

Vol. 12/ No. 47/Spring 2023

Research Article

# Spatial – Spectral Feature Extraction using Three-Dimensional Singular Spectrum Analysis for Hyperspectral Image Classification

Ehsan Dashtifard, PhD Student <sup>1</sup> | Azar Mahmoodzadeh, Assistant Professor <sup>2\*</sup> | Ahmad Keshavarz, Associate Professor <sup>3</sup> | Hamed Agahi, Associate Professor <sup>4</sup>

<sup>1</sup>Department of Electrical Engineering, Shiraz Branch, Islamic Azad University, Shiraz, Iran, [dashtifard.e@gmail.com](mailto:dashtifard.e@gmail.com)

<sup>2</sup>Department of Electrical Engineering, Shiraz Branch, Islamic Azad University, Shiraz, Iran, [mahmoodzadeh@iaushiraz.ac.ir](mailto:mahmoodzadeh@iaushiraz.ac.ir)

<sup>3</sup>IoT and Signal Processing Research Group, ICT Research Institute, Faculty of Intelligent Systems Engineering and Data Science, Persian Gulf University, 7516913817 Bushehr, Iran, [a.keshavarz@pgu.ac.ir](mailto:a.keshavarz@pgu.ac.ir)

<sup>4</sup>Department of Electrical Engineering, Shiraz Branch, Islamic Azad University, Shiraz, Iran, [agahi@iaushiraz.ac.ir](mailto:agahi@iaushiraz.ac.ir)

Correspondence

Azar Mahmoodzadeh, Assistant Professor, Department of Electrical Engineering, Shiraz Branch, Islamic Azad University, Shiraz, Iran, [mahmoodzadeh@iaushiraz.ac.ir](mailto:mahmoodzadeh@iaushiraz.ac.ir)

Received: 4 November 2022

Revised: 6 January 2022

Accepted: 21 January 2022

## Abstract

Feature extraction has a valuable role in hyperspectral images processing. In recent years, various methods have been presented to extract efficient features of hyperspectral images. Recent studies have successfully used conventional singular spectrum analysis in the spectral domain and two-dimensional singular spectrum analysis in the spatial domain for feature extraction in hyperspectral images. However, a lack of success in joint spectral-spatial feature extraction is a problem with both algorithms. This study uses a three-dimensional singular spectrum analysis extension to overcome this problem. The implementation of proposal model on hyperspectral images removes the noise components during spectral-spatial feature extraction process and significantly improves features identification capability. This study conducts experiments using two publically available datasets. Experimental results show that our proposed method has a promising performance so that it has improved the classification accuracy compared to recent methods by at least 1.93% and 1.27% for datasets Indian Pines and Pavia University, respectively.

**Keywords:** Feature Extraction, Hyperspectral Image (HSI), 3D-Singular Spectrum Analysis (3D-SSA), Classification, Spatial-Spectral

## Highlights

- Using the cubic window in the stage of embedding the proposed algorithm.
- Spatial partitioning of the HSI cube and reduction of computational complexity for Singular Value Decomposition (SVD).
- Extraction of effective spectral-spatial features using the proposed algorithm.

**Citation:** E. Dashtifard, Azar Mahmoodzadeh, A. Keshavarz, and H. Agahi, "Spatial -Spectral Feature Extraction using Three-Dimensional Singular Spectrum Analysis for Hyperspectral Image Classification," *Journal of Southern Communication Engineering*, vol. 12, no. 47, pp. 37–52, 2023, doi: 10.30495/jce.2023.1972096.1176, (in Persian).

## مقاله پژوهشی

## استخراج ویژگی طیفی - مکانی با استفاده از تحلیل طیفی تکین سه بعدی برای طبقه‌بندی تصاویر ابرطیفی

احسان دشتی فرد<sup>۱</sup> | آذر محمودزاده\*<sup>۲</sup> | احمد کشاورز<sup>۳</sup> | حامد آگاهی<sup>۴</sup>

## چکیده:

استخراج ویژگی دارای نقشی ارزنده در پردازش تصاویر ابرطیفی است. در سال‌های اخیر روش‌های گوناگونی برای استخراج ویژگی‌های کارآمد تصاویر ابرطیفی ارائه شده است. اخیراً تحلیل طیفی تکین شامل ویرایش معمولی آن در حوزه طیفی و تحلیل طیفی تکین دو بعدی در حوزه مکانی با موفقیت برای استخراج ویژگی در تصاویر ابرطیفی بکار گرفته شده است. با این حال عدم توفیق در استخراج ویژگی‌های مؤثر طیفی - مکانی مشترک به عنوان یکی از اشکالات این دو الگوریتم به شمار می‌رود. در این مقاله برای غلبه بر این اشکال، یک توسعه سه بعدی از تحلیل طیفی تکین ارائه شده است. اعمال مدل پیشنهادی به تصاویر ابرطیفی منجر به حذف مؤلفه‌های نویزی شده و توانایی تشخیص ویژگی‌ها بسیار بهبود می‌یابد. در این پژوهش، از دو مجموعه داده در دسترس عموم برای انجام آزمایش‌ها استفاده شده است. نتایج آزمایشگاهی نشان می‌دهد که روش پیشنهادی ما عملکرد امیدوارکننده‌ای دارد به گونه‌ای که دقت طبقه‌بندی را در مقایسه با روش‌های اخیر، حداقل ۱/۹۳٪ و ۱/۲۷٪ به ترتیب برای مجموعه داده ابرطیفی ایندیانا و دانشگاه پائوایا بهبود بخشیده است.

کلید واژه‌ها: استخراج ویژگی، تصویر ابرطیفی، تحلیل طیفی تکین سه‌بعدی، طبقه‌بندی، طیفی - مکانی

<sup>۱</sup> گروه مهندسی برق، واحد شیراز، دانشگاه آزاد اسلامی، شیراز، ایران، dashtifard.e@gmail.com

<sup>۲</sup> گروه مهندسی برق، واحد شیراز، دانشگاه آزاد اسلامی، شیراز، ایران، mahmoodzadeh@iaushiraz.ac.ir

<sup>۳</sup> گروه مهندسی برق، دانشکده مهندسی سیستم‌های هوشمند و علوم داده، دانشگاه خلیج فارس، بوشهر، ایران، a.keshavarz@pgu.ac.ir

<sup>۴</sup> گروه مهندسی برق، واحد شیراز، دانشگاه آزاد اسلامی، شیراز، ایران، agahi@iaushiraz.ac.ir

نویسنده مسئول

\* آذر محمودزاده، استادیار، گروه مهندسی برق، واحد شیراز، دانشگاه آزاد اسلامی، شیراز، ایران، mahmoodzadeh@iaushiraz.ac.ir

تاریخ دریافت: ۱۳ آبان ۱۴۰۱

تاریخ بازنگری: ۱۶ دی ۱۴۰۱

تاریخ پذیرش: ۱ بهمن ۱۴۰۱

<https://doi.org/10.30495/jce.2023.1972096.1176>

## ۱- مقدمه

تصویر ابرطیفی<sup>۱</sup> (HSI) یک ابرمکعب سه بعدی را در دسترس قرار می‌دهد که شامل یک ساختار مکانی دو بعدی و خصوصیات طیفی یک بعدی می‌شود. این ابر مکعب سه بعدی مملو از اطلاعات طیفی مربوط به ماهیت فیزیکی مواد است و می‌توان از آن برای تشخیص تفاوت‌های جزئی اشیاء از نظر دما، رطوبت و مؤلفه‌های شیمیایی بهره‌برداری کرد [۱]. علاوه بر این، تصویر ابرطیفی با دارا بودن باندهای طیفی متعدد و پیوسته ناشی از نور مرئی تا مادون قرمز (نزدیک) در بسیاری از حوزه‌ها نظیر نظارت بر کشاورزی [۲]، شناسایی مواد معدنی [۳]، مطالعات محیط‌زیست [۴]، و نظامی [۵] کاربرد دارد. با این حال، به دلیل ماهیت ذاتی داده HSI، موضوع افزونگی و نویز در حین جمع‌آوری، انتقال و پردازش داده اجتناب‌ناپذیر است و این مسئله مزایای فناوری HSI را محدود می‌کند [۶، ۷]. به منظور غلبه بر این کاستی‌ها، تلاش‌هایی نظیر استخراج ویژگی‌های مؤثرتر، در هر دو حوزه طیفی و مکانی پیشنهاد شده است [۸]. برخی از روش‌های استخراج ویژگی طیفی پرکاربرد مانند تحلیل مؤلفه اصلی<sup>۲</sup> (PCA) [۹]

<sup>۱</sup> Hyperspectral image

<sup>۲</sup> Principal component analysis

و تحلیل طیفی تکین<sup>۱</sup> (SSA) [۱۱،۱۰] می‌توانند ویژگی‌های طیفی مؤثری را به دست آورند. روش SSA در مقایسه با PCA، اطلاعات طیفی بیشتری را حفظ می‌کند و قابلیت تفکیک‌پذیری بهتری در امر طبقه‌بندی داده‌ها دارد [۱۲]. روش SSA فقط ویژگی‌های رویه‌ی طیفی<sup>۲</sup> را استخراج می‌کند درحالی‌که اطلاعات فراوان محتوای مکانی را نادیده می‌گیرد و منجر به طبقه‌بندی نادرست و نویز در نقشه‌های طبقه‌بندی می‌گردد. به دلیل محدودیت استخراج ویژگی‌های طیفی و نیز استفاده بالقوه از اطلاعات مکانی، برخی تکنیک‌های پردازش مکانی پیشنهاد شده است. پروفایل‌های ویژگی توسعه‌یافته<sup>۳</sup> (EAP) یکی از رویکردهای رایج استخراج ویژگی‌های مکانی بر اساس پروفایل‌های ریختشناسی<sup>۴</sup> (MP) است [۱۳]. ویژگی‌های گابور می‌توانند ساختارهای مکانی با مقیاس‌ها و جهت‌گیری‌های مختلف را در HSI نشان دهند [۱۴]. ویرایش دو بعدی SSA (2D-SSA) [۱۶،۱۵] اطلاعات مکانی کلی را برای هر تصویر باند استخراج می‌کند اما می‌تواند داده‌ها را بیش‌ازحد هموار نماید و منجر به خطای طبقه‌بندی شود. علاوه بر این، بعضی از تکنیک‌ها مانند روش‌های مبتنی بر فیلترهای حفظ لبه<sup>۵</sup> (EPF) [۱۷]، تجزیه تصویر ذاتی [۱۸]، واکر تصادفی گسترده [۱۹] از اطلاعات طیفی- مکانی استفاده می‌کنند.

اخیراً، یادگیری عمیق به یک موضوع تحقیقاتی داغ در پردازش تصویر تبدیل شده است و برای کاربردهای مختلف نظیر آشکارسازی تغییر [۲۰]، طبقه‌بندی تصویر [۲۱،۲۲] و بخش‌بندی تصویر [۲۳] مورد استفاده قرار می‌گیرد. تکنیک‌های یادگیری عمیق با استفاده از معماری‌های شبکه، می‌توانند سطح عمیق‌تر و ویژگی‌های انتزاعی‌تر از داده‌ها را به دست آورند و به عملکرد امیدوارکننده‌تری از مدل‌های سنتی با ساختارهای کم‌عمق دست یابند [۲۴،۲۵]. روش‌های مبتنی بر شبکه‌های عصبی پیچشی<sup>۶</sup> (CNN) عمیق معمولاً به دلیل ویژگی‌های منحصربه‌فرد و مفید، از سایر مدل‌های یادگیری عمیق بهتر عمل می‌کنند. CNN و ویرایش‌های بهینه‌شده‌ی آن به‌طور گسترده‌ای برای طبقه‌بندی طیفی- مکانی HSI استفاده شده است [۲۶،۲۷] و می‌تواند با تکنیک‌های دیگر، نظیر MP [۲۸] و نمایش تنک [۲۹] ترکیب شود تا عملکرد طبقه‌بندی را بهتر نماید. با این حال، روش‌های یادگیری عمیق دارای پارامترهای آموزشی متعددی هستند و بیشتر به‌عنوان جعبه سیاه معرفی می‌شوند. برای کاربردهای HSI، رویکردهای مرسوم همچنان مطلوب هستند که دلیل عمده آن عدم وجود نمونه‌های آموزشی کافی برای آموزش مدل‌های یادگیری عمیق است.

در این مقاله، یک الگوریتم استخراج ویژگی مبتنی بر SSA ارائه خواهیم داد. روش پیشنهادی ما، توسعه‌ی سه بعدی SSA است که به زیر مکعب‌های تصویر ابرطیفی اعمال می‌شود، درحالی‌که هر یک از این زیرمکعب‌ها هم اندازه و دارای طیف کامل هستند و از قسمت‌بندی مکانی تصویر ابرطیفی به دست می‌آیند. دو الگوریتم SSA و 2D-SSA توفیقی در استخراج ویژگی‌های طیفی- مکانی مشترک نداشته‌اند. روش پیشنهادی 3D-SSA با اسکن کردن هم‌زمان ابعاد مکانی و طیفی تصویر ابرطیفی در مرحله تشکیل ماتریس مسیر<sup>۷</sup> انجام می‌شود در نتیجه نه‌تنها محتوای مکانی بلکه اطلاعات طیفی غنی را نیز در نظر می‌گیرد. از طرفی اگرچه SSA کارایی استخراج ویژگی را بهبود می‌بخشد، اما پیچیدگی محاسباتی آن قابل توجه است زیرا در پیاده‌سازی مبتنی بر پیکسل، مرحله تجزیه مقدار تکین<sup>۸</sup> (SVD) به‌طور جداگانه برای هر پیکسل مورد نیاز است. همچنین با وجود اینکه 2D-SSA در طبقه‌بندی پیکسل بسیار مؤثر است، اما پیاده‌سازی مبتنی بر باند آن ایجاب می‌کند که مرحله SVD برای هر باند طیفی مکعب ابرطیفی به‌طور جداگانه محاسبه شود. این واقعیت منجر به پیچیدگی محاسباتی قابل توجهی می‌گردد. روش پیشنهادی 3D-SSA به‌جای اعمال به مکعب تصویر ابرطیفی، بر روی زیرمکعب‌ها اجرا و در نتیجه مرحله SVD به تعداد زیرمکعب‌ها پیاده‌سازی می‌شود. با توجه به تعداد بسیار کمتر زیرمکعب‌ها در مقایسه با تعداد پیکسل‌ها و تعداد باندها، پیچیدگی محاسباتی تا حد زیادی کاهش یافته و کارایی بهبود پیدا می‌کند. در این مقاله، کارآمدی ویژگی‌های استخراج‌شده توسط روش پیشنهادی را از طریق طبقه‌بندی و مقایسه با نتایج سایر روش‌های اخیر نشان خواهیم داد.

<sup>۱</sup> Singular spectrum analysis

<sup>۲</sup> Spectral trend features

<sup>۳</sup> Extended attribute profiles

<sup>۴</sup> Morphological profile

<sup>۵</sup> Edge-preserving filters

<sup>۶</sup> Convolutional neural networks

<sup>۷</sup> Trajectory

<sup>۸</sup> Singular value decomposition

ادامه این مقاله به گونه‌ای سازمان‌دهی شده است که در بخش دوم، اصول تحلیل طیفی تکین (SSA) را به طور خلاصه معرفی می‌کنیم. در بخش سوم، روش پیشنهادی 3D-SSA برای آنالیز HSI ارائه خواهد شد. نتایج آزمایش‌ها و تجزیه و تحلیل آن‌ها در بخش چهارم شرح داده می‌شود. در نهایت، نتایج مهم در بخش پنجم بیان می‌گردد.

## ۲- اصول تحلیل طیفی تکین

روش تحلیل طیفی تکین (SSA) یکی از روش‌های تحلیل سری‌های زمانی است که با توجه به توانمندی آن مورد استقبال زیادی قرار گرفته و روزه‌روز بر گستره کاربرد آن در حوزه‌های مختلف افزوده می‌شود. روش SSA به ترتیب شامل مراحل تعبیه کردن<sup>۱</sup>، تجزیه مقدار تکین (SVD)، گروه‌بندی و میانگین‌گیری قطری (هنکلسازی)<sup>۲</sup> است که مطابق زیر پیاده‌سازی می‌شود [۳۰]: سیگنال یک بعدی  $\mathbf{p} = [p_1, p_2, \dots, p_N]^T \in R^N$  را در نظر بگیرید. در این صورت و در گام اول که مرحله تعبیه کردن است، به کمک پنجره‌ای با اندازه  $L \in Z$  که  $L \in [1, N]$  می‌توان سیگنال اصلی را به دنباله‌ای از بردارهای lagged، یعنی ماتریس مسیر  $\mathbf{X}$  نگاشت کرد.

$$\mathbf{X} = \begin{bmatrix} p_1 & p_2 & \dots & p_k \\ p_2 & p_3 & \dots & p_{k+1} \\ \vdots & \vdots & \ddots & \vdots \\ p_L & p_{L+1} & \dots & p_N \end{bmatrix} = (\mathbf{c}_1, \mathbf{c}_2, \dots, \mathbf{c}_K) \quad (1)$$

ستون‌های ماتریس  $\mathbf{X}$ ، یعنی  $\mathbf{c}_k$ ، به صورت  $\mathbf{c}_k = [p_k, p_{k+1}, \dots, p_{k+L-1}]^T \in R^L$  تعریف می‌شوند که  $k \in [1, K]$  و  $K = N - L + 1$  است. هر یک از قطرهای فرعی ماتریس مسیر  $\mathbf{X}$  مقادیر یکسانی دارند بنابراین ماتریس  $\mathbf{X}$  طبق تعریف، یک ماتریس هنکل است. در مرحله دوم، ماتریس  $\mathbf{S}$  مطابق رابطه  $\mathbf{S} = \mathbf{X}\mathbf{X}^T$  تعریف می‌گردد. در این صورت، مقادیر ویژه  $\mathbf{S}$  و بردارهای ویژه متناظر با آن‌ها به ترتیب به صورت  $(\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_L)$  و  $(\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_L)$  نشان داده می‌شوند؛ بنابراین بعد از تجزیه مقدار تکین (SVD) ماتریس  $\mathbf{X}$  را می‌توان با جمع بستن چندین ماتریس ابتدایی بازسازی کرد. برای سادگی،  $L$  را مساوی رنک ماتریس مسیر قرار می‌دهند. از این رو خواهیم داشت:

$$\mathbf{X} = \mathbf{X}_1 + \mathbf{X}_2 + \dots + \mathbf{X}_L \quad (2)$$

که  $\mathbf{X}_l | l \in [1, L]$  ماتریس ابتدایی خوانده می‌شود و مطابق رابطه ۳ به دست می‌آید.  $\mathbf{u}_l$  و  $\mathbf{v}_l$  به ترتیب توابع متعامد تجربی و مؤلفه‌های اصلی ماتریس  $\mathbf{X}$  هستند.

$$\mathbf{X}_l = \sqrt{\lambda_l} \mathbf{u}_l \mathbf{v}_l^T, \quad \mathbf{v}_l = \mathbf{X}^T \mathbf{u}_l / \sqrt{\lambda_l} \quad (3)$$

در مرحله گروه‌بندی، مجموعه کلی شامل  $L$  مؤلفه به  $M$  مجموعه جدا از هم  $\mathbf{t}_1, \mathbf{t}_2, \dots, \mathbf{t}_M$  تقسیم‌بندی می‌شود که  $\sum |\mathbf{t}_m| = L$  و  $m \in [1, M]$  است. اگر  $\mathbf{t} = [l_1, l_2, \dots, l_q]$  نشان‌دهنده یکی از مجموعه‌های تقسیم‌بندی شده باشد و ماتریس  $\mathbf{X}_t$  مربوط به گروه  $\mathbf{t}$  مطابق با  $\mathbf{X}_t = \mathbf{X}_{l_1} + \mathbf{X}_{l_2} + \dots + \mathbf{X}_{l_q}$  تعریف شود، آنگاه ماتریس مسیر  $\mathbf{X}$  مطابق رابطه ۴ خواهد بود:

$$\mathbf{X} = \mathbf{X}_{\mathbf{t}_1} + \mathbf{X}_{\mathbf{t}_2} + \dots + \mathbf{X}_{\mathbf{t}_M} \quad (4)$$

ماتریس‌های  $\mathbf{X}_{\mathbf{t}_m} | m \in [1, M]$  به دست آمده از مرحله گروه‌بندی، لزوماً مانند ماتریس اصلی  $\mathbf{X}$  از نوع هنکل نیستند. باین حال، برای نمایش هر یک از این ماتریس‌ها به سیگنالی یک بعدی، لازم است که آن‌ها را هنکل کرد. فرآیند هنکلسازی با میانگین‌گیری در همه قطرهای فرعی ماتریس‌های  $\mathbf{X}_{\mathbf{t}_m}$  انجام می‌شود. اگر بردار  $\mathbf{z}_m = [z_{m1}, z_{m2}, \dots, z_{mN}]^T \in R^N$  نشان‌دهنده سیگنال یک بعدی برآمده از ماتریس  $\mathbf{X}_{\mathbf{t}_m}$  باشد؛ آنگاه می‌توان عناصر این بردار را با میانگین‌گیری قطری به دست آورد که  $a_{r,n-r+1}$  نشان‌دهنده عناصر ماتریس  $\mathbf{X}_{\mathbf{t}_m}$  است:

<sup>1</sup> Embedding

<sup>2</sup> Hankelization

$$z_{m_n} = \begin{cases} \frac{1}{n} \sum_{r=1}^n a_{r,n-r+1}, & 1 \leq n \leq L \\ \frac{1}{L} \sum_{r=1}^L a_{r,n-r+1}, & L < n < K \\ \frac{1}{N-n+1} \sum_{r=n-K+1}^L a_{r,n-r+1}, & K \leq n \leq N \end{cases} \quad (5)$$


با استفاده از  $z_m$  به دست آمده می توان سیگنال یک بعدی  $\mathbf{p}$  اصلی را به صورت زیر بازسازی نمود:

$$\mathbf{p} = \mathbf{z}_1 + \mathbf{z}_2 + \dots + \mathbf{z}_M = \sum_{m=1}^M \mathbf{z}_m \quad (6)$$

به طور کلی، اولین مؤلفه بازسازی شده، متناظر با مقدار ویژه بیشینه، می تواند تقریباً جایگزین داده ی اصلی شود. این بدان معناست که گروه بندی مقدار ویژه<sup>۱</sup> (EVG) برابر با ۱ معمولاً عملکرد خوبی را در طبقه بندی نشان می دهد [۱۰].

### ۳- روش پیشنهادی تحلیل طیفی تکین سه بعدی برای آنالیز HSI

ما در این مقاله، توسعه سه بعدی تحلیل طیفی تکین (3D-SSA) را با هدف استخراج ویژگی های طیفی- مکانی مؤثر HSI و نیز بهبود عملکرد ویرایش های قبلی SSA پیشنهاد می کنیم. اگرچه اخیراً استفاده از 3D-SSA در برخی کاربردها نظیر مرجع [۳۱] گزارش شده است اما تا جایی که می دانیم این اولین بار است که 3D-SSA در استخراج ویژگی های مؤثر HSI و طبقه بندی داده سنسجش از دور بکار می رود. در هیچ یک از ویرایش های قبلی SSA، پنجره اسکن مرحله تعبیه کردن، به فرم مکعبی انتخاب نشده است. ما در روش پیشنهادی از یک پنجره مکعبی در مرحله تعبیه کردن استفاده می کنیم. از آنجاکه اعمال الگوریتم پیشنهادی به کل مکعب HSI نیازمند حافظه زیاد است بنابراین مطابق شکل ۱، مکعب HSI را به زیرمکعب هایی هم اندازه قسمت بندی مکانی نموده و پس از آن الگوریتم پیشنهادی به هر یک از این زیرمکعب ها اعمال می گردد. در قسمت بندی مکانی سعی بر این است که تعداد زیرمکعب ها تا جایی که ممکن است حداقل باشد.



شکل ۱: قسمت بندی مکانی مکعب تصویر ابرطیفی به زیرمکعب هایی با اندازه یکسان

Figure 1. Spatial partitioning the hyperspectral image cube into some same-sized sub-cubes

بنابراین با فرض اینکه مکعب ابرطیفی اصلی دارای ابعاد  $D_x \times D_y \times N_z$  باشد، ابتدا آن را قسمت بندی مکانی می کنیم به نحوی که هر یک از زیرمکعب های حاصل دارای ابعاد  $N_x \times N_y \times N_z$  گردد. در این صورت مراحل مختلف روش پیشنهادی 3D-SSA در هر زیرمکعب ابرطیفی به شرح زیر خواهد بود:

#### ۳-۱- تعبیه کردن تصویر 3D

فرض کنید  $\mathbf{P}^{3D}$  با ابعاد  $N_x \times N_y \times N_z$  نشان دهنده زیرمکعب ابرطیفی باشد که می توان آن را مطابق ماتریس رابطه ۷ نمایش داد:

<sup>1</sup> Eigenvalue grouping

$$\mathbf{P}^{3D} = \begin{bmatrix} & & & \mathbf{P}_{N_z} \\ & & \ddots & \\ & \mathbf{P}_2 & & \\ \mathbf{P}_1 & & & \end{bmatrix} \quad (7)$$

که  $\mathbf{P}_1$  و  $\mathbf{P}_2$  به ترتیب نشان‌دهنده باندهای طیفی شماره ۱ و ۲ تصویر سه بعدی  $\mathbf{P}^{3D}$  است و مطابق رابطه ۸ تعریف می‌شوند:

$$\mathbf{P}_1 = \begin{bmatrix} p_{1,1,1} & p_{1,2,1} & \cdots & p_{1,N_y,1} \\ p_{2,1,1} & p_{2,2,1} & \cdots & p_{2,N_y,1} \\ \vdots & \vdots & \ddots & \vdots \\ p_{N_x,1,1} & p_{N_x,2,1} & \cdots & p_{N_x,N_y,1} \end{bmatrix}, \quad \mathbf{P}_2 = \begin{bmatrix} p_{1,1,2} & p_{1,2,2} & \cdots & p_{1,N_y,2} \\ p_{2,1,2} & p_{2,2,2} & \cdots & p_{2,N_y,2} \\ \vdots & \vdots & \ddots & \vdots \\ p_{N_x,1,2} & p_{N_x,2,2} & \cdots & p_{N_x,N_y,2} \end{bmatrix} \quad (8)$$

به همین ترتیب  $\mathbf{P}_{N_z}$  باند طیفی شماره  $N_z$  تصویر سه بعدی  $\mathbf{P}^{3D}$  را نشان می‌دهد:

$$\mathbf{P}_{N_z} = \begin{bmatrix} p_{1,1,N_z} & p_{1,2,N_z} & \cdots & p_{1,N_y,N_z} \\ p_{2,1,N_z} & p_{2,2,N_z} & \cdots & p_{2,N_y,N_z} \\ \vdots & \vdots & \ddots & \vdots \\ p_{N_x,1,N_z} & p_{N_x,2,N_z} & \cdots & p_{N_x,N_y,N_z} \end{bmatrix} \quad (9)$$

در این صورت لازم است پنجره‌ای برای تعبیه کردن ماتریس مسیر تعریف شود. در روش پیشنهادی 3D-SSA، یک پنجره مکعبی  $\mathbf{W}_{i,j,k}$  با ابعاد  $L_x \times L_y \times L_z$  مطابق رابطه ۱۰ تعریف می‌شود که  $L_x \in [1, N_x]$ ،  $L_y \in [1, N_y]$  و  $L_z \in [1, N_z]$  است.

$$\mathbf{W}_{i,j,k} = \begin{bmatrix} & & & (\mathbf{w}_{i,j,k})_{L_z} \\ & & \ddots & \\ & & & \\ & & & (\mathbf{w}_{i,j,k})_2 \\ & & & \\ (\mathbf{w}_{i,j,k})_1 & & & \end{bmatrix} \quad (10)$$

که  $(\mathbf{w}_{i,j,k})_q$  مطابق رابطه زیر است:

$$(\mathbf{w}_{i,j,k})_q = \begin{bmatrix} p_{i,j,k+q-1} & p_{i,j+1,k+q-1} & \cdots & p_{i,j+L_y-1,k+q-1} \\ p_{i+1,j,k+q-1} & p_{i+1,j+1,k+q-1} & \cdots & p_{i+1,j+L_y-1,k+q-1} \\ \vdots & \vdots & \ddots & \vdots \\ p_{i+L_x-1,j,k+q-1} & p_{i+L_x-1,j+1,k+q-1} & \cdots & p_{i+L_x-1,j+L_y-1,k+q-1} \end{bmatrix} \quad (11)$$

برای ساختن ماتریس مسیر، پنجره  $\mathbf{W}_{i,j,k}$  باید در همه موقعیت‌های ممکن روی تصویر ابرطیفی  $\mathbf{P}^{3D}$  قرار بگیرد. مسیر حرکت پنجره به صورت پیمایش از بالا سمت چپ تا پایین سمت راست تصویر است. این روال در امتداد بعد طیفی ادامه می‌یابد. بدین ترتیب شروع مسیر پیمایش، یعنی  $(i, j, k)$  است که  $i \in [1, N_x - L_x + 1]$ ،  $j \in [1, N_y - L_y + 1]$ ،  $k \in [1, N_z - L_z + 1]$  و در نهایت همه موقعیت‌های ممکن برای پیمایش پنجره روی تصویر برابر با  $(N_x - L_x + 1)(N_y - L_y + 1)(N_z - L_z + 1)$  خواهد بود. پیکسل‌های تحت پوشش پنجره مکعبی 3D در نقطه مرجع  $(i, j, k)$ ، متناظر با بردار ستونی  $\mathbf{A}_{i,j,k}$  باز چینش می‌شوند:

$$\mathbf{A}_{i,j,k} = \begin{bmatrix} p_{i,j,k} \\ p_{i,j+1,k} \\ \vdots \\ p_{i,j+L_y-1,k} \\ p_{i+1,j,k} \\ \vdots \\ p_{i+L_x-1,j+L_y-1,k} \\ p_{i,j,k+1} \\ \vdots \\ p_{i+L_x-1,j+L_y-1,k+L_z-1} \end{bmatrix} \quad (12)$$

پس از پیمایش HSI، ماتریس  $\mathbf{X}^{3D}$  با ابعاد  $L_x L_y L_z \times (N_x - L_x + 1)(N_y - L_y + 1)(N_z - L_z + 1)$  را می‌توان به صورت زیر استخراج کرد:

$$\mathbf{X}^{3D} = \begin{bmatrix} \mathbf{A}_{1,1,1}^T \\ \mathbf{A}_{1,2,1}^T \\ \vdots \\ \mathbf{A}_{1,N_y-L_y+1,1}^T \\ \mathbf{A}_{2,1,1}^T \\ \vdots \\ \mathbf{A}_{N_x-L_x+1,N_y-L_y+1,1}^T \\ \mathbf{A}_{1,1,2}^T \\ \vdots \\ \mathbf{A}_{N_x-L_x+1,N_y-L_y+1,N_z-L_z+1}^T \end{bmatrix}^T \quad (13)$$

در حقیقت تمام پیکسل‌های تحت پوشش پنجره مکعبی در ماتریس  $\mathbf{A}$  قرار داده می‌شود و وقتی پنجره جابجا می‌شود لازم است تمام پیکسل‌های تحت پوشش پنجره در یک ماتریس  $\mathbf{A}$  جدید قرار بگیرند؛ بنابراین ماتریس‌های  $\mathbf{A}$  با اندیس‌های مختلف نشان‌دهنده حرکت پنجره هستند. در نتیجه، ماتریس مسیر  $\mathbf{X}^{3D}$  به دست آمده ساختاری مطابق رابطه ۱۴ خواهد داشت.

$$\mathbf{X}^{3D} = \begin{bmatrix} \mathbf{H}_1 & \mathbf{H}_2 & \cdots & \mathbf{H}_{N_z-L_z+1} \\ \mathbf{H}_2 & \mathbf{H}_3 & \cdots & \mathbf{H}_{N_z-L_z+2} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{H}_{L_z} & \mathbf{H}_{L_z+1} & \cdots & \mathbf{H}_{N_z} \end{bmatrix}_{L_z \times (N_z-L_z+1)} \quad (14)$$

که هر بلوک زیر ماتریس  $\mathbf{H}_q$  از نوع هنکل بلوک هنکل است و مطابق رابطه ۱۵ تعریف می‌شود:

$$\mathbf{H}_q = \begin{bmatrix} \mathbf{h}_{1,q} & \mathbf{h}_{2,q} & \cdots & \mathbf{h}_{N_x-L_x+1,q} \\ \mathbf{h}_{2,q} & \mathbf{h}_{3,q} & \cdots & \mathbf{h}_{N_x-L_x+2,q} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{h}_{L_x,q} & \mathbf{h}_{L_x+1,q} & \cdots & \mathbf{h}_{N_x,q} \end{bmatrix}_{L_x \times (N_x-L_x+1)} \quad (15)$$

و هر بلوک زیر ماتریس  $\mathbf{h}_{r,q}$  از نوع هنکل است و مطابق رابطه ۱۶ تعریف می‌شود:

$$\mathbf{h}_{r,q} = \begin{bmatrix} p_{r,1,q} & p_{r,2,q} & \cdots & p_{r,N_y-L_y+1,q} \\ p_{r,2,q} & p_{r,3,q} & \cdots & p_{r,N_y-L_y+2,q} \\ \vdots & \vdots & \ddots & \vdots \\ p_{r,L_y,q} & p_{r,L_y+1,q} & \cdots & p_{r,N_y,q} \end{bmatrix}_{L_y \times (N_y-L_y+1)} \quad (16)$$

بنابراین ماتریس  $\mathbf{X}^{3D}$  را اصطلاحاً هنکل بلوک هنکل بلوک هنکل<sup>۱</sup> (HbHbH) می‌نامند. این ملاحظات به‌خصوص در مرحله آخر الگوریتم پیشنهادی 3D-SSA باید در نظر گرفته شوند.

### ۳-۲- تجزیه مقدار تکین (SVD) و گروه‌بندی

این دو مرحله مشابه الگوریتم اصلی SSA هستند. با این حال، زمانی که الگوریتم SSA به حالت سه بعدی بسط داده می‌شود، باید ابعاد مربوطه تغییر کند بنابراین  $K^{3D} = (N_x-L_x+1)(N_y-L_y+1)(N_z-L_z+1)$  و  $L^{3D} = L_x L_y L_z$  خواهند بود.

### ۳-۳- میانگین‌گیری قطری (هنکل سازی)

ماتریس‌های  $\mathbf{X}_{im}^{3D}$  حاصل از مرحله گروه‌بندی الگوریتم 3D-SSA لزوماً از نوع هنکل بلوک هنکل بلوک هنکل نیستند. در نتیجه، لازم است که به ماتریس‌های HbHbH تبدیل شوند. این کار را می‌توان از طریق فرآیند هنکل‌سازی سه مرحله‌ای محقق کرد؛ بنابراین برای مرحله میانگین‌گیری نیاز به سه عملیات هنکل‌سازی متوالی داریم، بر این اساس در ابتدا این عملیات به هر بلوک رابطه ۱۶ اعمال می‌شود، سپس بین بلوک‌ها در رابطه ۱۵ اجرا می‌گردد و سرانجام هنکل‌سازی بین بلوک‌ها در رابطه ۱۴ انجام

<sup>۱</sup> Hankel block Hankel block Hankel

می‌گیرد. در نتیجه بعد از انجام عملیات هنکلسازی در رابطه ۱۴، هر یک از باندهای طیفی زیرمکعب ابرطیفی اصلی بر اساس ترتیب انجام عملیات میانگین‌گیری بازسازی خواهد شد. این مراحل برای بقیه زیر مکعب‌ها نیز اجرا می‌شود. در نتیجه مکعب تصویر ابرطیفی اصلی بازسازی می‌گردد. جدول ۱ مراحل مختلف روش پیشنهادی 3D-SSA را نشان می‌دهد.

جدول ۱: روش پیشنهادی 3D-SSA در HIS

Table 1. Proposed 3D-SSA method in HSI

الگوریتم ۱: روش پیشنهادی 3D-SSA در HSI
ورودی: مکعب ابرطیفی با ابعاد $D_x \times D_y \times N_z$ ، که $D_x$ و $D_y$ ابعاد مکانی و $N_z$ نشان‌دهنده بعد طیفی مکعب ابرطیفی است.
قسمت‌بندی مکانی: تصویر ابرطیفی ورودی به R زیر مکعب هم‌اندازه با ابعاد $N_x \times N_y \times N_z$ قسمت‌بندی مکانی می‌شود.
انتخاب پارامتر: اندازه پنجره مکعبی $L^{3D} = L_x L_y L_z$ و نیز EVG انتخاب می‌گردد. این پارامترها برای همه زیرمکعب‌ها استفاده می‌شوند.
اعمال روش پیشنهادی 3D-SSA به زیرمکعب ۱، $(r=1)$ :
۱. تعبیه کردن زیر مکعب ابرطیفی روی یک ماتریس مسیر $X^{3D}$ با استفاده از پنجره $L^{3D}$
۲. به دست آوردن مقادیر ویژه $X^{3DT} X^{3D}$ و بردارهای ویژه متناظر آن‌ها
۳. گروه‌بندی و به دست آوردن ماتریس‌های $X_{im}^{3D}$
۴. میانگین‌گیری قطری (هنکلسازی) و به دست آوردن تصویر بازسازی‌شده نهایی زیرمکعب.
تکرار مبتنی بر زیرمکعب: مراحل چهارگانه 3D-SSA برای زیرمکعب‌های دیگر $(r=2, \dots, R)$ تکرار می‌گردد.
خروجی: یک مکعب ابرطیفی جدید با ابعاد $D_x \times D_y \times N_z$ به دست می‌آید که همه زیرمکعب‌های آن با استفاده از 3D-SSA بازسازی شده است.

#### ۴-آزمایش‌ها و تجزیه و تحلیل

##### ۴-۱-مجموعه داده‌ها و راه‌اندازی

در این قسمت مجموعه داده‌های ابرطیفی مورد استفاده برای ارزیابی عملکرد روش پیشنهادی 3D-SSA معرفی می‌شوند. اولین مجموعه داده ابرطیفی، ایندیانا<sup>۱</sup> است که توسط سنسور AVIRIS در محل کشاورزی در شمال غربی ایندیانا ایالات متحده به دست آمده است. اندازه مکانی این تصویر ابرطیفی  $145 \times 145$  پیکسل، شامل ۲۲۴ باند طیفی مجاور هم و با طول موج‌های بین ۴۰۰ تا ۲۵۰۰ نانومتر است. مشابه دیگران [۳۲، ۱۲] تعداد ۲۴ باند نوپزی را کنار گذاشته و تنها ۲۰۰ باند برای طبقه‌بندی در نظر گرفته‌ایم. تصویر شبه رنگی<sup>۲</sup> از مجموعه داده ایندیانا و نقشه مرجع زمینی<sup>۳</sup> آن به ترتیب در شکل ۲ الف و ب، ارائه شده است. در این مجموعه داده، ۱۶ کلاس پوشش زمینی وجود دارد. مجموعه داده دیگر، دانشگاه پاولیا<sup>۴</sup> است که به وسیله سنسور ROSIS به دست آمده است. این مجموعه داده دارای اندازه مکانی  $610 \times 340$  پیکسل و ۱۱۵ باند طیفی مجاور در محدوده طول موج‌های بین ۴۳۰ تا ۸۶۰ نانومتر است. در آزمایش‌های ما، تعداد باندها با حذف ۱۲ باند نوپزی به ۱۰۳ باند کاهش می‌یابد. شکل ۳ الف و ب، به ترتیب تصویر شبه رنگی و نقشه مرجع زمینی مربوط به آن را با ۹ کلاس مختلف پوشش زمینی ارائه می‌دهد. تعداد نمونه‌های مورد استفاده در آزمایش‌ها در جدول ۲ نشان داده شده است.

<sup>1</sup> Indian Pines

<sup>2</sup> Pseudo-color image

<sup>3</sup> Ground reference map

<sup>4</sup> Pavia University



جدول ۲: تعداد نمونه‌های مورداستفاده در آزمایش‌ها  
Table 2. Number of samples used in the experiments

دانشگاه پاویا		ایندیانا	
تعداد نمونه‌ها	نوع پوشش زمین	تعداد نمونه‌ها	نوع پوشش زمین
۶۶۳۱	آسفالت	۴۶	یونجه
۱۸۶۴۹	چمن	۱۴۲۸	ذرت سالم
۲۰۹۹	شن و ماسه	۸۳۰	ذرت آفت‌زده
۳۰۶۴	درخت	۲۳۷	ذرت در ابتدای رشد
۱۳۴۵	ورقه‌های فلزی رنگ‌شده	۴۸۳	چمن - مرتع
۵۰۲۹	خاک	۷۳۰	چمن - درخت
۱۳۳۰	قیر	۲۸	چمن - مرتع - درو شده
۳۶۸۲	آجر	۴۷۸	دسته‌های یونجه
۹۴۷	سایه	۲۰	جو
		۹۷۲	سویا سالم
		۲۴۵۵	سویا آفت‌زده
		۵۹۳	سویا در ابتدای رشد
		۲۰۵	گندم
		۱۲۶۵	چوب
		۳۸۶	ساختمان - سبزه - درخت - ماشین
		۹۳	برنج سنگ فولاد

#### ۴-۲-طبقه‌بندی

طبقه‌بندی، یکی از پردازش‌های مهم HSI است [۳۴،۳۳]. طبقه‌بندی پیکسل‌های HSI برای ارزیابی کارایی روش استخراج ویژگی پیشنهادی انجام می‌شود، زیرا انتظار می‌رود ویژگی‌های مؤثرتر منجر به دقت طبقه‌بندی بالاتر شود [۳۲]. بعد از استخراج ویژگی‌ها توسط روش پیشنهادی نیاز به یک طبقه‌بندی کننده داریم. بر اساس معیار margin، ماشین بردار پشتیبان<sup>۱</sup> (SVM) استحکام بالایی در مسائل ابعادی دارد. در حقیقت، SVM به‌طور گسترده در طبقه‌بندی HSI استفاده شده است [۳۲،۱۲]. بعلاوه، چندین ابزار نرم‌افزاری و کتابخانه در دسترس وجود دارد که برای پیاده‌سازی SVM با هدف مدل‌سازی دقیق و سریع داده بکار می‌روند. همچنین SVM از انواع توابع کرنل نظیر خطی، چندجمله‌ای و توابع پایه شعاعی گوسی<sup>۲</sup> (RBF) پشتیبانی می‌کند. لذا می‌توان آن را به‌طور انعطاف‌پذیر در محدوده گسترده‌ای از مسائل طبقه‌بندی داده بکار برد. با توجه به این توضیحات در مرحله طبقه‌بندی و پس از استخراج ویژگی، طبقه‌بندی کننده SVM را به‌وسیله کتابخانه LIBSVM [۳۵] استفاده نموده و با پیروی از دیگران [۳۲،۱۲]، کرنل RBF و اعتبارسنجی تقاطعی ۵ فولد<sup>۳</sup> را در طبقه‌بندی کننده لحاظ کرده‌ایم. همچنین با تبعیت از مراجع [۱۰-۱۲]، [۱۵،۱۶] و [۳۲] از رویکرد انتخاب تصادفی نمونه‌های آموزشی به‌صورت درصدی از نمونه‌های هر کلاس برای ارزیابی عملکرد روش پیشنهادی بهره برده‌ایم. برای اجتناب از بروز خطای سیستماتیک و کاهش اختلاف‌های تصادفی، همه آزمایش‌ها به‌طور مستقل ۱۰ بار انجام شده است. مجموعه نمونه‌های آموزشی و آزمایشی به‌طور تصادفی و بدون هرگونه همپوشانی، هر بار نمونه‌برداری گردیده که ۱۰ درصد از نمونه‌های هر کلاس برای مجموعه داده‌ی ایندیانا و نیز دانشگاه پاویا

<sup>۱</sup> Support vector machine

<sup>۲</sup> Radial basis function

<sup>۳</sup> five-fold cross-validation

به عنوان نمونه های آموزشی در نظر گرفته شده است. علاوه بر این، شاخص های ۱- دقت کلی<sup>۱</sup> (OA)، ۲- دقت متوسط<sup>۲</sup> (AA)، ۳- ضریب کاپا و نیز دقت کلاس به کلاس برای ارزیابی عملکرد طبقه بندی تصویر مورد استفاده قرار گرفته است.

#### ۳-۴- تجزیه و تحلیل پارامتر

این پژوهش ویژگی های HSI را برای طبقه بندی استخراج می کند. این کار با قسمت بندی مکانی HSI به زیر مکعب هایی با اندازه های یکسان و سپس پیاده سازی 3D-SSA بر روی هر زیر مکعب انجام می شود. تا جایی که از عهده نرم افزار متلب بر بیاید تعداد زیر مکعب ها حداقل انتخاب می شود. بر این اساس، تصویر ابرطیفی ایندیانا با اندازه مکانی  $145 \times 145$  پیکسل و  $200$  باند طیفی مجاور هم به  $25$  زیر مکعب ابرطیفی با ابعاد یکسان قسمت بندی می شود که اندازه مکانی هر یک از آن ها  $29 \times 29$  پیکسل و شامل  $200$  باند طیفی مجاور هم هستند. تصویر ابرطیفی دانشگاه پاویا با اندازه مکانی  $610 \times 340$  پیکسل و  $103$  باند طیفی مجاور هم به  $50$  زیر مکعب ابرطیفی با ابعاد یکسان تقسیم می شود که اندازه مکانی هر کدام از آن ها  $61 \times 68$  پیکسل و شامل  $103$  باند طیفی مجاور هم هستند.

#### ۴-۴- مقایسه دقت طبقه بندی

در این بخش کارآمدی ویژگی های استخراج شده از روش پیشنهادی با ۱- تصویر ابرطیفی اصلی خام، ۲- PCA، ۳- SSA معمولی، ۴- EAP، ۵- فیلترینگ گابور، ۶- EPF، ۷- 2D-SSA و ۸- روش یادگیری عمیق CNN [۳۶] مقایسه شده است. نتایج طبقه بندی روش پیشنهادی و ۸ روش فوق الذکر بر روی دو مجموعه داده ابرطیفی برای ارزیابی عملکرد مورد استفاده قرار گرفته است. ما برای ارزیابی عملکرد روش پیشنهادی سه پنجره  $3 \times 3 \times 3$ ،  $5 \times 5 \times 5$  و  $7 \times 7 \times 7$  را بکار برده ایم. از میان پنجره های انتخابی در روش پیشنهادی، پنجره  $7 \times 7 \times 7$  برای داده ایندیانا و پنجره  $3 \times 3 \times 3$  برای داده دانشگاه پاویا بهترین عملکرد را داشته اند. بر این اساس پنجره های بهینه مورد استفاده برای روش پیشنهادی و سایر روش های مبتنی بر SSA در جدول (۳) درج شده است. پارامترهای روش های دیگر که مبتنی بر SSA نیستند در [۳۲] فهرست شده است.

جدول ۳: فهرست اندازه پنجره های بهینه روش پیشنهادی و سایر روش های مبتنی بر SSA  
Table 3. List of optimal window sizes of the proposed method and other SSA-based methods

روش	اندازه پنجره ایندیانا	اندازه پنجره دانشگاه پاویا
SSA - [12, 10]	10	10
2D-SSA - [15, 12]	10x10	5x5
روش پیشنهادی 3D-SSA	7x7x7	3x3x3

نقشه های طبقه بندی و نتایج کمی روش پیشنهادی در مقایسه با هشت معیار سنجش به ترتیب در شکل های ۲ و ۳ و جداول ۴ و ۵ نشان داده شده است.

#### داده ایندیانا

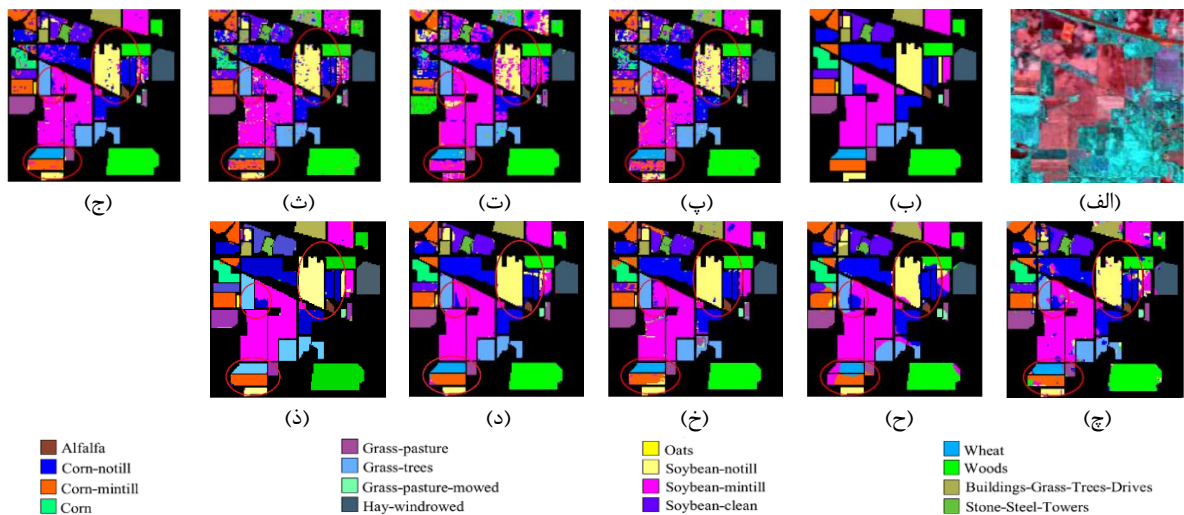
دقت طبقه بندی ویژگی های استخراج شده از روش پیشنهادی در مقایسه با هشت روش دیگر در جدول ۴ نشان داده شده است. بر این اساس، روش های SVM، PCA و SSA که فقط از اطلاعات طیفی استفاده می کنند، دقت کمتری نسبت به سایر روش ها دارند. همان گونه که در جدول ۴ مشاهده می شود روش پیشنهادی بهترین نتایج را در کلاس های ۲، ۳، ۶، ۸، ۹، ۱۰، ۱۱ و ۱۲ ارائه می دهد. روش پیشنهادی در کلاس های دارای تعداد نمونه های کم عملکرد چشمگیری دارد.

<sup>1</sup> Overall accuracy

<sup>2</sup> Average accuracy

جدول ۴: دقت طبقه‌بندی (٪) روش‌های مختلف برای داده ایندیانا  
Table 4. Classification accuracy (%) of different methods for the Indian Pines dataset

کلاس	SVM [۳۲]	PCA [۳۲]	SSA [۳۲]	EAP [۳۲]	Gabor [۳۲]	EPF [۳۲]	CNN-SVM [۳۲]	2D-SSA [۱۲]	روش پیشنهادی
۱	۱۴/۶۳	۲۶/۸۳	۷۳/۱۷	۹۵/۱۲	۸۰/۴۹	۷۷/۷۸	۹۷/۷۸	۷۸/۰۵	۹۲/۳۱
۲	۷۵/۳۳	۳۶/۹۶	۸۱/۸۷	۸۲/۸۸	۸۵/۹۱	۹۵/۲۱	۹۱/۳۵	۹۱/۶۷	۹۸/۰۲
۳	۶۶/۶۷	۴۳/۹۱	۷۷/۳۸	۸۶/۷۵	۸۸/۶۲	۸۳/۰۳	۹۳/۳۶	۹۶/۵۲	۹۷/۱۶
۴	۴۶/۰۱	۱۰/۸۰	۷۰/۴۲	۸۱/۶۹	۹۴/۸۴	۹۹/۱۴	۸۴/۹۱	۹۸/۵۹	۹۵/۵۲
۵	۸۵/۷۱	۲۶/۵۰	۹۴/۴۷	۹۴/۹۳	۹۲/۸۶	۸۸/۳۷	۹۷/۴۶	۹۸/۱۶	۹۵/۳۷
۶	۹۲/۳۹	۹۵/۷۴	۹۲/۵۴	۹۸/۶۳	۸۶/۳۰	۷۸/۸۸	۹۰/۴۹	۹۷/۲۶	۹۹/۹۸
۷	۶۸/۰۰	۵۲/۰۰	۸۰/۰۰	۸۴/۰۰	۹۲/۰۰	۱۰۰	۹۶/۳۰	۹۶/۰۰	۹۵/۶۵
۸	۹۹/۰۷	۹۷/۴۴	۹۹/۷۷	۹۹/۳۰	۹۶/۰۵	۹۸/۷۲	۱۰۰	۹۸/۶۰	۱۰۰
۹	۳۳/۳۳	۱۱/۱۱	۵۵/۵۶	۱۰۰	۴۴/۴۴	۵۲/۶۳	۱۰۰	۹۷/۲۲	۱۰۰
۱۰	۷۵/۰۶	۵۴/۵۸	۸۴/۲۱	۸۵/۳۵	۸۶/۱۶	۸۷/۹۲	۹۲/۱۲	۹۳/۵۹	۹۵/۶۴
۱۱	۸۴/۵۶	۸۲/۶۶	۸۴/۹۳	۹۲/۵۳	۹۱/۰۸	۹۶/۵۱	۹۶/۰۹	۹۷/۲۸	۹۸/۴۲
۱۲	۶۱/۵۴	۹/۷۶	۷۴/۳۰	۸۰/۳۰	۸۶/۴۹	۷۹/۵۲	۷۹/۸۶	۹۰/۹۹	۹۸/۴۱
۱۳	۹۱/۸۵	۹۳/۴۸	۹۰/۷۶	۹۸/۹۱	۹۰/۲۲	۷۳/۵۰	۹۹/۰۰	۹۸/۳۷	۹۶/۵۵
۱۴	۹۳/۷۶	۹۷/۸۹	۹۱/۳۹	۹۹/۳۰	۹۳/۹۴	۹۳/۳۸	۹۸/۸۷	۹۸/۹۵	۹۸/۷۰
۱۵	۵۷/۳۵	۱۱/۲۴	۴۹/۵۷	۹۸/۲۷	۷۷/۲۳	۸۷/۸۳	۹۴/۷۱	۹۸/۸۵	۹۸/۱۷
۱۶	۷۹/۵۲	۹۵/۱۸	۸۵/۵۴	۱۰۰	۱۰۰	۶۱/۵۴	۹۵/۶۰	۹۶/۳۹	۹۸/۷۳
OA	۷۹/۷۵	۶۲/۶۴	۸۴/۰۲	۹۱/۱۹	۸۹/۲۵	۹۰/۳۲	۹۳/۸۴	۹۶/۰۰	۹۷/۹۳
AA	۷۰/۳۰	۵۲/۸۸	۸۰/۳۷	۹۲/۳۷	۹۶/۶۶	۸۴/۶۲	۹۴/۲۴	۹۳/۸۴	۹۷/۴۱
Kappa	۰/۷۷	۰/۵۶	۰/۸۲	۰/۹۰	۰/۸۸	۰/۸۹	۰/۹۳	۰/۹۵	۰/۹۷



شکل ۲: نقشه‌های طبقه‌بندی داده ایندیانا: الف) تصویر شبه رنگی، ب) نقشه مرجع، پ) SVM، ت) PCA، ث) SSA، ج) EAP، چ) Gabor، ح) EPF،

خ) CNN-SVM، د) 2D-SSA، ذ) روش پیشنهادی

Figure 2. Classification maps of the Indian Pines data set: (a) Pseudo-color image, (b) Ground-truth, (c) SVM, (d) PCA, (e) SSA, (f) EAP, (g) Gabor, (h) EPF, (i) CNN-SVM, (j) 2D-SSA, (k) Proposed method

روش پیشنهادی به دلیل اینکه از اطلاعات طیفی و مکانی به طور همزمان استفاده می کند نتایج بهتری را به دست آورده است به نحوی که شاخص های OA، AA و ضریب Kappa روش پیشنهادی نسبت به سایر روش ها دارای مقادیر بالاتری است. مقدار روش پیشنهادی در مقایسه با SVM که روی داده خام تصویر ابرطیفی انجام شده است، افزایش قابل توجهی دارد. روش پیشنهادی ما نتایج طبقه بندی بهتری در مقایسه با CNN دارد. عملکرد روش پیشنهادی در مقایسه با SSA به اندازه ۱۳/۹۱ درصد بهبود دقت دارد. همچنین روش پیشنهادی در مقایسه با 2D-SSA به میزان ۱/۹۳ درصد بهبود دقت طبقه بندی را نشان می دهد. این در حالی است که 2D-SSA نسبت به سایر روش ها عملکرد بهتری دارد. نقشه های طبقه بندی روش پیشنهادی در مقایسه با ۸ معیار سنجش در شکل ۲ نشان داده شده است.

### داده دانشگاه پاولیا

مطابق با نتایج طبقه بندی جدول ۵، روش EAP در کلاس های ۳، ۷ و ۸ نتایج بهتری نسبت به روش پیشنهادی به بار می آورد اما در سایر کلاس ها یعنی کلاس های ۱، ۲، ۴، ۵، ۶ و ۹ بهترین نتایج متعلق به روش پیشنهادی است. از طرفی، شاخص های OA، AA و ضریب Kappa روش پیشنهادی نسبت به سایر روش ها مقدار بالاتری دارد. مقدار OA روش پیشنهادی در مقایسه با SSA معمولی که فقط از اطلاعات طیفی استفاده می کند، افزایش قابل ملاحظه ای دارد. روش SSA معمولی روی داده دانشگاه پاولیا خوب عمل نمی کند به گونه ای که نتایج آن فقط از PCA بیشتر است. روش پیشنهادی ما نتایج طبقه بندی بهتری در مقایسه با CNN دارد. علاوه بر این، روش پیشنهادی ما در مقایسه با 2D-SSA و EAP به ترتیب به میزان ۱/۶۴ درصد و ۱/۲۷ درصد بهبود دقت طبقه بندی را نشان می دهد. این در حالی است که EAP در مقایسه با سایر روش ها عملکرد بهتری دارد. نقشه های طبقه بندی روش پیشنهادی در مقایسه با ۸ معیار سنجش در شکل ۳ نشان داده شده است.

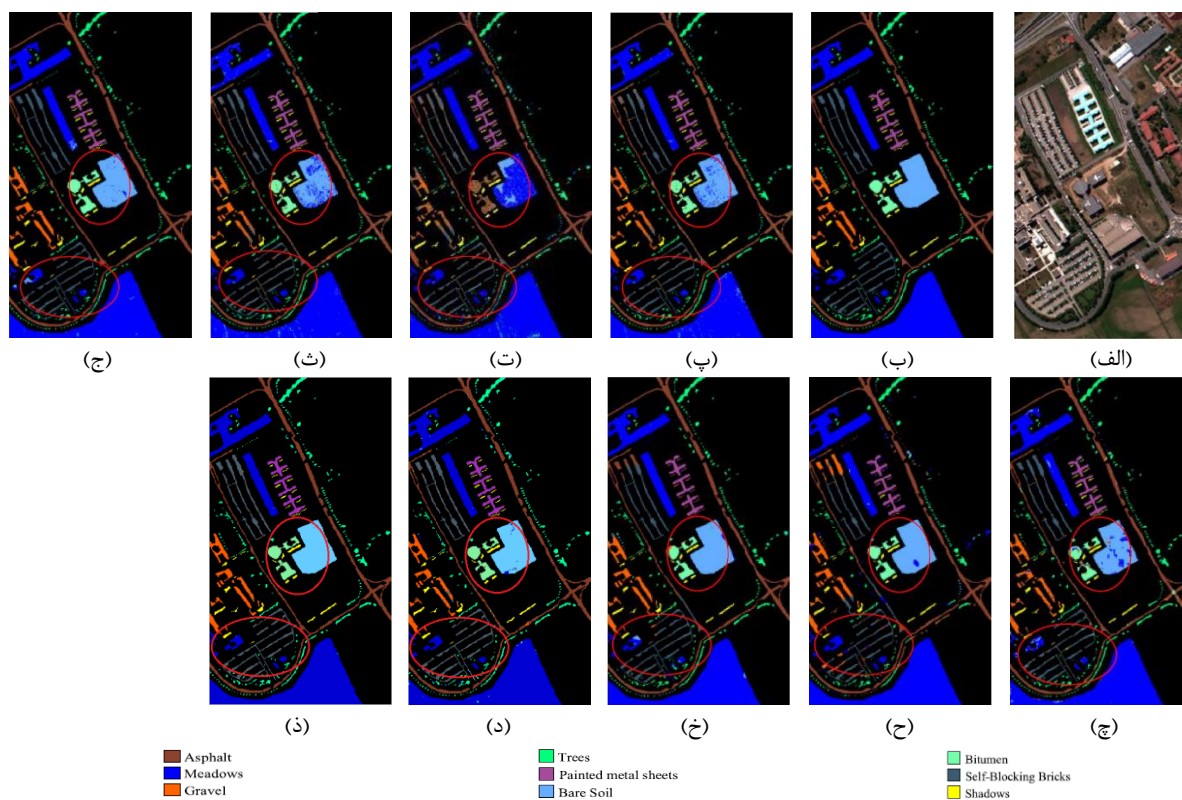
جدول ۵: دقت طبقه بندی (%) روش های مختلف برای داده دانشگاه پاولیا

Table 5. Classification accuracy (%) of different methods for the Pavia University dataset

کلاس	SVM [۳۲]	PCA [۳۲]	SSA [۳۲]	EAP [۳۲]	Gabor [۳۲]	EPF [۳۲]	CNN-SVM [۳۲]	2D-SSA [۳۷]	روش پیشنهادی
۱	۹۴/۳۴	۹۱/۸۷	۹۳/۸۸	۹۹/۴۵	۹۴/۵۹	۹۳/۶۹	۹۶/۵۳	۹۷/۹۲	۹۹/۵۷
۲	۹۷/۹۸	۹۸/۶۲	۹۷/۷۶	۹۸/۳۰	۹۷/۵۳	۹۹/۹۰	۹۹/۱۱	۹۹/۵۹	۹۹/۹۲
۳	۸۱/۵۲	۳۵/۸۴	۷۸/۳۰	۹۸/۰۹	۸۰/۱۵	۸۵/۵۴	۹۶/۵۰	۹۰/۱۸	۹۵/۲۹
۴	۹۵/۱۴	۷۴/۴۶	۹۴/۶۰	۹۳/۷۶	۸۸/۲۱	۶۶/۵۷	۹۶/۹۲	۹۴/۵۵	۹۹/۲۷
۵	۹۹/۵۰	۹۹/۳۴	۹۹/۵۰	۹۹/۵۹	۹۹/۹۲	۱۰۰	۱۰۰	۱۰۰	۱۰۰
۶	۸۸/۴۲	۱۷/۲۶	۷۶/۸۲	۹۶/۵۸	۸۸/۳۸	۹۸/۰۴	۹۸/۱۶	۹۷/۰۷	۹۹/۷۵
۷	۸۶/۷۲	۰/۴۲	۸۶/۵۵	۹۹/۴۲	۷۶/۶۱	۹۴/۲۶	۸۸/۵۹	۹۳/۷۲	۹۷/۶۵
۸	۸۸/۹۲	۸۴/۵۸	۸۹/۲۲	۹۸/۴۹	۸۹/۱۳	۷۱/۴۲	۸۵/۹۷	۹۵/۵۸	۹۷/۹۶
۹	۱۰۰	۹۹/۸۸	۹۹/۸۸	۱۰۰	۹۰/۷۳	۶۶/۴۵	۸۲/۹۹	۱۰۰	۱۰۰
OA	۹۴/۲۴	۷۸/۹۹	۹۲/۵۳	۹۸/۰۷	۹۳/۰۳	۹۲/۲۶	۹۷/۳۳	۹۷/۷۰	۹۹/۳۴
AA	۹۲/۵۱	۶۶/۹۲	۹۰/۷۲	۹۸/۱۹	۸۹/۴۷	۸۶/۲۱	۹۳/۸۶	۹۶/۵۱	۹۸/۸۲
Kappa	۰/۹۲	۰/۷۱	۰/۹۰	۰/۹۷	۰/۹۱	۰/۹۰	۰/۹۶	۰/۹۷	۰/۹۹

به طور کلی و بر اساس نتایج جدول ۳ و ۴، می توان گفت که PCA عملکرد بسیار ضعیفی دارد زیرا کاملاً به نویز حساس است. SSA معمولی دقت طبقه بندی را در مجموعه داده ایندیانا بهبود می بخشد اما در مجموعه داده دانشگاه پاولیا به دقت پایینی دست می یابد، احتمالاً دلیلش این باشد که پیکسل های بازسازی شده بیش از حد هموار هستند به گونه ای که به طور نادرست طبقه بندی می شوند. روش EAP به دقت طبقه بندی خوبی از ویژگی های استخراج شده دست پیدا می کند. CNN از یک ساختار چندلایه برای استفاده کامل از اطلاعات طیفی و مکانی محلی و دستیابی به دقت بهتر استفاده می کند. روش پیشنهادی، دقت

بالاتری نسبت به همه روش‌ها در اکثر کلاس‌های پوشش زمینی به دست می‌آورد که نشان‌دهنده پیشرفت بزرگی در طبقه‌بندی HSI به‌ویژه در مقایسه با SSA معمولی و 2D-SSA است. علاوه بر این، ویژگی‌های طیفی و مکانی استخراج‌شده توسط روش پیشنهادی قابل‌مقایسه و در مواردی، برتر از آن‌هایی هستند که توسط CNN استخراج‌شده‌اند. به نظر می‌رسد عدم وجود نمونه‌های آموزشی کافی برای آموزش مدل یادگیری عمیق CNN، باعث برتری روش پیشنهادی نسبت به CNN گردیده است.



شکل ۳: نقشه‌های طبقه‌بندی داده دانشگاه پاویا: (الف) تصویر شبه رنگی، (ب) نقشه مرجع، (پ) SVM، (ت) PCA، (ث) SSA، (ج) EAP، (چ) Gabor، (ح) روش پیشنهادی

Figure 3. Classification maps of the Pavia University dataset: (a) Pseudo-color image, (b) Ground-truth, (c) SVM, (d) PCA, (e) SSA, (f) EAP, (g) Gabor, (h) EPF, (i) CNN-SVM, (j) 2D-SSA, (k) Proposed method

## ۵- نتیجه‌گیری

در حوزه پردازش تصویر و بینایی ماشین، استخراج ویژگی یکی از تحقیقات مهم به‌ویژه برای HSI در سنجش‌ازدور است. استفاده جامع از اطلاعات طیفی و مکانی برای استخراج ویژگی در HSI ضروری است. تحلیل طیفی تکین (SSA) عملکرد خوبی برای استخراج ویژگی و حذف نویز در داده‌های HSI نشان داده است. در این مقاله، روش پیشنهادی 3D-SSA ارائه شده است که می‌تواند به‌طور هم‌زمان از اطلاعات مکانی و محتوای طیفی تصویر ابرطیفی بهره‌برداری کند. بدین منظور، ابتدا مکعب ابرطیفی به زیرمکعب‌هایی هم‌اندازه قسمت‌بندی مکانی شده و پس‌از آن روش پیشنهادی ما به هر یک از این زیرمکعب‌ها اعمال می‌گردد. در روش پیشنهادی، با انتخاب پنجره‌ای مکعبی در مرحله تعبیه کردن، امکان اسکن کردن هم‌زمان پیکسل‌ها در ابعاد مکانی و طیفی فراهم می‌شود. نتایج طبقه‌بندی روی دو مجموعه داده ابرطیفی در دسترس عموم نشان می‌دهد که روش پیشنهادی ما عملکرد امیدوارکننده‌ای دارد به‌گونه‌ای که دقت طبقه‌بندی را در مقایسه با روش‌های جدید، حداقل ۱/۹۳٪ و ۱/۲۷٪ به ترتیب برای مجموعه داده ابرطیفی ایندیانا و دانشگاه پاویا بهبود بخشیده است.

## مراجع

- [1] L. He, J. Li, C. Liu, and S. Li, "Recent advances on spectral-spatial hyperspectral image classification: An overview and new guidelines," *IEEE Trans. Geosci. Remote Sens.*, vol. 56, no. 3, pp. 1579-1597, Mar. 2018, doi: 10.1109/TGRS.2017.2765364.
- [2] S. D. Fabiyi *et al.*, "Varietal classification of rice seeds using RGB and hyperspectral images," *IEEE Access*, vol. 8, pp 22493-22505, Jan. 2020, doi: 10.1109/ACCESS.2020.2969847.
- [3] F. Luo, B. Du, L. Zhang, L. Zhang and D. Tao, "Feature learning using spatial-spectral hypergraph discriminant analysis for hyperspectral image," *IEEE Trans. Cybern.*, vol. 49, no. 7, pp. 2406-2419, July. 2019, doi: 10.1109/TCYB.2018.2810806.
- [4] B. Kumar, O. Dikshit, A. Gupta and M.K. Singh, "Feature extraction for hyperspectral image classification: A review," *Int. J. Remote Sens.*, vol. 41, no. 16, pp. 6248-6287, Jun. 2020, doi: 10.1080/01431161.2020.1736732.
- [5] C. Zhao, X. Li, J. Ren, and S. Marshall, "Improved sparse representation using adaptive spatial support for effective target detection in hyperspectral imagery," *Int. J. Remote Sens.*, vol. 34, no. 24, pp. 8669-8684, 2013, doi: 10.1080/01431161.2013.845924.
- [6] T. Qiao *et al.*, "Effective denoising and classification of hyperspectral images using curvelet transform and singular spectrum analysis," *IEEE Trans. Geosci. Remote Sens.*, vol. 55, no. 1, pp. 119-133, Jan. 2017, doi: 10.1109/TGRS.2016.2598065.
- [7] G. Chen and S.-E. Qian, "Denoising of hyperspectral imagery using principal component analysis and wavelet shrinkage," *IEEE Trans. Geosci. Remote Sens.*, vol. 49, no. 3, pp. 973-980, Mar. 2011, doi: 10.1109/TGRS.2010.2075937.
- [8] T. Qiao *et al.*, "Joint bilateral filtering and spectral similarity-based sparse representation: A generic framework for effective feature extraction and data classification in hyperspectral imaging," *Pattern Recognit.*, vol. 77, pp. 316-328, 2018, doi: 10.1016/j.patcog.2017.10.008.
- [9] X. Kang, X. Xiang, S. Li, and J. A. Benediktsson, "PCA-based edgepreserving features for hyperspectral image classification," *IEEE Trans. Geosci. Remote Sens.*, vol. 55, no. 12, pp. 7140-7151, Dec. 2017, doi: 10.1109/TGRS.2017.2743102.
- [10] J. Zabalza, R. Jinchang, W. Zheng, S. Marshall, and W. Jun, "Singular spectrum analysis for effective feature extraction in hyperspectral imaging," *IEEE Geosci. Remote Sens. Lett.*, vol. 11, no. 11, pp. 1886-1890, Nov. 2014, doi: 10.1109/LGRS.2014.2312754.
- [11] J. Zabalza, J. Ren, Z. Wang, H. Zhao, J. Wang, and S. Marshall, "Fast implementation of singular spectrum analysis for effective feature extraction in hyperspectral imaging," *IEEE J. Sel. Topics Appl. Earth Observation Remote Sens.*, vol. 8, no. 6, pp. 2845-2853, Jun. 2015, doi: 10.1109/JSTARS.2014.2375932.
- [12] Genyun Sun, *et al.*, "SpaSSA: Superpixelwise Adaptive SSA for Unsupervised Spatial-Spectral Feature Extraction in Hyperspectral Image," *IEEE Trans. Geosci. Remote Sens.*, vol. 48, no. 11, pp. 4071-4084, Nov. 2021, doi: 10.1109/TCYB.2021.3104100.
- [13] P. R. Marpu, M. Pedernana, M. D. Mura, J. A. Benediktsson, and L. Bruzzone, "Automatic generation of standard deviation attribute profiles for spectral-spatial classification of remote sensing data," *IEEE Geosci. Remote Sens. Lett.*, vol. 10, no. 2, pp. 293-297, Mar. 2013, doi: 10.1109/LGRS.2012.2203784.
- [14] S. Jia, L. Shen, and Q. Li, "Gabor feature-based collaborative representation for hyperspectral imagery classification," *IEEE Trans. Geosci. Remote Sens.*, vol. 53, no. 2, pp. 1118-1129, Feb. 2015, doi: 10.1109/TGRS.2014.2334608.
- [15] J. Zabalza *et al.*, "Novel two-dimensional singular spectrum analysis for effective feature extraction and

- data classification in hyperspectral imaging,” *IEEE Trans. Geosci. Remote Sens.*, vol. 53, no. 8, pp. 4418–4433, Aug. 2015, doi: 10.1109/TGRS.2015.2398468.
- [16] J. Zabalza, C. Qing, P. Yuen, G. Sun, H. Zhao, and J. Ren, “Fast implementation of two-dimensional singular spectrum analysis for effective data classification in hyperspectral imaging,” *J. Franklin Inst.*, vol. 355, no. 4, pp. 1733–1751, 2018, doi: 10.1016/j.jfranklin.2017.05.020.
- [17] J. Xia, L. Bombrun, T. Adalı, Y. Berthoumieu, and C. Germain, “Spectral– spatial classification of hyperspectral images using ICA and edge-preserving filter via an ensemble strategy,” *IEEE Trans. Geosci. Remote Sens.*, vol. 54, no. 8, pp. 4971–4982, Aug. 2016, doi: 10.1109/TGRS.2016.2553842.
- [18] X. Kang, S. Li, L. Fang, and J. A. Benediktsson, “Intrinsic image decomposition for feature extraction of hyperspectral images,” *IEEE Trans. Geosci. Remote Sens.*, vol. 53, no. 4, pp. 2241–2253, Apr. 2015, doi: 10.1109/TGRS.2014.2358615.
- [19] B. Sun, X. Kang, S. Li, and J. A. Benediktsson, “Random-walker-based collaborative learning for hyperspectral image classification,” *IEEE Trans. Geosci. Remote Sens.*, vol. 55, no. 1, pp. 212–222, Jan. 2017, doi: 10.1109/TGRS.2016.2604290.
- [20] F. Samadi, G. Akbarizadeh, and H. Kaabi, “Change detection in SAR images using deep belief network: A new training approach based on morphological images,” *IET Image Process.*, vol. 13, no. 12, pp. 2255–2264, 2019, doi: 10.1049/iet-ipr.2018.6248.
- [21] F. Sharifzadeh, G. Akbarizadeh, and Y. Seifi Kaviani, “Ship classification in SAR images using a new hybrid CNN–MLP classifier,” *J. Indian Soc. Remote Sens.*, vol. 47, no. 4, pp. 551–562, 2018, doi: 10.1007/s12524-018-0891-y.
- [22] Y. Chen, Y. Wang, Y. Gu, X. He, P. Ghamisi, and X. Jia, “Deep learning ensemble for hyperspectral image classification,” *IEEE J. Sel. Topics Appl. Earth Observ. Remote Sens.*, vol. 12, no. 6, pp. 1882–1897, Jun. 2019, doi: 10.1109/JSTARS.2019.2915259.
- [23] O. Oktay *et al.*, “Anatomically constrained neural networks (ACNNs): Application to cardiac image enhancement and segmentation,” *IEEE Trans. Med. Imag.*, vol. 37, no. 2, pp. 384–395, Feb. 2018, doi: 10.1109/TMI.2017.2743464.
- [24] M. Zalpour, G. Akbarizadeh, and N. Alaei-Sheini, “A new approach for oil tank detection using deep learning features with control false alarm rate in high-resolution satellite imagery,” *Int. J. Remote Sens.*, vol. 41, no. 6, pp. 2239–2262, 2019, doi: 10.1080/01431161.2019.1685720.
- [25] X. Kang, C. Li, S. Li, and H. Lin, “Classification of hyperspectral images by gabor filtering based deep network,” *IEEE J. Sel. Topics Appl. Earth Observ. Remote Sens.*, vol. 11, no. 4, pp. 1166–1178, Apr. 2018, doi: 10.1109/JSTARS.2017.2767185.
- [26] Y. Guo, H. Cao, J. Bai, and Y. Bai, “High efficient deep feature extraction and classification of spectral-spatial hyperspectral image using cross domain convolutional neural networks,” *IEEE J. Sel. Topics Appl. Earth Observ. Remote Sens.*, vol. 12, no. 1, pp. 345–356, Jun. 2019, doi: 10.1109/JSTARS.2018.2888808.
- [27] Y. Kong, X. Wang, and Y. Cheng, “Spectral–spatial feature extraction for HSI classification based on supervised hypergraph and sample expanded CNN,” *IEEE J. Sel. Topics Appl. Earth Observ. Remote Sens.*, vol. 11, no. 11, pp. 4128–4140, Nov. 2018, doi: 10.1109/JSTARS.2018.2869210.
- [28] E. Aptoula, M. C. Ozdemir, and B. Yanikoglu, “Deep learning with attribute profiles for hyperspectral image classification,” *IEEE Geosci. Remote Sens. Lett.*, vol. 13, no. 12, pp. 1970–1974, Dec. 2016, doi: 10.1109/LGRS.2016.2619354.
- [29] L. Heming and Q. Li, “Hyperspectral imagery classification using sparse representations of convolutional neural network features,” *Remote Sens.*, vol. 8, no. 99, 2016, doi: 10.3390/rs8020099.

- [30] N. Golyandina and A. Zhigljavsky, "Singular Spectrum Analysis for Time Series," Heidelberg, Germany: Springer, 2013.
- [31] A. Shlemov, N. Golyandina, D. Holloway, and A. Spirov, "Shaped 3D Singular Spectrum Analysis for Quantifying Gene Expression with Application to the Early Zebrafish Embryo," *Hindawi Publishing Corporation. BioMed Research International*, pp. 1-15, 2015, doi: 10.1155/2015/986436.
- [32] H. Fu, G. Sun, J. Zabalza, A. Zhang, J. Ren, and X. Jia, "A novel spectral-spatial singular spectrum analysis technique for near realtime in situ feature extraction in hyperspectral imaging," *IEEE J. Sel. Topics Appl. Earth Observation Remote Sens.*, vol. 13, pp. 2214–2225, May 2020, doi: 10.1109/JSTARS.2020.2992230.
- [33] N. C. Shirazi, R. Hamzehyan, and A. Masoomi, "The Comparison of Classification Algorithms for Remote Sensing Images," *Journal of Communication Engineering.*, vol. 5, no.17, pp. 31-38, 2015, (in Persian).
- [34] F. Hajiani, N. Parhizgar, and A. Keshavarz, "Hyperspectral Image Classification Using Low Rank Representation and Spectral-Spatial Information," *Journal of Southern Communication Engineering.*, vol. 11, no.43, pp. 27-38, 2022, (in Persian).
- [35] C. Chih-Chung and L. Chih-Jen, "LIBSVM: A library for support vector machines," *ACM Trans. Intell. Syst. Technol.*, vol. 2, no. 3, pp. 1–27, 2011, doi: 10.1145/1961189.1961199.
- [36] B. Liu, X. Yu, P. Zhang, A. Yu, Q. Fu, and X. Wei, "Supervised deep feature extraction for hyperspectral image classification," *IEEE Trans. Geosci. Remote Sens.*, vol. 56, no. 4, pp. 1909–1921, Apr. 2018, doi: 10.1109/TGRS.2017.2769673.
- [37] P. Ma, J. Ren, H. Zhao, G. Sun, P. Murray, and J. Zheng, "Multiscale 2-D Singular Spectrum Analysis and Principal Component Analysis for Spatial-Spectral Noise-Robust Feature Extraction and Classification of Hyperspectral Images," *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 14, pp. 1233–1245, 2021, doi: 10.1109/JSTARS.2020.3040699.

---

#### COPYRIGHTS

©2023 by the authors. Published by the Islamic Azad University Bushehr Branch. This article is an open-access article distributed under the terms and conditions of the Creative Commons Attribution 4.0 International (CC BY 4.0) <https://creativecommons.org/licenses/by/4.0>

---

