

جداسازی طیفی و مکانی تصاویر ابرطیفی با استفاده

از Semi-NMF و تبدیل PCA

حبیب علی زاده و حسن قاسمیان

گروه مخابرات، دانشکده مهندسی برق و کامپیوتر، دانشگاه تربیت مدرس، تهران، ایران

چکیده

در سال‌های اخیر جداسازی داده‌های سنجش از دور با استفاده از تجزیه ماتریس نامنفی (Nonnegative Matrix Factorization) مورد توجه قرار گرفته است و برای بهبود کارایی آن، به تابع هزینه اقلیدسی قیدهای کمکی می‌افزایند. چالش اصلی در این میان معرفی قیدهایی است که بتواند نتایج بهتری را استخراج کند. همبستگی بین باندهای تصاویر ابرطیفی مسأله‌ای است که کمتر مورد توجه الگوریتم‌های جداسازی قرار گرفته است. این مسأله در جداسازی کلاس‌های مشابه بیشتر مشخص می‌شود. در این مقاله یک روش جدید برای جداسازی داده‌های ابرطیفی سنجش از دور با استفاده از تجزیه ماتریس نیمه‌نامنفی (Semi-NMF) و تحلیل مؤلفه‌های اصلی پیشنهاد کردیم. در روش پیشنهادی جداسازی طیفی و مکانی به صورت هم‌زمان انجام می‌شود و تمام محدودیت‌های فیزیکی مسأله براساس مدل مخلوط خطی اعمال می‌شود. همچنین، علاوه بر محدودیت‌های فیزیکی، از ویژگی داده‌های ابرطیفی در فرآیند جداسازی بهره‌برداری شده است. تنگی ضرایب فراوانی یکی از ویژگی‌های مهم داده‌های ابرطیفی است که در این مقاله ما با استفاده از ماتریس nsNMF به درون تابع هزینه اعمال کرده‌ایم. در روش پیشنهادی قواعد به‌روزرسانی الگوریتم با استفاده از روش ALS به‌دست آمده است. در بخش انتهایی این مقاله از داده‌های ابرطیفی مصنوعی و واقعی به منظور بررسی کارآمدی الگوریتم پیشنهادی استفاده شده است. نتایج به دست آمده برتری الگوریتم پیشنهادی را در مقایسه با برخی از الگوریتم‌ها جداسازی نشان می‌دهد.

واژگان کلیدی: تصاویر ابرطیفی، جداسازی داده‌های سنجش از دور، جداسازی کور منابع، تجزیه ماتریس نیمه‌نامنفی، تجزیه و تحلیل مؤلفه‌های اصلی.

پیش از بهره‌برداری از این تصاویر در زمینه‌های مختلف علمی و کاربردی، باید چنین پیکسل‌هایی به مواد تشکیل‌دهنده خود تفکیک شوند. جداسازی داده‌های ابرطیفی قصد دارد چنین پیکسل‌هایی را طی دو مرحله تفکیک نماید:

(۱) جداسازی طیفی: استخراج امضای طیفی خالص عناصر کوچک‌تر از ابعاد پیکسل در صحنه که به اصطلاح اعضای انتهایی^۲ می‌نامند.

(۲) جداسازی مکانی: تعیین درصد حضور هر یک از اعضای انتهایی در هر پیکسل که به اصطلاح ضرایب فراوانی^۳ نامیده می‌شود.

۱- مقدمه

با توسعه فناوری سنجیده‌های سنجش از دور، کاربردهای نظامی و غیرنظامی تصاویر ابرطیفی بیش از پیش مورد توجه قرار گرفته است. تصاویر ابرطیفی، مجموعه تصاویری از منطقه مورد مطالعه در صدها باند طیفی مجاور و نزدیک به هم است. این تصاویر حاوی اطلاعات طیفی و مکانی از عناصر و پدیده‌های مختلف موجود در صحنه است. تصاویر ابرطیفی برخلاف برخورداری از قدرت تفکیک طیفی بسیار بالا، قدرت تفکیک مکانی پایین دارند. به همین دلیل عناصر کوچک‌تر از ابعاد یک پیکسل، باعث تشکیل پیکسل‌هایی با امضای طیفی^۱ مخلوط می‌شوند. بنابراین

² Endmembers

³ Abundance Fractions

¹ Spectral Signature

داده‌های ابرطیفی به تابع هزینه افزوده شده است. از جمله آنها می‌توان به CNMF (Pauca, et al., 2006) و MiniDisCoNMF (Huck, 2010) اشاره کرد. در الگوریتم CNMF، قید همواری به تابع هزینه افزوده شده است و تنها برای استخراج اعضای انتهایی مورد استفاده قرار می‌گیرد و تخمین ضرایب فراوانی با استفاده از روش‌های دیگر همچون FCLS انجام می‌شود (Pauca, et al., 2006). در الگوریتم MiniDisCoNMF، قید کاهش پراکندگی طیفی به تابع هزینه افزوده شده است و پارامترهای تنظیم آن از طریق الگوریتم PG² تعیین می‌شود (Huck, 2010) که فرایندی بسیار طولانی است. این الگوریتم، جداسازی طیفی و مکانی را به صورت هم‌زمان انجام می‌دهد؛ ولی با این وجود، تخمین ضرایب فراوانی به خوبی استخراج اعضای انتهایی انجام نمی‌شود و این مسئله به سبب قیدی است که به تابع هزینه افزوده شده است، زیرا قید افزوده شده تنها برای استخراج اعضای انتهایی مناسب است.

یکی از ویژگی‌های داده‌های ابرطیفی، همبستگی بین باندهای تصاویر است. واضح است که این ویژگی امکان شناسایی امضای طیفی طبقه‌های مختلف را دشوار می‌کند و این مسئله در طراحی الگوریتم‌ها جداسازی مورد توجه قرار نگرفته است. در این مقاله ما یک شیوه جدید برای جداسازی داده‌های ابرطیفی سنجنش از دور با استفاده از تجزیه ماتریس نیمه نامنفی (Semi-NMF) (et al., 2009) (Cichocki, et al., 2009) و تحلیل مؤلفه‌های اصلی³ پیشنهاد کردیم. همچنین برای غلبه بر مسئله جواب غیر یکتا، دو قید مطابق با ویژگی داده‌های ابرطیفی به تابع هزینه افزوده‌ایم. روش پیشنهادی علاوه بر افزایش صحت، می‌تواند سرعت اجرای فرایند جداسازی را نیز افزایش دهد.

بخش‌های بعدی مقاله به صورت زیر بیان شده است. از آنجایی که روش پیشنهادی براساس مدل مخلوط خطی است و از این مدل در تبدیل PCA نیز استفاده می‌شود، ابتدا مدل مخلوط خطی و تبدیل PCA به‌عنوان پیش‌زمینه در بخش دو توصیف می‌شود و سپس در بخش سه روش پیشنهادی با استفاده از PCA و Semi-NMF و قیدهای کمکی افزوده شده به تابع هزینه تشریح می‌شود. در بخش چهار روش پیشنهادی با استفاده از داده‌های ابرطیفی مصنوعی و واقعی ارزیابی می‌شود. بخش‌های پنج و شش به ترتیب شامل نتیجه‌گیری و مراجع هستند.

² Projected Gradient

³ Principal Component Analysis (PCA)

در سال‌های اخیر روش‌های زیادی برای جداسازی داده‌های ابرطیفی در قالب به‌کارگیری ویژگی‌های هندسی و آماری ارائه شده است. روش‌هایی از جمله VCA (Nascimento and Dias, 2005) N-FINDER، (Winter, 1999) و PPI (Boardman, 1993) از ویژگی‌های هندسی جهت جداسازی طیفی و استخراج اعضای انتهایی بهره می‌گیرند. اما این روش‌ها فقط برای تصاویری قابل به‌کارگیری هستند که دارای حداقل یک پیکسل خالص از هر عضو انتهایی باشند. همچنین این روش‌ها تنها اعضای انتهایی را استخراج می‌کنند و جداسازی مکانی و تخمین ضرایب فراوانی توسط الگوریتم‌های دیگری همچون FCLS (Heinz and Chang, 2001) SAM (Yuhas, et al., 1992) و SPM (Kwon and Nasrabadi, 2005) انجام می‌شود.

الگوریتم‌های آماری از ویژگی‌های آماری داده‌ها در استخراج اعضای انتهایی و تخمین ضرایب فراوانی استفاده می‌کنند. این الگوریتم‌ها با به‌کارگیری ویژگی‌های آماری، بر بسیاری از محدودیت‌ها و نقض‌های روش‌هایی که بر پایه ویژگی‌های هندسی قرار دارند، غلبه می‌کنند. تحلیل مؤلفه‌های مستقل (ICA)، معروف‌ترین روش در این زمینه است که موفقیت‌هایی در جداسازی منابع به‌صورت کور و تنها با استفاده از فرض استقلال آماری و غیر گوسی بودن کسب کرده است. با این وجود، در خصوص جداسازی تصاویر ابرطیفی، فرض استقلال آماری در حال مصالحه با محدودیت‌های فیزیکی مدل مخلوط خطی است و این مسئله، صحت نتایج داده‌های جداسازی شده با استفاده از این روش را زیر سؤال برده است (Nascimento and Dias, 2005).

تجزیه ماتریس نامنفی¹ یکی دیگر از روش‌های جدید در حوزه جداسازی کور منابع است که ماتریس داده‌ها را به صورت حاصل ضرب دو ماتریس نامنفی تفکیک می‌کند (Berry, et al., 2007). مهم‌ترین مسئله در به‌کارگیری الگوریتم NMF در جداسازی داده‌های سنجنش از دور عدم وجود پاسخ یکتا به سبب وجود کمینه‌های محلی ناشی از غیر محدب بودن تابع هزینه است. از جمله راه‌کارهای کاهش اثر این نقض افزودن قیدهای کمکی مطابق با ویژگی داده‌ها به تابع هزینه است (Liu, et al., 2004).

در خصوص جداسازی داده‌های سنجنش از دور، الگوریتم‌هایی متعددی با استفاده از NMF طراحی شده است. در هر یک از آنها قیدهایی براساس ویژگی‌های

¹ Nonnegative Matrix Factorization (NMF)

که نقشه فراوانی^۲ نامیده می‌شود. هر یک از این نقشه‌ها، فراوانی یک عضو انتهایی در همه پیکسل‌های تصویر را نشان می‌دهد. $E = (e_1, e_2, \dots, e_N) \in R^{L \times N}$ ماتریس خطا و نوفه در همه پیکسل‌های تصویر را مدل می‌کند.

مدل مخلوط خطی تنها به معادله (۲) محدود نمی‌شود و دارای محدودیت‌های فیزیکی است. این محدودیت‌ها باید در طراحی الگوریتم جداسازی در نظر گرفته شوند و به گونه‌ای اعمال شوند که نتایج به دست آمده بنیان فیزیکی مسئله را نقض نکنند، در غیر این صورت نتایج به دست آمده از صحت کافی برخوردار نخواهد بود. این محدودیت‌های فیزیکی عبارتند از:

(۱) همه عناصر ماتریس اعضای انتهایی M باید نامنفی باشند. این قید بر پایه این حقیقت استوار است که درصد انرژی بازتابی از همه پدیده‌های روی زمین مقادیر نامنفی هستند و مقادیر منفی نامفهوم و بی‌معنی خواهد بود.

(۲) همه عناصر ماتریس ضرایب فراوانی A باید نامنفی باشند، یعنی:

$$A_{ij} \geq 0 \quad (1 \leq i \leq P, 1 \leq j \leq N) \quad (3)$$

این محدودیت را به اصطلاح قید نامنفی بودن فراوانی^۳ می‌گویند (Iordache, et al., 2011) و براساس این واقعیت است که مقادیر فراوانی، پارامترهای فیزیکی نامنفی هستند.

(۳) مجموع هر یک از بردارهای فراوانی باید برابر واحد باشد، یعنی:

$$\sum_{i=1}^P A_{ij} = 1 \quad (1 \leq j \leq N) \quad (4)$$

این محدودیت را به اصطلاح، قید مجموع واحد^۴ می‌نامند (Iordache, et al., 2011) و بر این مبنا است که باید مجموع سطح‌های پوشیده شده توسط هر یک از اعضای انتهایی، برابر با سطح پیکسل باشد.

اگر درون یک ماده چندین بازتاب وجود نداشته باشد یعنی بازتاب از یک ماده دوباره توسط همان ماده بازتاب نشود و از طرف دیگر بین مواد درون پیکسل بازتاب‌های متقابل وجود نداشته باشد و مقیاس مخلوط‌شدگی در مقابل اندازه مواد بسیار بزرگ باشد (Lucas, et al., 2004)، می‌توان مخلوط طیفی را به صورت خطی در نظر گرفت و از LMM برای جداسازی استفاده کرد.

² Abundance Map

³ Abundance Nonnegative Constraint (ANC)

⁴ Abundance Sum-to-one Constraint (ASC)

۲- پیش‌زمینه

از آنجایی که از مفاهیم مدل مخلوط خطی^۱ و تحلیل مؤلفه‌های اصلی در فرایند جداسازی روش پیشنهادی استفاده شده است LMM و PCA به ترتیب در بخش ۲-۱ و ۲-۲ توصیف می‌گردند.

۲-۱- مدل مخلوط خطی

بسیاری از روش‌های جداسازی داده‌های ابرطیفی براساس مدل LMM عمل می‌کنند. این مدل اولین بار در سال ۱۹۷۱ معرفی شد (Horwitz, et al., 1971) و براساس آن، امضای طیفی هر پیکسل به وسیله ترکیب خطی وزن‌داری از امضای طیفی اعضای انتهایی در صحنه مدل می‌شود. وزن هر یک از اعضای انتهایی، با سطحی از پیکسل که توسط عضو انتهایی پوشانده شده متناظر است. اگر $x_i \in R^{L \times 1}$ بردار امضای طیفی یک پیکسل با L باند طیفی باشد، براساس LMM به صورت زیر مدل خواهد شد:

$$x_i = MA_i + e_i \quad (1)$$

که $M = [M_1, M_2, \dots, M_P] \in R^{L \times P}$ ماتریس اعضای انتهایی است و $M_j \in R^{L \times 1}, 1 \leq j \leq P$ بردار امضای طیفی ژ آمین عضو انتهایی می‌باشد. P تعداد اعضای انتهایی موجود در تصویر است. $A_i = (A_{1i}, A_{2i}, \dots, A_{Pi})^T \in R^{P \times 1}$ بردار وزن یا بردار فراوانی اعضای انتهایی در پیکسل i ام است و همچنین، $e_i \in R^{L \times 1}$ بردار نوفه و خطا در پیکسل i ام می‌باشد.

می‌توان رابطه (۱) را برای همه N پیکسل تصویر به صورت زیر توسعه داد:

$$X = MA + E \quad (2)$$

که در رابطه فوق $X \in R^{L \times N}$ ماتریس شامل بردار امضای طیفی همه پیکسل‌های تصویر است که به صورت ستونی مرتب شده‌اند. $A = (A_1, A_2, \dots, A_N) \in R^{P \times N}$ ماتریس ضرایب فراوانی است که شامل بردارهای فراوانی همه پیکسل‌های تصویر است. اگر هر یک از سطرهاى ماتریس فراوانی A به یک ماتریس متناظر با محل اصلی پیکسل‌های تصویر، تبدیل شوند، تصویری به دست می‌آید

¹ Linear Mixing Model (LMM)

۲-۲- تبدیل مؤلفه‌های اصلی

از تبدیل مؤلفه‌های اصلی آنها در فرایند جداسازی استفاده می‌شود. در روش پیشنهادی، این تبدیل به‌منظور کاهش ویژگی داده‌ها مورد استفاده قرار نمی‌گیرد؛ بلکه با استفاده از این تبدیل خطی، تصاویر به فضایی ناهمبسته نگاشته می‌شوند. در این فضا داده‌ها ناهمبسته و متعام خواهند شد و همچنین امضای طیفی هر یک از طبقه‌ها به فضایی نگاشته می‌شود که تمایز آنها نمایان‌تر خواهد شد و موجب کارآمدتر شدن فرایند جداسازی می‌شود. بنابراین، پیش از اینکه داده‌ها به‌طور مستقیم در فرایند جداسازی قرار گیرند باید توسط تبدیل PCA به فضایی جدید نگاشته شوند و سپس داده‌های جدید در فضایی جدید توسط الگوریتم جداسازی تفکیک شوند. همه مؤلفه‌های اصلی در فرایند جداسازی مورد استفاده قرار می‌گیرند. از آنجایی که جداسازی داده‌ها براساس مدل مخلوط خطی انجام می‌گیرد باید مدل LMM را با استفاده از تبدیل PCA، به‌صورت زیر تغییر داد:

$$Y=BX=BMA=SA \quad (6)$$

$$S=BM \quad (7)$$

که در معادله (Y, Y) داده‌های جدید حاصل از تبدیل PCA است و S تبدیل PCA ماتریس اعضای انتهایی M است که در نتیجه اعمال تبدیل PCA داده‌ها جدید است. بنابراین با تبدیل PCA داده‌های ابرطیفی، تنها ماتریس اعضای انتهایی M تغییر می‌کند، ولی همچنان ماتریس ضرایب فراوانی A بدون تغییر باقی می‌ماند. پس از تفکیک داده‌های جدید توسط الگوریتم جداسازی ماتریس S به دست خواهد آمد و با عکس تبدیل PCA، ماتریس اعضای انتهایی دوباره به‌صورت زیر به دست خواهد آمد:

$$M=B^{-1}S. \quad (8)$$

در رابطه (6) دو ماتریس S و A مجهول هستند و باید با استفاده از ماتریس Y تعیین شوند. این مسأله به‌طور کامل با موضوع جداسازی کور منابع منطبق است. در این مقاله ما از یک روش جدید در حوزه جداسازی کور منابع به نام تجزیه ماتریس نیمه نامنفی (Semi-NMF) برای تفکیک ماتریس Y به دو ماتریس S و A استفاده کرده‌ایم که در بخش ۲-۳ چگونگی این تفکیک تشریح شده است.

تحلیل مؤلفه‌های اصلی یک روش ریاضی است که از ویژگی‌های آماری داده‌ها برای تبدیل مجموعه داده‌های به‌احتمال همبسته به مجموعه داده‌های ناهمبسته استفاده می‌کند، به‌گونه‌ای که حداکثر اطلاعات ممکن حفظ شود (Li, 2009). به این مجموعه داده ناهمبسته، به‌اصطلاح مؤلفه‌های اصلی می‌گویند. تعداد مؤلفه‌های اصلی کمتر یا برابر تعداد داده‌های اولیه است به همین دلیل از این تبدیل می‌توان برای کاهش ویژگی نیز استفاده کرد. ما در روش پیشنهادی خود از همه مؤلفه‌های اصلی در فرایند جداسازی استفاده کرده‌ایم. اگر X ماتریس داده‌های ابرطیفی باشد، تبدیل PCA آن به‌گونه‌ای تعریف می‌شود که ماتریس کوواریانس مجموعه داده به دست آمده $Y \in R^{d \times N}$ ناهمبسته باشد:

$$Y=BX \quad (5)$$

در رابطه بالا $B \in R^{d \times L}$ ماتریس تبدیل PCA است و $d, (1 \leq d \leq L)$ تعداد مؤلفه‌های اصلی می‌باشد. تحت این تبدیل، L تصویر همبسته ابرطیفی به d تصویر ناهمبسته تبدیل می‌شود. ماتریس تبدیل B با استفاده از بردارهای ویژه ماتریس کوواریانس مجموعه داده اصلی X به دست می‌آید و به‌گونه‌ای تعریف می‌شود که مؤلفه اصلی اول، دارای بیش‌ترین واریانس ممکن است و واریانس مؤلفه‌های اصلی بعدی، به‌صورت نزولی کاهش می‌یابد.

۳- روش پیشنهادی

۳-۱- توسعه تبدیل PCA با مدل LMM

همبستگی بین باندهای تصاویر ابرطیفی یکی از ویژگی‌ها این مجموعه داده‌هاست. وجود چنین ویژگی بین باندهای تصاویر ابرطیفی امکان شناسایی امضای طیفی طبقه‌های مختلف را دشوار می‌کند. این مسأله را می‌توان در طبقه‌بندی طبقه‌ها و الگوریتم‌های جداسازی ابرطیفی که از امضای طیفی هر پیکسل در فرایند طبقه‌بندی و تفکیک داده‌ها استفاده می‌کنند به‌وضوح مشاهده کرد. این مسأله در جداسازی داده‌های ابرطیفی زمانی بیشتر آشکار می‌شود که طبقه‌ها دارای امضای طیفی مشابه باشند؛ اما با روش پیشنهادی می‌توان تا حد زیادی این مسأله را بهبود داد. در روش پیشنهادی به‌جای استفاده مستقیم از داده‌های طیفی،

دارای تعداد زیادی کمینه محلی است. کمینه‌های محلی باعث می‌شود که نتایج جداسازی یکتا نباشد یعنی با تکرار دوباره الگوریتم جداسازی، ماتریس A و S متفاوتی حاصل می‌شود. مهم‌ترین راه حل این مسأله افزودن قیدهای کمکی مطابق با ویژگی داده‌های ابرطیفی است (Liu et al., 2004). قیدهایی افزوده شده باید به گونه‌ای انتخاب شوند که بتواند تا حد زیادی مسأله تعداد زیاد کمینه‌های محلی را بهبود دهند.

در این مقاله ما دو قید مطابق با ویژگی داده‌های ابرطیفی به تابع هزینه افزوده‌ایم. قیدهایی که به تابع هزینه رابطه (۱۰) افزوده می‌شود به ماتریس ضرایب فراوانی اعمال می‌گردد که باید با ویژگی‌های داده‌ها مطابقت داشته باشد. با توجه به اینکه ماتریس Y دارای مقادیر معین است و تنها ماتریس A و S مجهول می‌باشند، هرچه مقادیر ماتریس A با دقت بیشتری استخراج شود نتایج حاصل در ماتریس S نیز از دقت بیشتری برخوردار خواهد بود.

یکی از ویژگی‌های داده‌های ابرطیفی این است که در تشکیل امضای طیفی یک پیکسل مخلوط، به طور حتم همه اعضای انتهایی شرکت ندارند و تنها عناصر و پدیده‌هایی که درون پیکسل قرار دارند در تشکیل امضای طیفی شرکت دارند. این ویژگی در ماتریس ضرایب فراوانی باید بدین صورت نمایان شود که برخی از عناصر ضرایب فراوانی ماتریس اعضای انتهایی که در خارج از پیکسل مخلوط قرار دارند صفر شوند. به عبارت دیگر ماتریس اعضای انتهایی تنک خواهد بود. برای اعمال این ویژگی ما از ماتریس nsNMF استفاده کرده‌ایم (Cichocki, et al., 2009). در این روش تنکی ماتریس فراوانی توسط ماتریس زیر کنترل می‌شود.

$$C = (1-\theta)I + \frac{\theta}{P} \mathbf{1} \quad (11)$$

در رابطه بالا C یک ماتریس ثابت است و روشی ریاضی است که برای کنترل تنکی ماتریس A استفاده می‌شود. I ماتریس همانی با ابعاد $P \times P$ است و $\mathbf{1}$ ماتریسی با ابعاد $P \times P$ و دارای مؤلفه‌هایی برابر عدد یک است. همچنین برای کنترل میزان تنکی ماتریس فراوانی از θ استفاده می‌شود، به گونه‌ای که با افزایش θ از صفر تا یک، تنکی ماتریس فراوانی افزایش می‌یابد. ماتریس C به صورت یک عامل ضرب‌شونده به ماتریس فراوانی A افزوده می‌شود.

۳-۲- جداسازی تبدیل PCA داده‌ها با استفاده از Semi-NMF محدود شده

ماتریس X شامل مقادیر انعکاس همه پیکسل‌های مجموعه تصاویر ابرطیفی است. انعکاس یک پارامتر فیزیکی همواره نامنفی است. تبدیل PCA ماتریس داده‌های ابرطیفی X ، موجب می‌شود ماتریس Y شامل مقادیر نامنفی و منفی شود، یعنی:

$$Y_{\pm} = S_{\pm} A_{+} \quad (9)$$

که زیرنویس \pm بیان می‌کند ماتریس شامل مقادیر نامنفی و منفی است و همچنین زیرنویس $+$ بیان می‌کند، ماتریس فقط شامل مقادیر نامنفی است. همچنین در رابطه بالا ماتریس‌های S و A مجهول هستند و تنها ماتریس Y مشخص و معین است. برای تفکیک ماتریس Y به حاصل ضرب دو ماتریس S و A ، الگوریتم NMF روشی ریاضی نوین می‌باشد. روش‌های جداسازی داده‌های ابرطیفی CNMF و MiniDisCoNMF، شیوه‌هایی هستند که از NMF برای تفکیک داده‌های ابرطیفی استفاده می‌کنند. شرط به کارگیری NMF در تفکیک داده‌ها، نامنفی بودن هر سه ماتریس Y ، S و A است. اما در روش پیشنهادی تنها ماتریس A نامنفی است و ماتریس Y و S شامل مقادیر منفی و نامنفی است. این ویژگی ما را به سوی الگوریتم جداسازی هدایت می‌کند که بتواند ماتریس شامل مقادیر نامنفی و منفی را به حاصل ضرب دو ماتریس تفکیک کند که یکی از ماتریس‌ها شامل مقادیر نامنفی و منفی باشد و ماتریس دیگر تنها شامل مقادیر نامنفی باشد. ما برای این منظور از الگوریتم Semi-NMF (Cichocki, et al., 2009) استفاده کردیم.

این الگوریتم نوع توسعه یافته الگوریتم NMF است و از طریق یک مدل خطی و با استفاده از تابع هزینه اقلیدسی زیر، ماتریس داده‌های Y شامل مقادیر نامنفی و منفی را به دو ماتریس A و S تفکیک می‌کند:

$$CF(S, A) = \frac{1}{2} \|Y - SA\|_F^2 = \frac{1}{2} \text{trace}((Y-SA)^T (Y-SA)) \quad (10)$$

که در معادله بالا $\|\cdot\|_F$ ، نرم Frobenius است. اما این الگوریتم همانند NMF به سبب غیرمحدب بودن تابع هزینه،

$$S \leftarrow (YA^T C^T)(CAA^T C^T)^{-1} \quad (16)$$

$$A \leftarrow \left[(C^T S^T S C^T + \alpha I)^{-1} (C^T S^T Y) \right]_+ \quad (17)$$

که در رابطه بالا، و عملگر $[\cdot]_+$ ، همه مؤلفه‌های غیر منفی ماتریس را صفر می‌کند و موجب نامنفی شدن عناصر ماتریس A می‌شود تا قید فیزیکی ANC مدل LMM در نظر گرفته شود. پس از عکس تبدیل PCA ماتریس S ، ماتریس اعضای انتهایی M به دست خواهد آمد. برای اعمال قید فیزیکی ASC از روش ارائه شده در (Heinz and Chang, 2001) استفاده شده است، یعنی:

$$Y \leftarrow \begin{bmatrix} Y \\ \delta 1^T \end{bmatrix}, S \leftarrow \begin{bmatrix} S \\ \delta 1^T \end{bmatrix} \quad (18)$$

که در رابطه بالا 1^T بردار سطری شامل تنها عدد یک است و پارامتر δ مجموع ضرایب فراوانی را کنترل می‌کند.

۳-۳- مقداردهی اولیه و معیار توقف الگوریتم

ماتریس‌های S و A در الگوریتم Semi-NMF به صورت تصادفی مقداردهی اولیه می‌شوند و این موضوع می‌تواند روی نتایج به دست آمده مؤثر باشد، چون انتخاب مقدار اولیه الگوریتم‌های یادگیری از اهمیت ویژه‌ای برخوردار است. انتخاب مقدار اولیه مناسب می‌تواند در اجرای سریع الگوریتم کمک فراوانی می‌کند، همچنین می‌تواند تا حد زیادی از به دست آمدن نتایج مربوط به کمینه‌های محلی جلوگیری کند. به همین دلیل برخی از پژوهش‌گران، پژوهش‌های خود را بر روی انتخاب مؤثر مقادیر اولیه متمرکز کرده‌اند که از بین آنها می‌توان به مقداردهی اولیه براساس SVD (Boutsidis and Gallopoulos, 2008)، اما هیچ یک از روش‌ها برای داده‌های ابرطیفی مناسب نیستند.

در این مقاله ما از یک روش ساده برای مقداردهی اولیه ماتریس S استفاده کرده‌ایم. در این روش تعداد P داده به صورت تصادفی و یکی یکی از ماتریس X ، به گونه‌ای انتخاب می‌شود که ضریب همبستگی بین همه آن‌ها از مقدار آستانه‌ای که از قبل تعیین شده است، کمتر باشد و سپس داده‌های متناظر آن‌ها در ماتریس Y به عنوان مقادیر اولیه ماتریس S در نظر گرفته می‌شود. بنابراین با استفاده از این

ضرایب فراوانی از یک پیکسل به پیکسل بعدی به صورت آنی تغییر نمی‌کند و در اکثر مواقع تغییر آنها به آرامی و نرمی انجام می‌شود. این ویژگی به این سبب است که حضور عناصر و پدیده‌ها از یک پیکسل به پیکسل دیگر به سرعت تغییر نمی‌کند. این ویژگی را می‌توان به صورت همواری ضرایب فراوانی از یک پیکسل به پیکسل بعدی توصیف کرد که باید به ماتریس ضرایب فراوانی اعمال شود. برای اعمال این ویژگی از روش سنتی نرم Frobenius ارائه شده در الگوریتم CNMF استفاده شده است که به صورت زیر تعریف می‌شود (Pauca, et al., 2006):

$$\|A\|_F^2 = \text{trace}(A^T A) = \sum_{i=1}^P \sum_{j=1}^N |A_{ij}|^2 \quad (12)$$

بنابراین با معرفی قیدهای تنکی و همواری ضرایب فراوانی به تابع هزینه اقلیدسی، با تابع هزینه توسعه یافته جدید زیر روبه‌رو خواهیم شد:

$$CF(S,A) = \frac{1}{2} \|Y - SCA\|_F^2 + \alpha J(A) \quad (13)$$

$$J(A) = \|A\|_F^2 \quad (14)$$

که در رابطه (13) C ماتریس nsNMF است که به درون تابع هزینه اقلیدسی به منظور اعمال تنکی روی بردارهای فراوانی ماتریس فراوانی افزوده شده است و $J(A)$ قید همواری ماتریس ضرایب فراوانی است که به وسیله پارامتر تنظیم α به تابع هزینه افزوده شده است.

برای محاسبه قاعده به‌روزرسانی ما از الگوریتم یادگیری ALS¹ استفاده کرده‌ایم. شیوه ALS در مقایسه با شیوه Gradient Descent نیازی به طول گام و تنظیم آن ندارد و سریع‌تر عمل می‌کند (Comon and Jutten, 2010)، (Berry, 2007) و از ویژگی مهم دیگر آن کمک به تنکی ماتریس فراوانی است. الگوریتم یادگیری ALS با مساوی صفر قراردادن گرادیان تابع هزینه نسبت به هر یک از ماتریس‌های S و A با فرض ثابت بودن دیگری، قواعد به‌روزرسانی ماتریس‌ها را محاسبه می‌کند، یعنی:

$$\frac{\partial CF(S,A)}{\partial S} = 0, \frac{\partial CF(S,A)}{\partial A} = 0 \quad (15)$$

با حل معادلات بالا، قواعد به‌روزرسانی ماتریس‌های S و A به صورت زیر به دست می‌آید:

¹ Alternating Least Square

همچنین SID که یک معیار براساس نظریه اطلاعات است برای k امین عضو انتهایی استخراج شده به صورت زیر تعریف می شود (Chang, 2003):

$$SID_k = D(\hat{M}_k | M_k) + D(M_k | \hat{M}_k) \quad (21)$$

که در رابطه بالا $D(M_k | \hat{M}_k)$ آنتروپی نسبی \hat{M}_k با توجه به M_k می باشد و به صورت زیر تعریف می شود:

$$D(M_k | \hat{M}_k) = \sum_{i=1}^L p_i \log\left(\frac{p_i}{q_i}\right) \quad (22)$$

$$p_i = \frac{M_{ik}}{\sum_{j=1}^L M_{jk}} \quad (23)$$

$$q_i = \frac{\hat{M}_{ik}}{\sum_{j=1}^L \hat{M}_{jk}}$$

مقادیر این معیار هر چه به صفر نزدیک تر باشد شباهت نتایج استخراج شده بیشتر خواهد بود. معیار RMSE برای k امین نقشه فراوانی به صورت زیر تعریف می شود (Plaza, 2004):

$$RMSE_k = \sqrt{\frac{1}{N} \sum_{j=1}^N (A_{kj} - \hat{A}_{kj})^2} \quad (24)$$

در رابطه بالا \hat{A}_{kj} و A_{kj} به ترتیب ضریب نسبت فراوانی k امین عضو انتهایی در پیکسل j ام است و N تعداد کل پیکسل های تصویر است.

۴-۱- نتایج داده های مصنوعی ابرطیفی

برای تولید تصویر ابرطیفی مصنوعی، امضای طیفی چهار ماده از کتابخانه طیفی USGS انتخاب شده و تصویری با پیکسل های مخلوط با ابعاد 100×100 تولید می شود. در انتخاب مواد به شباهت امضای طیفی توجه شده است. به منظور بررسی کارآمدی الگوریتم پیشنهادی در فرایند جداسازی داده ها، سه آزمایش طراحی شده است. هر یک از آزمایش های یکی از عوامل مهم را مورد بررسی قرار می دهد. در این بخش روش پیشنهادی با دو الگوریتم جداسازی CNMF و MiniDisCoNMF که براساس NMF طراحی شده اند مقایسه می شود.

آزمایش اول، تأثیر قدرت نوفه در فرایند جداسازی داده ها با استفاده از روش پیشنهادی را مورد بررسی قرار می دهد. وجود نوفه گوسی موجب تغییر شکل امضای طیفی

روش، امضای طیفی پیکسل هایی به عنوان مقدار اولیه انتخاب می شود که کمترین ارتباط خطی با یکدیگر دارند، به عبارت دیگر مقدار اولیه ماتریس k پیکسل هایی از مواد مختلف و تا حد ممکن خالص خواهند بود. با تعیین مقدار اولیه ماتریس اعضای انتهایی، مقدار اولیه ماتریس A به صورت زیر با استفاده از مقادیر اولیه ماتریس S به دست می آید:

$$A = S^{-1}Y. \quad (19)$$

از آنجایی که تابع هزینه در هر تکرار به صورت نزولی در حال کاهش است، تفاضل تابع هزینه در دو حلقه تکرار متوالی به عنوان معیاری برای توقف الگوریتم پیشنهادی استفاده شده است. اگر تفاضلهای در تعداد معینی از تکرارها از مقدار خطا مورد نظر کمتر باشد می توان الگوریتم را متوقف کرد در غیر این صورت الگوریتم بعد از حداکثر تعداد تکرار متوقف خواهد شد.

۴-۲ نتایج آزمایشی

در این بخش از مجموعه داده های ابرطیفی مصنوعی و واقعی برای بررسی کارایی الگوریتم پیشنهادی استفاده شده است. برای مقایسه کمی نتایج، از سه معیار SAD^1 ، SID^2 و $RMSE^3$ استفاده شده است. این معیارها، سه معیار متداول در مطالعات جداسازی داده های سنجنش از دور هستند که برای اندازه گیری میزان شباهت نتایج به دست آمده و مقادیر مرجع مورد استفاده قرار می گیرند. معیار SAD برای k امین عضو انتهایی استخراج شده به صورت زیر تعریف می شود (Keshava and Mustard, 2002):

$$SAD_k = \cos^{-1}\left(\frac{\hat{M}_k^T M_k}{|\hat{M}_k| |M_k|}\right) \quad (20)$$

که در رابطه بالا، \hat{M}_k و M_k به ترتیب عضو انتهایی استخراج شده و عضو انتهایی مرجع می باشد و نماد $|\cdot|$ ، عملگر نرم برداری است. هر چه مقدار SAD کمتر باشد، شباهت عضو انتهایی استخراج شده بیشتر خواهد بود. این معیار بیشتر در مواردی مناسب است که عضو انتهایی استخراج شده دارای ابعاد مناسب باشد، چون ضریبها تأثیری در عبارت کسری درون رابطه (20) ندارد.

¹ Spectral Angel Distance

² Spectral Information Divergence

³ Root Mean Square Error

یک پیکسل خالص امکان پذیر است. در این آزمایش توانایی الگوریتم‌ها در جداسازی داده‌هایی مورد بررسی قرار می‌گیرند که تعداد پیکسل‌های مختلط آن‌ها در مقایسه با پیکسل‌های خالص بسیار زیاد باشند. در این آزمایش SNR ثابت برابر 40dB در نظر گرفته شده است.

شکل (۴-۲-الف) و (۴-۲-ب) به ترتیب مربوط به اعضای انتهایی استخراج شده و ضرایب فراوانی است. همان‌طور که در شکل (۴-۲) نشان داده شده است، الگوریتم‌ها به‌ویژه الگوریتم پیشنهادی در استخراج اعضای انتهایی کمتر تحت تأثیر افزایش تعداد پیکسل‌های مخلوط قرار گرفته‌اند و مقادیر متوسط معیارهای SAD و RMSE کمتری به خود اختصاص داده است؛ اما با افزایش تعداد پیکسل‌های مختلط متوسط مقادیر معیارها در حال افزایش است و نشان می‌دهد که کارایی الگوریتم‌ها در حال کاهش است. اما الگوریتم پیشنهادی نسبت به دو روش دیگر کمتر متأثر شده است و افت و خیز کمتری دارد؛ به‌ویژه وقتی که هیچ پیکسل خالصی در تصویر وجود ندارد و متوسط RMSE با شیب بسیار زیادی افزایش می‌یابد؛ اما روش پیشنهادی با شیب کمتری افزایش یافته است.

آزمایش سوم، تأثیر قیدهای پیشنهادی افزوده شده و تبدیل PCA در جداسازی داده‌ها را مورد بررسی قرار می‌دهد و کارایی الگوریتم به‌صورت جداگانه با حضور و عدم حضور قیدها و تبدیل PCA، توسط معیارها بررسی شده است.

در این آزمایش فرایند جداسازی همراه با قیدها پیشنهادی و بدون آنها و همچنین با وجود و عدم وجود تبدیل PCA، ده بار تکرار شده و در هر بار اجرا معیار SAD و RMSE آن‌ها محاسبه شده است. در جدول (۴-۱)، متوسط معیارها و انحراف استاندارد آنها نشان داده شده است. نتایج این جدول نشان می‌دهد که قیدهای پیشنهادی و تبدیل PCA علاوه بر افزایش صحت نتایج به دست آمده، انحراف استاندارد آنها را نیز کاهش داده است و نتایج استخراج شده از قابلیت اطمینان بیشتری برخوردارند. جداسازی داده‌ها بدون قیدها و با حضور و عدم حضور تبدیل PCA نیز در جدول (۴-۱) نشان داده شده است. نتایج نشان می‌دهد که

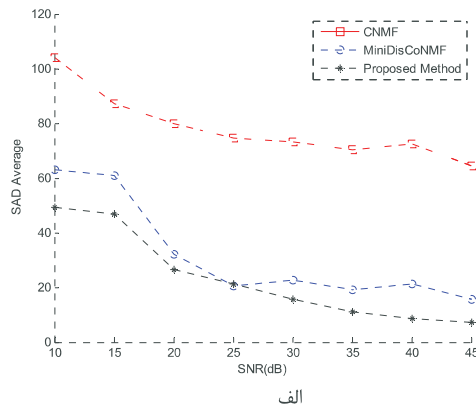

پیکسل‌ها می‌شود و زمانی که امضای طیفی هر یک از پیکسل‌ها به‌صورت تصادفی توسط نوفه گوسی تغییر شکل یافته باشند، آزمون مناسبی برای بررسی و مقایسه کارایی الگوریتم‌ها است. برای این منظور داده‌های شبیه‌سازی شده به نوفه گوسی با متوسط صفر و با SNR معین آغشته می‌شوند. در این حالت SNR به‌صورت زیر توصیف می‌شود:

$$\text{SNR}_{\text{dB}} = 10 \log \frac{E\{x_i^T x_i\}}{E\{n^T n\}} \quad (25)$$

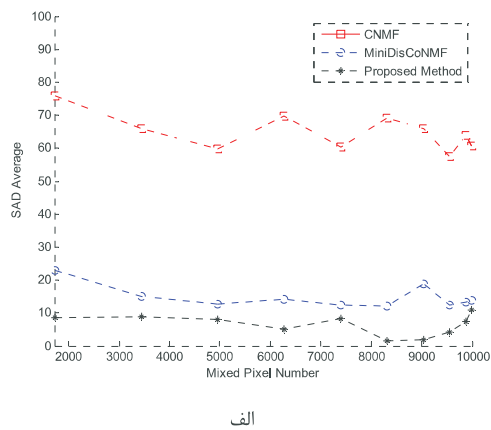
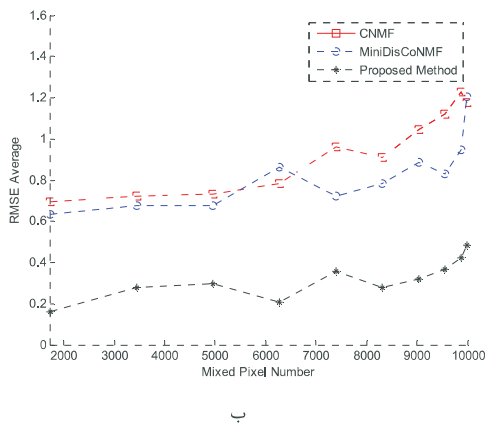
که در رابطه بالا x_i و n به ترتیب مشاهدات و نوفه مربوط به یک پیکسل تصویر می‌باشد و همچنین $E\{\cdot\}$ نماد عملگر امید ریاضی است.

شکل (۴-۱-الف) و (۴-۱-ب) به ترتیب مربوط به مقایسه اعضای انتهایی استخراج شده و ضرایب فراوانی است. همان‌طور که انتظار داشتیم و در شکل (۴-۱) می‌توان مشاهده کرد، با افزایش SNR میزان کارایی الگوریتم‌ها در حال افزایش است؛ اما کارایی الگوریتم پیشنهادی در استخراج اعضای انتهایی و تخمین ضرایب فراوانی بهتر از دو الگوریتم دیگر است و منحنی‌های مربوط به روش پیشنهادی مقادیر پایین‌تر از دو روش دیگر به خود اختصاص می‌دهد. الگوریتم پیشنهادی برخلاف دو الگوریتم دیگر متناسب با افزایش مقدار SNR، با کم‌ترین میزان افت و خیز در حال افزایش است و پایداری الگوریتم و قیدهای پیشنهادی در شرایط نویزی متفاوت را نشان می‌دهد. با وجود این که الگوریتم MiniDisCoNMF نتایجی نزدیک به الگوریتم پیشنهادی در استخراج اعضای انتهایی دارد، ولی تخمین ضرایب فراوانی به‌خوبی استخراج اعضای انتهایی انجام نمی‌شود؛ این مسأله می‌تواند به دلیل معرفی تنها یک قید به تابع هزینه باشد.

آزمایش دوم، تأثیر تعداد پیکسل‌های مخلوط تصویر در استخراج اعضای انتهایی و نقشه فراوانی مورد بررسی قرار می‌دهد. برخی از الگوریتم‌های جداسازی همچون VCA (Nascimento and Dias, 2005) فقط برای تصاویری قابل به‌کارگیری هستند که حداقل یک پیکسل خالص از هر عضو انتهایی داشته باشند؛ اما روش پیشنهادی مشروط به وجود چنین شرطی نیست و فرایند جداسازی حتی بدون وجود



شکل ۴-۱): مقایسه کارایی الگوریتم‌ها بر حسب SNR های مختلف. الف) SAD. ب) RMSE



شکل ۴-۲): مقایسه کارایی الگوریتم‌ها بر حسب تعداد پیکسل‌های مختلف. الف) SAD. ب) RMSE


(جدول ۴-۱): متوسط و انحراف استاندارد معیارهای SAD و RMSE نتایج استخراج‌شده با توجه به حضور و عدم حضور قیدها و تبدیل PCA

	جداسازی با روش پیشنهادی	جداسازی با قیدها و بدون PCA	جداسازی بدون قیدها و با PCA	جداسازی بدون قیدها و بدون PCA
SAD Mean	۸/۶۵	۲۰/۱۲	۶۲/۶۱	۵۶/۸۴
SAD S.D	۰/۰۸	۰/۱۲	۱۵/۰۴	۱۱/۳۲
RMSE Mean	۰/۱۶	۱/۰۱	۱/۰۳	۱/۰۶
RMSE S.D	۰/۰۰۱	۰/۰۱	۰/۲۵	۰/۲۲

مرجع مقایسه شده‌اند. اعدادی که ضخیم نشان داده شده‌اند نتایج بهتر در مقایسه با سایر روش‌ها نشان می‌دهند. در شکل (۴-۴) نقشه فراوانی تخمینی توسط هر یک از روش‌ها نشان داده شده است.

امضای طیفی Road و Water در این تصویر شباهت بسیار زیادی به یکدیگر دارند و با وجود این‌که در تصویر پیکسل مخلوطی بین این دو عضو انتهایی وجود ندارد، هیچ یک از روش‌های جداسازی به جز روش پیشنهادی، نتوانسته آنها را از یکدیگر تفکیک کنند. با دقت نظر در جدول‌های (۴-۲) و (۴-۳) و شکل (۴-۴) ستون (الف) متوجه خواهیم شد که الگوریتم‌های جداسازی VCA و CNMF نتوانسته‌اند، عضو انتهایی Road را به صورت مجزا استخراج کنند و با این‌که امضای طیفی عضو انتهایی Water استخراج شده اما در نقشه فراوانی آنها همراه با عضو انتهایی Road نشان داده شده است. الگوریتم MiniDisCoNMF با وجود اینکه عضو انتهایی Road را با شباهت کمتری نسبت به روش پیشنهادی استخراج کرده، اما نقشه فراوانی آن به خوبی این مناطق را نشان نداده است و نقشه فراوانی Water همانند دو الگوریتم دیگر همراه با عضو انتهایی Road نشان داده شده است. در این تصویر علاوه بر شباهت امضای طیفی Road و Water، امضای طیفی Tree و Grass نیز به یکدیگر شباهت دارند و با دقت نظر در جدول‌های (۴-۲) و (۴-۳) و شکل (۴-۴) ستون‌های (ب) و (ج) متوجه خواهیم شد که روش پیشنهادی به وضوح بین این دو طبقه تمایز قرار داده است و موفق به جداسازی آنها از یکدیگر شده است. روش پیشنهادی علاوه بر استخراج همه اعضای انتهایی و تمایز بین امضای طیفی اعضای انتهایی و تخمین نقشه فراوانی آنها، از متوسط نتایج بهتری نیز برخوردار است و این نتیجه در جدول‌های (۴-۲) و (۴-۳) نشان داده شده است.

مجموعه داده ابرطیفی دوم توسط سنجنده AVIRIS^۲ و از ایالت Indiana در سال ۱۹۹۲ به دست آمده است که نمایش رنگی آن در شکل (۴-۵) نشان داده شده است. این داده ابرطیفی شامل مجموعه تصاویری با ابعاد ۱۴۵×۱۴۵ در ۲۲۰ باند طیفی است که برخی از باندهای نوفه‌ای حذف شده‌اند. دقت طیفی و مکانی آن به ترتیب 10nm و 17m است. این داده ابرطیفی شامل ۱۷ طبقه است (Landgrebe, 1998). با ادغام برخی از طبقه‌ها، تعداد طبقه‌ها به ۵ طبقه کاهش می‌یابد. در جدول‌های (۴-۴) و (۴-۵)



(شکل ۴-۳): نمایش رنگی باندهای ۲۵، ۸۰ و ۱ از داده Washington

تبدیل PCA بر روی تعداد کمینه‌های محلی تأثیری چندانی ندارد و همچنان انحراف معیار نتایج به دست آمده بسیار زیاد است. در این آزمایش الگوریتم با قیدها و بدون تبدیل PCA نیز مورد بررسی قرار گرفت. نتایج به دست آمده بهبود معیارها را نشان می‌دهد؛ اما نتایج نشان می‌دهد که همراهی قیدها و تبدیل PCA با یکدیگر تأثیر زیادی در خروجی الگوریتم پیشنهادی دارد.

۴-۲- نتایج داده‌های واقعی ابرطیفی


در این بخش الگوریتم پیشنهادی با استفاده از دو مجموعه داده ابرطیفی واقعی ارزیابی شده است. همچنین علاوه بر الگوریتم‌های CNMF و MiniDisCoNMF از الگوریتم جداسازی VCA که بر پایه ویژگی‌های هندسی عمل می‌کند برای مقایسه نتایج استخراج شده استفاده شده است.

از آنجایی که برای این داده‌ها اعضای انتهایی مرجع وجود ندارد، تعدادی پیکسل نمونه از هر طبقه با استفاده از Ground Truth انتخاب شده و پس از متوسط‌گیری، به عنوان اعضای انتهایی مرجع در نظر گرفته می‌شوند تا با اعضای انتهایی استخراج شده مورد مقایسه قرار گیرد.

مجموعه داده ابرطیفی اول توسط سنجنده HYDICE^۱ و از Washington, DC به دست آمده است. بخشی از این داده ابرطیفی که شامل مجموعه تصاویری با ابعاد ۱۵۰×۱۵۰ است، مورد استفاده قرار گرفته که در شکل (۴-۳) تصویر رنگی از آن نشان داده شده است. این داده دارای ۲۱۰ باند طیفی در محدوده ۰/۴-۲/۴ μm است. پیش از استفاده از این داده برخی از باندهای نوفه‌ای حذف شده‌اند. این داده ابرطیفی شامل ۵ طبقه است، که در جدول‌های (۴-۲) و (۴-۳) اعضای انتهایی استخراج شده و

^۲ Airborne Visible/Infrared Imaging Spectrometer

^۱ Hyperspectral Digital Imagery Collection Experiment



شکل ۴-۴ نقشه فراوانی هر یک از اعضای انتهایی استخراج شده توسط VCA ، CNMF ، MiniDisCoNMF و روش پیشنهادی (به ترتیب از بالا به پایین). الف-Water. ب-Tree. ج-Grass. د-Road. ه-Roof.

جدول ۴-۲ مقایسه معیار SAD اعضای انتهایی استخراج شده و مرجع

Washington Data	Roof	Road	Grass	Tree	Water	Average
VCA -FCLS	۱۸/۱۴	—	۸/۸۶	۳/۴۲	۲۲/۸۱	—
CNMF	۱۷/۸۲	—	۹/۵۰	۱۴/۷۲	۲۱/۰۱	—
MiniDisCoNMF	۱۵/۶۶	۱۹/۶۳	۱۰/۹۲	۴/۵۹	۲۵/۳۵	۷۷/۱۷
Proposed Method	۴/۰۷	۱۵/۳۱	۱/۰۹	۳/۴۵	۱۶/۱۵	۴۰/۰۸

جدول ۴-۳ مقایسه معیار SID اعضای انتهایی استخراج شده و مرجع

Washington Data	Roof	Road	Grass	Tree	Water	Average
VCA -FCLS	۰/۱۳	—	۰/۰۶	۰/۰۲	۰/۱۴	—
CNMF	۰/۱۰	—	۰/۰۷	۰/۱۰	۰/۱۳	—
MiniDisCoNMF	۰/۰۷	۰/۱۵	۰/۰۷	۰/۰۳	۰/۲۱	۰/۵۵
Proposed Method	۰/۰۰۶	۰/۰۸	۰/۰۰۵	۰/۰۱	۰/۰۸	۰/۱۸

روش پیشنهادی توجه ویژه‌ای به همبستگی بین باندهای تصاویر ابرطیفی شده است و برای کاهش اثر آن به‌ویژه در طبقه‌های مشابه، تبدیل مؤلفه‌های اصلی مورد استفاده قرار گرفته است، همچنین با استفاده از این تبدیل خطی امضای طیفی هر یک از طبقه‌ها به فضایی نگاشته می‌شود که تمایز آنها نمایان‌تر خواهد شد و جداسازی اعضای انتهایی مشابه بهتر انجام خواهد شد. برای بهبود کارایی Semi-NMF و کاهش جواب‌های غیر یکتا، ما قید nsNMF را به تابع هزینه برای تنکی ضرایب فراوانی ارائه کردیم. با استفاده از این قید و به همراه قید همواری علاوه‌بر بهبود نتایج استخراج‌شده واریانس آن‌ها نیز کاهش می‌یابد. همچنین برای الگوریتم پیشنهادی روشی ساده برای مقاردهی اولیه پیشنهاد شد. عدم نیاز به حداقل یک پیکسل خالص از هر عضو انتهایی و استخراج اعضای انتهایی و ضرایب فراوانی به‌صورت هم‌زمان از ویژگی‌های الگوریتم پیشنهادی در مقایسه با الگوریتم VCA است. توسعه مدل مخلوط خطی (LMM) با استفاده از تبدیل ساده PAC و همچنین استفاده از Semi-NMF به همراه قید nsNMF برای تنکی از جمله ویژگی‌های الگوریتم پیشنهادی در مقایسه با الگوریتم‌های CNM و MinDisCoNMF است. روش پیشنهادی با استفاده از داده‌های ابرطیفی مصنوعی و واقعی مورد بررسی و مقایسه با الگوریتم‌های جداسازی بالا قرار گرفت و نتایج استخراج‌شده برتری روش پیشنهادی را نشان می‌دهد.


۶- مراجع

Berry Michael W., Browne Murray, Langville Amy N., V. Paul Pauca, Robert J. Plemmons, Algorithms and applications for approximate nonnegative matrix factorization, Computational Statistics & Data Analysis 52, 2007, pp. 155 – 173.

Boardman Joseph W., Automating spectral unmixing of AVIRIS data using convex geometry concepts, in Summaries 4th Annu. JPL Airborne Geoscience Workshop, 1993, vol. 1, JPL Pub. 93-26, pp. 11–14.

Boutsidis C. and Gallopoulos E., SVD based initialization: A head start for nonnegative matrix factorization, Pattern Recognit., Apr. 2008 vol. 41, no. 4, pp. 1350–1362.

Cichocki Andrzej, Zdunek Rafal, Anh Huy Phan., Amari Shun-ichi, Nonnegative Matrix and Tensor Factorizations: Application to Exploration Multi-Way Data Analysis and Blind Source Separation, First edition, Singapore, United Kingdom: John Wiley & Sons, Ltd, 2009.




(شکل ۴-۵) نمایش رنگی باندهای ۱۵۰ و ۱۰۹۰ از داده Indiana

نتایج مقایسه اعضای انتهایی استخراج‌شده و مرجع نشان داده شده است. اعدادی که ضخیم نشان داده شده‌اند نتایج بهتر در مقایسه با سایر روش‌ها را نشان می‌دهند.

در شکل (۴-۶) نیز نقشه فراوانی تخمینی توسط هر یک از روش‌ها نشان داده شده است. امضای طیفی اعضای انتهایی E3 و E4 شباهت بسیار زیادی به یکدیگر دارند. همچنین در تصاویر پیکسل‌های مختلط زیادی در مرز بین آنها وجود دارند که متعلق به هر دو عضو انتهایی باشند؛ حتی در بعضی از پیکسل‌ها، اعضای انتهایی دیگری نیز حضور دارند. با این وجود الگوریتم‌های CNMF و MinDisCoNMF در تفکیک این دو طبقه موفقیت چندانی نداشته‌اند؛ ولی الگوریتم پیشنهادی توفیق بیشتری داشته است. این موضوع را به‌راحتی می‌توان از شکل (۴-۶) ستون‌های (ج) و (د) که به ترتیب مربوط به نقشه ضرایب فراوانی هستند مشاهده کرد. در نقشه ضرایب فراوانی مربوط به الگوریتم‌های CNMF و MinDisCoNMF وجود عضو انتهایی E4 در نقشه ضرایب فراوانی E3 کامل مشهود است؛ اما در نقشه ضرایب فراوانی الگوریتم پیشنهادی این دو عضو انتهایی تا حد بسیار زیادی متمایز شده‌اند. این نتیجه را تا حدودی می‌توان در نقشه ضرایب فراوانی الگوریتم VCA نیز مشاهده کرد. نتایج جدول‌های (۴-۴) و (۴-۵) این موضوع را تأیید می‌کنند. متوسط نتایج به‌دست آمده نشان می‌دهد، الگوریتم پیشنهادی با اختلاف زیادی بهتر از روش‌های دیگر داده‌های ابرطیفی را تفکیک کرده است.

۵- نتیجه‌گیری

در این مقاله یک روش جدید برای جداسازی طیفی و مکانی تصاویر ابرطیفی با استفاده از تجزیه ماتریس نیمه‌نامنفی و براساس تبدیل مؤلفه‌های اصلی داده‌ها ارائه شده است. در



(شکل ۴-۶) نقشه فراوانی هر یک از اعضای انتهایی استخراج شده توسط VCA ، CNMF ، MiniDisCoNMF و روش پیشنهادی (به ترتیب از بالا به پایین). الف-E1. ب-E2. ج-E3. د-E4. ه-E5.

(جدول ۴-۴) مقایسه معیار SAD اعضای انتهایی استخراج شده و مرجع

Indiana Data	E5	E4	E3	E2	E1	Average
VCA -FCLS	۲۱/۸۸	۶/۰۴	۱۶/۸۶	۳/۴۶	۱۱/۴۱	۵۹/۶۷
CNMF	۲۱/۶۶	۲۸/۹۴	۱۸/۴۸	۸/۵۶	۳۱/۴۲	۱۰۹/۰۸
MiniDisCoNMF	۱۰/۷۸	۱۲/۷۹	۱۲/۵۹	۷/۴۴	۳۱/۴۳	۷۵/۰۶
Proposed Method	۵/۳۲	۳/۵۵	۱۳/۱۳	۵/۵۸	۷/۹۷	۳۵/۵۶

(جدول ۴-۵) مقایسه معیار SID اعضای انتهایی استخراج شده و مرجع

Indiana Data	E5	E4	E3	E2	E1	Average
VCA -FCLS	۰/۰۱۶	۰/۰۵	۰/۲۱	۰/۱۱	۰/۳۳	۰/۷۳
CNMF	۰/۱۳	۰/۲۳	۰/۱۳	۰/۰۵	۰/۴۱	۰/۹۸
MiniDisCoNMF	۰/۰۴	۰/۰۷	۰/۰۶۶	۰/۰۳	۰/۴۱	۰/۶۴
Proposed Method	۰/۰۱۱	۰/۰۰۵	۰/۰۶۵	۰/۰۱	۰/۰۲	۰/۱۲

Wild S., Curry J., and Dougherty A., Improving non-negative matrix factorization through structured initialization, Pattern Recognit., Nov. 2004, vol. 37, no. 11, pp. 2217–2232.

Winter Michael E., N-find: an algorithm for fast autonomous spectral endmember determination in hyperspectral data, in: Proceedings of the SPIE conference on Imaging Spectrometry V, 1999, vol.3753, pp.266-275.

Yuhas R. H., Goetz A. F. H., and Boardman J. W., Discrimination among semi-arid landscape endmember using the spectral angle mapper (SAM) algorithm, in Proc. Summaries3rd Annu. JPL Airborne Geosci. Workshop, 1992, vol. 1, pp. 147–149.



حبیب علی زاده تحصیلات خود را در

مقطع کارشناسی مهندسی مخابرات

دانشگاه امام حسین (ع) در سال ۱۳۸۷

و در مقطع کارشناسی ارشد مهندسی

مخابرات دانشگاه تربیت مدرس در سال

۱۳۹۰ به پایان رسانده است. حوزه

تحقیقاتی وی عبارتند از: پردازش تصویر، پردازش تصاویر

سنجش از دور، جداسازی کور منابع.

نشانی رایانامه ایشان عبارت است از:

Habib.alizadeh@modares.ac.ir



حسن قاسمیان تحصیلات مقطع

کارشناسی ارشد و دکترای خود را در

مهندسی مخابرات و کامپیوتر دانشگاه

Purdue آمریکا به ترتیب در سالهای

۱۳۶۳ و ۱۳۶۷ به اتمام رساند. ایشان

مدرک کارشناسی خود را در مهندسی

مخابرات از دانشگاه مخابرات در سال ۱۳۵۹ دریافت کرد.

وی در حال حاضر استاد گروه مهندسی مخابرات و مهندسی

پزشکی دانشگاه تربیت مدرس است. زمینه‌های پژوهشی

مورد علاقه ایشان پردازش و آنالیز اطلاعات تصاویر و

سیگنال‌های دیجیتال، پردازش تصاویر سنجش از دور است.

نشانی رایانامه ایشان عبارت است از:

ghassemi@modares.ac.ir

Comon Pierre and Jutten Christian, Handbook of Blind Source Separation, 1st edition USA, Elsevier, 2010.

Heinz Daniel C. and Chang Chein-I, Fully constrained least squares linear spectral mixture analysis method for material quantification in hyperspectral imagery, IEEE Trans. Geosci. Remote Sens., Mar. 2001, vol.39, no.3, pp.529-545

Horwitz H. M., Nalepka R. F., Hyde P. D., and Morgensten J. P., Estimating the proportions of objects within a single resolution element of a multispectral scanner, in Proc. 7th Int. Symp. Remote Sens. Environ, Ann Arbor, MI, 1971, pp. 1307–1320.

Huck Alexis, Guillaume Mireille., Jacques.Blanc-Talon, Minimum Dispersion Constrained Non-negative Matrix Factorization to Unmix Hyperspectral Data, IEEE Trans. Geosci. Remote Sens., June 2010, vol. 48, no. 6, pp. 2590–2602.

Iordache Marian-Daniel, Bioucas-Dias José M., Antonio Plaza, Sparse Unmixing of Hyperspectral Data, IEEE Trans. Geosci. Remote Sens., June. 2011, vol. 49, no. 6, pp. 2014–2039

Keshava Nirmal and Mustard John F., Spectral unmixing, IEEE Signal Process. Mag., Jan. 2002 vol. 19, no. 1, pp. 44–57.

Kwon Heesung and Nasrabadi N. M., Kernel orthogonal subspace projection for hyperspectral signal classification, IEEE Trans. Geosci. Remote Sens., Dec. 2005, vol. 43, no. 12, pp. 2952–2962.

Liu Wen., Zheng N., and Li X., Review on nonnegative matrix factorization, Inst. Artif. Intell. Robot, Xi'an Jiaotong Univ., Xi'an, China, Tech. Rep., Sep. 2004.

Nascimento José M. P. and Dias José M. Bioucas, Does independent component analysis play a role in unmixing hyperspectral data?, IEEE Trans. Geosci. Remote Sens., Jan. 2005, vol. 43, no. 1, pp. 175–187.

Nascimento José M. P. and Dias José M. Bioucas, Vertex component analysis: A fast algorithm to unmix hyperspectral data, IEEE Trans. Geosci. Remote Sens, Apr. 2005., vol. 43, no. 4, pp. 898–910.

Pauca V. Paul, Piper J., Plemmons Robert J., Non-negative matrix factorization for spectral data analysis, Linear Algebra and its Applications, 2006, pp.29–47

Plaza A., Martinez P., Perez R., and Plaza J., A quantitative and comparative analysis of endmember extraction algorithms from Hyperspectral data, IEEE Trans. Geosci. Remote Sens., Mar. 2004, vol. 42, no. 3, pp. 650–663.

فصلنامه
دو

