



سجش از دور

GIS ایران



سنجش از دور و GIS ایران
Iranian Remote Sensing & GIS

سال هفتم، شماره سوم، پاییز ۱۳۹۴
Vol.7, No. 3, Autumn 2015

۹۷-۱۱۴

بهبود طبقه‌بندی بدون نظارت تصاویر فراطیفی با استفاده از مدل خوشه‌بندی فازی Gustafson-Kessel

حمید عزت‌آبادی پور^{۱*}، سعید همایونی^۲

۱. مری رشتۀ مهندسی نقشه‌برداری، دانشکده مهندسی عمران، دانشگاه صنعتی سیرجان
۲. استادیار، گروه جغرافیا، مطالعات محیطی و ژئوماتیک، دانشگاه اتاوا

تاریخ پذیرش مقاله: ۱۳۹۵/۱/۳۱

تاریخ دریافت مقاله: ۱۳۹۴/۲/۲۱

چکیده

مدل‌های خوشه‌بندی c-means یکی از پرکاربردترین شیوه‌های طبقه‌بندی نظارت‌نشده در آنالیز داده‌ها به‌شمار می‌رود. مدل فازی این روش، یعنی Fuzzy c-means، یکی از مشهورترین مدل‌هایی است که در آن هر داده با یک مقدار درجه عضویت بین ۰ و ۱، به هر یک از خوشه‌ها اختصاص داده می‌شود. این مدل خوشه‌بندی جهت طبقه‌بندی داده‌های سنجش از دوری بسیار استفاده شده است. مدل Fuzzy c-means از فاصله اقلیدسی جهت خوشه‌بندی استفاده کرده و برای همه خوشه‌ها شکل یکسانی فرض می‌کند. با وجود این، این مدل برای داده‌هایی که در آن‌ها کلاس‌ها دارای شکل و حجم متفاوت‌اند، مناسب به نظر نمی‌رسد. برای رفع این مشکل، مدل Gustafson-Kessel جهت خوشه‌بندی داده‌های پیچیده ارائه شده است. این مدل بر مبنای به‌کارگیری یک ماتریس کوواریانس فازی برای هر خوشه عمل می‌کند و شکل هندسی، حجم و جهت‌گیری یکسانی برای همه خوشه‌ها در نظر نمی‌گیرد. در این تحقیق، از هر دو مدل خوشه‌بندی مذکور جهت داده‌های سنجش از دوری فراطیفی واقعی حاصل از سنجنده‌های Hyperion، ROSIS و CASI استفاده شده است. نتایج حاصل از مدل‌های خوشه‌بندی Fuzzy c-means و Gustafson-Kessel به پارامتری به نام فازی‌کننده وابسته است که در این تحقیق، مقدار بهینه آن با محاسبه و بررسی دقت طبقه‌بندی هر یک از این مدل‌ها، در ازای فازی‌کننده‌های مختلف به‌دست آمده است. نتایج به‌دست آمده در ازای مقدار بهینه فازی‌کننده، نشان می‌دهد که مدل Gustafson-Kessel دقت و صحت طبقه‌بندی را حدود ۱۲/۵٪ برای داده‌های Hyperion و حدود ۸/۴۵٪ برای داده‌های ROSIS افزایش می‌دهد. همچنین، ارزیابی دیداری نتایج دو مدل خوشه‌بندی روی داده‌های CASI نشان می‌دهد که مدل Gustafson-Kessel عملکرد بهتری دارد. البته در مقابل، باید گفت مدل Gustafson-Kessel هزینه زمانی بیشتری را صرف می‌کند و همچنین، جهت تعیین پارامتر مربوط به حجم خوشه‌ها، به دانش قبلی نیاز دارد.

کلید واژه‌ها: خوشه‌بندی فازی، مدل خوشه‌بندی Gustafson-Kessel، تصاویر فراطیفی.

* نویسنده عهده‌دار مکاتبات: سیرجان، ابتدای جاده بافت، دانشگاه صنعتی سیرجان، کد پستی: ۷۸۱۳۷۳۳۸۵ تلفن ثابت: ۰۳۴-۴۲۲۴۲۱۱۶ - همراه: ۰۹۱۳۳۷۹۲۹۴۱
Email: hezzatabadi@sirjantech.ac.ir

۱- مقدمه

یکی از روش‌های اصلی استخراج اطلاعات از تصاویر سنجش از دوری، طبقه‌بندی است. با توجه به اینکه سنجنده‌های فراطیفی، تصاویر را در صدها باند طیفی باریک و پیوسته ثبت می‌کنند، برای پیکسل‌های مربوط به مواد گوناگون روی سطح زمین، مقادیر مختلف و متنوعی از درجات خاکستری تولید می‌شود. از این رو، یکی از موفقیت‌آمیزترین کاربردهای تصاویر فراطیفی، طبقه‌بندی و تولید نقشه پوشش زمین است (Shah et al., 2013). روش‌های طبقه‌بندی را می‌شود بر این اساس، که آیا از داده‌های آموزشی برای آنالیز تصویر استفاده می‌کنند یا خیر، به دو گروه روش‌های نظارت‌شده و نظارت‌نشده تقسیم‌بندی کرد.

اگر چه روش‌های نظارت‌شده در مقایسه با روش‌های نظارت‌نشده همواره به نتایج بهتری در طبقه‌بندی تصاویر سنجش از دوری منجر می‌شوند، جمع‌آوری داده‌های آموزشی در روش‌های نظارت‌شده، در هر صورت، مشکلی عمده محسوب می‌شود زیرا هزینه‌بر و زمان‌بر است. در صورتی که روش‌های نظارت‌شده برای طبقه‌بندی داده‌های تصویری فراطیفی، به دلیل افزایش تعداد باندهای طیفی، به تعداد داده‌های آموزشی نیاز دارند. از این رو، با توجه به دشواری مضاعف جمع‌آوری داده‌های آموزشی در تصاویر فراطیفی، طبقه‌بندی آن‌ها با استفاده از روش‌های نظارت‌نشده، ضروری به نظر می‌رسد.

خوشه‌بندی یکی از روش‌های اصلی طبقه‌بندی نظارت‌نشده است که هدف در آن عبارت است از بیشینه کردن شباهت بین داده‌های داخل-کلاسی^۱ و کمینه کردن شباهت بین داده‌های بین-کلاسی^۲. خوشه‌بندی در حوزه‌هایی مانند داده‌کاوی، فراگیری ماشین، زیست‌شناسی و آمار پایه کاربرد دارد. این روش در حوزه‌های مختلفی از قبیل تجارت، شناسایی الگو، ارتباطات، زیست‌شناسی، فیزیک، نجوم و غیره مورد استفاده قرار گرفته است. در میان روش‌های خوشه‌بندی، روش جزءبندی^۳ اهمیت ویژه‌ای در

طبقه‌بندی نظارت‌نشده تصاویر سنجش از دوری دارد. این نوع خوشه‌بندی اغلب از الگوریتم‌های بهینه‌سازی تناوبی^۴ جهت تشکیل خوشه‌ها استفاده می‌کند و از طریق نمونه‌های اولیه^۵ و اندازه‌گیری فاصله، می‌تواند دانش راجع به شکل یا اندازه خوشه‌ها را در خود جای دهد (Tsai et al., 2002).

روش‌های خوشه‌بندی جزءبندی را می‌شود به دو دسته تقسیم کرد: خوشه‌بندی قطعی یا سخت که هر داده فقط به یک خوشه تعلق دارد و خوشه‌بندی فازی یا نرم که در آن هر داده به یک خوشه معین با یک مقدار عضویت بین ۰ و ۱ تعلق دارد. وقتی که مرز بین خوشه‌ها واضح و مشخص نیست و یک داده به بیش از یک خوشه تعلق دارد، خوشه‌بندی فازی مناسب‌تر به نظر می‌رسد. این شرایط در تصاویر سنجش از دوری به فراوانی مشاهده می‌شود.

پژوهش‌های بسیاری روی استفاده از روش‌های خوشه‌بندی، جهت طبقه‌بندی تصاویر چندطیفی ارائه شده است (Rosenberger and Chehdi, 2003)، (Fana et al., 2003)، (Tran et al., 2008)، (Jie et al., 2008)، (2009). در دهه اخیر، در زمینه طبقه‌بندی تصاویر فراطیفی با استفاده از روش‌های خوشه‌بندی نیز، تحقیقات وسیعی انجام شده است (Xie and Zhang, 2012)، (Naeni et al., 2013)، (Lu et al., 2014)، (Aydav and Minz, 2014).

یکی از پرکاربردترین روش‌های خوشه‌بندی، خانواده خوشه‌بندی c-means است که جهت آنالیز تصاویر سنجش از دوری نیز در زمینه‌های گوناگون کاربرد دارد. مدل Fuzzy c-means (FCM) یک روش خوشه‌بندی فازی و از موفق‌ترین مدل‌های خانواده خوشه‌بندی c-means است. این مدل از فاصله اقلیدسی برای اندازه‌گیری نزدیکی پیکسل‌های تصویری و مراکز

1. intra-class
2. inter-class
3. partitioning
4. alternating optimization
5. prototypes

کمیته کردن یک تابع هدف، در پی برآورد یک طبقه‌بندی بهینه‌اند (Timm et al., 2004). در خوشه‌بندی مبتنی بر تابع هدف، معمولاً هر خوشه به وسیله یک نمونه اولیه مدل می‌شود که اغلب فقط شامل مرکز خوشه است. به عبارت دیگر، نماینده هر خوشه میانگین داده‌های وابسته به آن خوشه خواهد بود. این نوع خوشه‌بندی را می‌شود به صورت زیر ارائه کرد:

- ورودی: مجموعه داده $X = \{\vec{x}_1, \dots, \vec{x}_n\} \subseteq R^p$
n: تعداد داده‌ها p : بعد داده‌ها
- خروجی: ماتریس جزءبندی U و ماتریس مراکز خوشه‌ها V

c: تعداد خوشه‌ها ($1 < c < n$)

$$U = \begin{bmatrix} u_{11} & \dots & u_{1n} \\ \vdots & \ddots & \vdots \\ u_{c1} & \dots & u_{cn} \end{bmatrix}, V = \begin{bmatrix} v_{11} & \dots & v_{1p} \\ \vdots & \ddots & \vdots \\ v_{c1} & \dots & v_{cp} \end{bmatrix}$$

- هدف: بیشینه کردن شباهت داخل خوشه‌ها و کمیته کردن شباهت بین خوشه‌ها

۲-۱- مدل خوشه‌بندی FCM

مدل خوشه‌بندی FCM، از سوی Dunn (1973) ارائه و به وسیله Bezdek (1981) توسعه داده شد. در این مدل، هدف کمیته کردن تابع هدف مفید زیر است

رابطه (۱)

$$\min_{(U, V)} \left\{ J_m(U, V; X) = \sum_{k=1}^n \sum_{i=1}^c u_{ik}^m \|\vec{x}_k - \vec{v}_i\|^2 \right\}$$

تحت شروط:

$$\sum_{k=1}^n u_{ik} > 0, \quad \forall i \quad (۲)$$

$$\sum_{i=1}^c u_{ik} = 1, \quad \forall k \quad (۳)$$

در رابطه (۱)، u_{ik} مقدار عضویت داده $\vec{x}_k \in R^p$ به i امین خوشه، $\vec{v}_i \in R^p$ مرکز i امین خوشه، و $\|\vec{x}_k - \vec{v}_i\|^2$ مربع فاصله اقلیدسی بین \vec{x}_k و \vec{v}_i است. $U = [u_{ik}]_{c \times n}$ و $V = [\vec{v}_1, \dots, \vec{v}_c]_{c \times p}$ هم، به ترتیب، ماتریس‌های مراکز خوشه‌ها و جزءبندی فازی‌اند. پارامتر m فازی‌کننده نامیده می‌شود. این پارامتر

1. hyperspherical
2. fuzzifier

خوشه‌ها استفاده می‌کند و بالطبع، خوشه‌هایی با شکل یکسان و ابرکره^۱ تولید می‌کند. مدل دیگر خانواده خوشه‌بندی c-means، مدل خوشه‌بندی Gustafson-Kessel (GK) است که این مدل از یک نرم جدید برای اندازه‌گیری نزدیکی پیکسل‌های تصویری و مراکز خوشه‌ها استفاده می‌کند. مدل خوشه‌بندی GK حجم، شکل و جهت‌گیری متفاوتی برای هر یک از خوشه‌ها در نظر می‌گیرد.

مدل خوشه‌بندی GK، پیش‌تر، از سوی چندین محقق برای طبقه‌بندی تصاویر چندطیفی و تهیه نقشه کاربری مورد استفاده قرار گرفته است (Turčan, 2003)، (Jie et al., 2008)، (Sadykhov et al., 2009). اما در زمینه طبقه‌بندی تصاویر فراطیفی با استفاده از مدل خوشه‌بندی GK تحقیقات زیادی انجام نشده است. از این رو، ضروری به نظر می‌رسد در این زمینه مطالعه بیشتری صورت پذیرد. در همین راستا، در این تحقیق، مدل خوشه‌بندی GK جهت خوشه‌بندی تصاویر فراطیفی برای تولید نقشه‌های کاربری ارزیابی می‌شود و نتایج آن با مدل خوشه‌بندی FCM مقایسه خواهد شد. از آنجا که تصاویر فراطیفی داده‌های پیچیده‌ای‌اند و معمولاً کلاس‌هایی با شکل و حجم متفاوت دارند، به نظر می‌رسد مدل خوشه‌بندی GK بتواند نتایج طبقه‌بندی را بهبود بخشد.

این مقاله شامل چهار بخش است. در بخش نخست، به مقدمه‌ای کوتاه درباره انگیزه، هدف و بیان مسئله تحقیق و روش کار پرداخته شده است. در بخش دوم، مبانی نظری مدل‌های خوشه‌بندی مورد استفاده بیان می‌شود. بخش سوم، در برگیرنده پیاده‌سازی مدل‌های خوشه‌بندی و ارزیابی آن‌ها خواهد بود. در آخر و در بخش چهارم، نتیجه‌گیری‌ها ارائه می‌شود.

۲- مدل‌های خوشه‌بندی جزءبندی فازی

روش‌های خوشه‌بندی جزءبندی اغلب بر مبنای تابع هدف‌اند و از الگوریتم‌های بهینه‌سازی تناوبی برای تشکیل خوشه‌ها استفاده می‌کنند. این الگوریتم‌ها با

$$\vec{v}_i = \frac{\sum_{k=1}^n u_{ik}^m \vec{x}_k}{\sum_{k=1}^n u_{ik}^m}, \quad 1 \leq i \leq c \quad (6) \text{ رابطه}$$

رابطه (۵) با کمینه کردن تابع هدف J_m در ازای V ثابت و شرط (۳) و رابطه (۶) با کمینه کردن تابع هدف J_m در ازای U ثابت به دست می‌آید. در مدل FCM زمانی مشکل تکینگی رخ می‌دهد که در یک تکرار، یک یا چند فاصله برابر با صفر باشد ($\|\vec{x}_k - \vec{v}_i\| = 0$). هنگامی که این مشکل تکینگی رخ می‌دهد، نمی‌شود u_{ik} را با رابطه (۵) محاسبه کرد. در این حالت که عملاً به ندرت اتفاق می‌افتد، باید به هر u_{ik} که $\|\vec{x}_k - \vec{v}_i\| > 0$ است، مقدار صفر اختصاص داده شود و مقادیر غیر صفر عضویت در میان \vec{v}_i ‌هایی که $\|\vec{x}_k - \vec{v}_i\| = 0$ است، تحت شروط (۲) و (۳)، به‌طور دلخواه توزیع شوند.

۲-۲- مدل خوشه‌بندی GK

مدل خوشه‌بندی GK را Gustafson و Kessel (1979) ارائه کردند. در این مدل نیز هدف کمینه کردن تابع هدف مقید زیر، تحت شروط (۲) و (۳) است

$$\min_{(U, V)} \left\{ J_m(U, V, \{M_i\}; X) = \sum_{k=1}^n \sum_{i=1}^c u_{ik}^m (\vec{x}_k - \vec{v}_i)^T M_i (\vec{x}_k - \vec{v}_i) \right\} \quad (7) \text{ رابطه}$$

در رابطه بالا، $(\vec{x}_k - \vec{v}_i)^T M_i (\vec{x}_k - \vec{v}_i)$ نرم فاصله تطبیقی^۱ است که در آن M_i یک ماتریس متقارن و مثبت-معین است (Abonyi and Feil, 2007). باید توجه کرد که در رابطه (۷) تابع هدف J_m نسبت به M_i خطی است و با انتخاب M_i کوچک‌تر، به‌سادگی می‌شود تابع هدف J_m را به میزان دلخواه کمینه کرد (Gustafson and Kessel, 1979). بنابراین، کمینه‌سازی J_m نسبت به M_i به‌طور مستقیم امکان‌پذیر نیست و دچار مشکل تکینگی می‌شود (Abonyi and Feil, 2007). برای

1. adaptive

میزان فازی بودن خوشه‌بندی را تعیین می‌کند. m ممکن است هر عدد حقیقی بزرگ‌تر مساوی با ۱ باشد که در ازای مقادیر بالای m مرز بین خوشه‌ها غیردقیق-تر، و در ازای مقادیر پایین m مرز بین خوشه‌ها مشخص‌تر می‌شود. معمولاً $m=2$ انتخاب می‌شود (Timm et al., 2004).

رابطه شرط (۲) ضمانت می‌کند که هیچ خوشه‌ای خالی نباشد و از سوی دیگر، رابطه شرط (۳) تضمین می‌کند که مجموع عضویت‌ها برای هر داده برابر ۱ باشد. تابع هدف J_m را نمی‌شود به‌طور مستقیم کمینه کرد. از این رو، کمینه‌سازی تقریبی J_m به وسیله الگوریتم تکراری FCM-AO انجام می‌شود (Pal et al., 2005). این الگوریتم بر مبنای تکرار شرایط لازم برای کران‌های محلی J_m است. پس از اعمال شرط (۳) می‌شود از طریق نظریه ضرایب لاگرانژ شرایط لازم برای کران‌های محلی J_m را به دست آورد. در این حالت، تابع هدف بسط داده شده با ضرایب لاگرانژی به صورت زیر بیان می‌شود

رابطه (۴)

$$\min_{(U, V, \lambda)} \left\{ J_m(U, V, \lambda; X) = \sum_{k=1}^n \sum_{i=1}^c u_{ik}^m \|\vec{x}_k - \vec{v}_i\|^2 + \sum_{k=1}^n \lambda_k \left(\sum_{i=1}^c u_{ik} - 1 \right) \right\}$$

شرایط لازم برای کران‌های محلی تابع هدف J_m به سادگی از طریق برابر با صفر قرار دادن گرادیان رابطه (۴) نسبت به پارامترهای u_{ik} ، λ_k (ضرایب لاگرانژ) و \vec{v}_i که باید بهینه شوند، استنتاج می‌شود (Bezdek, 1981). اگر $m > 1$ $\|\vec{x}_k - \vec{v}_i\| > 0$ (به ازای هر i و k) و X شامل دست کم c داده مجزا باشد، آن‌گاه تابع هدف J_m کمینه می‌شود، فقط اگر:

رابطه (۵)

$$u_{ik} = \left(\sum_{j=1}^c \left(\frac{\|\vec{x}_k - \vec{v}_i\|}{\|\vec{x}_k - \vec{v}_j\|} \right)^{\frac{2}{m-1}} \right)^{-1}, \quad 1 \leq i \leq c, \quad 1 \leq k \leq n$$

$$\bar{v}_i = \frac{\sum_{k=1}^n u_{ik}^m \bar{x}_k}{\sum_{k=1}^n u_{ik}^m}, \quad 1 \leq i \leq c \quad (12)$$

در رابطه (۱۰)، F_i ماتریس کوواریانس فازی نامین خوشه است که به صورت زیر محاسبه می شود (Gustafson and Kessel, 1979)

رابطه (۱۳)

$$F_i = \frac{\sum_{k=1}^n u_{ik}^m (\bar{x}_k - \bar{v}_i)(\bar{x}_k - \bar{v}_i)^T}{\sum_{k=1}^n u_{ik}^m}, \quad 1 \leq i \leq c$$

پارامتر ρ_i در رابطه (۱۰) بیانگر حجم خوشه i است. در صورتی که هیچ دانش قبلی در مورد این پارامتر در دسترس نباشد، به اجبار برای همه خوشه ها برابر با یک قرار داده می شود. با توجه به رابطه شرط (۸)، این امر باعث می شود که مدل خوشه بندی GK به خوشه های با حجم تقریباً مساوی بینجامد (Babuška, 2001).

ساختار ویژه ماتریس کوواریانس فازی F_i ، اطلاعاتی در مورد شکل و جهت گیری خوشه ها در اختیار قرار می دهد. در مدل خوشه بندی GK، خوشه ها به شکل ابربیضی^۱ در نظر گرفته می شوند. نسبت جذر مقادیر ویژه F_i بیانگر نسبت طول محورهای ابربیضی، و بردارهای ویژه F_i ، بیانگر جهت محورهای ابربیضی است (Babuška, 2001). مدل خوشه بندی GK برای آشکارسازی خوشه هایی با شکل هندسی متفاوت، مناسب است (Abonyi and Feil, 2007).

۳- پیاده سازی

مدل های خوشه بندی c-means از طریق الگوریتم های بهینه سازی تناوبی (AO) پیاده سازی می شوند. معادلات (۵) و (۶) روابط به روزرسانی عضویت ها و مراکز خوشه ها در الگوریتم FCM-AO هستند. هر تکرار این الگوریتم شامل یک گردش است که به دو حالت امکان انجام شدن دارد:

حل این مسئله باید روی M_i ها شرط اعمال کرد. ایده ها این است که نرم فاصله تطبیقی در هر بُعد از داده ها مقیاس گذاری متفاوتی را اعمال کند. به عبارت دیگر، بهتر است نرم جدید در شکل خوشه ها تغییر ایجاد کند اما این نرم بدون محدودیت بزرگ نشود (Gustafson and Kessel, 1979). این امر فقط با محدود کردن درمیان ماتریس M_i صورت می پذیرد

$$|M_i| = \rho_i, \quad \rho_i > 0 \quad (8)$$

در رابطه شرط بالا، ρ_i برای هر خوشه ثابت در نظر گرفته می شود. با اعمال شرط (۸) حجم خوشه ها ثابت می ماند اما شکل آن ها در جهت کمینه سازی J_m تغییر می کند. در این مدل نیز شروط (۳) و (۸) از طریق تئوری ضرایب لاگرانژ روی تابع هدف J_m در رابطه (۷) اعمال می شود و تابع هدف به صورت زیر بیان می شود

رابطه (۹)

$$\min_{(U, V)} \{J_m(U, V, \lambda, \beta, \{M_i\}; X) =$$

$$\sum_{k=1}^n \sum_{i=1}^c u_{ik}^m (\bar{x}_k - \bar{v}_i)^T M_i (\bar{x}_k - \bar{v}_i) + \sum_{k=1}^n \lambda_k \left(\sum_{i=1}^c u_{ik} - 1 \right) + \sum_{i=1}^c \beta_i (|M_i| - \rho_i) \}$$

شرایط لازم برای کران های محلی تابع هدف بالا نیز از طریق برابر با صفر قرار دادن گرادیان رابطه (۹) نسبت به پارامترهای λ_k ، β_i ، M_i ، u_{ik} و \bar{v}_i که باید بهینه شوند، به دست می آید. اگر $m > 1$ ، $(\bar{x}_k - \bar{v}_i)^T M_i (\bar{x}_k - \bar{v}_i) > 0$ (به ازای هر i و k) و X شامل دست کم c داده مجزا باشد، آن گاه تابع هدف J_m کمینه می شود، فقط اگر

$$M_i = (\rho_i |F_i|)^{\frac{1}{m}} F_i^{-1}, \quad 1 \leq i \leq c \quad (10)$$

رابطه (۱۱)

$$u_{ik} = \left(\sum_{j=1}^c \left(\frac{(\bar{x}_k - \bar{v}_i)^T M_i (\bar{x}_k - \bar{v}_i)}{(\bar{x}_k - \bar{v}_j)^T M_j (\bar{x}_k - \bar{v}_j)} \right)^{\frac{2}{m-1}} \right)^{-1}$$

$$1 \leq i \leq c; 1 \leq k \leq n$$

1. hyperellipsoid

مجموعه داده را دربر دارد

۳. انتخاب c داده در امتداد قطر هایپرباکسی که مجموعه داده را دربر دارد، به طوری که با فواصل یکسان توزیع شده باشند.

برای داده‌های سنجش از دوری، روش سوم منطقی‌تر به نظر می‌رسد. زیرا در این روش، مقادیر اولیه در ناحیه‌ای از فضای چندطیفی یا فراطیفی توزیع شده‌اند که بیشتر کلاس‌های طیفی در آن واقع می‌شوند (Richards, 2012). از سوی دیگر، با این روش همگرایی زودتر حاصل می‌شود. در داده‌های سنجش از دوری، هایپرباکسی که کل فضای طیف را دربر بگیرد، با استخراج مقادیر کمینه و بیشینه روشنایی از روی هیستوگرام هر باند طیفی تعیین می‌شود (Richards, 2012). در این تحقیق نیز از روش سوم برای مقادیر اولیه استفاده شده است. با توجه به نزدیکی توزیع داده‌های سنجش از دوری مورد استفاده به توزیع نرمال، حدود ۷۰٪ پیکسل‌های تصویری در هر باند طیفی در بازه $[\vec{\mu}_k - \vec{\sigma}_k, \vec{\mu}_k + \vec{\sigma}_k]$ واقع می‌شوند. در این تحقیق، محدوده‌های طیفی هایپرباکس موردنظر در هر باند طیفی از طریق این بازه به دست آمده است زیرا اگر از بازه طیفی $[\vec{min}_k, \vec{max}_k]$ استفاده شود، مقادیر اولیه نزدیک به \vec{min}_k و \vec{max}_k تحت تأثیر طیف‌های نویزی و دور از کلاس‌های طیفی قرار می‌گیرند.

پس از تعیین مقادیر اولیه مراکز خوشه‌ها، با اجرای الگوریتم‌های FCM-AO و GK-AO نتایج خوشه‌بندی به صورت ماتریس جزءبندی U به دست می‌آید. این نتایج جهت ارزیابی، باید غیرفازی و به تصاویر خوشه‌بندی تبدیل شوند. برای این منظور، با در نظر گرفتن حداکثر مقدار عضویت هر پیکسل، آن پیکسل به یک خوشه اختصاص داده می‌شود و یک تصویر خوشه‌بندی به دست می‌آید.

روند اجرای الگوریتم‌های FCM-AO و GK-AO در شکل ۱ نشان داده شده است.

۱. $V^{(t)} \Rightarrow U^{(t)} \Rightarrow V^{(t-1)}$: در این حالت، مقداردهی اولیه و پایان‌یابی روی V صورت می‌گیرد و در پایان هر تکرار، $\|V^{(t)} - V^{(t-1)}\| / (p \times c) \leq \varepsilon$ کنترل می‌شود.

۲. $U^{(t-1)} \Rightarrow V^{(t)} \Rightarrow U^{(t)}$: در این حالت، مقداردهی اولیه و پایان‌یابی روی U صورت می‌گیرد و در پایان هر تکرار، $\|U^{(t)} - U^{(t-1)}\| / (n \times c) \leq \varepsilon$ کنترل می‌شود.


ε حد آستانه است. هر دو حالت بالا در منابع علمی گوناگون به کار رفته‌اند. نظریه همگرایی در هر دو حالت یکسان است. اما حالت نخست چند مزیت دارد که از آن‌ها، می‌شود به راحت‌تر بودن، پردازش سریع‌تر و نیاز به حجم کمتر حافظه برای ذخیره‌سازی اشاره کرد. مقداردهی اولیه و پایان‌یابی روی U از این جهت سخت‌تر است که هنگام کنترل $\|U^{(t)} - U^{(t-1)}\| / (n \times c) \leq \varepsilon$ در پایان هر تکرار، باید تعداد پارامترهای بیشتری به هم نزدیک شوند. در این تحقیق، از الگوریتم FCM-AO در حالت $V^{(t-1)} \Rightarrow U^{(t)} \Rightarrow V^{(t)}$ استفاده شده است.

مشابه مدل خوشه‌بندی FCM، معادلات (۱۰)، (۱۱) و (۱۲)، فرمول‌های به‌روزرسانی ماتریس‌های $\{M_i\}$ ، عضویت‌ها و مراکز خوشه‌ها در الگوریتم تکراری GK-AO هستند. مانند الگوریتم FCM-AO در این تحقیق، الگوریتم GK-AO در حالت $V^{(t)} \Rightarrow U^{(t)} \Rightarrow \{M_i\}^{(t-1)} \Rightarrow V^{(t-1)}$ استفاده شده است. در تکرار نخست نیز جهت محاسبه $\{M_i\}^{(0)}$ ، به $U^{(0)}$ نیاز است که از طریق رابطه (۵) در مدل FCM محاسبه شده است.

طبیعت تکراری الگوریتم‌های AO آن‌ها را به مقداردهی اولیه حساس می‌کند و باعث می‌شود این الگوریتم‌ها به کمینه‌های محلی منجر شوند. تاکنون هیچ روش کلی و قطعی برای مقداردهی اولیه ارائه نشده است (Bezdek et al., 1999). روش‌های معمول عبارت‌اند از:

- انتخاب c داده مجزای نخست مجموعه داده
- انتخاب تصادفی c داده از داخل هایپرباکسی که

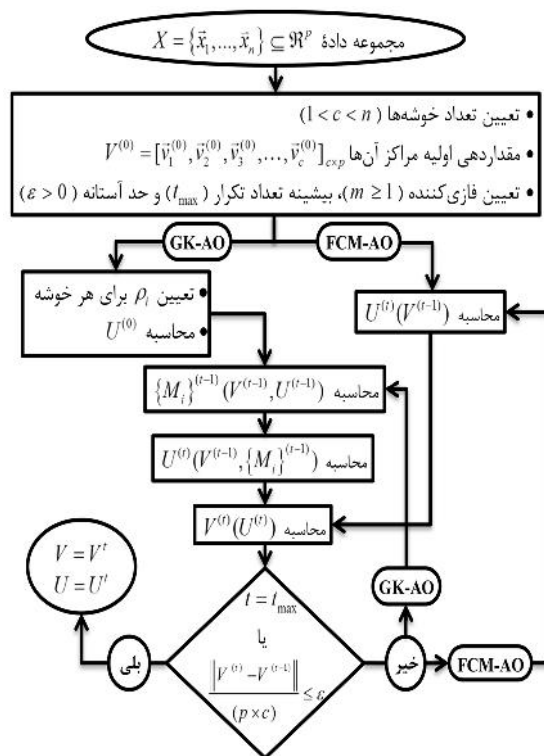
آب را پوشش می‌دهند، حذف شده‌اند و ۱۴۵ باند باقی مانده است که شامل [۱۰-۵۵، ۸۲-۹۷، ۱۰۲-۱۱۹، ۱۳۴-۱۶۴، ۱۸۷-۲۲۰] می‌شود. پیش‌پردازش این داده‌ها را مرکز تحقیقات فضایی دانشگاه تگزاس، جهت کاهش آثار نامطلوب آشکارسازها، خطای کالیبراسیون داخلی آشکارسازها و ناهنجاری‌های دوره‌ای انجام داده است. در منطقه زیرپوشش این تصاویر چهارده کلاس شناسایی شده و داده‌های واقعیت زمینی مربوط به این کلاس‌ها به صورت دستی، با ترکیبی از GPS، تصاویر هوایی و تصاویر چندطیفی IKONOS، با قدرت تفکیک ۲.۶ متر، استخراج شده است. داده‌های تصویری منطقه مورد مطالعه و موقعیت مکانی این چهارده کلاس در شکل ۲ نشان داده شده است. جدول ۱ نیز تعداد نمونه و نوع کلاس‌های داده‌های واقعیت زمینی را نشان می‌دهد.



شکل ۲. ترکیب رنگی (RGB) باندهای ۵۱، ۱۴۹، ۳۱ داده‌های Hyperion و نقشه واقعیت زمینی

جدول ۱. تعداد نمونه و نوع کلاس‌های داده‌های واقعیت زمینی در

تصویر Hyperion		
Code	Class	Sample Size
1	Water	270
2	Hippo Grass	101
3	Floodplain Grasses1	251
4	Floodplain Grasses2	215
5	Reeds1	269
6	Riparian	269
7	Firescar2	259
8	Island Interior	203
9	Acacia Woodlands	314
10	Acacia Shrublands	248
11	Acacia Grasslands	305
12	Short Mopane	181
13	Mixed Mopane	268
14	Exposed Soils	95



شکل ۱. گردش کار الگوریتم‌های GK-AO و FCM-AO


در این تحقیق، از آنجاکه هیچ دانش قبلی درمورد حجم خوشه‌ها در دسترس نبوده است، پارامتر ρ_i در الگوریتم GK-AO برای همه خوشه‌ها برابر با یک در نظر گرفته شده است.

۳-۱- داده‌های مورد استفاده

در این مقاله از سه دسته داده تصویری فراطیفی برای ارزیابی و مقایسه دقت و کارایی مدل‌های FCM و GK استفاده شده است.


دسته نخست داده‌ها تصویر فراطیفی اخذ شده به وسیله سنجنده Hyperion است. این تصویر از دلتای Okavango واقع در شمال غرب Botswana (در تاریخ ۳۱ می ۲۰۰۱) گرفته شده و دارای ابعاد تصویری ۲۵۶×۱۴۷۶ پیکسل و قدرت تفکیک مکانی ۳۰ متر است. این داده‌های تصویری دارای قدرت تفکیک طیفی ۲۴۲ باند در گستره طیفی ۴۰۰-۲۵۰۰ نانومترند. باندهای کالیبره نشده و نویزی، که خصوصیات جذبی

مجموعه داده سوم داده‌های تصویری سنجنده CASI است. CASI یک سنجنده هواپرد فرایطیفی با قدرت تفکیک طیفی ۲۲۸ باند است که البته می‌شود طبق نیاز کاربر، این تعداد را تغییر داد. باندهای طیفی محدوده‌ای شامل ۰/۴ تا ۱ میکرومتر را پوشش می‌دهند. قدرت تفکیک مکانی این سنجنده نیز به ارتفاع سکوی حامل بستگی دارد و از ۱ تا ۱۰ متر متغیر است. تصویر مورد استفاده در این تحقیق در می ۲۰۰۱، از منطقه شهری تولوز، در جنوب فرانسه، اخذ شده است. این تصویر به ابعاد ۱۲۸×۱۲۸ پیکسل، با قدرت تفکیک مکانی ۲ متر و شامل ۳۲ باند طیفی است. برای این داده‌های تصویری، نقشه واقعیت زمینی وجود ندارد و از آن‌ها برای ارزیابی بصری مدل‌های خوشه‌بندی پیاده‌سازی شده استفاده شده است. شکل ۴ ترکیب رنگی کاذب این تصویر را نشان می‌دهد.



شکل ۴. ترکیب رنگی کاذب تصویر CASI (۱/۴۶۸=B، ۴/۶۲۰=G، ۴/۸۲۷=R نانومتر)

دسته دوم داده‌ها، شامل یک تصویر فرایطیفی اخذ شده با سنجنده^۱ ROSIS است. ROSIS سنجنده فرایطیفی هواپردی است که در محدوده طیفی ۸۶۰-۴۳۰ نانومتر، با قدرت تفکیک طیفی ۴ نانومتر طراحی شده است. این تصویر از دانشگاه پابوا واقع در شمال ایتالیا گرفته شده که ابعاد تصویری ۳۴۰×۶۱۰ پیکسل، قدرت تفکیک مکانی ۱/۳ متر و ۱۰۳ باند طیفی دارد. در منطقه‌ای که این صحنه تصویربرداری پوشش می‌دهد، نه کلاس اطلاعاتی از سوی تولیدکننده شناسایی شده است. داده‌های تصویری منطقه مورد مطالعه و موقعیت مکانی این نه کلاس در شکل ۳ نشان داده شده است. جدول ۲ نیز تعداد نمونه و نوع کلاس‌های داده‌های واقعیت زمینی را نشان می‌دهد.



شکل ۳. ترکیب رنگی کاذب باندهای ۱۰۳، ۵۶، ۱۰ داده‌های ROSIS و نقشه واقعیت زمینی

۳-۲- پیش‌پردازش داده‌های تصویری

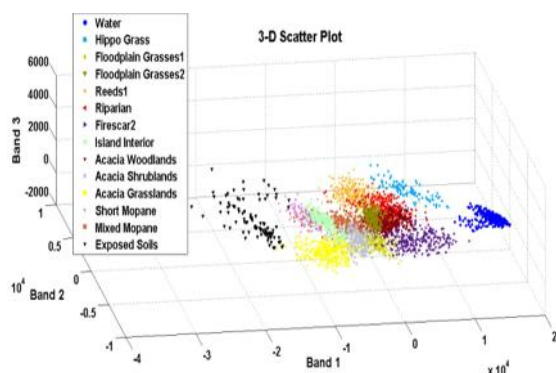
در این تحقیق، پیش از پیاده‌سازی مدل‌های خوشه‌بندی FCM و GK، نخست از تبدیل PCA^۲ جهت کاهش تعداد باندها، حذف وابستگی بین باندها و جداسازی نویز داده‌ها در داده‌های تصویری استفاده شده است (Richards, 2012)، (Jie et al., 2008).

1. reflective optics system imaging spectrometer
2. principal component analysis

جدول ۲. تعداد نمونه و نوع کلاس‌های داده‌های واقعیت زمینی

در تصویر ROSIS		
Code	Class	Sample Size
1	Asphalt	6631
2	Meadows	18649
3	Gravel	2099
4	Trees	3064
5	Painted metal sheets	1345
6	Bare Soil	5029
7	Bitumen	1330
8	Self-Blocking Bricks	3682
9	Shadows	947

برای سه باند نخست تبدیل PCA نشان می‌دهد.



شکل ۵. نمودار پراکنندگی سه‌بعدی چهارده کلاس تصویر Hyperion

در تصویر ROSIS کلاس‌های ۱، ۲ و ۶ (آسفالت، چمنزار و خاک بایر) کلاس‌های یکنواختی نیستند و گاه شامل کلاس‌های ناشناخته دیگر می‌شوند. این مطلب در شکل ۶ به روشنی قابل مشاهده است.



شکل ۶. غیریکنواختی کلاس‌های ۱، ۲ و ۶ (آسفالت، چمنزار و خاک بایر) در تصویر ROSIS



کلاس آسفالت شامل خطوط ترافیک و جداول است. کلاس چمنزار دارای تراکم متفاوت در مناطق مختلف تصویر است. همچنین کلاس خاک بایر، در واقع، کلاسی واحد نیست و چند کلاس ناشناخته دیگر را نیز شامل می‌شود. غیریکنواختی این کلاس‌ها در امضاهای طیفی آن‌ها نیز مشهود است، به طوری که محدوده داخل آن‌ها امضاهای طیفی با اختلاف فاحش را دربر دارد. افزون بر این، کلاس‌های ۳ و ۸ از نظر طیفی به هم بسیار شبیه‌اند و امضای طیفی آن‌ها به یکدیگر نزدیک است. امضای طیفی میانگین این دو کلاس در شکل ۷ نشان داده شده است.

کاهش تعداد باندها سبب پایین آمدن زمان پردازش داده‌ها خواهد شد. تبدیل PCA مبدأ را به میانگین داده‌ها انتقال می‌دهد و محورهای متعامد فضای طیفی را به گونه‌ای دوران می‌دهد که واریانس داده‌ها بیشینه شود. خروجی تبدیل PCA تصویری با تعداد باندهای برابر با تصویر ورودی است که این باندها براساس مقدار واریانس یا میزان اطلاعات مرتب شده‌اند. به طوری که اولین باند بیشترین اطلاعات، و آخرین باند کمترین اطلاعات را دربر دارد. از آنجاکه باندهای آخر واریانس بسیار کوچکی دارند، نویز محسوب می‌شوند. تبدیل PCA می‌تواند هم براساس ماتریس کوواریانس و هم براساس ماتریس همبستگی انجام شود. در این مقاله، تبدیل PCA براساس ماتریس کوواریانس صورت گرفته است.

البته آزمایش‌های انجام‌شده روی داده‌های فراطیفی مورد استفاده، نشان داد که مدل خوشه‌بندی GK تصویر خروجی PCA را بهتر از تصویر اصلی طبقه‌بندی می‌کند. زیرا این مدل در خوشه‌بندی تصویر اصلی خوشه‌های منطبق برهم تولید و چندین خوشه را با هم ادغام می‌کند. بنابراین، می‌شود گفت مدل خوشه‌بندی GK روی تصویر خروجی PCA به نتایج بهتری منجر می‌شود. این امر ممکن است به این دلیل باشد که باندها در تصویر خروجی PCA مستقل، ولی در تصویر اصلی وابسته‌اند زیرا مدل خوشه‌بندی GK اغلب در خوشه‌بندی داده‌های وابسته به هم دچار مشکل می‌شود (Babuška et al., 2002).

پس از اعمال تبدیل PCA روی داده‌های تصویری فراطیفی، چند باند نخست تصویر خروجی جهت خوشه‌بندی انتخاب شد. در تصاویر Hyperion و ROSIS، سه باند نخست و در تصویر CASI، چهار باند نخست انتخاب شده است. این باندها شامل عمده اطلاعات تصویری موجود در داده‌های فراطیفی‌اند، به طوری که در Hyperion، ROSIS و CASI باندهای انتخاب‌شده به ترتیب، ۹۹/۵۷٪ و ۹۹/۶۹٪ و ۹۹/۰۴٪ واریانس داده‌های تصویری را دربر دارند. شکل ۵ نمودار پراکنندگی سه‌بعدی چهارده کلاس تصویر Hyperion را

شکل ۹ دقت کلی محاسبه‌شده برای خروجی مدل‌های خوشه‌بندی FCM و GK پیاده‌سازی‌شده روی تصاویر فراطیفی Hyperion و ROSIS را در ازای تغییرات m نشان می‌دهد.




شکل ۹. دقت کلی مدل‌های خوشه‌بندی FCM و GK در ازای

تغییرات m


شکل ۹ نشان می‌دهد که دقت و صحت نتایج حاصل از پیاده‌سازی مدل‌های خوشه‌بندی FCM و GK در ازای m های مختلف روی تصویر Hyperion، تغییرات تقریباً یکنواختی داشته ولی روی تصویر ROSIS در چند نقطه تغییری چشمگیر داشته است. به‌طور کلی، هر دو مدل خوشه‌بندی FCM و GK در تصویر ROSIS، در ازای m های مختلف، دقت‌های کلی نسبتاً بالایی دارند. این امر به‌دلیل تمایز نسبتاً خوب کلاس‌های انتخاب‌شده در مرحله پیش‌پردازش است.

دقت کلی مدل خوشه‌بندی FCM در تصویر Hyperion در ازای تغییرات m از ۱ تا ۲.۲۵ روند عمدتاً صعودی داشته و ۴.۷٪ افزایش یافته است اما در ازای تغییرات m از ۲.۲۵ تا ۴ روند عمدتاً نزولی داشته و ۱۱.۵٪ کاهش یافته است. FCM در این تصویر، در حالت $m=2.25$ بیشترین دقت را دارد. دقت کلی مدل خوشه‌بندی GK در تصویر Hyperion، در ازای تغییرات m از ۱ تا ۲، روند عمدتاً صعودی داشته (از ۱ تا ۱.۵ این روند قابل توجه است) و ۲۷.۶٪ افزایش یافته، اما



شکل ۷. امضای طیفی میانگین کلاس‌های ۳ و ۸ تصویر ROSIS

در این تحقیق، کلاس‌های ۱ و ۲ و ۶ به‌دلیل غیریکنواختی و دربرداشتن کلاس‌های ناشناخته دیگر و کلاس ۳ به‌دلیل شباهت بسیار با کلاس ۸ حذف شده و فقط از کلاس‌های ۴، ۵، ۷، ۸ و ۹ تصویر ROSIS، برای ارزیابی کارایی مدل‌های خوشه‌بندی FCM و GK استفاده شده است. شکل ۸ نمودار پراکندگی سه‌بعدی پنج کلاس انتخاب‌شده از تصویر ROSIS را برای سه باند نخست تبدیل PCA نشان می‌دهد.



شکل ۸. نمودار پراکندگی سه‌بعدی پنج کلاس انتخاب‌شده از

تصویر ROSIS

۳-۳- ارزیابی نتایج

جهت ارزیابی کمی نتایج مدل‌های خوشه‌بندی FCM و GK با شناسایی خوشه متناظر هر کلاس، ماتریس خطا برای هر مدل محاسبه شده است (Jie et al., 2008). (Aydav and Minz, 2014). از این ماتریس‌ها پارامترهای دقت طبقه‌بندی شامل دقت کلی، ضریب کاپا، دقت تولیدکننده و دقت کاربر استخراج می‌شود. دقت تولیدکننده و دقت کاربر برای هر کلاس جداگانه محاسبه می‌شوند. همچنین، برای ارزیابی پارامتر مؤثر در خوشه‌بندی، یعنی فازی کننده (m)، دقت کلی برای هر یک از این مدل‌ها در ازای m های مختلف محاسبه شده است. هدف از این امر تعیین مقدار بهینه m است.

قطری ماتریس خطا صفر یا نزدیک به صفر می‌شود که این دقت کلی را بسیار کاهش می‌دهد. جدول ۳ تعداد کلاس‌های بدون خوشه متناظر را برای تصاویر فرایطیفی Hyperion و ROSIS در ازای تغییرات m نشان می‌دهد. مقایسه نتایج جدول ۳ و مقادیر دقت کلی در شکل ۹ نشان می‌دهد که وجود یا نبود کلاس بدون خوشه متناظر اغلب باعث تغییر ناگهانی در مقدار دقت کلی شده است. با مقایسه دقت کلی مدل‌های خوشه‌بندی FCM و GK در ازای m بهینه در شکل ۹ می‌شود نتیجه گرفت که مدل خوشه‌بندی GK دقت طبقه‌بندی را ۱۲.۵٪ برای تصویر Hyperion و ۸.۴۵٪ برای تصویر ROSIS افزایش داده است. همچنین، با بررسی کلی این دقت‌ها، می‌شود دید که مدل‌های خوشه‌بندی FCM و GK، به ترتیب، در ازای $m=2.25$ و $m=1.5$ در هر دو تصویر Hyperion و ROSIS به نتایج با دقت خوبی منجر شده‌اند. در این حالت نیز، مدل خوشه‌بندی GK دقت طبقه‌بندی را ۱۱.۴٪ برای تصویر Hyperion و ۸.۶٪ برای تصویر ROSIS افزایش داده است.

جدول‌های ۴ و ۵ ضریب کاپا، دقت کلی، دقت تولیدکننده و دقت کاربر محاسبه‌شده برای مدل‌های خوشه‌بندی FCM و GK را در ازای مقدار بهینه m نشان می‌دهند.

در ازای تغییرات m از ۲ تا ۴ روند عمدتاً نزولی داشته و ۲۴.۶٪ کاهش یافته است. همان‌طور که مشاهده می‌شود، دقت GK در این تصویر در حالت $m=2$ دارای بیشترین مقدار است.

دقت کلی مدل خوشه‌بندی FCM در تصویر ROSIS، در حالت $m=1.75$ بیشترین مقدار را داشته و در ازای افزایش m از ۱ به ۱.۲۵ و از ۲.۷۵ به ۳، افزایش و کاهش چشمگیری یافته است. دقت کلی مدل خوشه‌بندی GK در تصویر ROSIS در حالت $m=1.25$ دارای بیشترین مقدار بوده و در ازای افزایش m از ۱ به ۱.۲۵، از ۱.۵ به ۱.۷۵ و از ۲.۲۵ به ۲.۵ تغییر بسیار کرده است.

همان‌طور که در نتایج بالا مشاهده می‌شود، دقت کلی نتایج مدل‌های خوشه‌بندی FCM و GK در برخی از موارد تغییرات ناگهانی و دور از انتظار داشته است (به‌ویژه در تصویر ROSIS). دلیل اصلی کاهش ناگهانی دقت کلی در این موارد، این است که پس از ایجاد ماتریس خطا در این موارد، پیکسل‌های دو کلاس در یک خوشه (خطای omission) و پیکسل‌های کلاسی دیگر در دو خوشه (خطای omission) قرار می‌گیرند. در نتیجه، یکی از کلاس‌ها بدون یک خوشه متناظر باقی می‌ماند یا به عبارتی دیگر، یکی از عناصر

جدول ۳. تعداد کلاس‌های بدون خوشه متناظر برای تصاویر فرایطیفی Hyperion و ROSIS در ازای تغییرات m

	m	1	1.25	1.5	1.75	2	2.25	2.5	2.75	3	3.25	3.5	3.75	4
Hyperion	FCM	1	2	1	1	1	0	0	0	1	0	0	0	1
	GK	0	1	0	1	0	0	1	0	0	1	1	2	3
ROSI	FCM	1	0	0	0	0	0	0	0	1	1	1	1	1
	GK	1	0	0	1	1	1	0	0	0	0	0	0	0

جدول ۴. پارامترهای دقت طبقه‌بندی برای مدل‌های FCM و GK در ازای m بهینه در تصویر Hyperion

Code	Class	FCM ($m=2.25$)		GK ($m=2$)	
		K. C. =	O. A. =	P. A. (%)	U. A. (%)
1	Water	99.6	99.6	100.0	100.0
2	Hippo Grass	70.3	42.3	100.0	85.6
3	Floodplain Grasses1	82.9	65.4	95.2	69.1
4	Floodplain Grasses2	80.5	63.1	83.3	69.9
5	Reeds1	71.0	80.3	71.8	78.5
6	Riparian	33.1	39.2	64.7	65.2
7	Firescar2	68.7	96.2	87.3	100.0
8	Island Interior	33.0	29.0	61.6	55.8
9	Acacia Woodlands	34.7	44.0	75.2	80.8
10	Acacia Shrublands	56.1	53.9	35.9	41.8
11	Acacia Grasslands	53.4	92.6	79.7	95.3
12	Short Mopane	92.3	54.8	95.0	75.8
13	Mixed Mopane	48.9	51.2	45.9	54.9
14	Exposed Soils	95.8	96.8	86.3	97.6

بهبود طبقه‌بندی بدون نظارت تصاویر فراطیفی با استفاده از مدل خوشه‌بندی فازی Gustafson-Kessel

جدول ۵. پارامترهای دقت طبقه‌بندی برای مدل‌های FCM و GK در ازای m بهینه در تصویر ROSIS

Code	Class	FCM (m=1.75)		GK (m=1.25)	
		K. C. =	0.8633	K. C. =	0.9753
		O. A. =	89.71%	O. A. =	98.16%
		P. A. (%)	U. A. (%)	P. A. (%)	U. A. (%)
4	Trees	98.92	100	97.91	100
5	Painted metal sheets	73.38	99.9	96.65	99.77
7	Bitumen	99.77	65.99	96.02	94.94
8	Self-Blocking Bricks	81.75	89.45	99.27	98.46
9	Shadows	100	97.33	99.79	93.75

در هر دو مدل با هم برابر است. دقت تولیدکننده کلاس ۹ و دقت کاربر کلاس ۵ در هر دو مدل تقریباً یکسان است و دقت کاربر کلاس‌های ۷ و ۸ به‌طور میانگین ۱۹٪ و دقت تولیدکننده کلاس‌های ۵ و ۸ به‌طور میانگین ۲۳.۴٪ در مدل GK بزرگ‌تر از مدل FCM است. البته دقت کاربر کلاس ۹، ۳.۶٪ و دقت تولیدکننده کلاس‌های ۴ و ۷ به‌طور میانگین ۲.۴٪ در مدل FCM بزرگ‌تر از مدل GK است.

ارزیابی کمی نتایج را می‌شود از طریق مقایسه مراکز خوشه‌های به‌دست‌آمده از مدل‌های خوشه‌بندی FCM و GK، در ازای مقدار بهینه m و میانگین کلاس‌های متناظر نیز، بررسی کرد. در جدول‌های ۶ و ۷، فاصله اقلیدسی بین مراکز خوشه‌ها و میانگین کلاس‌ها برای هر مدل محاسبه شده است.

دقت‌های به‌دست‌آمده برای تصویر Hyperion در جدول ۴ نشان می‌دهد که در اغلب موارد، دقت تولیدکننده و دقت کاربر در مدل GK بهتر از مدل FCM است. زیرا همان‌طور که مشاهده می‌شود، دقت تولیدکننده کلاس‌های ۱، ۲، ۳، ۴، ۵، ۶، ۷، ۸، ۹، ۱۱ و ۱۲ به‌طور میانگین ۱۷.۶٪ و دقت کاربر کلاس‌های ۱، ۲، ۳، ۴، ۶، ۷، ۸، ۹، ۱۱، ۱۲، ۱۳ و ۱۴ به‌طور میانگین ۱۴.۶٪ در مدل GK بزرگ‌تر از مدل FCM است. در دیگر موارد، عملکرد مدل FCM بهتر بوده است، به‌طوری‌که دقت تولیدکننده کلاس‌های ۱۰، ۱۳ و ۱۴ به‌طور میانگین ۱۰.۹٪ و دقت کاربر کلاس ۵ و ۱۰ به‌طور میانگین ۶.۹٪ در مدل FCM بزرگ‌تر از مدل GK است.

با بررسی دقت‌های به‌دست‌آمده برای تصویر ROSIS در جدول ۵ می‌شود گفت دقت کاربر کلاس ۴

جدول ۶. مقایسه مراکز خوشه‌های به‌دست‌آمده از مدل‌های FCM و GK در ازای m بهینه و میانگین کلاس‌ها در تصویر Hyperion

Code	Class	FCM (m=2.25)			GK (m=2)	
		Mean	Center of Cluster	Distance	Center of Cluster	Distance
1	Water	[16346.47 -1698.15 659.78]	[16663.70 -1721.09 655.02]	318.09	[16548.68 -1710.43 661.84]	202.60
2	Hippo Grass	[5999.66 1518.78 1310.49]	[5699.30 1793.40 -25.35]	1396.45	[5639.37 1539.65 1245.29]	366.73
3	Floodplain Grasses1	[859.97 -1137.46 -800.84]	[984.54 -1095.88 -653.87]	197.10	[585.21 -1119.07 -765.69]	277.61
4	Floodplain Grasses2	[517.02 418.59 189.75]	[378.22 653.77 12.03]	325.82	[500.88 405.13 250.23]	64.03
5	Reeds1	[-634.84 2966.79 584.35]	[-901.61 2966.29 516.23]	275.33	[-786.30 3037.12 577.54]	167.14
6	Riparian	[2684.24 2494.65 -19.71]	[3729.15 2069.36 -327.49]	1169.37	[3247.29 2486.00 -130.21]	573.85

ادامه جدول ۶.

Code	Class	FCM (m=2.25)			GK (m=2)	
		Mean	Center of Cluster	Distance	Center of Cluster	Distance
7	Firescar2	$\begin{bmatrix} 5092.60 \\ -3121.48 \\ 213.98 \end{bmatrix}$	$\begin{bmatrix} 6823.10 \\ -3123.80 \\ 193.29 \end{bmatrix}$	1730.63	$\begin{bmatrix} 5406.65 \\ -3513.91 \\ 233.00 \end{bmatrix}$	502.98
8	Island Interior	$\begin{bmatrix} -6825.24 \\ -278.09 \\ 402.87 \end{bmatrix}$	$\begin{bmatrix} -5686.52 \\ -1108.59 \\ -358.69 \end{bmatrix}$	1601.99	$\begin{bmatrix} -7056.73 \\ 208.17 \\ 535.79 \end{bmatrix}$	554.71
9	Acacia Woodlands	$\begin{bmatrix} 3041.87 \\ 1714.83 \\ -618.98 \end{bmatrix}$	$\begin{bmatrix} 2112.18 \\ 1775.66 \\ -280.34 \end{bmatrix}$	991.30	$\begin{bmatrix} 2741.29 \\ 1687.36 \\ -600.95 \end{bmatrix}$	302.36
10	Acacia Shrublands	$\begin{bmatrix} -2220.56 \\ -649.11 \\ -681.89 \end{bmatrix}$	$\begin{bmatrix} -1422.23 \\ -394.13 \\ -573.86 \end{bmatrix}$	844.99	$\begin{bmatrix} -4173.81 \\ -913.13 \\ -402.94 \end{bmatrix}$	1990.66
11	Acacia Grasslands	$\begin{bmatrix} -7109.34 \\ -2158.84 \\ -647.85 \end{bmatrix}$	$\begin{bmatrix} -8417.27 \\ -2201.43 \\ -461.32 \end{bmatrix}$	1321.86	$\begin{bmatrix} -7410.58 \\ -2310.28 \\ -605.52 \end{bmatrix}$	339.82
12	Short Mopane	$\begin{bmatrix} -8171.08 \\ 1210.82 \\ 71.94 \end{bmatrix}$	$\begin{bmatrix} -8068.51 \\ 701.70 \\ 292.53 \end{bmatrix}$	564.25	$\begin{bmatrix} -7789.60 \\ 1046.69 \\ 93.75 \end{bmatrix}$	415.86
13	Mixed Mopane	$\begin{bmatrix} -3214.03 \\ 736.59 \\ -238.05 \end{bmatrix}$	$\begin{bmatrix} -3605.79 \\ 129.16 \\ -304.81 \end{bmatrix}$	725.88	$\begin{bmatrix} -1372.90 \\ 311.01 \\ -488.99 \end{bmatrix}$	1906.27
14	Exposed Soils	$\begin{bmatrix} -18179.46 \\ -2517.88 \\ 1815.40 \end{bmatrix}$	$\begin{bmatrix} -17764.47 \\ -2347.08 \\ 1544.25 \end{bmatrix}$	524.32	$\begin{bmatrix} -17998.82 \\ -2682.21 \\ 1517.68 \end{bmatrix}$	385.06

جدول ۷. مقایسه مراکز خوشه‌های به دست آمده از مدل‌های FCM و GK در ازای m بهینه و میانگین کلاس‌ها در تصویر ROSIS

Code	Class	FCM (m=1.75)			GK (m=1.25)	
		Mean	Center of Cluster	Distance	Center of Cluster	Distance
4	Trees	$\begin{bmatrix} 7751.05 \\ 7039.61 \\ -691.74 \end{bmatrix}$	$\begin{bmatrix} 7733.86 \\ 7499.57 \\ -650.54 \end{bmatrix}$	462.12	$\begin{bmatrix} 7855.86 \\ 7084.53 \\ -723.72 \end{bmatrix}$	118.44
5	Painted metal sheets	$\begin{bmatrix} -18540.47 \\ 1801.79 \\ -3050.90 \end{bmatrix}$	$\begin{bmatrix} -23299.38 \\ 3843.86 \\ -2819.73 \end{bmatrix}$	5183.70	$\begin{bmatrix} -18631.40 \\ 1733.64 \\ -3177.83 \end{bmatrix}$	170.37
7	Bitumen	$\begin{bmatrix} 125.01 \\ -4697.42 \\ 507.02 \end{bmatrix}$	$\begin{bmatrix} -204.57 \\ -4068.58 \\ 689.13 \end{bmatrix}$	732.96	$\begin{bmatrix} -369.49 \\ -4466.18 \\ 464.22 \end{bmatrix}$	547.57
8	Self-Blocking Bricks	$\begin{bmatrix} -2241.91 \\ -2109.21 \\ 2389.81 \end{bmatrix}$	$\begin{bmatrix} -3042.89 \\ -1877.31 \\ 2284.02 \end{bmatrix}$	840.56	$\begin{bmatrix} -2225.90 \\ -2118.85 \\ 2388.90 \end{bmatrix}$	18.71
9	Shadows	$\begin{bmatrix} 9869.00 \\ -10470.67 \\ -3439.16 \end{bmatrix}$	$\begin{bmatrix} 9808.14 \\ -10244.49 \\ -3401.70 \end{bmatrix}$	237.20	$\begin{bmatrix} 9521.13 \\ -9611.35 \\ -3200.08 \end{bmatrix}$	957.40

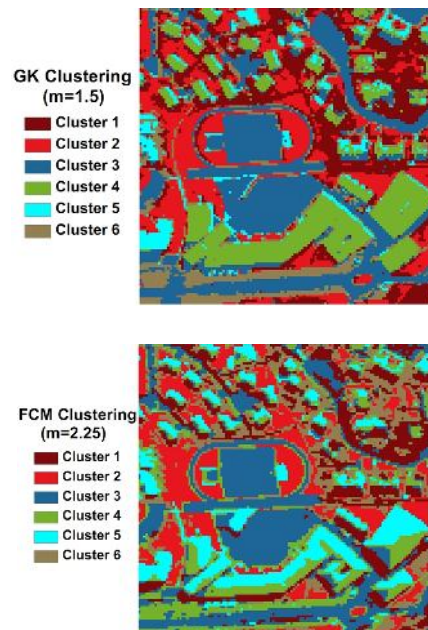
انجام شده است. شکل ۱۰ تصاویر خوشه‌بندی به‌دست‌آمده از این دو مدل را در ازای مقدار بهینه m در تصاویر Hyperion و ROSIS نشان می‌دهد. تعداد خوشه‌ها در این داده‌ها برابر با ۶ در نظر گرفته شده است. با مقایسه تصاویر خوشه‌بندی در شکل ۱۰ و تصویر رنگی کاذب در شکل ۴، می‌شود بیان کرد مدل GK ساختمان‌ها، خیابان‌ها و پوشش گیاهی را بسیار بهتر از مدل FCM استخراج کرده است. برای نمونه، برخی از ساختمان‌ها با بام‌های شیروانی مختلف که در اثر تغییرات زاویه تابش، میزان روشنایی و بازتاب طیفی متفاوتی دارند، در روش FCM به‌درستی طبقه‌بندی نشده‌اند ولی در روش GK، به‌درستی در یک کلاس طیفی قرار داده شده‌اند.

در ارزیابی پایانی، هزینه زمانی مدل‌های خوشه‌بندی FCM و GK بررسی شده است. همه محاسبات و پردازش‌های این مقاله با لپ‌تاپی دارای پردازنده دو هسته‌ای ۲.۲ گیگاهرتز و رم دو گیگابایت، در محیط برنامه‌نویسی IDL انجام شده است. همان‌طور که پیش‌تر بیان شد، مدل‌های خوشه‌بندی FCM و GK با الگوریتم‌های تکراری FCM-AO و GK-AO پیاده‌سازی می‌شوند. در جدول ۸ هزینه زمانی هر تکرار الگوریتم‌های FCM-AO و GK-AO نشان داده است.

باید توجه داشت که هزینه زمانی در الگوریتم‌های FCM-AO و GK-AO به تعداد باندهای تصویر، تعداد پیکسل‌های تصویر و تعداد خوشه‌ها وابسته است. نتایج جدول ۸ نشان می‌دهد مدل خوشه‌بندی GK زمان محاسباتی بیشتری را صرف می‌کند. این امر به دلیل محاسبات اضافی و وقت‌گیر، یعنی محاسبه و به‌روزرسانی ماتریس M_i برای هر خوشه و محاسبه نرم فاصله تطبیقی است.

با مقایسه مراکز خوشه‌های به‌دست‌آمده از مدل‌های خوشه‌بندی FCM و GK در جدول‌های ۶ و ۷، می‌شود گفت در همه موارد، به جز کلاس‌های ۳، ۱۰ و ۱۳ در تصویر Hyperion و کلاس ۹ در تصویر ROSIS، مراکز خوشه‌های تولیدشده در مدل خوشه‌بندی GK به میانگین کلاس‌ها نزدیک‌ترند. بنابراین، می‌شود نتیجه گرفت که مدل خوشه‌بندی GK در تخمین میانگین کلاس‌ها موفق‌تر بوده است.

مدل‌های خوشه‌بندی FCM و GK روی تصویر CASI نیز پیاده‌سازی شده‌اند. از آنجاکه این تصویر فاقد داده واقعیت زمینی است، ارزیابی کمی آن میسر نبوده است. به همین دلیل، نتایج حاصل از خوشه‌بندی این تصویر به‌صورت دیداری بررسی شده است. این عمل با مقایسه تصاویر خوشه‌بندی به‌دست‌آمده از مدل‌های خوشه‌بندی FCM و GK و تصویر رنگی کاذب (شکل ۴)



شکل ۱۰. تصاویر خوشه‌بندی به‌دست‌آمده از مدل‌های FCM و GK در داده‌های تصویری سنجنده CASI

جدول ۸. هزینه زمانی هر تکرار الگوریتم‌های FCM-AO و GK-AO

Name	Data		Clusers	Computation Time of each Iteration	
	Sample Size	Bands (PCA)		FCM-OA	GK-OA
Hyperion	3248	3	14	0.38 s	0.69 s
ROSIS	10368	3	5	0.41 s	0.76 s
CASI	16384	4	6	0.73 s	1.43 s

۴- نتیجه گیری

در این مقاله، مدل خوشه بندی GK جهت طبقه بندی نظارت شده به کار رفته است. این مدل خوشه بندی شکل خوشه ها را ابربیزی فرض می کند و جهت گیری آن ها را در فضای p -بعدی داده ها متغیر در نظر می گیرد. افزون بر این، در مدل خوشه بندی GK می شود برای هر خوشه حجمی دلخواه تعیین کرد. در حالی که مدل خوشه بندی FCM شکل همه خوشه ها را یکسان و ابرکره فرض می کند. پارامتر مؤثر در عملکرد هر دو مدل خوشه بندی FCM و GK، فازی کننده (m) است که در این تحقیق مقدار بهینه آن از طریق بررسی دقت طبقه بندی هر یک از این مدل ها، در ازای مقادیر مختلف آن، تعیین شده است. از آنجا که داده های تصویری سنجنش از دوری، به ویژه تصاویر فراطیفی، ساختار پیچیده ای دارند، استفاده از مدل خوشه بندی GK برای خوشه بندی آن ها مناسب تر به نظر می رسد. آزمون های انجام شده روی تصاویر فراطیفی نشان داد که استفاده از مدل خوشه بندی GK، به جای مدل خوشه بندی FCM، دقت طبقه بندی تصاویر فراطیفی را بهبود می بخشد. از دیگر سو، همان طور که بیان شد، مدل خوشه بندی GK روی تصویر خروجی PCA به نتایج بهتری منجر می شود. این ویژگی مدل خوشه بندی GK مزیت به شمار می آید زیرا لزوم تبدیل PCA باعث کاهش تعداد باندها و، به تبع آن، افزایش سرعت پردازش می شود. با وجود این، مدل خوشه بندی GK هزینه زمانی بیشتری را صرف می کند و همچنین، برای تعیین حجم هر خوشه، به اطلاعات قبلی نیاز دارد که معمولاً موجود نیست.

۵- سپاسگزاری

نویسندگان بر خود لازم می دانند از آقای پروفسور Paolo Gamba از آزمایشگاه ارتباطات و سنجنش از راه دور دانشگاه پابویا (ایتالیا)، برای در دسترس قرار دادن داده های تصویری ROSIS؛ محققان سنجنش از دور مرکز تحقیقات فضایی دانشگاه نگزاس در Austin، برای

فراهم آوردن امکان دسترسی به داده های تصویری Hyperion؛ و پروفسور Michel Roux از مدرسه عالی مخابرات پاریس، برای در اختیار قرار دادن تصاویر سنجنده CASI سپاسگزاری کنند.

همچنین از نظرها و پیشنهادهای داوران محترم نشریه علمی- پژوهشی سنجنش از دور و GIS ایران که موجب بالا بردن سطح علمی و رفع کاستی های این پژوهش شد، سپاسگزاری ویژه می شود.

۶- منابع

- Abonyi, J. & Feil, B., 2007, **Cluster Analysis for Data Mining and System Identification**, Birkhäuser Basel, Boston, Berlin.
- Aydav, P.S.S. & Minz, S., 2014, **Soft Subspace Fuzzy C-Means with Spatial Information for Clustering of Hyperspectral Images**, Journal of Basic and Applied Engineering Research, 1(7): 38-42.
- Babuška, R., 2001, **Fuzzy and Neural Control, Control Engineering Laboratory**, Faculty of Information Technology and Systems, Delft University of Technology, the Netherlands.
- Babuška, R., Veen, P.J.v.d. & Kaymak, U., 2002, **Improved Covariance Estimation for Gustafson-Kessel Clustering**, In Proceedings of the IEEE International Conference on Fuzzy Systems, 2: 1081-1085.
- Bezdek, J.C., 1981, **Pattern Recognition With Fuzzy Objective Function Algorithms**, Springer, New York.
- Bezdek, J.C., Keller, J., Krisnapuram, R. & Pal, N.R., 1999, **Fuzzy Models and Algorithms for Pattern Recognition and Image Processing**, Springer Science+Business Media, New York.
- Dunn, J.C., 1973, **A Fuzzy Relative of the ISODATA Process and Its Use in Detecting Compact Well-Separated Clusters**, Journal of Cybernetics, 3(3): 32-57.
- Fan, J., Han, M. & Wang, J., 2009, **Single Point Iterative Weighted Fuzzy C-Means**

- Sadykhov, R.Kh., Ganchenko, V.V. & Podenok, L.P., 2009, **Fuzzy Clustering Methods in Multispectral Satellite Image Segmentation**, International Journal of Computing, 8(1): 87-94.
- Shah, C.A., Watanachaturaporn, P., Varshney, P.K. & Arora, M.K., 2003, **Some Recent Results on Hyperspectral Image Classification**, Advances in Techniques for Analysis of Remotely Sensed Data, IEEE Workshop on, 346-353.
- Timm, H., Borgelt, C., Doring, C. & Kruse, R., 2004, **An extension to possibilistic fuzzy cluster analysis**, Elsevier, Fuzzy Sets and Systems, 147(1): 3-16.
- Tran, T.N., Wehrens, R. & Buydens, L.M.C., 2003, **SpaRef: A Clustering Algorithm for Multispectral Images**, Elsevier, Analytica Chimica Acta, 490(1-2): 303-312.
- Tsai, C.-F., Wu, H.-C. & Tsai, C.-W., 2002, **A New Data Clustering Approach for Data Mining in Large Databases**, Parallel Architectures, Algorithms and Networks, I-SPAN '02. Proceedings. International Symposium on, 278-283.
- Turčan, A., 2003, **Fuzzy C-Means Algorithms in Remote Sensing**, 1st Slovakian-Hungarian Joint Symposium on Applied Machine Intelligence (SAMI).
- Xie, J. & Zhang, X., 2012, **Clustering of Hyperspectral Image Based on Improved Fuzzy C Means Algorithm**, Journal of Convergence Information Technology, 7(12): 320-327.
- Clustering Algorithm for Remote Sensing Image Segmentation**, Elsevier, Pattern Recognition, 42(11): 2527-2540.
- Gustafson, D.E. & Kessel, W.C., 1979, **Fuzzy Clustering With a Fuzzy Covariance Matrix**, IEEE, 761-766.
- Jie, Y., Peihuang, G., Pinxiang, C., Zhongshan, Z. & Wenbin, R., 2008, **Remote Sensing Image Classification Based on Improved Fuzzy c-Means**, Geo-spatial Information Science, 11(2): 90-94.
- Lu, Q., Huang, X. & Zhang, L., 2014, **A Novel Clustering-Based Feature Representation for the Classification of Hyperspectral Imagery**, Remote Sensing, 6(6): 5732-5753.
- Naeini, A.A., Niazmardi, S., Namin, S.R., Samadzadegan, F. & Homayouni, S., 2013, **A Comparison Study Between Two Hyperspectral Clustering Methods: KFCM and PSO-FCM**, Computational Intelligence and Decision Making: Trends and Applications, Intelligent Systems, Control and Automation: Science and Engineering, Chapter 3, Springer Science, 61: 23-33.
- Pal, N.R., Pal, K., Keller, J.M. & Bezdek, J.C., 2005, **A Possibilistic Fuzzy C-Means Clustering Algorithm**, Fuzzy Systems, IEEE Transactions on, 13(4): 517-530.
- Richards, J.A., 2012, **Remote Sensing Digital Image Analysis**, Springer, London.
- Rosenberger, C. & Chehdi, K., 2003, **Unsupervised Segmentation of Multi-Spectral Images**, International Conference on Advanced Concepts for Intelligent Vision Systems (ACIVS2003), Ghent, Belgium, 1-6.