

بخش بندی نظارت نشده سلسله مراتبی تصاویر SAR با استفاده از سوپرپیکسل و فشرده سازی پر اتلاف داده

غلامرضا اکبری زاده^۱، استادیار؛ زینب تیرانداز^۲، دانشجوی کارشناسی ارشد؛ سیده مرجان آل سیدغفور^۳، دانشجوی کارشناسی ارشد

۱- گروه مهندسی برق - دانشکده مهندسی - دانشگاه شهید چمران اهواز - اهواز - ایران - g.akbari@scu.ac.ir

۲- گروه مهندسی برق - دانشکده مهندسی - دانشگاه شهید چمران اهواز - اهواز - ایران - z.tirandaz@mscstu.scu.ac.ir

۳- دانشکده مهندسی برق و کامپیوتر - مؤسسه آموزش عالی شهاب دانش - قم - ایران - marjanaleghafour@gmail.com

چکیده: این مقاله روشی بنام بخش بندی نظارت نشده سلسله مراتبی با استفاده از فشرده سازی پر اتلاف داده برای تصاویر رادار روزنه ترکیبی (SAR) ارائه می دهد که در آن از سوپرپیکسل ها به جای پیکسل ها استفاده شده است. در این مقاله، با ترکیب ویژگی هایی از قبیل لبه، بافت و شدت روشنایی به ادغام سوپرپیکسل ها پرداخته می شود که روند ادغام طی دو مرحله صورت می گیرد. با توجه به اینکه بسیاری از روش های مبتنی بر سوپرپیکسل، مشکل زمان اجرای بالا را دارند، الگوریتم دومرحله ای پیشنهادی، علاوه بر بهبود دقت، زمان اجرای برنامه را نیز کاهش می دهد. مرحله اول ادغام نمودن تمامی سوپرپیکسل هایی است که مرز مجزا و مشخصی بین آن ها وجود ندارد. در مرحله دوم ادغام سوپرپیکسل ها در صورتی انجام می شود که طول کد داده ها تحت اعوجاجی مشخص، حداقل گردد. الگوریتم پیشنهادی بر روی تصاویر SAR اجرا شده و مشاهده می شود که این الگوریتم از دقت و سرعت خوبی بهره مند است.

واژه های کلیدی: تصویر رادار روزنه ترکیبی، بخش بندی تصویر، فشرده سازی پر اتلاف، توزیع ترکیب گوسی، ادغام نواحی، ماتریس هم رخداد سطح خاکستری.

Hierarchical Unsupervised Segmentation of SAR Images via Super Pixel and Lossy Data Compression

G. Akbarizadeh¹, Assistant Professor; Z. Tirandaz², MSc Student; M. Aleghafour³, MSc Student

1- Department of Electrical Engineering, Faculty of Engineering, Shahid Chamran University of Ahvaz, Ahvaz, Iran, Email: g.akbari@scu.ac.ir

2- Department of Electrical Engineering, Faculty of Engineering, Shahid Chamran University of Ahvaz, Ahvaz, Iran, Email: z.tirandaz@mscstu.scu.ac.ir

3- Faculty of Electrical and Computer Engineering, University of Shahab Danesh, Qom, Iran, Email: marjanaleghafour@gmail.com

Abstract: This paper describes a method named hierarchical unsupervised segmentation using lossy data compression for synthetic aperture radar (SAR) images in which super pixels are used instead of pixels. In this paper, using a combination of several features such as edge, texture, and intensity, the super pixels are merged where the merging procedure is done by two steps. Since, many superpixel-based methods suffer from long run-times, the two step-proposed algorithm beside improving the accuracy, reduces the running-time. The first step is merging super pixels which there are not discriminative and clear edges between them. The merging of super pixels is done in the second step, if the length of data codes is minimized under a distinct distortion. The proposed algorithm is performed on SAR images and the simulation results demonstrate that the algorithm has a good accuracy and high processing speed.

Keywords: Synthetic aperture radar (SAR), image segmentation, lossy compression, mixture of gaussian distributions, region merging, GLCM.

تاریخ ارسال مقاله: ۱۳۹۴/۰۱/۲۰

تاریخ اصلاح مقاله: ۱۳۹۴/۰۴/۰۴

تاریخ پذیرش مقاله: ۱۳۹۴/۰۷/۰۱

نام نویسنده مسئول: غلامرضا اکبری زاده

نشانی نویسنده مسئول: اهواز - اهواز - دانشگاه شهید چمران اهواز - دانشکده مهندسی - گروه مهندسی برق.

۱- مقدمه

سنسورهای رادار روزنه ترکیبی^۱ (SAR) قادر به نفوذ در میان ابرها بوده و می‌توانند تحت شرایطی که سنسورهای نوری بلااستفاده‌اند، مانند شرایط بد آب و هوایی و شب به فعالیت بپردازند؛ به همین علت تصاویر SAR در محیط‌زیست، باستان‌شناسی، زمینه‌های نظامی و غیره، کاربرد وسیعی پیدا کرده‌اند [۱].

از آنجاکه سطح زمین از ناحیه‌های متفاوتی مانند مزارع، مرتع، مناطق شهری، رودخانه‌ها، بیابان‌ها و غیره تشکیل شده است، بخش‌بندی به‌عنوان مرحله‌ای پیش‌پردازش برای درک و تفسیر تصویر SAR الزامی است. بخش‌بندی، تصویر SAR را به نواحی با مشخصات متفاوت تقسیم می‌کند. یک بخش‌بندی مؤثر و صحیح نه‌تنها می‌تواند هزینه‌های محاسباتی را کاهش دهد، بلکه باعث افزایش بهره‌وری پردازش تصویر SAR در سطح بالا می‌گردد.

در تحلیل داده‌های پیچیده، بزرگ‌ترین مشکلی که با آن مواجه می‌شویم، انتخاب تعداد متغیرهای موردنیاز است. تحلیل با استفاده از تعداد زیادی از متغیرها، عموماً نیاز به حجم حافظه و توان محاسباتی بالا دارد. با استخراج ویژگی، تعداد این متغیرها کاهش می‌یابد. استخراج ویژگی، ترکیبی از متغیرها است؛ به طوری که بتواند داده را با دقت کافی توصیف کند. از جمله ویژگی‌های استخراجی، بافت است. بافت، نقش مهمی در تحلیل تصاویر، شناسایی هدف، بخش‌بندی نواحی، شناسایی الگو و غیره دارد. هدف از تحلیل بافتی، پیدا کردن مشخصات بافتی در یک فرم ساده‌تر ولی منحصر به فرد است که در این صورت بخش‌بندی دقیق و پایدار را به همراه خواهد داشت. بافت، شامل اطلاعات بااهمیتی از ساختار و آرایش سطوح است [۲].

چهارده ویژگی بافتی، توسط هارالیک و همکارانش [۳] در سال ۱۹۷۳ پیشنهاد شد. این ویژگی‌ها شامل اطلاعاتی در مورد مشخصات بافتی تصویر مانند همگنی، وابستگی خطی تن خاکستری^۲، کنتراست، تعداد، نوع و طبیعت مرزهای موجود و پیچیدگی تصویر است. هارالیک و همکارانش استفاده از ماتریس هم‌رخدادی سطح خاکستری^۳ (GLCM) را برای استخراج ویژگی‌های بافتی مختلف پیشنهاد دادند. GLCM همچنین ماتریس وابستگی سطح خاکستری^۴ نیز نامیده می‌شود [۴]. در این مقاله، GLCM برای به دست آوردن ویژگی‌های بافتی آماری به کار برده می‌شود. نشان داده شده است که GLCM روش آماری مناسبی برای استخراج ویژگی‌های بافتی از تصویر است. از بین این ویژگی‌ها، فقط ۹ ویژگی بافتی که بیش‌ترین تأثیر را بر عملکرد بهتر روش پیشنهادی دارند، انتخاب شده‌اند. این ویژگی‌ها عبارت‌اند از: ۱- کنتراست؛ ۲- همبستگی^۵؛ ۳- انرژی؛ ۴- یکنواختی^۶؛ ۵- آنتروپی؛ ۶- چولگی^۷؛ ۷- میانگین؛ ۸- انحراف معیار و ۹- کشیدگی^۸. این ۹ ویژگی، قدرت تمایز بالا را در روش ارائه‌شده به وجود می‌آورند که در نتیجه، دقت بالای روش پیشنهادی را نسبت به سایر روش‌های مورد مقایسه، به دنبال خواهد داشت. GLCM، روشی آماری است که به‌منظور استخراج ویژگی‌هایی

از بافت به کار برده می‌شود که رابطه مکانی بین پیکسل‌ها تلقی می‌شوند. در تحلیل آماری بافت، ویژگی‌های بافتی از آن دسته از توزیع‌های آماری مورد محاسبه قرار می‌گیرند که آن توزیع‌ها، ترکیبی از شدت روشنایی‌های مشاهده‌شده در مکان‌های مشخص شده مرتبط با یکدیگر در تصویر باشند. بر اساس تعداد پیکسل‌ها در هر ترکیب، ویژگی‌های آماری، به ویژگی‌های مرتبه اول، دوم، سوم و بالاتر تقسیم می‌شوند [۲]. GLCM، ماتریسی است که تعداد سطرها و تعداد ستون‌ها در آن برابر با تعداد سطوح خاکستری است. تعریف دیگری هم می‌توان برای آن در نظر گرفت. طبق این تعریف، GLCM یک هیستوگرام دوبعدی از سطوح خاکستری برای هر جفت از پیکسل‌ها است که این جفت پیکسل، توسط یک رابطه مکانی ثابت از هم جدا شده‌اند. در تابع GLCM، ابتدا ویژگی‌های بافتی تصویر با محاسبه اینکه هر چند وقت یک‌بار جفت پیکسل‌ها با مقادیر خاص و تعیین شده و با یک رابطه مکانی مشخص در تصویر رخ می‌دهند، مشخص می‌شوند و GLCM ایجاد می‌شود. سپس، مقادیر ویژگی‌های آماری از ماتریس استخراج می‌شود [۲ و ۴].

با وجود ساختار ژئومتریک منحصر به فرد هر ناحیه از زمین، مانند ناهمواری‌های سطح، پوشش‌های گیاهی و رطوبت سطح که منجر به تفاوت در بافت و روشنایی می‌گردد، نواحی مناطق مختلف، گاهی بافت مشابهی را از خود نشان می‌دهند. از این رو ویژگی‌هایی که تنها مبتنی بر بافت ناحیه باشند، اغلب از درجه اعتبار ساقط هستند. برای حل این مشکل، نیاز به ترکیب ویژگی‌های مختلف برای عملکرد بهتر بخش‌بندی تصویر SAR داریم. ویژگی‌هایی از قبیل مجاورت، لبه‌ها، شدت روشنایی و ویژگی‌های بافتی که ترکیب آن‌ها منجر به افزایش سرعت و دقت الگوریتم بخش‌بندی می‌گردد.

در گذشته تمرکز روی سرعت محاسباتی الگوریتم بود، در حالی که اخیراً توجه بیش‌تری به دقت بخش‌بندی می‌گردد [۵]. برای کمک به این امر، ما از ناحیه به‌عنوان واحد عملکرد به‌جای پیکسل استفاده کرده‌ایم؛ زیرا روش‌های مبتنی بر ناحیه می‌توانند به‌طور مؤثری هزینه‌های محاسباتی را کم کنند و نیز باعث کاهش اثر نویز اسپکل^۹ شوند و این‌گونه، دقت محاسباتی را تا حدودی بالا می‌برند.

امروزه روش‌های زیادی برای بخش‌بندی تصویر SAR ارائه شده است که برخی از مهم‌ترین آن‌ها شامل روش‌های آستانه‌ای [۶ و ۷]، الگوریتم‌های خوشه‌بندی [۸ و ۹]، روش‌های مبتنی بر مدل‌های آماری [۱۰ و ۱۱] و روش‌های رشد ناحیه‌ای [۱۱ و ۱۲] هستند.

بعضی از مدل‌های متداول یا مبتنی بر توزیع‌های احتمالی مانند گوسی ترکیبی هستند که مدلی محبوب به شمار می‌رود [۱۳] و همچنین روش‌های مبتنی بر مجموعه‌های جبری/هندسی مانند شبه فضای خطی نیز از جمله این روش‌ها است. مدل گوسی ترکیبی قابل انعطاف بوده و یک روش مدل کردن آماری مؤثر برای داده‌های چند متغیره است. این مدل می‌تواند هر تابع غلطتی را که شامل مؤلفه‌های

حدودی کاهش می دهد؛ ولی به دلیل استفاده از فیلتر گابور برای استخراج ویژگی، پیچیدگی محاسباتی آن و زمان اجرای برنامه نیز بالا است.

در این مقاله، سعی شده است که از روش خوشه بندی برای بخش بندی تصویر SAR استفاده شود. خوشه بندی بر مبنای مدل، روشی نظارت نشده متناسب با مدل های ترکیبی داده است. در این مقاله، ابتدا یک مرحله پیش پردازش بر روی تصویر SAR انجام می شود و تصویر، به سوپرپیکسل هایی که گروهی از پیکسل های مشابه، منسجم و محلی تحت برخی از محدودیت ها هستند، [۱۹] تقسیم می شود. سپس در مرحله بعد با استفاده از ویژگی های لبه استخراجی از تصویر SAR، قسمت اعظمی از سوپرپیکسل ها ادغام می شوند و این گونه سرعت محاسباتی بالا می رود. در مرحله آخر با استفاده از روش فشرده سازی پراتلاف به ادغام سوپرپیکسل های باقی مانده بر اساس بردارهای ویژگی پرداخته و نتیجه نهایی به دست می آید.

باید توجه داشت که اگرچه در اینجا از روش فشرده سازی پراتلاف برای بخش بندی تصویر استفاده شده ولی برای بخش بندی کردن، فشرده کردن تصویر، پیشنهاد نمی شود و به جای استفاده از مقادیر پیکسل، از ویژگی های استخراجی بافت برای فشرده سازی و سپس بخش بندی استفاده می شود. برای این کار از ویژگی های استخراجی GLCM در مقیاس مکانی بزرگ تر استفاده کرده تا بعد فضای ویژگی به اندازه کافی بزرگ باشد تا بتواند تمام ساختار بافت را به طور واقعی نشان دهد و همچنین این ویژگی، پیچیدگی محاسباتی پایینی دارد که به کاهش زمان اجرای برنامه کمک می کند.

ادامه مقاله به صورت زیر تنظیم شده است:

بخش ۲، بخش بندی داده های ترکیب گوسی با فشرده سازی پراتلاف را ارائه می دهد و سپس معرفی سوپرپیکسل ها در بخش ۳ به عنوان واحد عملیاتی مورد استفاده، ارائه شده است. در بخش ۴، تجزیه و تحلیل الگوریتم پیشنهادی و ساخت بردارهای ویژگی تشریح شده و در آخر، در بخش ۵ و ۶ به ترتیب، ارائه آزمایش ها و نتیجه گیری نهایی صورت گرفته است.

۲- بخش بندی ترکیب های گوسی با فشرده سازی پراتلاف

باید توجه داشت که درستی بخش بندی، متکی بر چگونگی انتخاب مناسب و مؤثر مدل آماری است و از آنجا که مدل ترکیبی گوسی، به طور مؤثری ویژگی های تصویر SAR را به عنوان داده های چندمتغیره تحت وجود نویز اسپیکل مدل می کند، از این روش تصویر، به چندین داده از داده های ترکیبی در خوشه های گوسی متعدد، تبدیل می شود.

در این مقاله، روش خوشه بندی معرفی شده در [۱۶] اتخاذ شده است که به ویژه در بررسی تعداد نامشخص گوسی، به طور مؤثر عمل می کند. در اینجا، خلاصه ای از این روش ارائه خواهد شد. این روش بر مبنای اصل زیر، پایه گذاری شده است:

اصل ۱: (بخش بندی داده با فشرده سازی پراتلاف). این نوع بخش بندی را به شرطی به عنوان یک بخش بندی بهینه تعریف می کنیم که تعداد

ترکیبی کافی است، به علت توانایی تقریب بالایش مدل کند. الگوریتم حداکثر انتظار (EM) که روشی استاندارد است، از مدل ترکیب گوسی برای داده ها استفاده کرده که به بیشترین برآورد احتمال پارامترهای ترکیبی همگرا می شود [۱۴].

به هر حال، از آنجا که ممکن است در ترکیب گوسی با ابعاد ناشناخته سروکار داشته باشیم، الگوریتم خوشه بندی مرسوم EM، در اینجا ناکارآمد بوده و در این کاربرد، باید بهبود یابد [۱۵]. از این رو، ما و همکاران [۱۶] رابطه ای بین فشرده سازی پراتلاف داده و خوشه داده ترکیبی ارائه دادند که در این مقاله، از الگوریتم خوشه بندی برای ترکیبی از توزیع گوسی، استفاده شده است. یانگ و همکاران [۱۵] در سال ۲۰۰۷ ادغامی بافتی مبتنی بر فشردگی (CTM) را پیشنهاد دادند. این روش، روشی بدون نظارت و مبتنی بر ویژگی های بافتی برای بخش بندی تصاویر است. با استفاده از بانک های فیلتر دوبعدی یا پنجره های با سایز ثابت، ویژگی های بافتی به دست می آیند. آن ها توزیع بافتی ویژگی ها را با استفاده از ترکیب هایی از توزیع های گوسی مدل کردند. توزیع های ترکیبی با استفاده از یک الگوریتم ساده خوشه بندی تراکمی مبتنی بر فشردگی پراتلاف، بخش بندی می شوند.

رائو و همکاران بخش بندی کدگذاری شده مرز و بافت (TBES) [۱۷] را که روشی بدون نظارت است، برای بخش بندی تصاویر پیشنهاد دادند. روش آن ها مبتنی بر تحت کنترل قرار دادن کمترین طول تعریف شده (MDL) [۱۸] است. در روش آن ها، ابتدا ویژگی های بافتی ایجاد شده و پنجره ای در اطراف هر پیکسل، اعمال می شود. سپس هر پنجره به صورت بردار درآورده می شود و بعد بردارها با استفاده از PCA کاهش می یابند. آن ها نشان دادند که نواحی بافتی همگن تصاویر با استفاده از توزیع گوسی و مرز بین نواحی با استفاده از کد زنجیره ای وفقی [۱۳] مدل می شوند. در روش ارائه شده آن ها بخش بندی بهینه هر تصویر، آن بخش بندی است که کوتاه ترین طول کد را برای کدگذاری [۱۴] همه بافت ها و همه مرزهای تصویر بدهد. کمترین طول کد با استفاده از پردازش خوشه بندی متراکم [۱۰] که به پنجره هایی با سایز کاهشی اعمال می شود، به دست می آید. مشکلی که در این روش وجود دارد، استفاده از PCA است. PCA فقط در فضای خطی عمل می کند و در همه فضاها پاسخ گو نیست؛ ولی ممکن است داده های ما در فضای خطی نباشند که این امر، عملکرد الگوریتم را محدود می کند.

یو و همکاران با استفاده از ادغام نابرابر سلسله مراتبی مبتنی بر بافت (CHUMSIS) [۶]، الگوریتمی برای بخش بندی تصاویر SAR ارائه دادند. روش آن ها دومرحله ای بود و از علم روان شناختی [۱۲] استفاده می کرد که محدودیت هایی را از بالا و پایین برای ادغام سوپرپیکسل ها ایجاد می کرد. در مرحله اول، الگوریتم، سوپرپیکسل ها را بر اساس معیار تعیین شده ای ادغام می کند. در مرحله دوم با استفاده از فیلتر گابور، ویژگی های سوپرپیکسل ها استخراج می شوند و سپس با استفاده از معیار شباهت، سوپرپیکسل های باقی مانده، مجدداً ادغام می شوند. این روش زمان محاسباتی را با استفاده از ادغام انجام شده در مرحله اول تا

جدول ۱: روش نزولی شدید [۱۵]

الگوریتم ۱: روش نزولی شدید
1: input: the data $V = (v_1, v_2, \dots, v_M) \in R^{L \times M}$ and a distortion ϵ^2 .
2: initialize $\rho = \{S_i = \{v_i\} i = 1, \dots, M\}$.
3: while $ \rho > 1$ do
4: choose distinct groups $S_1, S_2 \in \rho$ such that $\Gamma^*(S_1 \cup S_2) - \Gamma^*(S_1, S_2)$ is minimal.
5: if $\Gamma^*(S_1 \cup S_2) - \Gamma^*(S_1, S_2) \geq 0$ then break;
6: else $\rho = \rho \setminus \{S_1, S_2\} \cup \{S_1, S_2\}$.
7: end
8: output: ρ

تجربه نشان داده است که الگوریتم موجود در جدول ۱ با استفاده از طول کد به‌عنوان یک مقیاس بین گروه‌ها، برای داده‌هایی که دارای ترکیب گوسی هستند، بسیار مناسب بوده و می‌تواند مقادیر هنگفتی از نقاط دورافتاده را تحمل کند. همچنین بررسی‌ها نشان داده که عامل اصلی در همگرایی کلی این الگوریتم، تراکم نمونه‌ها نسبت به اعوجاج ϵ^2 است و همچنین برای به دست آوردن نتایج بهتر، پارامتر اعوجاج ϵ^2 باید نزدیک به واریانس نویز تصویر انتخاب گردد که در ادامه در بخش مربوطه توضیح داده خواهد شد.

۳- مرحله پیش‌پردازش: سوپریکسل‌ها

در روش پیشنهادی، سوپریکسل‌ها جایگزین پیکسل‌ها شده و به‌عنوان واحد عملکرد پایه، اتخاذ شده‌اند. یک سوپریکسل [۱۹] شامل مجموعه‌ای از پیکسل‌ها بوده و دارای برخی از محدودیت‌ها مانند مکان، شدت، لبه و بافت است؛ به‌گونه‌ای که پیکسل‌های مربوط به هر سوپریکسل دارای بیش‌ترین شباهت از نظر شدت یا بافت و غیره هستند. در تصاویر SAR، استفاده از سوپریکسل‌ها عاملی برای کاهش نویز اسپکل بوده و همچنین سرعت محاسباتی را نسبت به روش‌های مبتنی بر پیکسل، افزایش می‌دهد. در این مقاله، روشی مبتنی بر level-set بنام Turbopixel برای تولید سوپریکسل‌ها انتخاب شده است. در این روش، تعدادی دانه که توسط کاربر انتخاب می‌گردد، به‌طور یکنواخت روی سطح تصویر توزیع می‌شوند. سپس دانه‌ها بر اساس رویکرد ساختار محلی تصویر، گسترش می‌یابند. شیب لبه‌های تصویر و انحنای مرز دانه‌ها، معادل تکامل دانه در نظر گرفته می‌شود.

اندازه تقریباً یکنواخت سوپریکسل‌ها در این روش، منطبق بودن آن‌ها بر لبه‌های تصویر، عدم همپوشانی بین سوپریکسل‌ها و از همه مهم‌تر، کاستن اثر نویز اسپکل، باعث شده تا سوپریکسل‌ها به‌عنوان واحد عملکرد پایه در این مقاله منظور گردند. سوپریکسل‌های سه تصویر SAR که توسط Turbopixel [۱۹] تولید شده‌اند، در شکل ۱ نشان داده شده است.

در این مرحله که مرحله ابتدایی پردازش است، تصویر SAR را به N سوپریکسل $\{S_j, j=1, 2, \dots, N\}$ بخش‌بندی می‌کنیم، به‌گونه‌ای که تمامی پیکسل‌های مربوط به هر سوپریکسل دارای برچسب یکسانی باشند.

بیت‌های موردنیاز برای کد کردن داده بخش‌بندی‌شده، تحت اعوجاج داده‌شده، حداقل گردد.

در ابتدای کار، با توجه به اصل بالا باید طول کد (تعداد بیت‌های موردنیاز برای کدگذاری) داده‌های ترکیبی گوسی مشخص باشد که در اینجا از طول کد داده گوسی تک، شروع می‌شود. اگر فرض شود که بردار تصادفی $v \in R^L$ دارای توزیع گوسی $N(\mu, \Sigma)$ باشد، هدف، کدگذاری آن به‌صورتی است که بردار اصلی را بتوان با اعوجاج ϵ^2 به‌شرط $E\|v - \hat{v}\|^2 \leq \epsilon^2$ بازبازی کرد. با توجه به مقاله [۱۶]، تعداد میانگین بیت‌های موردنیاز برای کد کردن بردار v توسط تابع نرخ توزیع گوسی، به‌صورت زیر تقریب زده می‌شود:

$$R(\epsilon) = \frac{1}{2} \log_2 \det(I + \frac{L}{\epsilon^2} \Sigma) \quad (1)$$

که در آن Σ ، کوواریانس است.

حال M نمونه رسم‌شده از توزیع گوسی $V = (v_1, v_2, \dots, v_M) \in R^{L \times M}$ را در نظر گرفته، به‌گونه‌ای که $\mu = \frac{1}{M} \sum_{i=1}^M v_i$ و $\bar{V} = V - \mu \cdot 1_{1 \times M}$ باشند. همچنین با فرض اینکه $\hat{\Sigma} = \frac{1}{M} \bar{V} \bar{V}^T$ تخمینی از Σ باشد، در آن صورت خواهیم داشت:

$$R(\epsilon, V) = \frac{1}{2} \log_2 \det(I + \frac{L}{\epsilon^2 M} \bar{V} \bar{V}^T) \quad (2)$$

در اینجا برای کد کردن M بردار در V به $MR(V)$ بیت‌گذاری که با $LR(V)$ معرفی می‌شود، نیاز خواهیم داشت. از آنجاکه داده، دارای میانگین غیر صفر است، به $\frac{L}{2} \log_2(1 + \frac{\mu^T \mu}{\epsilon^2})$ بیت اضافی نیز برای کدگذاری بردار میانگین μ نیاز است. از این‌رو، تعداد کل بیت‌های موردنیاز برای کدگذاری مجموعه داده V به‌صورت زیر است:


$$\Gamma(V) = \frac{M+L}{2} \log_2 \det(I + \frac{L}{\epsilon^2 M} \bar{V} \bar{V}^T) + \frac{L}{2} \log_2(1 + \frac{\mu^T \mu}{\epsilon^2}). \quad (3)$$

حال، اگر مجموعه M بردار $V = (w_1, w_2, \dots, w_M)$ در K گروه غیر همپوشان $V = w_1 \cup w_2 \cup \dots \cup w_K$ تقسیم‌بندی شوند، تعداد بیت‌های موردنیاز برای کد کردن داده بخش‌بندی شده، به‌صورت زیر خواهد بود:

$$\Gamma^s(w_1, \dots, w_k) = \sum_{i=1}^K \{\Gamma(w_i) - |w_i| \log_2(|w_i|/M)\} \quad (4)$$

که جمله دوم در عبارت بالا، تعداد بیت‌های موردنیاز برای کدگذاری اعضای M نمونه در گروه K ، با استفاده از روش Huffman است.

سپس برای داشتن یک بخش‌بندی بهینه و محاسبه طول کد حداقل، از روش نزولی شدید استفاده می‌شود. در مرحله ابتدایی، هر بردار v_i به‌عنوان یک گروه، تلقی می‌گردد. سپس در هر تکرار، یک جفت از گروه‌های S_i و S_j ادغام شده، به‌طوری‌که کاهش در طول کدگذاری، ناشی از حداکثر شدن کدگذاری هم‌زمان S_i و S_j باشد. باید توجه داشت که الگوریتم، زمانی متوقف می‌گردد که طول کدگذاری، نتواند توسط ادغام هر جفت از گروه‌ها، باز هم کاهش پیدا کند. در جدول ۱، الگوریتم روش نزولی شدید، ارائه شده است.



شکل ۱: سوپریکسل های سه تصویر SAR.

برای رسیدن به این هدف، استفاده از آشکارساز لبه می تواند بسیار مفید باشد. آشکارساز لبه می تواند اطلاعات غیر ضروری تصویر را با حفظ ویژگی های ساختاری مهم، کم کند. از این رو، ما از آشکارساز لبه Canny که روشی محبوب به شمار می رود، استفاده می کنیم. این روش به کم کردن اثر نویز اسپکل کمک می کند، به گونه ای که در ابتدا تصویر را با فیلتر گوسی با ماسک ساده کانالو می کند. سپس، بر مبنای تصویر یکنواخت شده، مشتقات در هر دو جهت x و y محاسبه می گردند؛ بدین گونه مقدار شیب تصویر به دست می آید. سپس، پروسه حذف نقاط غیر ماکزیمم، اجرا می شود که در آن پیکسل هایی که ماکزیمم محلی نیستند، حذف می گردند. مرحله نهایی در تشخیص گر لبه Canny، عملگر هیستریزیس^{۱۸} است که در آن پیکسل ها یا به عنوان لبه یا غیر لبه و یا در بین این دو حالت مشخص می گردند. برای این کار از دو حد آستانه بالا (β_2) و پایین (β_1) استفاده می شود. اگر مقدار پیکسل از β_2 بیش تر بود، آن پیکسل، لبه در نظر گرفته می شود و پیکسل هایی که مقادیرشان بین دو حد آستانه باشد، در صورتی به عنوان لبه در نظر گرفته می شوند که بتوان اتصال بین آن پیکسل و پیکسل های لبه ایجاد کرد و اگر مقدار پیکسل از β_1 کم تر بود، آن پیکسل، شانسی برای لبه بودن ندارد.

در ادامه برای ادغام کردن سوپریکسل هایی که بر روی لبه قرار ندارند، ابتدا باید تمامی سوپریکسل های همسایه را با استفاده از گراف مجاورت ناحیه^{۱۹} (RAG) مشخص کنیم؛ بدین گونه فقط سوپریکسل هایی مورد بررسی قرار گیرند که از نظر مکانی، همسایه باشند. RAG معمولاً در دیگر روش های خوشه بندی ادغام و جداسازی استفاده می شود [۵] و [۱۵]. RAG برای هر سوپریکسل، لیست همسایگی $\{i\}$ را ارائه می دهد؛ به گونه ای که اندیس z در فهرست $\{i\}$ قرار دارد، اگر S_i در همسایگی S_j باشد. سپس، جفت سوپریکسل های مجاورتی که شرایط زیر را دارا باشند، ادغام می گردند:

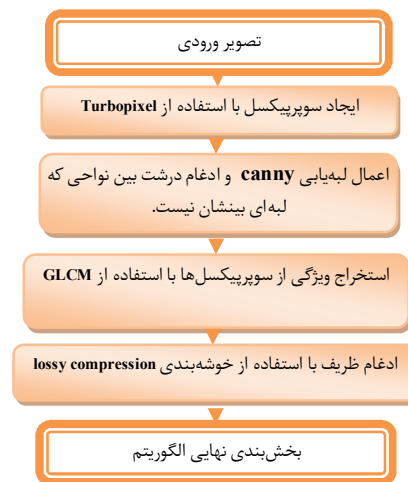
$$\left| \frac{\text{Count boundary pixels that on edge}}{\text{Count boundary pixels}} \right| < \alpha \quad i \neq j, i, j = 1, 2, \dots, N \quad (5)$$

که در رابطه فوق، α شرط توقف و تعیین مرز بین سوپریکسل ها است. در صورت برقراری شرط بالا، نتیجه می گیریم که دو سوپریکسل S_i و S_j ، مرز مجزایی نداشته و ادغام می گردند؛ سپس در یک جستجو،

۴- الگوریتم بخش بندی نظارت نشده سلسله مراتبی

این الگوریتم در دو مرحله طراحی شده است که در هر دو مرحله با توجه به محدودیت های تعریف شده، به ادغام سوپریکسل ها می پردازد. مرحله اول، ادغام سوپریکسل هایی است که لبه مجزایی بین آن ها وجود نداشته باشد. وجود این مرحله برای بالا بردن سرعت پردازش است.

مرحله دوم، بر اساس روش خوشه بندی معرفی شده در بخش ۲، به ادغام سوپریکسل های به دست آمده از مرحله یک می پردازد. این مرحله در بالا بردن دقت روش پیشنهادی، مؤثر است. بنابراین روش ارائه شده در این مقاله، هر دو فاکتور دقت و سرعت را با هم بهبود می بخشد. فلوچارت روش پیشنهادی در شکل ۲ نشان داده شده است.



شکل ۲: فلوچارت الگوریتم پیشنهادی

۴-۱- مرحله اول: ادغام درشت

زمانی که یک تصویر مورد بررسی قرار می گیرد، همیشه اولین چیزی که مطابق با سیستم بینایی انسان به ذهن خطور می کند، اشیاء بزرگ و مختلف بوده و جزئیاتی مانند شکل دقیق اشیاء در نظر گرفته نمی شوند. از این رو، در مرحله اول نیز، چنین پروسه ای مورد توجه قرار می گیرد؛ یعنی در ابتدا، سوپریکسل هایی که مرز مشخصی بین آن ها وجود نداشته باشد، ادغام می شوند.

سوپریکسل، چندین ماتریس GLCM در راستاهای مختلف گرفته می‌شود. اگرچه این ایده، سرعت الگوریتم را تا حدودی کاهش می‌دهد، اما دقت بخش‌بندی افزایش می‌یابد.

منظور از محاسبه ماتریس GLCM در جهت خاص، جهت یا زاویه‌ای است که جفت پیکسل‌های آن ماتریس با یکدیگر می‌سازند. به‌طور کلی از چهار زاویه اصلی ۰، ۴۵، ۹۰ و ۱۳۵ درجه جهت استخراج این ویژگی‌ها استفاده می‌شود [۲۱]. ویژگی مهم دیگری که در ساخت ماتریس GLCM نقش به‌سزایی دارد، مسافت پیکسل‌ها است که در اینجا "یک" قرار داده شده است. معمولاً مسافت پیکسل کوتاه‌تر، ویژگی‌های بافت مناسب‌تری ارائه می‌دهد.

۴-۲-۲- اجرای روش خوشه‌بندی

باید توجه داشت که تعداد سوپریکسل‌ها پس از اجرای مرحله اول، به میزان بالایی کاهش یافته‌اند. از این‌رو محاسبه بردارهای ویژگی کلی تصویر از هر سوپریکسل، با سرعت بالاتری انجام خواهد شد. پس از این‌که بردار ویژگی v_i مربوط به هر سوپریکسل با توجه به توضیحات بالا محاسبه شد، با استفاده از روش نزولی شدید بیان‌شده در جدول ۱، به محاسبه طول کد حداقل و رسیدن به یک بخش‌بندی بهینه می‌پردازیم.

البته همان‌گونه که در اصل ۱ در بخش ۲ گفته شد، بخش‌بندی بهینه تحت اعوجاجی معین صورت می‌گیرد که اغلب مقدار آن تقریباً برابر با انحراف معیار نویز تصویر انتخاب می‌شود.

در مرحله ابتدایی، هر بردار v_i به‌عنوان یک گروه تلقی می‌گردد. سپس در هر تکرار، یک جفت از گروه‌های S_i و S_j ادغام می‌شوند؛ به‌طوری‌که:

۱- هیچ‌گونه لبه‌ای بین دو سوپریکسل S_i و S_j وجود نداشته باشد؛ که این شرط توسط شرط مرحله اول دوباره اجرا می‌شود؛

۲- دو سوپریکسل S_i و S_j دارای شدت روشنایی تقریباً مشابهی باشند؛

۳- کاهش در طول کدگذاری ناشی از حداکثر شدن کدگذاری هم‌زمان S_i و S_j باشد.

باید توجه داشت که الگوریتم، زمانی متوقف می‌گردد که طول کدگذاری دیگر نتواند توسط ادغام هر جفت از گروه‌ها کاهش یابد. الگوریتم مرحله دوم در جدول ۳ بیان شده است.

جدول ۳: الگوریتم مرحله دوم

الگوریتم ۳: مرحله دوم	
-	یافتن جفت سوپریکسل‌های همسایه
-	استخراج بردارهای ویژگی از سوپریکسل‌ها
-	یافتن جفت سوپریکسل‌هایی که معادله (۵) را ارضا کنند و دارای شدت روشنایی تقریباً مشابهی باشند.
-	اجرای الگوریتم ۱

تمامی جفت سوپریکسل‌های همسایه بررسی می‌گردند تا نهایتاً هیچ سوپریکسلی برای ادغام با توجه به شرایط معادله (۵) وجود نداشته باشد.

الگوریتم مرحله اول در جدول ۲ نشان داده شده است.

جدول ۲: الگوریتم مرحله اول

الگوریتم ۲: مرحله اول	
-	یافتن لبه‌های تصویر
-	پیدا کردن جفت سوپریکسل‌های همسایه
-	یافتن جفت سوپریکسل‌هایی که معادله (۵) را ارضا کنند و ادغام نمودن آن‌ها تا زمانی که جفت سوپریکسلی برای ادغام وجود نداشته باشد.

۴-۲-۲- مرحله دوم: ادغام ظرف

در این مرحله با استفاده از روش خوشه‌بندی معرفی‌شده در بخش ۲، به ادغام سوپریکسل‌هایی پرداخته می‌شود که در مرحله اول، ادغام بین آن‌ها صورت نگرفته است و نیاز به ادغام دارند که این ادغام با توجه به ویژگی‌های بافت و روشنایی تصویر، صورت می‌گیرد. البته در این مرحله باید شرایط مرحله اول نیز در نظر گرفته شود تا از ادغام سوپریکسل‌های بیش‌تر، جلوگیری به عمل آید.

استفاده از ترکیب دو ویژگی بافت و روشنایی در این الگوریتم، کمک شایانی به توصیف دقیق‌تر تصویر SAR می‌کند. از آنجایی‌که بافت، ویژگی آماری تصویر را شرح می‌دهد و روشنایی نیز به بیان قدرت بازتاب رادار [۵] می‌پردازد؛ لذا هر دو، ویژگی‌های مهمی برای توصیف تصویر SAR هستند. ساخت بردارهای ویژگی و اجرای روش خوشه‌بندی، دو فرآیند مهم در این مرحله هستند که در ادامه شرح داده می‌شوند.

۴-۲-۱- ساخت بردارهای ویژگی

از آنجایی‌که این الگوریتم به بخش‌بندی پیکسل‌ها بر مبنای گروه‌بندی بردارهای ویژگی می‌پردازد، انتخاب روشی مناسب برای استخراج ویژگی‌های بافت بسیار مهم است. ویژگی‌های مناسب باید به‌گونه‌ای انتخاب گردند که بین پوشش‌های مختلف سطح زمین، تمایز قائل شوند. در این مقاله سعی شده تا با ترکیب تمامی ویژگی‌ها نظیر لبه، بافت و روشنایی، این هدف به دست آید. در اینجا برای استخراج ویژگی‌های بافت، بر روی کارایی ویژگی‌های آماری که از ماتریس هم‌رخداد سطح خاکستری (GLCM) گرفته شده‌اند، تمرکز شده است. روش GLCM، غالباً در تحلیل و استخراج ویژگی‌های بافت تصاویر SAR استفاده می‌شود [۲۰]. در این مقاله، علاوه بر ویژگی‌های پیشنهادی Haralick [۳]، ویژگی‌های مرتبه سوم و چهارم آماری همچون چولگی و کشیدگی [۱] نیز به آن‌ها اضافه شده است. ویژگی‌های بیش‌تر، موجب عملکرد بهتر الگوریتم پیشنهادی می‌گردد.

از ماتریس GLCM غالباً جهت شناسایی ویژگی‌های جهت‌ی و تشخیص وجود تناوب‌های مختلف در راستاهای متفاوت در یک تصویر استفاده می‌شود. در یک تصویر غالباً این ویژگی‌ها در جهت‌های مختلف وجود دارند. بنابراین برای استخراج مناسب ویژگی‌ها از هر

۵- ارزیابی الگوریتم پیشنهادی

روی دو تصویر شبیه سازی شده و سه تصویر حقیقی انجام شده است. در بررسی های به عمل آمده، بهترین نتیجه بخش بندی از ۱۰ بار اجرای الگوریتم، انتخاب شده است.

۵-۱- بخش بندی تصاویر شبیه سازی شده

برای داشتن ارزیابی عددی از الگوریتم پیشنهادی، لازم است که تصویر زمین مرجع را داشته باشیم. بدیهی است که داشتن تصویر زمین مرجع از تصاویر حقیقی، کار ساده ای نبوده و در برخی موارد، بسیار دشوار نیز است؛ لذا جهت بررسی کارایی الگوریتم های بخش بندی، تصاویر راداری را با اضافه نمودن نویزهای مختلف، شبیه سازی نموده و بدین ترتیب با داشتن تصویر زمین مرجع، می توان خطای بخش بندی و دقت را محاسبه نمود. در این زیربخش، روش پیشنهادی را مورد ارزیابی و مقایسه قرار دادیم.

بدین منظور، آن را با الگوریتم های مختلف بر روی تصاویر شبیه سازی شده، مورد مقایسه قرار دادیم.

شکل های ۳ و ۴، نتیجه مقایسه روش پیشنهادی با الگوریتم های TBES و CTM بر روی تصاویر شبیه سازی شده SAR را نشان می دهد.


در این بخش از مقاله، نتایج به دست آمده از اعمال روش بخش بندی را روی تصاویر SAR بررسی کرده و نتایج را با نتیجه الگوریتم های k-means, C-MLL, JRGs, CHUMSIS, CTM و TBES مقایسه می کنیم.

پارامترهای به کار برده شده در این روش به صورت زیر هستند:

پارامتر شرط توقف α تعداد سوپریکسل هایی را که در مرحله اول ادغام می گردند، کنترل می کند. در مقادیر بزرگ برای α ، سوپریکسل های بیش تری ادغام می گردند؛ در صورتی که این مقدار خیلی بزرگ انتخاب گردد، مقادیر زیادی از سوپریکسل ها ادغام شده و خطا رخ می دهد. برعکس، اگر α بسیار کوچک انتخاب شود، در مرحله اول سوپریکسل های کمی ادغام شده و در نتیجه هزینه محاسباتی مرحله دوم افزایش می یابد.

در این مقاله، α متناسب با تصویر و تعداد سوپریکسل ها انتخاب می گردد؛ به گونه ای که در مرحله اول، بیش ترین ادغام سوپریکسل ها را خواهیم داشت. سپس در مرحله دوم، مقدار ϵ به صورت تجربی برای تصاویر SAR، مقدار 0.02 در نظر گرفته شده است. در این حالت بهترین نتیجه را در به حداقل رساندن طول کد خواهیم داشت.

برای به تصویر کشیدن قابلیت روش بخش بندی سلسله مراتبی با استفاده از فشرده سازی پراتلاف داده بر روی تصاویر SAR، آزمایش ها بر



شکل ۳: (الف) تصویر زمین مرجع (256×256) ، (ب) تصویر نویزی (شبیه سازی شده)، (پ) بخش بندی به دست آمده با TBES، (ت) نتیجه بخش بندی با استفاده از CTM و (ث) نتیجه بخش بندی توسط الگوریتم پیشنهادی

شکل های ۳ (الف)، (ب)، (ت) و (ث)، به ترتیب نتایج الگوریتم های TBES، CTM و الگوریتم پیشنهادی را نشان می دهند.

شکل ۳ (الف) تصویری چهار کلاسه با اندازه 256×256 را نشان می دهد. با الهام از تصاویر حقیقی SAR، این تصویر با نویز نمک و لفل 30% نویزی شده است که در شکل ۳ (ب) نشان داده شده است.

را نشان می‌دهد، Q نامیده شود، با توجه به اینکه P و Q دارای اندازه یکسانی هستند، تصویر P از Q کم شده و تصویر حاصل از این تفاضل، باینری و E نامیده می‌شود. پیکسل‌هایی از تصویر E که سیاه نیستند، نشان‌دهنده خطا در بخش‌بندی تصویر موردنظر توسط آن الگوریتم است. پس تعداد پیکسل‌های سفید تصویر E را بر تعداد کل پیکسل‌های تصویر، تقسیم کرده، خطای حاصل از بخش‌بندی آن الگوریتم، به دست می‌آید. بنابراین بخش‌بندی هر الگوریتم با استفاده از رابطه (۶) به صورت زیر، به دست می‌آید:

$$Error\ rate = \frac{Q - P}{A \times B} \times 100 = \frac{E}{A \times B} \times 100 \quad (۶)$$

در جدول ۴، نتایج بخش‌بندی به روش‌های مختلف، باهم مورد مقایسه قرار گرفته است.

همان‌طور که در جدول ۴ نشان داده شده، برای تصویر شکل ۳، خطای روش TBES از CTM بیش‌تر است و برای تصویر شکل ۴، روش CTM دارای بیش‌ترین خطا در بخش‌بندی بوده است. برای هر دو تصویر شکل ۳ و ۴، الگوریتم پیشنهادی دارای کم‌ترین مقدار خطا در بخش‌بندی است.


همان‌طور که در شکل ۳ (پ) دیده می‌شود، TBES در بخش‌بندی این تصویر، خطای بالایی دارد و این تصویر را دو کلاسه تشخیص داده است. CTM بخش‌بندی را بهبود داده؛ ولی در سه ناحیه از تصویر، در شناسایی مرزها، ناموفق عمل کرده است. الگوریتم پیشنهادی، بهترین عملکرد را داشته و مرزها به خوبی تشخیص داده شده‌اند.

در شکل ۴ (الف)، (ب)، (پ)، (ت) و (ث) به ترتیب تصاویر دو کلاسه، تصویر نویزی 10-look شبیه‌سازی شده و بخش‌بندی با استفاده از الگوریتم‌های CTM، TBES و الگوریتم پیشنهادی نشان داده شده‌اند. TBES در مرز تمامی شکل‌های بیضی، دایره، شش‌ضلعی و مستطیل مشکل پیدا کرده است. CTM بخش‌بندی را بهبود داده ولی در مرز شش‌ضلعی خطای بالایی مشاهده می‌شود و در این مرز ناموفق عمل کرده است. الگوریتم پیشنهادی، همان‌طور که در شکل ۴ (ث) نشان داده شده، در مرزها بهتر عمل کرده و کم‌ترین خطا را دارد.

برای به دست آوردن خطای بخش‌بندی هر الگوریتم، ابتدا تصویر با اندازه $B \times A$ در نظر گرفته می‌شود. اگر نتیجه حاصل از بخش‌بندی هر الگوریتم، P و تصویر زمین مرجع که بخش‌بندی صحیح تصویر موردنظر

جدول ۴: مقایسه خطای نتایج روش‌های مختلف بر روی تصاویر شبیه‌سازی شده

شکل	خطا (%)	
	CTM	TBES
۳	۱/۷۳	۱۹/۳۶
۴	۰/۵۷	۰/۴۳



شکل ۴: (الف) تصویر زمین مرجع (256×256) ، (ب) تصویر نویزی، (پ) نتیجه بخش‌بندی به دست آمده با TBES، (ت) نتیجه بخش‌بندی با CTM و (ث) نتیجه بخش‌بندی توسط الگوریتم پیشنهادی

۵-۲- بخش بندی تصاویر حقیقی

روش پیشنهادی همچنین، با سه الگوریتم دیگر مورد مقایسه قرار گرفت. روش های مقایسه شده عبارتند از:

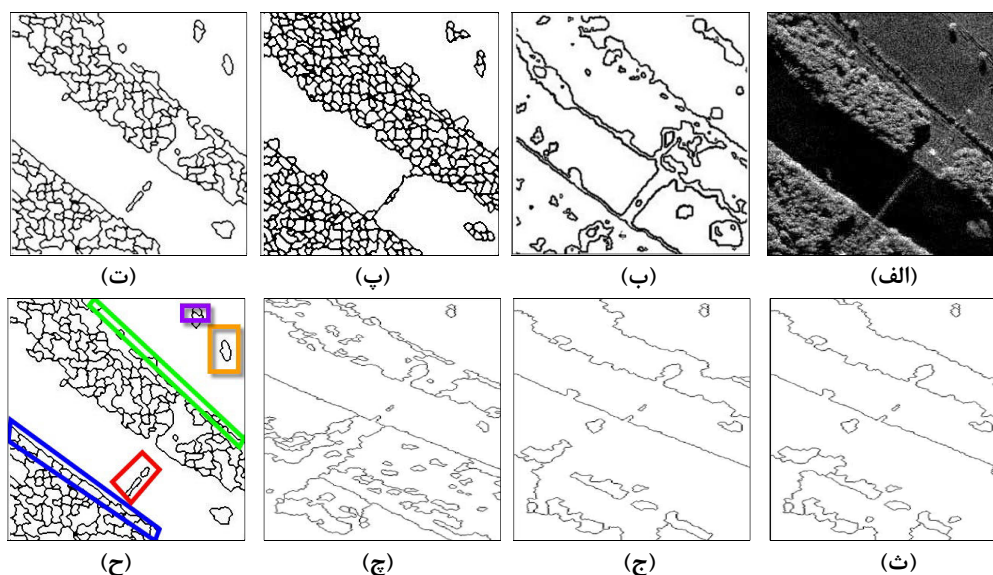
روش CHUMSIS، روش منطقی (لجستیک) چندسطحی کلاسیک^{۲۰} (C-MLL) و روش رشد ناحیه ای با استفاده از معناشناسی تکرارشونده^{۲۱} (IRGS). روش های C-MLL و IRGS هر دو روش هایی مبتنی بر میدان های تصادفی مارکوف^{۲۲} (MRF) هستند [۲۲]. C-MLL برای جبران مرز بین نواحی بخش بندی شده مختلف، مدلی بافت - مکانی^{۲۳} طراحی می کند. IRGS، ابتدا از چندین مرحله توابع جبران سازی لبه افزایشی^{۲۴} برای تقریب مدل بافت - مکانی استفاده می کند و سپس یک رشد ناحیه ای برای ادغام نواحی که بخش بندی بیش از حد در آن رخ داده است، مورداستفاده قرار می گیرد؛ که این کار در هر تکرار الگوریتم، انجام می شود. پارامترهای انتخابی برای این سه الگوریتم، مطابق [۵ و ۲۲] است.

تصویر نشان داده شده در شکل ۵ (الف) قسمتی از یک تصویر SAR در باند Ku با رزولوشن مکانی 1-m در ناحیه رودخانه Rio Grand نزدیک ایالت Albuquerque است. این تصویر شامل سه نوع از پوشش زمینی است: رودخانه، جنگل و محصولات کشاورزی.

این تصویر از نظر بافت و روشنایی دارای پیچیدگی هایی است. اول این که روشنایی محصولات کشاورزی تا حدود زیادی متفاوت است و بعضی نواحی مربوط به محصولات کشاورزی در روشنایی، به جنگل شبیه اند. دیگر این که جنگل، دارای بافت با مقدار بزرگ است؛ در نتیجه، ناحیه شامل سایه های بزرگ، شبیه به رودخانه است. این تغییرات و تفاوت ها، این تصویر SAR را برای بخش بندی مشکل می سازد.

در این حالت، بخش بندی به دست آمده توسط K-means در شکل ۵ (ب) نشان داده شده است. همان طور که مشهود است، مرز بین رودخانه و جنگل، دقیقاً مشخص نشده است. علاوه بر این، بعضی نواحی در ناحیه داخل رودخانه، به درستی طبقه بندی نشده اند و خطاهای زیادی در ناحیه رودخانه به چشم می خورد که اشتباهاً پوشش گیاهی یا جنگل تشخیص داده شده اند. بخش بندی به دست آمده توسط مرحله اول و نتیجه نهایی بخش بندی به ترتیب در شکل ۵ (پ) و (ت) نشان داده شده است. همان طور که مشاهده می شود، بیش تر سوپریکسل ها در مرحله اول ادغام شده اند. همان طور که در شکل ۵ (ت) مشهود است، مرزهای نواحی به خوبی تعریف شده اند و نواحی کوچک درون رودخانه نیز قابل مشاهده هستند. همچنین در ناحیه جنگل، درخت ها و سایه ها نیز متمایز شده اند و نیز درختان موجود در محصولات کشاورزی نیز به خوبی مشاهده می شوند. شکل های ۵ (ث)، (ج) و (چ)، به ترتیب، بخش بندی با استفاده از C-MLL، IRGS و CHUMSIS را نشان می دهند. شکل ۵ (ح) اختلاف بخش بندی توسط الگوریتم پیشنهادی و سایر الگوریتم ها است.


ناحیه ای که با نارنجی مشخص شده در الگوریتم های C-MLL، IRGS و CHUMSIS تشخیص داده نشده است. ناحیه آبی رنگ، مرز رودخانه را نشان می دهد که در الگوریتم پیشنهادی به خوبی شناسایی شده است. ناحیه قرمز، پوشش گیاهی است که در رودخانه قرار دارد که سه الگوریتم C-MLL، IRGS و CHUMSIS به اشتباه آن را جزئی از رودخانه بخش بندی نموده اند. ناحیه سبز رنگ در الگوریتم پیشنهادی نسبت به k-means، C-MLL و IRGS بهتر تشخیص داده شده و ناحیه بنفش ناحیه ای است که k-means نتوانسته به درستی آن را بخش بندی کند.




شکل ۵: (الف) تصویر SAR در باند Ku از ناحیه ای از رودخانه Rio Grand واقع در ایالت Albuquerque (۲۵۶ × ۲۵۶)، (ب) بخش بندی به دست آمده با K-means، (پ) نتیجه بخش بندی مرحله اول از الگوریتم پیشنهادی، (ت) بخش بندی نهایی بعد از مرحله دوم از الگوریتم پیشنهادی، (ث) بخش بندی به دست آمده با C-MLL، (ج) بخش بندی با استفاده از IRGS، (چ) بخش بندی با استفاده از CHUMSIS و (ح) برخی از تفاوت های بارز بین نتیجه بخش بندی به دست آمده توسط الگوریتم پیشنهادی و سایر الگوریتم ها

شکل ۶ (ب) بخش‌بندی با استفاده از روش خوشه‌بندی k-means را نشان می‌دهد که در آن، ناحیه دریا به‌خوبی جدا شده است؛ اما مرز بین دریا و کوه و همچنین مرز بین دریا و ناحیه مسکونی به‌خوبی تعریف نشده است. در شکل ۶ (پ)، نتیجه حاصل از اعمال مرحله اول از روش بخش‌بندی پیشنهاد شده در این مقاله نشان داده شده است که در آن سوپرپیکسل‌های اولیه تولید شده است. در نهایت شکل ۶ (ت)، نتیجه حاصل از اعمال مرحله دوم (مرحله نهایی) از الگوریتم پیشنهاد شده در این مقاله را نشان می‌دهد. با توجه به شکل ۶ (ت) که نتیجه بخش‌بندی نهایی روش پیشنهادی ما را نشان می‌دهد، نواحی مربوط به هر بخش، کاملاً یکدست بوده و همچنین الگوریتم پیشنهادی توانسته است که مرز بین دو کوه را نیز به‌خوبی تعریف کند.


بررسی بعدی بر روی یک تصویر SAR در باند X از کشور سوئیس است که به‌صورت three-look (یعنی با استفاده از متوسط‌گیری از سه تصویر مستقل با سه زاویه دید مختلف از سنسور) جهت کاهش نویز موجود در تصاویر SAR گرفته شده است. این تصویر توسط مؤسسه Space Radar Laboratory Missions در سال ۱۹۹۴ به دست آمده است. تصویر اصلی در شکل ۶ (الف) نشان داده شده است. این تصویر شامل سه نوع از پوشش زمینی است: دریا، ناحیه مسکونی و کوه. سمت چپ تصویر، شامل کوه‌ها بوده، در سمت راست بالای تصویر، دریا قرار گرفته و در نهایت، سمت راست پایین تصویر، شامل ناحیه مسکونی است. پیچیدگی این تصویر، بخش‌بندی و متمایز نمودن ناحیه مسکونی و ناحیه کوهستانی است.




(ب)



(الف)



(ت)



(پ)

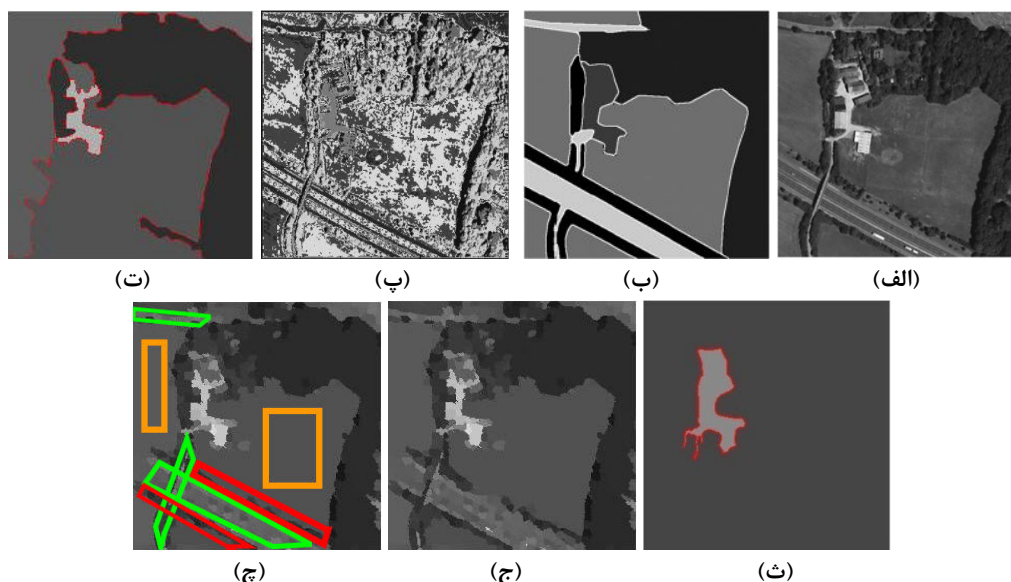
شکل ۶: (الف) تصویر X-SAR از Switzerland (۲۵۶ × ۲۵۶)، (ب) بخش‌بندی به‌دست‌آمده با K-means، (پ) نتیجه بخش‌بندی مرحله اول و (ت) بخش‌بندی نهایی بعد از مرحله دوم توسط الگوریتم پیشنهادی

در شکل ۷ (چ)، برخی از نواحی جاده مشخص شده توسط الگوریتم پیشنهادی با رنگ سبز و برخی از نواحی علفزار با رنگ نارنجی و برخی از نواحی جنگل در اطراف جاده نیز با رنگ سبز نشان داده شده‌اند که سایر الگوریتم‌ها قادر به شناسایی این نواحی نبوده‌اند. نتیجه مقایسه خطای الگوریتم پیشنهادی با سایر الگوریتم‌ها بر روی شکل ۷، در جدول ۵ آورده شده است. همان‌طور که مشاهده می‌شود، روش پیشنهادی دارای کم‌ترین مقدار خطا در مقایسه با سه روش دیگر است. با توجه به این‌که تصویر زمین مرجع شکل‌های ۵ و ۶ در دسترس نبود، مقایسه بر روی آن‌ها فقط به صورت کیفی انجام شد.

جدول ۵: مقایسه خطای نتایج روش‌های مختلف بر روی تصویر

حقیقی سنجش‌ازدور

شکل	خطا (%)		
	CTM	TBES	k-means
۷	۴/۴۶	۱۲/۰۹	۴۴/۰۳
	۱/۷۳		



شکل ۷: (الف) تصویر سنجش‌ازدور، (ب) تصویر زمین مرجع، (پ) بخش‌بندی به دست آمده با **k-means**، (ت) نتیجه بخش‌بندی با استفاده از **TBES**، (ث) بخش‌بندی به دست آمده با **CTM**، (ج) بخش‌بندی به دست آمده با الگوریتم پیشنهادی و (چ) تفاوت‌های بارز بین نتیجه بخش‌بندی به دست آمده توسط الگوریتم پیشنهادی با سایر الگوریتم‌ها.

۵-۳- دیتاست برکلی

به منظور ارزیابی بیش‌تر الگوریتم پیشنهادی و نشان دادن عمومیت آن، روش پیشنهادی بر روی تصاویر دیتاست صحنه‌های طبیعی برکلی [۲۳] که دیتاستی استاندارد و مبنای اعمال شد و نتایج حاصل از بخش‌بندی با سایر الگوریتم‌ها مورد مقایسه قرار گرفت. شکل ۸ نتیجه مقایسات انجام شده بر روی تصاویر این دیتاست را نشان می‌دهد.

شکل ۸، از راست به چپ، تصویر اصلی، بخش‌بندی با استفاده از الگوریتم **CTM**، بخش‌بندی با استفاده از الگوریتم پیشنهادی و تفاوت‌های بارز بین نتیجه بخش‌بندی دو الگوریتم پیشنهادی و **CTM** را نشان می‌دهد. در شکل ۸، در بالاترین تصویر و سمت چپ، آن دسته از نواحی که با رنگ سبز مشخص شده‌اند، جزئیاتی هستند که روش

شکل ۸، از راست به چپ، تصویر اصلی، بخش‌بندی با استفاده از الگوریتم **CTM**، بخش‌بندی با استفاده از الگوریتم پیشنهادی و تفاوت‌های بارز بین نتیجه بخش‌بندی دو الگوریتم پیشنهادی و **CTM** را نشان می‌دهد. در شکل ۸، در بالاترین تصویر و سمت چپ، آن دسته از نواحی که با رنگ سبز مشخص شده‌اند، جزئیاتی هستند که روش

سیستم عامل ویندوز در محیط نرم‌افزاری MATLAB اندازه‌گیری شد. زمان‌های گزارش‌شده در جدول ۷ برای روش‌های C-MLL و IRGS، میانگین زمان اجرای برنامه در ۳۰ تکرار است. همان‌طور که در جدول ۷ مشاهده می‌گردد، زمان اجرای برنامه برای دو الگوریتم C-MLL و IRGS زیاد است؛ چون هر دو این الگوریتم‌ها مبتنی بر MRF هستند که نیاز به چندین تکرار برای رسیدن به مقدار بهینه دارند و در هر بار تکرار نیز، برچسب‌های هر سوپریکسل باید مورد محاسبه قرار گیرند. از آنجایی که در روش IRGS از مکانیسم رشد ناحیه‌ای برای کاهش تعداد سوپریکسل‌ها در هر تکرار استفاده می‌شود، زمان آن خیلی کم‌تر از C-MLL است (کم‌تر از نصف زمان اجرای مورد نیاز برای C-MLL).


الگوریتم‌های CTM و TBES نیز زمان اجرای بالاتری نسبت به روش پیشنهادی دارند. با توجه به اینکه الگوریتم CHUMSIS الگوریتمی قطعی است، زمان اجرای کم‌تری دارد. الگوریتم CHUMSIS با استفاده از دو مرحله ادغام درشت و ظریف، دارای زمان اجرای کم‌تری نسبت به دو الگوریتم دیگر است. این الگوریتم از فیلتر گابور برای استخراج ویژگی استفاده می‌کند که پیچیدگی محاسباتی بیش‌تری نسبت به GLCM دارد. از آنجایی که برای استخراج ویژگی در الگوریتم پیشنهادی از GLCM استفاده شده است، الگوریتم پیشنهادی، کم‌ترین زمان اجرا را دارد.

در شکل ۸، پایین‌ترین تصویر و سمت چپ، نواحی مختلفی در قسمت سیاه‌رنگ مشخص شده‌اند. این نواحی، جزء آن دسته از نواحی هستند که در الگوریتم CTM به اشتباه بخش‌بندی شده‌اند؛ در حالی که توسط الگوریتم پیشنهادی، به درستی تشخیص داده شده و بخش‌بندی موفق بر روی آن‌ها انجام شده است. ناحیه سفیدرنگ نیز لبه و ناحیه‌هایی که در این الگوریتم به اشتباه تشخیص داده شده را نشان می‌دهد.

در جدول ۶ خطای بخش‌بندی الگوریتم CTM با الگوریتم پیشنهادی بر روی تصاویر دیتاست استاندارد برکلی، مورد مقایسه قرار گرفته است که نتایج این جدول حاکی از آن است که الگوریتم پیشنهادی، کم‌ترین خطا و بهترین عملکرد را دارد.

۴-۵- زمان اجرای برنامه


به منظور انعکاس بیش‌تر توانایی روش پیشنهادی در مدیریت کردن داده‌ها با سایز بالا، روش پیشنهادی در شکل ۹ بر روی سه تصویر سه‌کلاسه، چهارکلاسه و پنج‌کلاسه با نویزهای 1-look الی 10-look، یعنی در مجموع، ۳۰ تصویر، مورد آزمایش و مقایسه قرار گرفت. اندازه همه تصاویر 512×512 است. شکل‌های (الف) و (ب) به ترتیب، تصاویر 1-look و زمین مرجع را برای این سه تصویر نشان می‌دهند که به ترتیب از چپ به راست، تصاویر سه‌کلاسه، چهارکلاسه و پنج‌کلاسه هستند. زمان اجرای برنامه با استفاده از یک کامپیوتر شخصی پنج‌هسته‌ای (core (TM) i5)، با CPU ۲/۵۰ گیگاهرتزی و




شکل ۸: بخش‌بندی بر روی دیتاست برکلی؛ از راست به چپ، تصویر اصلی، بخش‌بندی با استفاده از CTM، بخش‌بندی با استفاده از الگوریتم پیشنهادی و تفاوت‌های بارز بین این دو بخش‌بندی

مینای برکلی

خطای بخش‌بندی (%)		شکل (۸)
روش پیشنهادی	CTM	تصاویر بالا تصاویر وسط تصاویر پایین میانگین بر روی کل دیتاست برکلی
۲/۸۸	۱۵/۹۷	
۱۳/۱۱	۱۶/۰۷	
۰/۷۷	۵/۶۳	
۱۹/۷۷	۲۳/۸۳	



(الف)



(ب)

شکل ۹: به ترتیب از چپ به راست، تصاویر سه کلاسه، چهارکلاسه و پنج کلاسه: (الف) تصویر شبیه‌سازی شده 1-look (۵۱۲ × ۵۱۲) و (ب) تصویر زمین مرجع [۵]

جدول ۷: مقایسه زمان اجرای الگوریتم‌های مختلف

الگوریتم	زمان اجرای برنامه (s)
TBES	۵۱۷۸/۶۳
C-MLL	۴۲۹۵/۴۱
IRGS	۱۸۸۹/۵۳
CTM	۱۶۸/۶۸
CHUMSIS	۱۰۹/۴۲
روش پیشنهادی	۹۳/۶۵

۶- نتیجه‌گیری

نشان داده شد که الگوریتم پیشنهادی بهترین عملکرد و کم‌ترین خطای بخش‌بندی را دارد. همچنین زمان اجرای برنامه نیز با این الگوریتم‌ها مورد مقایسه قرار گرفت. الگوریتم پیشنهادی کم‌ترین زمان اجرا را داشته که برتری آن را چه از نظر دقت و چه از نظر زمان نشان می‌دهد. با این حال هنوز مسائلی برای بهتر شدن روش وجود دارد؛ از جمله انتخاب تطبیقی پارامتر α و نیز شرط توقف مرحله اول به گونه‌ای که متناسب با تصویر SAR باشد؛ که این مسئله، چالش پیش‌روی این الگوریتم جهت ادامه کار خواهد بود.

مراجع

- [1] G. Akbarizadeh, "A New statistical-Based Kurtosis Wavelet Energy Feature for Texture Recognition of SAR Images," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 50, no. 11, pp. 4358-4368, 2012.
- [2] P. Mohanaiah, P. Sathyanarayana, L. GuruKumar, "Image texture feature extraction using GLCM

در این مقاله، روش بخش‌بندی نظارت‌نشده سلسله‌مراتبی تصویر SAR توسط فشرده‌سازی پراتلاف ارائه شده است. در این الگوریتم، از سوپریکسل‌ها به جای پیکسل‌ها، به عنوان واحد عملکرد استفاده شده، به گونه‌ای که باعث کاهش در اثر نویز اسپکل و هزینه‌های محاسباتی شده است.

ادغام سوپریکسل‌ها در دو مرحله صورت می‌گیرد. در مرحله اول ادغام سوپریکسل‌هایی که مرز مجزایی بین آن‌ها وجود ندارد، انجام می‌شود. پیش‌تر سوپریکسل‌ها در این مرحله ادغام می‌گردند. سپس در مرحله بعد، ادغام سوپریکسل‌های باقی‌مانده توسط روش فشرده‌سازی پراتلاف داده انجام می‌شود که خود این روش از سرعت بالایی برخوردار است.

نتایج الگوریتم پیشنهادی بر روی تصاویر شبیه‌سازی شده و حقیقی و نیز بر روی دیتاست برکلی با سایر الگوریتم‌ها مورد مقایسه قرار گرفت و

- [14] T. Nguyen, *Gaussian Mixture Model based Spatial Information Concept for Image Segmentation*, Ph.D. Thesis, University of Windsor, 2011.
- [15] Y. Yang, J. Wright, Y. Ma, S. Shankar Sastry, "Unsupervised segmentation of natural images via lossy Data compression", *Computer Vision and Image Understanding*, vol. 110, no. 2, pp. 212–225, 2008.
- [16] Y. Ma, H. Derksen, W. Hong, J. Wright, "Segmentation of multivariate mixed data via lossy coding and compression", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 29, no. 9, pp. 1546–1562, 2007.
- [17] S. R. Rao, H. Mobahi, A. Y Yang, S S. Sastry, Y. Ma, *Natural image segmentation with adaptive texture and boundary encoding*, Computer Vision–ACCV 2009, Springer, 2010.
- [18] D. Martin, C. Fowlkes, D. Tal, J. Malik, "A Database of Human Segmented Natural Images and its Application to Evaluating Segmentation Algorithms and Measuring Ecological Statistics", in *Proceedings of Eighth IEEE International Conference on Computer Vision (ICCV)*, pp. 416–423, 2001.
- [19] A. Levinstein, A. Stere, K. N. Kutulakos, D. J. Fleet, S. J. Dickinson, "TurboPixels: Fast Superpixels Using Geometric Flows", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 31, no. 12, pp. 2290–2297, 2009.
- [20] P. Han, R. Zhang, Z. G. Su, and R. B. Wu, "An iterative segmentation algorithm of SAR image based on support vector machine," in *Proceedings of 2nd Asia-Pac Conference on Synthetic Aperture Radar*, pp. 76–679, 2009.
- [21] M. Haindl and S. Mikeš, *Unsupervised Texture Segmentation*, Pattern Recognition Techniques, Technology and Applications, Book edited by: Peng-Yeng Yin, ITech, Vienna, Austria, 2008.
- [22] Q. Yu and D. A. Clausi, "IRGS: Image segmentation using edge penalties and region growing," *IEEE Transaction on Pattern Analysis and Machine Intelligence*, vol. 30, no. 12, pp. 2126–2139, 2008.
- [23] T. Kanungo, B. Dom, W. Niblack, D. Steele, "A fast algorithm for MDL-based multi-band image segmentation," in: *Proceedings of International Conference on Computer Vision and Pattern Recognition*, pp. 609–616, 1994.
- approach", *International Journal of Scientific and Research Publications*, vol. 3, no. 5, pp. 1–4, 2013.
- [3] Haralick, R. M., Shanmugan, K., and Dinstein, I., "Textural Features for Image Classification," *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 3, no. 6, pp. 610–621, 1973.
- [4] N. Zulpe, V. Pawar, "GLCM textural features for brain tumor classification", *IJCSI International Journal of Computer Science Issues*, vol. 9, no. 3, pp. 354–359, 2012.
- [5] H. Yu, Sh. Wang, "Context-Based Hierarchical Unequal Merging for SAR Image Segmentation," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 51, no. 2, 2013.
- [6] J. Xue, Y. Zhang, and X. Lin, "Rayleigh-distribution based minimum error thresholding for SAR images," *Journal of Electronics (China)*, vol. 16, no. 4, pp. 336–342, 1999.
- [7] J. S. Lee and I. Jurkevich, "Segmentation of SAR images," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 27, no. 6, pp. 674–680, 1989.
- [8] W. Chumsamrong, P. Thitimajshima, and Y. Rangsanseri, "Synthetic aperture radar (SAR) image segmentation using a new modified fuzzy c-means algorithm," in *Proceedings of IEEE Geoscience and Remote Sensing Symposium (IGARS)*, pp. 624–626, 2000.
- [9] X. R. Zhang, L. C. Jiao, F. Liu, L. F. Bo, and M. G. Gong, "Spectral clustering ensemble applied to SAR image segmentation," *IEEE Transaction on Geoscience and Remote Sensing*, vol. 46, no. 7, pp. 2126–2136, 2008.
- [10] Y. Dong, B. C. Forster, and A. K. Milne, "Comparison of radar image segmentation by Gaussian- and Gamma-Markov random field models," *International Journal of Remote Sensing*, vol. 24, no. 4, pp. 711–722, 2003.
- [11] Q. Yu and D. A. Clausi, "IRGS: Image segmentation using edge penalties and region growing," *IEEE Transaction on Pattern Analysis and Machine Intelligence*, vol. 30, no. 12, pp. 2126–2139, 2008.
- [12] E. A. Carvalho, D.M. Ushizima, F.N.S. Medeiros, C.I.O. Martins, R.C.P. Marques, and I.N.S. Oliveira, "SAR imagery segmentation by statistical region growing and hierarchical merging," *Digital Signal Processing*, vol. 20, no. 5, pp. 1365–1378, 2010.
- [13] P.D. McNicholas and T.B. Murphy, "Model-Based Clustering of Microarray Expression Data via Latent Gaussian Mixture Models," *Bioinformatics*, vol. 26, no. 21, pp. 2705–2712, 2010.

زیرنویس‌ها

^{۱۴} Encode^{۱۵} Agglomerative Clustering^{۱۶} Context-Based Hierarchical Unequal Merging for SAR Image Segmentation^{۱۷} Cognitive Science^{۱۸} Hysteresis^{۱۹} Region Adjacency Graph^{۲۰} Classical Multilevel Logistic^{۲۱} Iterative Region Growing Using Semantics^{۲۲} Markov Random Field^{۲۳} Spatial Context^{۲۴} Graduated Increased Edge Penalty Functions^{۲۵} Over Segmentation^۱ Synthetic Aperture Radar^۲ Gray-tone Linear Dependencies^۳ Gray Level Co-Occurance Matrix^۴ Gray Level Dependency^۵ Correlation^۶ Homogeneity^۷ Skewness^۸ Kurtosis^۹ Speckle^{۱۰} Compression-Based Texture Merging^{۱۱} Texture and Boundary Encoding Segmentation^{۱۲} Minimum Description Length^{۱۳} Adaptive Chain Code