gamma$ ، در فرایند برجسب‌گذاری دخیل شده است. آشکارسازی لبه‌ها با استفاده از دو الگوریتم Canny و Advanced CFED اجرا شده است. مقادیر کوچک  $h_i$  به حساسیت بیشتر به لبه‌ها و بنابراین، نمایش نویز بیشتر می‌انجامد؛ در حالی که مقادیر بزرگ‌تر  $l_0$  بیشتر لبه‌های ضعیف را به پس‌زمینه تصویر می‌کند. پس، به‌منظور دستیابی به بهترین نتایج، کاربر سطح مناسب حساسیت را تعیین می‌کند. انتخاب پارامترهای Advanced CFED، که منجر به نتایجی مطلوب شود، آسان است؛ در صورتی که آشکارساز لبه Canny ممکن است به اجراهای بسیار بیشتری، با

1. coarse

داد. نیز، می‌توان چگونگی عملکرد الگوریتم Advanced CFED را روی تصاویر تخریب‌شده با نویز بررسی کرد. پیشنهاد می‌شود، در صورت وجود داده‌های حقیقی و اطلاعات زمینی از منطقه، تحقیقات بیشتری در مورد شیوه عملکرد روش پیشنهادی برای این داده‌ها انجام شود. به‌طور کلی، روش MRF در زمینه تلفیق اطلاعات توانایی بالایی دارد و بررسی و توسعه الگوریتم‌های دیگر، در زمینه استفاده از آن به‌منظور آشکارسازی تغییرات تصاویر SAR، نیازمند تحقیقات بیشتری است.

#### منابع

- Aanæs, H., Nielsen, A.A., Carstensen, J.M., Larsen, R. & Ersbøll, B.K., 2009, **Efficient Incorporation of Markov Random Fields in Change Detection**, IEEE Trans. Geosci. Remote Sens., 8(4), PP. 689-692.
- Angiati, E., Dellepiane, S., Martino, M., Moser, G. & Serpico, S.B., 2010, **Flooding and Change Maps from Cosmo-SkyMed Images**, Riunione Annuale- Brescia, 21-23 June.
- Besag, J., 1974, **Spatial Interaction and the Statistical Analysis of Lattice Systems**, Journal of the Royal Statistical Society Series B (Methodological), 36(2), PP. 192-236.
- Bruzzone, L. & Prieto, D.F., 2000, **Automatic Analysis of the Difference Image for Unsupervised Change Detection**, IEEE Trans. Geosci. Remote Sensing, 38(3), PP. 1171-1182.
- Bujor, F., Trouve, E., Valet, L., Nicolas, J.M. & Rudant, J.P., 2004, **Application of Log-Cumulants to the Detection of Spatio-Temporal Discontinuities in Multitemporal SAR Images**, IEEE Trans. Geosci. Remote Sens., 42(10), PP. 2073-2084.
- Celeux, G., Forbes, F. & Peyrand, N., 2003, **EM Procedures Using Mean Field-Like Approximations for Markov Model-Based Image Segmentation**, Pattern Recognit., 36(1), PP. 131-144.
- Dierking, W. & Skriver, H., 2002, **Change Detection for Thematic Mapping by Means of Airborne Multi-Temporal Polarimetric SAR Imagery**, IEEE Trans. Geosci. Remote Sens., 40(3), PP. 618-636.

از الگوریتم MRF-Canny، این مقدار به ۰.۸٪ و در صورت در نظر گرفتن اطلاعات لبه، به ۰.۷۸٪ تنزل می‌یابد. به‌طور کلی، عملکرد الگوریتم Advanced CFED تا حدودی شبیه به الگوریتم Canny اما سرعت بسیار بیشتری دارد.

دستاورد دیگر تحقیق مشخص کرد که اطلاعات باندها و بافت مکانی، به تنهایی و بدون در نظر گرفتن اطلاعات لبه‌ها، قابلیت شناسایی تغییرات اندک و متوسط را ندارند. این در حالی است که نتایج حاصل از دخیل کردن اطلاعات لبه بیانگر عملکرد قوی این روش، به‌ازای هر سه نوع تغییرات (اندک، متوسط، زیاد) است. طبق نتایج به‌دست آمده، در صورت منفردانگاشتن هر باند، میانگین دقت آشکارسازی تغییرات برابر با ۰.۶۲٪ ارزیابی می‌شود. به‌طور کلی، نتایج حاصل از توابع چگالی احتمال LN و WR تقریباً مشابه است و بیشترین دقت حاصل به تابع چگالی احتمال WR، به‌ازای پلاریزاسیون HH، مربوط می‌شود. مدل NR، به‌دلیل نیاز به حل معادلات غیرخطی در هر تکرار، زمان محاسباتی بیشتری می‌طلبد. با وجود این، زمان محاسباتی در تمامی حالات اندک است و رسیدن به همگرایی، طی حداکثر چند دقیقه، انجام گرفته است. لازم است گفته شود، به‌علت توانایی میدان‌های تصادفی مارکوف در استخراج اطلاعات بافت مکانی طی فرایند طبقه‌بندی، پیش از به‌کار بستن این روش، لزومی برای حذف نویز نقطه‌ای نیست و الگوریتم، به‌ازای تصاویر SAR بسیار نویزی نیز، ثبات بالایی دارد.

برای کارهای آتی، می‌توان به استفاده از پارامترهای دینامیک  $lo$  و  $hi$  اشاره کرد که، در موارد ضروری، برای حساسیت بیشتر یا کمتر، روی تصویر (با توجه به کنتراست آن) تنظیم می‌شوند. همچنین، می‌توان تأثیر مقادیر متفاوت عرض، به‌ازای FSMF‌های متفاوت، را بررسی کرد. استفاده از لبه‌های ضعیف در سایه‌های خاکستری روشن‌تر، اما هنوز تاریک، به‌منظور افزودن اطلاعات بیشتر به نقشه لبه، از موارد دیگری است که می‌توان در آینده تحقیقات بیشتری در مورد آن انجام

- Dubes R.C., & Jain, A.K., 1989, **Random Field Models in Image Analysis**, J. Appl. Stat., 16(2), PP. 131-163.
- Fransson, J.E.S., Walter, F., Blennow, K., Gustavsson, A. & Ulander, L.M.H., 2002, **Detection of Storm-Damaged Forested Areas Using Airborne CARABAS-II VHF SAR Image Data**, IEEE Trans. Geosci. Remote Sens., 40(10), PP. 2170-2175.
- Geman, S. & Geman, D., 1984, **Stochastic Relaxation Gibbs Distribution and the Bayesian Restoration of the Image**, IEEE Trans. on Pattern Analysis and Machine Intelligence, 6(6), PP. 721-741.
- Jackson Q. & Landgrebe, D.A., 2001, **An Adaptive Classifier Design for High-Dimensional Data Analysis with a Limited Training Data Set**, IEEE Trans. Geosci. Remote Sens., 39(12), PP. 2664-2679.
- Jackson, Q. & Landgrebe, D., 2002, **Adaptive Bayesian Contextual Classification Based on Markov Random Fields**, IEEE Trans. Geosci. Remote Sens., 40(11), PP. 2454-2463.
- Li, S.Z., 2009, **Markov Random Field Modeling in Image Analysis**, London: Springer.
- Liang, L.R. & Looney, C.G., 2003, **Competitive Fuzzy Edge Detection**, Applied Soft Computing, 3, PP. 123-137.
- Liming, J., Mingsheng, L., Lu, Z.H. & Hui, L., 2007, **Unsupervised Change Detection in Multitemporal SAR Images Using MRF Models**, Geo-spatial Information Science, 10(2), PP. 111-116.
- Looney, C.G., 2001, **A Fuzzy Classifier Network with Ellipsoidal Epanechnikovs**, Computer Science Department, University of Nevada, Reno, NV.
- Moser, G. & Serpico, S.B., 2006, **Generalized Minimum-Error Thresholding for Unsupervised Change Detection from SAR Amplitude Imagery**, IEEE Trans. Geosci. Remote Sens., 44(10), PP. 2972-2982.
- Moser, G. & Serpico, S.B., 2009, **Unsupervised Change Detection from Multichannel SAR Data by Markovian Data Fusion**, IEEE Trans. Geosci. Remote Sens., 47(7), PP. 2114-2127.
- Moser, G. & Serpico, S.B., 2010, **Unsupervised Change Detection with Very High-Resolution SAR Images by Multiscale Analysis and Markov Random Fields**, IEEE Trans. Geosci. Remote Sens., 8(4), PP. 3082-3085.
- Nicolas, J.M., 2002, **Introduction aux statistiques de deuxième espèce: Applications des log-moments et des log-cumulants a l'analyse des lois d'images radar**, Trait. Signal, 19, PP. 139-167.
- Sneddon, I., 1972, **The Use of Integral Transforms**, New York: McGraw-Hill.
- Solberg, A.H.S., Taxt, T. & Jain, A.K., 1996, **A Markov Random Field Model for Classification of Multisource Satellite Imagery**, IEEE Trans. Geosci. Remote Sens., 34(1), PP. 100-113.
- Tso, B. & Mather, M., 2001, **Classification Methods for Remotely Sensed Data**, London: Taylor and Francis Ltd.
- Touzi, R., Lopez, A. & Bousquet, P., 1988, **A Statistical and Geometrical Edge Detector for SAR Images**, IEEE Trans. Geosci. Remote Sens., 26(6), PP. 764-773.
- Vaccaro, R., Smits, P.C. & Dellepiane, S.G., 2000, **Exploiting Spatial Correlation Features for SAR Image Analysis**, IEEE Trans. Geosci. Remote Sens., 38(3), PP. 1212-1223.