

## الگوریتم خوشه‌بندی طیفی مبتنی بر فاصله بافتی برای قطعه‌بندی تصاویر ماهواره‌ای SAR

غلامرضا اکبری زاده<sup>۱</sup>، معصومه رحمانی<sup>۲</sup>

### چکیده

در این مقاله یک روش قطعه‌بندی جدید مبتنی بر خوشه‌بندی طیفی خودتنظیم‌شونده برای تصاویر ماهواره‌ای SAR ارائه شده است. از این روش می‌توان به عنوان پیش‌پردازشی جهت انجام کاربردهای پیشرفته‌تری چون بازیابی تصاویر، ردگیری و تشخیص اشیا و غیره بهره برد. در این روش، ابتدا تصویر از لحاظ کمیت شدت روشنایی توسط الگوریتم انتقال میانگین قطعه‌بندی می‌شود و به دنبال آن با استفاده از ویژگی‌های بافت قطعات و از روش خوشه‌بندی طیفی خودتنظیم‌شونده عمل ادغام قطعات صورت می‌گیرد. استفاده از چندین نماینده بافت برای هر قطعه که توسط الگوریتم خوشه‌بندی سلسله‌مراتبی بدست می‌آیند، سبب شده تا نتایج این روش با بهترین الگوریتم‌های قطعه‌بندی موجود قابل رقابت باشد. از دیگر ویژگی‌های این روش استفاده نکردن از اطلاعات مکانی برای عملیات قطعه‌بندی است. یکی از کاربردهای بسیار مفید روش پیشنهادی، قطعه‌بندی و متمایز نمودن بافت هر ناحیه از هر تصویر SAR است. نتایج شبیه‌سازی و آزمایشات انجام شده توسط این الگوریتم بر روی تصاویر شبیه‌سازی شده SAR و همچنین تصاویر حقیقی SAR و POLSAR ارائه شده است. این نتایج بیانگر قدرت روش پیشنهادی در قطعه‌بندی و توصیف بافتهای مختلف در تصاویر حقیقی SAR بوده و کمتر تحت تأثیر شدت نویز Speckle در تصاویر SAR خواهد بود.

### کلیدواژه

قطعه‌بندی تصاویر ماهواره‌ای، خوشه‌بندی سلسله‌مراتبی، خوشه‌بندی طیفی خودتنظیم‌شونده.

### مقدمه

ویژگی‌های مشابهی دارند. معمولاً از قطعه‌بندی تصویر SAR به عنوان پردازشی مقدماتی در بسیاری از کاربردهای پیشرفته‌تری مانند محل‌یابی و تشخیص اشیا، فشرده‌سازی داده‌ها، ردگیری، بازیابی تصاویر SAR و فهم آن‌ها استفاده می‌شود. قطعه‌بندی تصاویر ماهواره‌ای SAR نقش مهمی در بازشناسی خودکار اهداف بازی می‌کند و اخیراً مورد توجه محققان بسیاری در زمینه‌ی سنجش از دور قرار گرفته است [۵-۲].

راهکارهای زیادی به منظور قطعه‌بندی تصاویر ماهواره‌ای SAR پیشنهاد شده است. اخیراً تکنیک‌های متنوعی در این حوزه به کار گرفته می‌شوند؛ مانند الگوریتم خوشه‌بندی [۶]، الگوریتم‌های آستانه‌گذاری [۸ و ۷]، روش‌های مورفولوژیک [۹]، راهکارهای مبتنی بر گراف [۱۰ و ۱۱] و روش‌های مبتنی بر مدل‌های آماری [۱۲]. راهکارهای مبتنی بر گراف در دهه اخیر طرفداران زیادی پیدا کرده است. در این راهکارها هر تصویر به صورت یک گراف وزن‌دار فرض می‌شود که در آن هر گره

تصاویر SAR دارای ویژگی تصویربرداری سنجش از دور، قابلیت نفوذ پذیری قوی، رزولوشن بالا و تصویربرداری در تمام شرایط جوی می‌باشند. این نوع تصویربرداری دارای کاربردهای وسیع در زمینه‌ی سیستم‌های نظامی و تجاری است؛ اما به دلیل وجود نویزهای Speckle در تصاویر SAR<sup>۳</sup>، این تصاویر را با بکارگیری روش‌های معمول و مرسوم نمی‌توان قطعه‌بندی نمود [۱]. قطعه‌بندی تصاویر SAR را می‌توان یک مسئله‌ی معکوس کلاسیک دانست که هدف در آن، یافتن ناحیه‌هایی با معنا و پیوسته در این نوع از تصاویر است که نقاط هر ناحیه،

<sup>۱</sup> استادیار گروه مهندسی برق، دانشگاه شهید چمران اهواز، g.akbari@scu.ac.ir

<sup>۲</sup> دانشجوی کارشناسی ارشد برق، دانشگاه شهید چمران اهواز

<sup>۳</sup> Synthetic Aperture Radar (SAR)

تاریخ دریافت: ۳ آبان ۱۳۹۲ تاریخ پذیرش: ۱۳ اسفند ۱۳۹۲

در مورد توزیع‌های گسسته، مسئله بهینه‌سازی که در محاسبه فاصله Mallows ظاهر می‌شود، با برنامه‌ریزی خطی قابل حل است. فرض کنید دو توزیع گسسته زیر را داشته باشیم:

$$\gamma_i = \left\{ \left( z_i^{(1)}, q_i^{(1)} \right), \left( z_i^{(2)}, q_i^{(2)} \right), \dots, \left( z_i^{(m_i)}, q_i^{(m_i)} \right) \right\}, i = 1, 2 \quad (2)$$

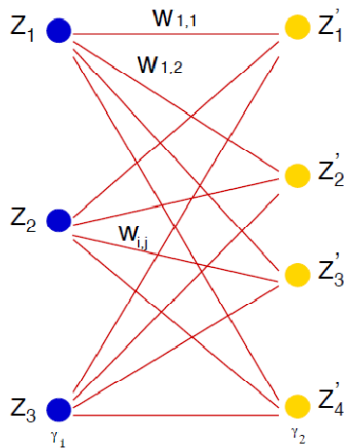
در این صورت تساوی (2) معادل با مسئله بهینه‌سازی زیر خواهد بود:

$$D^2(\gamma_1, \gamma_2) = \min_{\{\omega_{i,j}\}} \sum_{i=1}^{m_1} \sum_{j=1}^{m_2} \omega_{i,j} \left\| z_1^{(i)} - z_2^{(j)} \right\|^2 \quad (3)$$

با محدودیت‌های زیر:

$$\begin{aligned} \sum_{j=1}^{m_2} \omega_{i,j} &= q_1^{(i)}, i = 1, \dots, m_1; \\ \sum_{i=1}^{m_1} \omega_{i,j} &= q_2^{(j)}, j = 1, \dots, m_2; \\ \omega_{i,j} &\geq 0, i = 1, \dots, m_1, j = 1, \dots, m_2. \end{aligned} \quad (4)$$

مسئله بهینه‌سازی بالا نشان می‌دهد که مربع فاصله‌ی Mallows مجموعی وزن‌دار از مربع فاصله‌ی  $L_2$  بین هر یک از بردارهای پشتیبان  $\gamma_1$  و  $\gamma_2$  می‌باشد. بنابراین همان‌گونه که شکل (1) نشان می‌دهد، محاسبه فاصله Mallows در واقع همان بهینه‌سازی وزن‌های تطبیقی بین بردارهای پشتیبان در دو توزیع است به گونه‌ای که فاصله مجموع کمینه شود.



شکل 1. انطباق برای محاسبه فاصله Mallows [17]

در شکل (1)، باید وزن‌های  $\omega_{i,j}$  غیرمنفی باشند و مجموع وزن‌هایی که از هر بردار  $Z_i^{(i)}$  منتشر می‌شود، برابر با احتمال آن

متناظر با پیکسل‌های تصویر با یک ناحیه از تصویر است. وزن بالی که دو پیکسل یا دو ناحیه را به هم متصل می‌کند، نشان‌دهنده میزان مشابهت این دو است.

روش‌های زیاد دیگری نیز در دهه‌های اخیر به منظور حل مسئله‌ی قطعه‌بندی تصاویر بافت‌دار مطالعه و ارائه شده است. برخلاف الگوریتم‌های خوشه‌بندی، روش‌های قطعه‌بندی مبتنی بر اطلاعات مکانی بیشتر بر روی اطلاعات اتصالی بین پیکسل‌های مجاور تأکید دارند که این امر سبب سوق یافتن به سوی روش‌هایی چون مدل‌های آماری مبتنی بر میدان تصادفی مارکوف [13]، تکنیک‌های مبتنی بر انتقال میانگین [14] و رویه‌های تجزیه و ادغام مبتنی بر گراف [15 و 16] شده است.

در این مقاله یک روش جدید قطعه‌بندی تصویر معرفی شده است که برای ارائه‌ی آن نیاز به توضیح مفاهیمی مقدماتی چون فاصله‌ی Mallows، خوشه‌بندی طیفی خودتنظیم‌شونده و خوشه‌بندی سلسله‌مراتبی دیده می‌شود. ادامه‌ی این مقاله در بخش‌های زیر تنظیم شده است: مفاهیم مربوط به فاصله Mallows، خوشه‌بندی طیفی خودتنظیم‌شونده و خوشه‌بندی سلسله‌مراتبی در بخش دوم توضیح داده خواهند شد. در بخش سوم روش به کار برده شده برای استخراج ویژگی‌های بافت ارائه شده است و در بخش چهارم نیز الگوریتم اصلی ذکر شده است. در بخش پنجم هم نتایج عملی الگوریتم ارائه می‌شود.

## مفاهیم مقدماتی


### فاصله Mallows

برای محاسبه فاصله  $D(\gamma_1, \gamma_2)$  بین دو توزیع  $\gamma_1$  و  $\gamma_2$  از فاصله Mallows استفاده می‌شود. فرض کنید متغیر تصادفی  $Y \in R^k$  از توزیع  $\gamma_2$  پیروی کند. همچنین فرض کنید نشانگر مجموعه‌ی توزیع‌های مشترک روی  $X$  و  $Y$  باشد، با این ویژگی که توزیع‌های حاشیه‌ای  $X$  و  $Y$  به ترتیب همان  $\gamma_1$  و  $\gamma_2$  باشند. مخصوصاً اگر  $\zeta \in \gamma(\gamma_1, \gamma_2)$  آن‌گاه  $\zeta$  فضای نمونه  $R^k \times R^k$  را دارد و توزیع‌های حاشیه‌ای آن  $\zeta_X = \gamma_1$  و  $\zeta_Y = \gamma_2$  هستند. فاصله‌ی Mallows به صورت کمینه‌ی امید ریاضی فاصله‌ی بین  $X$  و  $Y$  تعریف می‌شود که این بهینگی روی همه‌ی توزیع‌های مشترک  $\zeta \in \gamma(\gamma_1, \gamma_2)$  که به صورت زیر به دست می‌آید:

$$D(\gamma_1, \gamma_2) \triangleq \min_{\zeta \in \gamma(\gamma_1, \gamma_2)} \left( E \|X - Y\|^p \right)^{1/p} \quad (1)$$

که در آن  $\| \cdot \|$  فاصله  $L_p$  بین دو بردار را نشان می‌دهد. ما در این‌جا از فاصله  $L_2$  استفاده می‌کنیم؛ یعنی  $p = 2$ .

می‌شد؛ در حالی که در این روش تعداد خوشه‌ها به صورت اتوماتیک یافته می‌شود.



شکل ۲. نتایج خوشه‌بندی بدون مقیاس‌بندی محلی [۲۰]

الگوریتم خوشه‌بندی طیفی خودتنظیم‌شونده به صورت زیر است:

فرض کنید بخواهیم مجموعه نقاط  $S = \{s_1, \dots, s_n\}$  را در فضای  $R^l$  خوشه‌بندی کنیم.

(۱) پارامتر مقیاس محلی  $\sigma_i$  را با استفاده از فرمول زیر برای هر یک از نقاط  $s_i \in S$  محاسبه می‌کنیم:

$$\sigma_i = d(s_i, s_K) \quad (7)$$

که در آن  $s_K$ ،  $K$  امین همسایه نقطه  $s_i$  است. بدین معنی که همسایه‌های نقطه  $s_i$  را از نظر فاصله آن‌ها به صورت صعودی مرتب می‌کنیم.  $s_K$ ،  $K$  امین همسایه در این لیست خواهد بود. انتخاب  $K$  مستقل از مقیاس و تابعی از ابعاد داده‌ها است.

(۲) ماتریس نزدیکی  $\hat{A} \in \mathcal{R}^{n \times n}$  را با استفاده از ایده پارامتر مقیاس محلی و از طریق رابطه زیر تشکیل می‌دهیم:

$$\hat{A}_{ij} = \exp\left(\frac{-d^2(s_i, s_j)}{\sigma_i \sigma_j}\right) \quad i \neq j$$

$$\hat{A}_{ii} = 0 \quad (8)$$

(۳) ماتریس قطری  $D$  را به صورت  $D_{ii} = \sum_{j=1}^n \hat{A}_{ij}$  تعریف می‌کنیم

و از طریق آن ماتریس نزدیکی نرمال‌شده را به صورت  $L = D^{-1/2} \hat{A} D^{-1/2}$  می‌سازیم.

(۴) بردارهای  $x_1, \dots, x_c$  را که  $C$  بردار ویژه بزرگتر  $L$  هستند، می‌یابیم و ماتریس  $X = [x_1, \dots, x_c] \in \mathcal{R}^{n \times c}$  را با استفاده از آن‌ها تشکیل می‌دهیم.  $C$  نشانگر حداکثر تعداد خوشه‌هاست.

(۵) برای هر یک از مقادیری که کاندید تعداد خوشه‌ها هستند، دورانی را بازیابی می‌کنیم که ستون‌های  $X$  را بهتر با سیستم مختصات استاندارد هم‌ردیف می‌کند. فرض کنید مقدار کاندید تعداد خوشه‌ها را  $C$  با  $Z \in \mathcal{R}^{n \times C}$  نیز نشان-

$q_i^{(i)}$  باشد. بنابراین  $q_i^{(i)}$  مقدار اثربخشی  $Z_i^{(i)}$  را روی فاصله کلی توزیع تنظیم می‌کند [۱۷].

### خوشه‌بندی طیفی خود تنظیم‌شونده

خوشه‌بندی طیفی یکی از قدرتمندترین و محبوب‌ترین روش‌ها است که اولین بار توسط Hoffman و Donath [۱۸] در سال ۱۹۷۳ ارائه شده است. این الگوریتم وابسته به بردارهای ویژه و مقادیر ویژه‌ی ماتریس همبستگی است که نمونه‌ها را به خوشه‌های منفصل تقسیم می‌کند. ماتریس همبستگی، شباهت بین داده‌ها را معین می‌کند.

مجموعه داده‌ی  $X$  را در نظر بگیرید:

$$X = \{x_1, x_2, \dots, x_n\} \quad (5)$$

که  $x_i \in R^d$  و  $n$  تعداد نمونه‌ها است.

عموماً تابع گوسی به عنوان تابع شباهت به صورت زیر به کار می‌رود:

$$W_{ij} = \exp(-\|x_i - x_j\|^2 / 2\sigma^2) \quad (6)$$

که  $\sigma$  پارامتر مقیاس و  $W_{ij}$ ، مشابهت نمونه‌های  $x_i$  و  $x_j$  است. خوشه‌بندی طیفی به پارامتر مقیاس  $\sigma$  در تابع گوسی بسیار حساس است. متأسفانه انتخاب مقدار مناسب  $\sigma$  برای بدست آوردن نتیجه‌ی خوبی از قطعه‌بندی مشکل است و تنظیم آن به صورتی دستی است. تنظیم پارامتر مقیاس هنوز به عنوان یک بحث ناتمام باقی‌مانده است [۱۹].

روش‌های خوشه‌بندی قبلی دارای دو مشکل عمده بودند [۶]، [۱۰ و ۱۱]: اول آن‌که زمانی که داده‌های ورودی شامل خوشه‌هایی با ویژگی‌های آماری متفاوت باشند، نمی‌توان مقداری برای پارامتر  $\sigma$  یافت که در مورد همه داده‌ها به خوبی کارا باشد. همچنین زمانی که داده‌ها شامل چندین مقیاس باشند، حتی استفاده از مقداری بهینه برای  $\sigma$  نیز نتایج خوبی جهت خوشه‌بندی در بر نخواهد داشت. بروز این مشکل بدان خاطر است که برای چندین مقیاس از یک مقدار برای پارامتر  $\sigma$  استفاده می‌شود. در شکل (۲) نتایج حاصل از خوشه‌بندی را بدون استفاده از ایده مقیاس‌بندی محلی مشاهده می‌کنید. به همین علت، به جای آن‌که از یک مقدار برای پارامتر  $\sigma$  استفاده شود، به ازای هریک از داده‌ها مقداری خاص جهت پارامتر مقیاس‌بندی محلی محاسبه می‌شود. مشکل دوم آن‌که در روش‌های قبلی، تعداد خوشه‌ها باید به صورت دستی تنظیم

نتیجه‌ی این خوشه‌بندی همان مراکز خوشه‌ها  $C_1, \dots, C_k$  و نسبت فراوانی هریک از خوشه‌ها در داده‌های قطعه اصلی  $p_1, \dots, p_k$  است.

(۲) فاصله اقلیدسی هر جفت از مراکز خوشه‌ها را بدست می‌آوریم و در برداری با نام  $Y$  قرار می‌دهیم.

(۳) سپس درخت خوشه سلسله‌مراتبی را با استفاده از  $Y$  تشکیل می‌دهیم. درخت سلسله‌مراتبی مجموعه‌ای تو در تو از پارتیشن‌های نمایش داده شده توسط یک نمودار درختی یا دندوگرام است. هر مقطع درخت در یک سطح مشخص، یک پارتیشن را به گروه‌های مجزا تقسیم می‌کند. در بالای درخت در محل اتصال شاخه‌ها، مقادیری عددی وجود دارد که با هر جایگاه در ارتباط است. این مقدار اندازه‌ی فاصله یا عدم تشابه میان خوشه‌هاست. اندازه‌گیری‌های متفاوتی برای فاصله‌ی بین خوشه‌ها موجود است؛ که در اینجا همان‌گونه که در مرحله‌ی دوم الگوریتم مشاهده می‌شود، از فاصله‌ی اقلیدسی استفاده شده است. در مرجع [۲۲] انواع روش‌های خوشه‌بندی سلسله‌مراتبی و نحوه‌ی تشکیل درخت به طور مفصل شرح داده شده است.

(۴) در انتها نیز خوشه‌ها را با استفاده از درخت ساخته شده تشکیل می‌دهیم و هریک از پیکسل‌های قطعه اصلی را با توجه به خوشه‌ای که در آن قرار گرفته، برچسب‌گذاری می‌کنیم. توجه بدین نکته ضروری است که بعد از خوشه‌بندی سلسله‌مراتبی باید مقادیر مراکز خوشه‌ها و نسبت فراوانی آن‌ها بروزرسانی شوند؛ چون ممکن است چندین خوشه از خوشه‌های اولیه‌ای که از kmeans حاصل شده بودند، طی این فرایند با هم ادغام شده باشند.

### ویژگی بافت

تابع گوسین دوبعدی همگن به صورت زیر تعریف می‌شود:

$$G_{\sigma}(x, y) = \left( \frac{1}{\sqrt{2\pi}\sigma} \right) \exp\left( \frac{-(x^2 + y^2)}{2\sigma^2} \right) \quad (11)$$

مشتق اول تابع گوسین در راستای محور  $x$  از رابطه زیر بدست می‌آید:

$$GD_{\sigma}(x, y) = \frac{\partial G_{\sigma}(x, y)}{\partial x} = -\frac{x}{\sigma^2} G_{\sigma}(x, y) \quad (12)$$

تفاضل توابع گوسین شیفت‌یافته در راستای محور  $x$  عبارت است از:

$$DOOG_{\sigma}(x, y) = G_{\sigma}(x, y) - G_{\sigma}(x + d, y) \quad (13)$$


دهنده ماتریسی باشد که از دوران ماتریس بردار ویژه  $X$  به دست می‌آید. به عبارت دیگر داشته باشیم  $Z = XR$  و نشان دهیم  $M_i = \max_j Z_{ij}$ . هدف ما بازیابی دورانی مانند  $R$  است که برای آن هر سطر ماتریس  $Z$  حداکثر یک درایه غیرصفر داشته باشد. بنابراین یک تابع هزینه به صورت زیر تعریف می‌کنیم:

$$J = \sum_{i=1}^n \sum_{j=1}^c \frac{Z_{ij}^2}{M_i^2} \quad (9)$$

کمینه‌کردن این تابع هزینه روی همه دوران‌های ممکن، بهترین هم‌ترازی با سیستم مختصات استاندارد را به دست می‌دهد. این کمینه‌سازی از روش Gradient descent صورت می‌گیرد. در نهایت تعداد خوشه‌ها همان تعدادی خواهد بود که کمترین مقدار را برای تابع هزینه فراهم می‌کند (اگر چندین مقدار کاندید تعداد خوشه‌ها مقدار کمینه برابری بدست دادند، بزرگترین آن‌ها انتخاب می‌شود). تعداد خوشه‌های نهایی را با  $C_{best}$  نشان می‌دهیم.

(۶) نتیجه هم‌ترازی حاصل از هریک از  $C_{best}$  بردار ویژه  $(Z)$  را در نظر گرفته و در صورتی نقطه داده  $s_i$  را به خوشه  $c$  اختصاص می‌دهیم اگر و تنها اگر داشته باشیم  $\max_j (Z_{ij}^2) = Z_{ic}^2$ .

نتایج خوشه‌بندی حاصل از این الگوریتم را در شکل (۳) مشاهده می‌کنید [۲۰].



شکل ۳. نتایج خوشه‌بندی با استفاده از الگوریتم خوشه‌بندی طیفی خود تنظیم شونده [۲۰]

### خوشه‌بندی سلسله‌مراتبی

مراحل خوشه‌بندی سلسله‌مراتبی [۲۱] به شرح زیر است:

(۱) ابتدا مجموعه داده را با استفاده از روش Kmeans به  $k$  خوشه تقسیم می‌کنیم. مقدار  $k$  از رابطه زیر بدست می‌آید:

$$k = \frac{\text{segment size}}{2000} + 1 \quad (10)$$

(۱) ابتدا با استفاده از روش انتقال میانگین، تصویر ورودی را در فضای LAB قطعه‌بندی می‌کنیم. مرکز هر قطعه یک بردار به طول سه خواهد بود که المان‌های آن میانگین ویژگی‌های  $A, L$  و  $B$  پیکسل‌های درون آن قطعه می‌باشند. در شکل (۵) نتایج قطعه‌بندی انتقال میانگین با نتایج الگوریتم پیشنهادی مقایسه شده است.

(۲) الگوریتم استخراج بردار ویژگی بافت را روی بلاک‌های  $8 \times 8$  تصویر ورودی اجرا می‌کنیم. در این صورت به ازای هر یک از پیکسل‌های تصویر ورودی یک بردار ویژگی بافت به طول ۴ خواهیم داشت که هر یک از المان‌های آن مقدار انرژی لبه بافتی را به ازای هر یک از مقادیر  $\theta$  برای آن پیکسل نشان می‌دهد.

(۳) سپس با استفاده از الگوریتم خوشه‌بندی سلسله‌مراتبی روی بردارهای ویژگی بافت همه پیکسل‌های هر یک از قطعه‌ها، چندین مرکز خوشه همراه با نسبت فراوانی آن خوشه‌ها به دست می‌آید که این مراکز نماینده بافت آن قطعه هستند. در واقع هر یک از قطعه‌های رنگی از لحاظ بافت به چند قطعه کوچکتر تقسیم می‌شود و نتیجه آن وجود چندین نماینده بافت برای هر قطعه رنگی خواهد بود.

(۴) وجود چند نماینده بافت همراه با احتمال حضور آن‌ها در یک قطعه رنگی در واقع تشکیل یک توزیع گسسته را برای آن قطعه رنگی می‌دهد. فاصله بافتی دو قطعه رنگی همان فاصله دو توزیع گسسته مربوط به آن‌ها خواهد بود که با استفاده از فاصله Mallows می‌توان آن را بدست آورد. فاصله رنگی دو قطعه رنگی همان فاصله اقلیدسی مراکز رنگ آن دو قطعه خواهد بود. با استفاده از دو مفهوم بالا فاصله رنگی و فاصله بافتی را بین هر جفت از قطعه‌های بدست آمده از انتقال میانگین می‌یابیم.

(۵) ماتریس‌های فاصله رنگ و فاصله بافت بین قطعه‌ها را نرمال می‌کنیم و سپس فاصله کلی بین هر دو قطعه  $s_i$  و  $s_j$  را از رابطه زیر بدست می‌آوریم:

$$distance(s_i, s_j) = (\alpha \times colorDistance(s_i, s_j)) + ((1 - \alpha) \times textureDistance(s_i, s_j)) \quad (17)$$

(۶) با استفاده از ماتریس فاصله، گراف بین قطعه‌ها را تشکیل می‌دهیم؛ بدین‌صورت که برای هر قطعه یک گره در گراف در نظر می‌گیریم و این گره را تنها به  $k$  نزدیک‌ترین همسایه‌اش متصل می‌کنیم که وزن هر یال با فاصله متناظرش رابطه عکس دارد.

که در آن  $d$  آفست بین مراکز دو کرنل گاوسی است و مقدار آن متناسب با  $\sigma$  تنظیم می‌شود. با دوران این دو تابع، خانواده-ای از توابع مشتق گاوسین و تفاضل توابع گاوسین شیفت‌یافته در راستای جهت‌های مختلف  $\theta$  می‌تواند تولید شود:

$$\begin{aligned} GD_{\sigma, \theta}(x, y) &= GD_{\sigma}(x', y') \\ DOOG_{\sigma, \theta}(x, y) &= DOOG_{\sigma}(x', y') \\ x' &= x \cos \theta + y \sin \theta, \\ y' &= -x \sin \theta + y \cos \theta \end{aligned} \quad (14)$$

فرض کنید مقدار پارامتر مقیاس  $\sigma$  را داشته باشیم. در این صورت کمترین فرکانس مرکزی فیلترهای گابور  $U_i$  را به صورت  $1/(4\sigma)$  سیکل بر ثانیه تعریف می‌کنیم. این مقدار به گونه‌ای انتخاب می‌شود که پنجره نرم‌کننده گاوسی حداقل یک سیکل کمترین فرکانس مکانی را پوشش دهد. بیشترین فرکانس مرکزی فیلترهای گابور  $U_h$  را با مقدار  $0.45$  سیکل بر ثانیه تنظیم می‌کنیم. زمانی که بازه طیف فرکانسی تعیین شد، باید تعداد مناسب مقیاس‌ها و جهت‌های فیلترها را برای پوشش بازه طیفی انتخاب کنیم. ما در آزمایشات خود از ۳ مقیاس و ۴ جهت و مقدار  $\sigma = 3$  استفاده کردیم.

تصاویر فیلترشده گابور مختلط هستند و می‌توان آن‌ها را به صورت زیر نوشت:

$$O_i(x, y) = I(x, y) * g_i(x, y) = m_i(x, y) \exp[\phi_i(x, y)] \quad (15)$$

که  $g_i(x, y)$  یک فیلتر گابور است و داریم  $1 \leq i \leq N$  که در آن  $N$  اندازه‌ی شبکه‌ی توری مستطیل شکلی است که برای نمونه‌برداری استفاده می‌شود.  $m(x, y)$  دامنه و  $\phi(x, y)$  فاز است. بردار ویژگی بافت را با در نظر گرفتن انرژی لبه بافتی در جهت‌های مختلف در هر مکان مانند  $S$  تشکیل می‌دهیم. انرژی لبه بافتی که تغییر اطلاعات بافتی محلی را اندازه‌گیری می‌کند با استفاده از رابطه‌ی زیر بدست می‌آید:

$$E(s, \theta) = \sum_{1 \leq i \leq N} m_i(x, y) * GD_{\sigma, \theta}(x, y) \cdot \omega_i \quad (16)$$

که در آن  $\Omega_i = \sum_{x, y} m_i(x, y)$  و  $\omega_i = 1/\Omega_i$  زیربند  $i$  است [۱۴].

همچنین به منظور استخراج ویژگی‌های بافت از مقادیر  $0, \pi/4, \pi/2, 3\pi/4$  برای  $\theta$  استفاده می‌شود.

### مراحل الگوریتم پیشنهادی

مراحل الگوریتم پیشنهادی در زیر آمده است:

### قطعه‌بندی تصاویر حقیقی SAR

از آنجا که مرحله‌ی ابتدایی الگوریتم پیشنهادی روش انتقال میانگین است، در شکل (۵) نتایج حاصل از روش انتقال میانگین و الگوریتم پیشنهادی با یکدیگر مقایسه شده‌اند. آزمایشات بسیاری بر روی روش پیشنهادی در این مقاله انجام دادیم که در آن‌ها از مجموعه تصاویر Berkeley [۲۳] استفاده شده است. این مجموعه داده شامل ۳۰۰ تصویر رنگی با اندازه  $481 \times 321$  است. همچنین برای نشان دادن توانایی این الگوریتم در قطعه‌بندی تصاویر SAR نمونه‌هایی از خروجی آن بر روی تصاویر SAR در شکل (۶) آورده شده است. از نتایج آزمایشات انجام شده، میانگین گرفته شده و در جدول (۱) ارائه شده است. الگوریتم‌هایی که در اینجا برای مقایسه از آن‌ها بهره می‌گیریم، الگوریتم‌های CTM<sup>۴</sup> [۲۵ و ۲۴]، انتقال میانگین [۱۴]، برش نرمال شده [۱۵]، FH [۱۶] و MD2S [۲۶] هستند. در جدول (۱)، الگوریتم پیشنهادی را با دیگر الگوریتم‌ها از نظر چهار معیار PRI، VoI، GCE و BDE مقایسه کرده‌ایم. این معیارها، در تمام مقالات مبتنی بر خوشه‌بندی تصاویر SAR به عنوان معیارهای مقایسه استاندارد استفاده می‌شوند.

همان‌طور که در جدول (۱) دیده می‌شود، الگوریتم پیشنهادی به طور کلی و با در نظر گرفتن هر ۴ معیار، کارایی خوبی را از خود نشان داده است و در مواردی بهتر از دیگر الگوریتم‌ها نیز می‌باشد. به طور خاص در معیار PRI الگوریتم پیشنهادی رتبه سوم را دارد. در معیارهای VoI و GCE الگوریتم پیشنهادی بهترین عملکرد را در مقایسه با دیگر الگوریتم‌ها دارد. همچنین در معیار BDE نیز الگوریتم پیشنهادی از لحاظ کیفیت در جایگاه سوم قرار دارد. این نتایج خوب حاصل ابتکاراتی بوده که در الگوریتم پیشنهادی ارائه شده است. در این الگوریتم استفاده ترکیبی از اطلاعات رنگ و بافت مدنظر قرار دارد و الگوریتم پایه آن، الگوریتم انتقال میانگین است که خود یکی از بهترین الگوریتم‌های قطعه‌بندی است؛ اما در الگوریتم پیشنهادی، این روش به عنوان گام اولیه مورد استفاده قرار گرفته است و سپس با نداشت مسئله به فضای گراف توانسته‌ایم توسط روش‌های خوشه‌بندی گراف، نتایج گام اولیه را بهبود بخشیم و الگوریتم قدرتمندی ارائه دهیم.


در شکل (۵) نیز نتیجه‌ی قطعه‌بندی حاصل از الگوریتم پیشنهادی بر روی یک تصویر ماهواره‌ای با رزولوشن فضایی  $4-m$  نشان داده شده و با الگوریتم انتقال میانگین مقایسه شده است. نتیجه‌ی قطعه‌بندی این تصویر توسط الگوریتم انتقال میانگین در شکل (۵-الف) و نتیجه‌ی قطعه‌بندی همان تصویر توسط الگوریتم پیشنهادی در شکل (۵-ب) نمایش داده شده است. همان‌طور که در تصاویر مشاهده

(۷) در انتها نیز با استفاده از الگوریتم خوشه‌بندی طیفی خودتنظیم‌شونده، عملیات خوشه‌بندی را روی گراف اعمال می‌کنیم.

### نتایج شبیه سازی

#### قطعه‌بندی تصاویر شبیه‌سازی شده‌ی SAR

به منظور ارزیابی روش پیشنهادی از نظر میزان درصد خطا در قطعه‌بندی، ابتدا آزمایشی بر روی یک تصویر شبیه‌سازی شده-ی three-look SAR انجام شده است. محاسبه‌ی میزان درصد خطا به این دلیل در این آزمایش قابل انجام می‌باشد که تصویر زمین مرجع آن مطابق شکل ۴ (الف) موجود است. تصویر زمین مرجع انتخاب شده، یک تصویر مشتمل بر دو کلاس (دو ناحیه) است و با اندازه‌ی  $256 \times 256$  است. فرآیند تولید تصویر شبیه‌سازی شده‌ی three-look SAR، برگرفته از تولید تصاویر راداری است که با متوسط‌گیری از ضرب سه بار نویز گاما در تصویر زمین مرجع ایجاد شده و در شکل ۴ (ب) نشان داده شده است. در شکل ۴ (ج) نتیجه‌ی حاصل از قطعه‌بندی توسط الگوریتم پیشنهادی در این مقاله نشان داده شده است. این تصویر پس از اجرای الگوریتم قطعه‌بندی، با انتخاب یک سطح آستانه‌ی بهینه به منظور مقایسه با تصویر زمین مرجع، باینری شده است. با توجه به این آزمایش، تعداد پیکسل‌های با قطعه‌بندی نادرست  $5.077\%$  و درصد خطا  $7.7469\%$  درصد می‌باشد.



شکل ۴. الف) تصویر زمین مرجع مشتمل بر دو ناحیه ( $256 \times 256$ )؛ ب) تصویر شبیه‌سازی شده‌ی three-look SAR؛ ج) نتیجه‌ی حاصل از قطعه‌بندی با روش پیشنهاد شده در این مقاله (نرخ خطا:  $7.7469\%$  و تعداد پیکسل‌های با قطعه‌بندی نادرست:  $5.077$ )

آمده است. این تصویر شامل سه نوع پوشش زمینی آب، منطقه‌ی شهری و کوهستان می‌باشد. سمت چپ این تصویر کوه و سمت راست بالای تصویر آب است و منطقه‌ی شهری در سمت راست پایین تصویر می‌باشد. همان‌طور که در این تصویر مشاهده می‌شود، مرز بین آب و کوه و مرز بین آب و منطقه‌ی شهری به خوبی مشخص شده و ناحیه‌ی آب به درستی قطعه-بندی شده است.

تصویر شکل (۶-ج)، تصویری در باند C با سایز  $1024 \times 1024$  از منطقه برنج‌کاری در نزدیکی اوکایاما در ژاپن است که توسط آزمایشگاه SAR فضایی NASA/JPL بدست آمده است. در این تصویر نیز مرزها با حفظ زوایا و فرورفتگی‌ها و برآمدگی‌ها مشخص شده‌اند.

جدول ۱. مقایسه الگوریتم پیشنهادی با دیگر الگوریتم‌ها

روش	PRI	VoI	GCE	BDE
Humans	0.8754	1.104	0.0797	4.994
CTM	0.7561	2.464	0.1767	9.9
Mean-shift	0.755	2.477	0.2598	9.7001
NCuts	0.7229	2.9329	0.2182	9.6038
FH	0.7841	2.6647	0.1895	9.9497
MD2s	0.784	2.361	0.235	10.368
الگوریتم پیشنهادی	0.781	2.35	0.1758	9.713

می‌شود، نتیجه‌ی حاصل از الگوریتم پیشنهادی، قطعه-بندی موفق‌تری را ارائه داده است؛ مثلاً در تصویر (۵-الف) ناحیه‌ی آبی رنگ در سمت چپ پایین تصویر به چند بخش تقسیم شده است؛ در صورتی که در تصویر (۵-ب) به درستی به صورت یکپارچه در یک ناحیه، قطعه‌بندی شده است و این به آن علت است که در الگوریتم پیشنهادی علاوه بر رنگ از ویژگی بافت نیز جهت قطعه‌بندی استفاده می‌شود. در مورد ناحیه‌ی سبز رنگ سمت راست پایین تصویر نیز به همین ترتیب است. در شکل (۶) نیز نمونه‌ای از نتایج الگوریتم پیشنهادی بر روی چند تصویر حقیقی SAR نشان داده شده است که حاکی از توانمندی روش پیشنهادی در این مقاله برای قطعه‌بندی تصاویر SAR است.

تصویر نمایش داده شده در شکل (۶-الف) قسمتی از یک تصویر SAR، در باند KU با رزولوشن فضایی ۱-m در منطقه‌ی رودخانه‌ی Rio Grand نزدیکی آلبکوک می‌باشد که توسط الگوریتم پیشنهادی قطعه‌بندی شده است. این تصویر شامل سه نوع پوشش زمینی آب، پوشش‌های گیاهی و محصولات کشاورزی است. همان‌طور که در این تصویر دیده می‌شود مرز بین آب و منطقه گیاهی با دقت زیادی مشخص شده است؛ بطوری که حتی مسیرهای باریک آب در میان پوشش گیاهی مشهود است و فرورفتگی‌ها و برآمدگی‌ها در مرز این دو ناحیه به خوبی مشخص شده است.

تصویر شکل (۶-ب)، تصویری در باند X از سوئیس است که توسط آزمایشگاه رادار فضایی Missions در سال ۱۹۹۴ بدست




(ب)




(الف)

شکل ۵. مقایسه نتیجه الگوریتم انتقال میانگین و الگوریتم پیشنهادی: (الف) نتیجه الگوریتم انتقال میانگین و (ب) نتیجه حاصل از الگوریتم پیشنهادی




(ب)



(ف)



(د)



(ج)

شکل ۶. نمونه‌ای از نتایج الگوریتم پیشنهادی

در الگوریتم پیشنهادی نیازی به تنظیم دستی پارامتر مقیاس  $\sigma$  که یکی از مشکلات خوشه‌بندی طیفی است، نمی‌باشد؛ ضمن آن که تعداد خوشه‌ها نیز به طور اتوماتیک تعیین می‌شود. همان‌طور که در نتایج مشاهده می‌شود، از جمله مزیت‌های بارز این الگوریتم آن است که فرورفتگی‌ها و برآمدگی‌ها و همچنین زوایا در مرز نواحی را به خوبی مشخص می‌کند و مهم‌تر آن که این الگوریتم برای قطعه‌بندی هر دو نوع تصاویر SAR و POLSAR مؤثر است. با وجود این مزایا، وابستگی تنظیم  $\alpha$  به تصویر، به عنوان یک چالش در پیش رو است.

## نتیجه گیری

در این مقاله الگوریتمی جدید مبتنی بر خوشه‌بندی طیفی خودتنظیم‌شونده به منظور قطعه‌بندی تصاویر ماهواره‌ای SAR پیشنهاد شده است. نتایج بدست آمده مبین توانایی روش پیشنهادی برای قطعه‌بندی این نوع از تصاویر ماهواره‌ای است. نتایج خوشه‌بندی پیشنهادی با شش دسته از جدیدترین روش‌های خوشه‌بندی مقایسه شده و همچنین برای انجام یک مقایسه‌ی شهودی نیز نتایج قطعه‌بندی بر روی چند تصویر حقیقی SAR و POLSAR نیز ارائه شده است.

- [12] D. A. Clausi and L. H. Deng, "Unsupervised segmentation of synthetic aperture radar sea ice imagery using a novel Markov random field mode," *IEEE Trans Geosci Remote Sens*, vol. 43, no. 3, pp. 528–538, 2005.
- [13] J. Besag, "On the statistical analysis of dirty pictures," *J. Roy. Statist. Soc. B*, vol. 48, pp. 259–302, 1986.
- [14] D. Comaniciu and P. Meer, "Mean shift: A robust approach toward feature space analysis," *IEEE Transactions on PAMI*, vol. 24, pp. 603–619, May 2002.
- [15] J. Shi and J. Malik, "Normalized cuts and image segmentation," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 22, no. 8, pp. 888–905, Aug. 2000.
- [16] P. Felzenszwalb and D. Huttenlocher, "Efficient graph-based image segmentation," *Int. J. Comput. Vis.*, vol. 59, pp. 167–181, 2004.
- [17] J. Z. Wang and J. Li, "Real-Time Computerized Annotation of Pictures," *IEEE Trans. Pattern Anal. Mach. Intell.*, 2008.
- [18] W.E. Donath and A.J. Hoffman, "Lower bounds for the partitioning of graphs," *IBM J. Res. Develop.* Vol. 17, No. 5, pp. 420–425, 1973.
- [19] X. Zhang, Z. Wei, J. Feng and L. Jiao, "Sparse Representation based Spectral Clustering for SAR image segmentation" *Proc. SPIE 8006*, MIPPR 2011: Remote Sensing Image Processing, Geographic Information Systems, and Other Applications, 800608, November 2011.
- [20] P. Perona and L. Z. Manor, "Self-Tuning Spectral Clustering," in *NIPS*, 2004.
- [21] Z. Sun, K. Jia, G. Zhao and P. Fu, "Hierarchical Clustering Tree for Organizing and Indexing of Image Database," *IEEE International Congress on Image and signal Processing*, 17-19 Oct. 2009.
- [22] A. R. Webb, "Statistical Pattern Recognition," Second Edition" J. Wiley and Sons Publications, 2002.
- [23] C. Fowlkes, D. Tal, J. Malik, and D. Martin, "A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics," in *IEEE International Conference on Computer Vision*, 2001, pp. 416–425.
- [24] W. Hong, J. Wright, Y. Ma, and H. Derksen, "Segmentation of multivariate mixed data via lossy coding and compression," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 29, no. 9, pp. 1546–1562, Sep. 2007.
- [25] S. Sastry, Y. Ma, A. Y. Yang, and J. Wright, "Unsupervised segmentation of natural images via lossy data compression," *Comput. Vis. Image Understand.*, 2007.
- [26] M. Mignotte, "MDS-based multiresolution nonlinear dimensionality reduction model for color image segmentation," *IEEE Trans. Neural Networks*, vol. 22, no. 3, pp. 447–460, 2011.

این مقاله برگرفته از نتایج تحقیق در راستای یک پایان‌نامه‌ی کارشناسی‌ارشد می‌باشد که توسط دانشگاه شهید چمران اهواز در قالب پژوهانه (اعتبار ویژه‌ی پژوهشی) سال ۱۳۹۳ حمایت مالی شده است. نویسندگان مقاله از حمایت‌های معنوی و مادی دانشگاه شهید چمران اهواز از این مقاله و پایان‌نامه، تشکر و قدردانی می‌نمایند.

## مراجع

- [1] F. Lang, J. Yang, D. Li, L. Zhao, and L. Shi, "Polarimetric SAR Image Segmentation Using Statistical Region Merging," *IEEE Geoscience and Remote Sensing Letters*, Vol. 11, No. 2, pp. 509–513, Feb. 2014.
- [2] X. Lian, Y. Wu, W. Zhao, F. Wang, Q. Zhang, and M. Li, "Unsupervised SAR Image Segmentation Based on Conditional Triplet Markov Fields," *IEEE Geoscience and Remote Sensing Letters*, Vol. PP, No. 99, pp. 1–5, Jun. 2014.
- [3] L. Gan, Y. Wu, F. Wang, P. Zhang, and Q. Zhang, "Unsupervised SAR Image Segmentation Based on Triplet Markov Fields With Graph Cuts," *IEEE Geoscience and Remote Sensing Letters*, Vol. 11, No. 4, pp. 853–857, April 2014.
- [4] G. Shuiping, X. Zhuang, H. Zhu, and T. Yu, "Parallel Sparse Spectral Clustering for SAR Image Segmentation," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, Vol. 6, No. 4, pp. 1949–1963, Aug. 2013.
- [5] H. Yu, X. Zhang, S. Wang, and B. Hou, "Context-Based Hierarchical Unequal Merging for SAR Image Segmentation," *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 51, No. 2, pp. 995–1009, Feb. 2013.
- [6] J. S. Lee, T. L. Ainsworth, and P. R. Kersten, "Unsupervised classification of polarimetric synthetic aperture radar images using fuzzy clustering and EM clustering," *IEEE Trans Geosci Remote Sens*, vol. 43, no. 3, pp. 519–527, 2005.
- [7] D. Ziou, S. Wang, Q. Jiang, and A. E. Zarrt, "Segmentation of SAR images," *Pattern Recogn*, vol. 35, no. 3, pp. 713–724, 2002.
- [8] I. Jurkevich and J. S. Lee, "Segmentation of SAR images," *IEEE Trans Geosci Remote Sens*, vol. 27, no. 6, pp. 674–680, 1989.
- [9] V. Haese-coat, J. Ronsin, and B. Ogor, "SAR image segmentation by mathematical morphology and texture analysis," in *Proceedings Int Geoscience and Remote Sensing Symposium*, Lincoln, Nebraska, USA, 1996, pp. 717–719.
- [10] L. C. Jiao and X. L. Ma, "SAR image segmentation based on watershed and spectral clustering," *Journal of Infrared Millim Waves*, vol. 27, no. 6, pp. 452–457, 2008.
- [11] L. C. Jiao, F. Liu, L. F. Bo, M. G. Gong, and X. R. Zhang, "Spectral clustering ensemble applied to SAR image segmentation," *IEEE Trans Geosci Remote Sens*, vol. 46, no. 7, pp. 2126–2135, 2008.