

## Original Article



# Classification of Hyperspectral Images Using a Combination of Features Extracted From the Weighted Local Kernel Matrix of Spectral and Fractal Features

Behnam Asghari Beirami<sup>1\*</sup> and Mehdi Mokhtarzade<sup>2</sup>

## Affiliation

1. Ph.D. student of remote sensing in Department of Photogrammetry and Remote Sensing, Faculty of Geodesy and Geomatics, K. N. Toosi University of Technology, Tehran, Iran
2. Associate Professor, Department of Photogrammetry and Remote Sensing, Faculty of Geodesy and Geomatics, K. N. Toosi University of Technology, Tehran, Iran

## ABSTRACT

**Introduction:** In recent years, the use of hyperspectral imagery in various fields of Earth science, especially in remote sensing, has significantly increased due to its rich spectral information. However, the classification of these images and the extraction of useful information from them present various challenges. These challenges include the effective management of high-dimensional data and the achievement of accurate classification when the number of training samples is limited. One of the primary objectives of the remote sensing scientific community has been to improve the accuracy of image classification, thereby facilitating comprehensive investigations of surface phenomena and changes. In recent years, there has been a growing interest in the use of spatial features as a means of improving the classification accuracy of hyperspectral images. Numerous methods have been suggested for the spectral-spatial classification of hyperspectral images. Currently, research is being conducted with the objective of developing simpler yet more accurate methodologies. The existence of intricate relationships between different bands of the hyperspectral image, as evidenced by research in the field of machine vision, has prompted the development of a novel methodology in current research for modelling the complex relationships between spectral and spatial features within a hyperspectral image. The main objective of this article is to present a novel and efficient approach that combines features derived from weighted local kernel matrices of spectral and fractal characteristics for hyperspectral image classification.

**Materials and methods:** In the present research, hyperspectral images are first subjected to a dimension reduction step. Subsequently, spatial features are generated based on the directional fractal dimension, and these features are further reduced in dimension. In the subsequent stage, the novel features are derived from the weighted local kernel matrices of both the spectral and fractal feature groups. These secondary features consider nonlinear local dependencies between spectral and fractal characteristics, which were not previously considered in other feature generation methods. Ultimately, this stage serves to enhance the accuracy of the classification process. The resulting feature vectors from both groups are then merged, creating a comprehensive vector that is rich in spectral-spatial information for each pixel. Finally, the support vector machine (SVM) algorithm is employed to classify the obtained feature vector and assign labels to each pixel. The experiments conducted as part of this research were carried out on two real hyperspectral benchmark images: one depicting Indian pine and the other the University of Pavia.

**Results and discussion:** The analysis of the outcomes demonstrates the effectiveness of the proposed approach, which incorporates features derived from weighted local kernel matrices of both spectral and fractal characteristics. The classification accuracy of both the Indian Pine and University of Pavia images is enhanced by 20% and 18%, respectively, compared to the exclusive use of spectral features. These findings confirm that incorporating spatial information significantly enhances classification accuracy, particularly in scenarios with limited training samples. Furthermore, the results demonstrate that the proposed method exhibits superior accuracy compared to other studies conducted in this domain.

**Conclusion:** The enhanced performance of the proposed method in comparison to other competitors can be attributed to the incorporation of local non-linear dependencies between both spectral and fractal features, which have not been considered in previous studies. In the future, further improvements to the proposed approach are anticipated. Firstly, efforts will be made to optimise the efficiency of the proposed method in terms of processing time. Furthermore, the accuracy of the method will be enhanced by considering additional fractal features in subsequent steps. These refinements will be pursued in future research endeavours.

**Keywords:** Weighted local kernel matrix, Classification, Hyperspectral, Fractal dimension, Texture of the image

**Citation:** Asghari Beirami, B. and Mokhtarzade, M. Classification of Hyperspectral Images Using a Combination of Features Extracted From the Weighted Local Kernel Matrix of Spectral and Fractal Features. *Iran J Remote Sens GIS*. 16(2):43-64.





# طبقه‌بندی تصاویر ابرطیفی با استفاده از ترکیب ویژگی‌های مستخرج از ماتریس محلی کرنل وزن دار و ویژگی‌های طیفی و فرکتالی

بهنام اصغری بیرامی<sup>۱\*</sup> و مهدی مختارزاده<sup>۲</sup>

سمت

۱. دانشجوی دکتری سنجش از دور گروه فتوگرامتری و سنجش از دور، دانشکده ژئودزی و ژئوماتیک، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ایران

۲. دانشیار گروه فتوگرامتری و سنجش از دور، دانشکده ژئودزی و ژئوماتیک، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ایران

## چکیده

**سابقه و هدف:** در سال‌های اخیر استفاده از تصاویر ابرطیفی به دلیل غنای بالای طیفی در زمینه‌های مختلف مطالعات زمین به‌خصوص در سنجش از دور بسیار افزایش یافته است. طبقه‌بندی این تصاویر به منظور استخراج اطلاعات از آنها همواره با چالش‌هایی مختلفی همچون چگونگی مدیریت ابعاد این داده‌ها و صحت کم طبقه‌بندی در هنگام وجود تعداد محدودی از نمونه‌های آموزشی همراه است. افزایش صحت طبقه‌بندی این تصاویر با هدف مطالعات دقیق پدیده‌ها و تغییرات سطح زمین همواره از موضوعات مورد مطالعه جامعه علمی سنجش از دور بوده است. در سال‌های اخیر استفاده از ویژگی‌های مکانی به منظور افزایش صحت طبقه‌بندی تصاویر ابرطیفی بسیار رایج شده است. تاکنون روش‌های مختلفی برای طبقه‌بندی طیفی-مکانی تصاویر ابرطیفی معرفی شده است و پژوهش‌های مربوطه در راستای معرفی روش‌هایی با ساختار ساده‌تر و صحت بالاتر نیز در جریان است. به دلیل وجود رابطه‌های پیچیده میان باندهای مختلف تصویر ابرطیفی با الهام از پژوهش‌های موجود در شاخهٔ بینایی ماشین در این پژوهش روشی توسعه داده شده است که می‌تواند روابط پیچیده میان ویژگی‌های طیفی و مکانی در یک تصویر ابرطیفی را مدل‌سازی کند. هدف اصلی این مقاله ارائه روشی جدید و کارا مبتنی بر ترکیب ویژگی‌های مستخرج از ماتریس محلی کرنل وزن دار و ویژگی‌های طیفی و فرکتالی به منظور تولید ویژگی برای طبقه‌بندی تصاویر ابرطیفی است.

**مواد و روش‌ها:** به منظور طبقه‌بندی تصاویر ابرطیفی در پژوهش حاضر ابتدا یک مرحله کاهش بعد بر روی تصویر ابرطیفی انجام می‌شود. در مرحله بعد ویژگی‌های مکانی مبتنی بر بعد فرکتال جهت‌دار تولید می‌شوند و مجدداً این ویژگی‌ها کاهش بعد پیدا می‌کنند. در مرحله بعد ویژگی‌های مستخرج از ماتریس محلی کرنل وزن دار از هر دو دسته ویژگی‌های طیفی و فرکتالی تولید می‌شوند. این ویژگی‌های ثانویه وابستگی‌های محلی غیرخطی میان ویژگی‌های طیفی و فرکتالی را که در روش‌های پیشین طبقه‌بندی مورد توجه نبوده است، در فرایند تولید ویژگی لحاظ می‌کنند که در نهایت سبب افزایش صحت طبقه‌بندی می‌شوند. سپس این دو دسته بردار ویژگی جدید برای هر پیکسل با هم الصاق می‌شود و یک بردار غنی از اطلاعات طیفی-مکانی را تشکیل می‌دهد. در نهایت به منظور تعیین برجسب هر پیکسل، بردار ویژگی حاصل از الگوریتم ماشین بردار پشتیبان طبقه‌بندی می‌شود. آزمایش‌های این پژوهش بر دو تصویر مرجع ابرطیفی واقعی ایندین پاین و دانشگاه پاپوا انجام شده است.

**نتایج و بحث:** تحلیل نتایج نشان می‌دهد که روش پیشنهادی با در نظر گرفتن ویژگی‌های مستخرج از ماتریس محلی کرنل وزن دار و ویژگی‌های طیفی-فرکتالی موجب افزایش ۲۰ و ۱۸ درصدی صحت طبقه‌بندی در مقایسه با طبقه‌بندی با ویژگی‌های طیفی تنها به ترتیب در تصاویر ایندین پاین و دانشگاه پاپوا شده است. این نتیجه تأیید می‌کند که در نظر گرفتن اطلاعات مکانی به‌طور مؤثر سبب افزایش چشمگیر صحت طبقه‌بندی حتی زمانی که نمونه‌های آموزشی اندکی در دسترس باشد، می‌شود. همچنین رویکرد پیشنهادی این پژوهش در مقایسه با چندین پژوهش دیگر در این حوزه به صحت‌های بالاتری رسیده است.

**نتیجه‌گیری:** عملکرد بهتر روش پیشنهادی در مقایسه با دیگر روش‌های رقیب به دلیل در نظر گرفتن وابستگی‌های محلی غیرخطی میان ویژگی‌های طیفی و فرکتالی است که تاکنون در پژوهش‌های پیشین مورد توجه نبوده است. در پژوهش‌های آتی در نظر داریم که رویکرد پیشنهادی را در گام اول از نظر زمانی و در گام بعدی با در نظر گرفتن تعداد بیشتری از ویژگی‌های مبتنی بر هندسه فرکتال از نظر صحت بهبود دهیم.

**واژه‌های کلیدی:** ماتریس محلی کرنل وزن دار، طبقه‌بندی، ابرطیفی، بعد فرکتال، بافت تصویر

**استناد:** اصغری بیرامی، ب. و مختارزاده، م. طبقه‌بندی تصاویر ابرطیفی با استفاده از ترکیب ویژگی‌های مستخرج از ماتریس محلی کرنل وزن دار و ویژگی‌های طیفی و فرکتالی، نشریه سنجش از دور و GIS ایران، سال ۱۶، شماره ۲، تابستان ۱۴۰۳، ۴۳-۶۴.



## ۱- مقدمه

سنجنده‌های ابرطیفی انرژی الکترومغناطیسی منعکس شده یا ساطع شده از یک ناحیه را به وسیلهٔ صدها باند طیفی باریک و پیوسته از محدودهٔ طول موج قابل مشاهده تا مادون قرمز اخذ می‌کنند. تصاویر ابرطیفی عموماً به وسیلهٔ سنجنده‌هایی اخذ می‌شوند که بر روی سکوها یا هواپرد یا فضایی قرار دارند و شامل اطلاعات بسیار غنی طیفی و مکانی از پدیده‌ها و عوارض زمینی هستند. این تصاویر کاربردهای فراوانی در مطالعات محیط زیستی و پایش گیاهان و مطالعات شهری و مطالعات کشاورزی و زمین‌شناسی دارند (Gomez et al., 2008; Liu et al., 2019; Singh et al., 2020; Peyghambari and Zhang, 2021). تصاویر ابرطیفی عموماً به وسیلهٔ یک مکعب تصویری نمایش داده می‌شوند که دو بعد مسطحاتی آن شامل ابعاد تصویر اصلی و بعد سوم آن بیانگر بعد طیفی است که هر کدام از آن‌ها میزان بازتابندگی عوارض در یک باند خاص را نشان می‌دهد (Leng et al. 2016).

طبقه‌بندی تصاویر که یکی از مهم‌ترین روش‌های استخراج اطلاعات از تصاویر است، به معنی در یک گروه قرار دادن پیکسل‌های مشابه و تعیین برچسب برای هر پیکسل است. طبقه‌بندی تصاویر ابرطیفی به صورت کلاسیک بر مبنای اطلاعات طیفی پیکسل‌ها انجام می‌شود. از کنار هم قرار دادن اطلاعات طیفی در هر باند برای هر پیکسل که یک ویژگی طیفی نامیده می‌شود، بردار ویژگی طیفی به دست می‌آید. این بردار نشان‌دهندهٔ یک نقطه در یک ابرفضای فرضی با ابعادی برابر تعداد باندهای تصویری است که این ابرفضا، فضای ویژگی طیفی نام دارد. پیکسل‌هایی که در این ابرفضا در نزدیکی یکدیگر قرار می‌گیرند معمولاً نشان‌دهندهٔ یک پدیدهٔ زمینی هستند. البته به منظور افزایش صحت طبقه‌بندی، ویژگی‌های دیگری مانند ویژگی‌های مکانی و بافتی را می‌توان به بردار ویژگی طیفی هر پیکسل اضافه کرد (Beirami and Mokhtarzade, 2019). یکی از مرسوم‌ترین و ساده‌ترین روش‌های به‌کارگیری

اطلاعات مکانی در فرایند طبقه‌بندی، تولید بردارهای ویژگی جدیدی تحت عنوان بردار ویژگی‌های مکانی قبل از فرایند طبقه‌بندی و سپس چسباندن این بردارهای ویژگی به بردار ویژگی‌های طیفی به منظور تولید بردارهای ویژگی ترکیبی طیفی- مکانی است (Xu et al. 2018). از مهم‌ترین روش‌های تولید ویژگی‌های مکانی می‌توان به پروفایل‌های مورفولوژی اشاره کرد که در پژوهش‌های مختلفی به منظور طبقه‌بندی تصاویر استفاده شده‌اند (Benediktsson et al., 2005; Asghari Beirami and Mokhtarzade, 2020). به‌تازگی با گسترش مفهوم پروفایل‌های مورفولوژی، پروفایل‌های ویژگی<sup>۱</sup> با یک مکانیسم پیشرفته‌تر پیشنهاد شده‌اند. از آنجاکه می‌توان پارامترهای گوناگونی را به منظور تولید این ویژگی‌ها استفاده کرد می‌توان به پروفایل‌های ویژگی گسترده‌شده<sup>۲</sup> رسید (Cavallaro et al., 2015; Falco et al., 2015). در این راستا، دوآن و همکاران (۲۰۲۰) یک استراتژی دوگانهٔ مکانی را به منظور طبقه‌بندی تصاویر ابرطیفی توسعه دادند که در آن از پروفایل‌های ساختاری<sup>۳</sup> و روش بهینه‌سازی مکانی واکر تصادفی<sup>۴</sup> توسعه‌یافته استفاده شده است (Duan et al., 2020). اما ویژگی‌های مکانی در پروفایل مورفولوژی خلاصه نمی‌شود و ویژگی‌های مکانی دیگری نیز وجود دارد. دسته‌ای دیگر از ویژگی‌های مکانی به نام فیلتر گابور در پژوهش دیگری به منظور افزایش صحت طبقه‌بندی تصاویر ابرطیفی از مناطق شهری استفاده شده است (Beirami and Mokhtarzade, 2019). علاوه‌بر ویژگی‌های گابور از اطلاعات مکانی مبتنی بر موجک نیز در کنار اطلاعات طیفی به منظور طبقه‌بندی تصاویر سنجنش از دور استفاده شده است (Kumar and Dikshit, 2015). در این راستا از مؤلفه‌های موجک سه‌بعدی که به طور هم‌زمان هم اطلاعات طیفی و هم

1. attribute profiles
2. extended attribute profiles
3. Structural profiles
4. extended random walker

چین که دارای پیچیدگی‌های زیادی است، با موفقیت استفاده شده است (Zhu et al., 2011). همچنین در پژوهش مهدی و حسن از بعد فرکتال برای طبقه‌بندی نظارت‌شده تصاویر با قدرت تفکیک مکانی بالا QuickBird استفاده شده است و نتایج نهایی نشان از این موضوع دارد که بعد فرکتال عملکردی مطلوب در طبقه‌بندی کلاس‌های مختلف تصویر دارد (Mahdi and Hassan, 2016). همچنین در پژوهشی جامع‌تر، بیرامی و مختارزاده از چندین ویژگی فرکتالی مانند بعد فرکتال، Lacunarity<sup>۴</sup> و چند فرکتال<sup>۴</sup> در ترکیب با ویژگی‌های طیفی برای طبقه‌بندی تصاویر ابرطیفی استفاده کردند و به نتایج مطلوبی بر روی تصاویر مرجع ابرطیفی رسیدند (Beirami and Mokhtarzade, 2022). علاوه بر روش‌های کلاسیک تولید ویژگی‌های بافتی و مکانی که ذکر شد، در چند سال اخیر مدل‌های مبتنی بر هندسه منیفلد<sup>۵</sup> مانند ویژگی‌های ماتریس کوواریانس نیز ابتدا در حوزه بینایی ماشین و سپس در سنجش از دور ابرطیفی مورد توجه قرار گرفته‌اند. منطق اصلی این روش‌ها بر این اصل استوار است که ماتریس کوواریانس تولیدشده از ویژگی‌های تصویری حاوی اطلاعاتی غنی است که دقت شناسایی عوارض و طبقه‌بندی تصویر را بالا می‌برد. مزیت اصلی به‌کارگیری این روش در مقایسه با روش‌های کلاسیک، صحت طبقه‌بندی بالاتر، پردازش سریع‌تر و نتایج مطلوب طبقه‌بندی در هنگام وجود نمونه‌های آموزشی محدود است. ویژگی‌های مبتنی بر ماتریس کوواریانس را نخستین بار توژل و همکاران (۲۰۰۶) به‌منظور شناسایی اشیاء و طبقه‌بندی تصاویر بافتی معرفی کردند (Tuzel et al., 2006). از ماتریس کوواریانس با ورودی‌های ضرایب گابور در چندین پژوهش به‌منظور

اطلاعات مکانی را در نظر می‌گیرند برای طبقه‌بندی تصاویر ابرطیفی استفاده شده است، هرچند سطح صحت حاصل‌شده قابل رقابت با الگوریتم‌های پیشرفته‌تر طبقه‌بندی طیفی- مکانی نیست (Anand, Veni et al., 2021). به‌تازگی از گشتاورهای هندسی نیز به‌منظور افزایش صحت طبقه‌بندی تصاویر ابرطیفی استفاده شده است. در این روش ابتدا از مؤلفه‌های اصلی تصویر ابرطیفی اطلاعات مومنت هندسی استخراج می‌شود و سپس همراه با اطلاعات طیفی برای طبقه‌بندی به ماشین بردار پشتیبان (SVM)<sup>۱</sup> داده می‌شوند (Kumar and Dikshit, 2015). از ادغام چندین ویژگی مکانی با ویژگی‌های طیفی در پژوهش‌های گوناگونی استفاده شده است. مثلاً از ویژگی‌های مکانی مبتنی بر گابور، ماتریس هم‌رخداد و مورفولوژی در کنار ویژگی‌های طیفی در پژوهش میرزاپور و قاسمیان (۲۰۱۵) برای افزایش صحت طبقه‌بندی تصاویر ابرطیفی استفاده شده است (Mirzapour and Ghassemian, 2015). این ویژگی‌های مکانی پس از استخراج از مؤلفه اصلی اول تصاویر ابرطیفی در ترکیب‌های گوناگونی با اطلاعات طیفی به طبقه‌بندی‌کننده SVM تزریق شدند.

یکی از انواع روش‌های استخراج ویژگی‌های مکانی، ویژگی‌های مبتنی بر هندسه فرکتال است. عملکرد این نوع ویژگی‌ها به‌منظور طبقه‌بندی تصاویر ابرطیفی کمتر مورد توجه پژوهشگران قرار گرفته است. توانایی ویژگی‌های فرکتالی در مدل‌سازی بافت تصویر در قالب پیچیدگی‌های محلی می‌تواند کمک شایان توجهی به افزایش صحت طبقه‌بندی تصاویر ابرطیفی کند. یکی از اصلی‌ترین ویژگی‌های مبتنی بر هندسه فرکتال در پردازش تصاویر ویژگی بعد فرکتال<sup>۲</sup> است که به‌عنوان معیاری برای کمی‌سازی پیچیدگی‌های محلی<sup>۳</sup> به حساب می‌آید (Myint 2003). در همین راستا، در پژوهش ژو و همکاران از ترکیب بعد فرکتال تولیدشده از مؤلفه‌های اصلی تصویر لندست ETM+ و باندهای طیفی به‌منظور طبقه‌بندی نواحی کوهستانی در کشور

1. Support Vector Machine
2. fractal dimension
3. local complexity
4. multifractal
5. Manifold

پس از انجام استخراج ویژگی به کمک روش MNF، از روش نرخ آنتروپی برای تولید نقشه‌های سوپرپیکسلی استفاده می‌شود و از پیکسل‌های موجود در هر سوپرپیکسل، ماتریس‌های کوواریانس تولید می‌شود (Ahmadi and Mehrshad, 2022). علاوه بر پژوهش‌های یادشده در چند سال گذشته تلاش‌هایی به منظور افزایش کارایی شبکه‌های عصبی عمیق با استفاده از روش کوواریانس انجام شده است (Feng et al., 2022). در این راستا به‌عنوان یک پژوهش شاخص، ژنگ و همکاران (۲۰۲۱) روشی بر مبنای یادگیری عمیق توسعه دادند که در آن از لایه‌های ادغام<sup>۳</sup> کوواریانسی به منظور ترکیب ویژگی‌های طیفی- مکانی عمیق استفاده شده است (Zheng et al., 2020).

یکی از نقاط ضعف اصلی ماتریس محلی کوواریانس این است که اساساً اطلاعاتی در مورد وابستگی‌های غیرخطی نمی‌دهد، از این رو در گامی فراتر، وانگ و همکاران (۲۰۱۵) با معرفی مفهوم ماتریس کرنل<sup>۴</sup> که قادر به کمی‌سازی آماره‌های مرتبه بالا و وابستگی‌های غیرخطی است به دقت‌های قابل قبولی در موضوع شناسایی رفتارهای انسان و طبقه‌بندی اشیاء رسیدند (Wang et al., 2015). گفتنی است که به‌رغم عملکرد مطلوب ماتریس کرنل این مفهوم کمتر در پردازش داده‌های ابرطیفی مورد توجه قرار گرفته است.

با توجه به توانایی ماتریس کرنل در کمی‌سازی وابستگی‌های غیرخطی، به نظر می‌رسد که این روش بهتر می‌تواند روابط پیچیده میان باندهای یک تصویر ابرطیفی را مدل کند. در رویکرد کلاسیک به منظور طبقه‌بندی طیفی- مکانی تصاویر ابرطیفی در مرحله اول دو دسته ویژگی‌های طیفی و مکانی به صورت مجزا تولید می‌شوند و سپس بردارهای ویژگی تولیدشده به یکدیگر الصاق شده، نتایج نهایی طبقه‌بندی به کمک

شناسایی دقیق چهره استفاده شده است (Pang et al., 2008; Qin et al., 2012). در سنجش از دور ابرطیفی به‌عنوان پژوهش اولیه، فانگ و همکاران (۲۰۱۸) روش ماتریس محلی کوواریانس را برای طبقه‌بندی تصاویر توسعه دادند (Fang et al., 2018). در این روش ابتدا، ماتریس‌های محلی کوواریانس از ویژگی‌های کاهش بعدیافته کسر نویز کمینه (MNF)<sup>۱</sup> در اطراف هر پیکسل محاسبه شده، سپس این ماتریس‌ها که به‌عنوان توصیفگر پیکسل مرکزی پنجره در نظر گرفته می‌شدند به منظور طبقه‌بندی به طبقه‌بندی‌کننده SVM با کرنل لگاریتم- اقلیدسی داده شد. پس از این پژوهش موضوع استفاده از ویژگی‌های مبتنی بر ماتریس کوواریانس در طبقه‌بندی تصاویر ابرطیفی مورد توجه قرار گرفت. یکی از مهم‌ترین مزیت‌های این روش‌ها پیچیدگی محاسباتی کم و صحت بسیار مطلوب در هنگام وجود نمونه‌های آموزشی بسیار کم است. در پژوهش دیگری که به‌تازگی منتشر شده است از ماتریس‌های کوواریانس چندمقیاسی در کنار طبقه‌بندی‌کننده شبکه عصبی عمیق پیچشی به منظور طبقه‌بندی تصاویر ابرطیفی استفاده شده است (He et al. 2018). سان و همکاران (۲۰۱۹) مدلی دوشاخه را به منظور طبقه‌بندی تصاویر ابرطیفی توسعه دادند که در شاخه اول ویژگی مکانی چندمقیاسی با استفاده از مدل نواحی تصادفی استخراج می‌شود و در شاخه دوم ویژگی‌های ماتریس محلی کوواریانس تولید می‌شود. در نهایت نیز از SVM برای طبقه‌بندی ویژگی‌های ترکیبی استفاده می‌شود (Sun et al., 2019). در روشی پیشرفته‌تر یانگ و همکاران (۲۰۱۹) از ماتریس‌های محلی کوواریانس که از پروفایل‌های ویژگی توسعه یافته تولید می‌شوند در کنار روش نمایش تنک مشترک مبتنی بر هسته لگاریتم اقلیدسی<sup>۲</sup> به منظور طبقه‌بندی تصاویر ابرطیفی استفاده کردند (Yang et al., 2019). در پژوهشی جدیدتر احمدی و مهرشاد (۲۰۲۲) روشی چندمقیاسی مبتنی بر سوپرپیکسل‌ها و ماتریس‌های کوواریانس را به منظور طبقه‌بندی تصاویر ابرطیفی ارائه کردند که در این روش

1. Minimum Noise Fraction
2. Log-euclidean kernel-based joint sparse representation
3. pooling layers
4. Kernel matrix representation



بعد فرکتال جهت‌دار، ماتریس محلی کرنل وزن‌دار و الگوریتم طبقه‌بندی SVM، روش طبقه‌بندی ارائه شده معرفی می‌شود. اطلاعات مجموعه داده‌های مورد استفاده در این پژوهش در بخش ۳ آورده شده است. بخش ۴ به نتایج تجربی و مقایسه‌ها اختصاص دارد. در نهایت در بخش ۵ این مقاله جمع‌بندی و نتیجه‌گیری نهایی پژوهش انجام می‌شود.

## ۲- روش پژوهش

در این قسمت پس از مروری بر مفاهیم بعد فرکتال جهت‌دار، ماتریس محلی کرنل وزن‌دار و الگوریتم طبقه‌بندی SVM، روش طبقه‌بندی پیشنهادی تشریح شده است.

### ۲-۱- بعد فرکتال جهت‌دار

معمولاً از روش پنتلند<sup>۱</sup> برای به دست آوردن ویژگی‌های بعد فرکتال جهت‌دار استفاده می‌شود (Zhu et al., 2011). در این روش، تغییرات درجه خاکستری در ناحیه مجاور هر پیکسل به‌منظور محاسبه بعد فرکتال در نظر گرفته می‌شود. در روش پنتلند یک پنجره متحرک به ابعاد  $L \times L$  از اطراف هر پیکسل تصویر در نظر گرفته می‌شود. در مرحله بعدی پارامتر رندوم  $r$  در محدوده  $r \in (0, L)$  در یک راستای خاص با استفاده از رابطه  $r = b - a$  محاسبه می‌شود ( $0 < a < b \leq L$ ). سپس پارامتر  $e_r$  از رابطه زیر محاسبه می‌شود:

$$e_r = \frac{|S_b - S_a|}{r} + 1 \quad \text{رابطه (۱)}$$

که در عبارت فوق  $S_a$  و  $S_b$  درجه خاکستری پیکسل‌ها در فاصله  $r$  از یکدیگر در یک راستای خاص است. مقدار میانگین پارامتر  $e_r$  در پنجره با در نظر گرفتن مقادیر مختلف برای  $a$  به صورت زیر محاسبه می‌شود:

$$\bar{e}_r = \frac{\sum_{a=0}^{L-r} e_r}{L-r+1} \quad \text{رابطه (۲)}$$

#### 1. Pentland Method

طبقه‌بندی‌کننده‌های مانند SVM تولید می‌شود. در این رویکرد وابستگی‌های محلی میان هریک از ویژگی‌ها در فرایند طبقه‌بندی لحاظ نمی‌شود. این در حالی است که بنابر پیشینه پژوهش مشارکت دادن اطلاعات وابستگی محلی ویژگی‌ها در فرایند طبقه‌بندی تصاویر ابرطیفی موجب افزایش صحت طبقه‌بندی می‌شود (Fang et al., 2018). به عبارت دیگر، استفاده از ویژگی‌های مستخرج از ماتریس محلی کرنل که از ویژگی‌های طیفی یا مکانی به دست می‌آید به تولید ویژگی‌هایی بهتر از ویژگی‌های طیفی و مکانی اصلی منجر می‌شود و به تبع آن استفاده از آنها نتایج طبقه‌بندی بهتری را به همراه دارد. دلیل این پدیده این است که ویژگی‌های مستخرج از ماتریس محلی کرنل می‌تواند وابستگی‌های غیرخطی بین ویژگی‌ها را مدل کند که در ویژگی‌های طیفی و مکانی اصلی در نظر گرفته نمی‌شود. توانایی بالای ویژگی‌های بعد فرکتال در مدل‌سازی پیچیدگی‌های محلی از یک سو و عملکرد مناسب ویژگی‌های مستخرج از ماتریس محلی کرنل، از سوی دیگر انگیزه اصلی این پژوهش را به وجود آورد تا روش جدیدی پیشنهاد شود که از ترکیب ویژگی‌های مستخرج از ماتریس محلی کرنل از هر دو ویژگی طیفی و فرکتالی استفاده می‌کند. مشارکت‌های عمده در این مقاله شامل دو جنبه اصلی زیر است:

- در این پژوهش با استفاده از مفهوم ماتریس محلی کرنل وزن‌دار و ویژگی‌های بعد فرکتال جهت‌دار روشی جدید به‌منظور تولید ویژگی‌های مکانی معرفی شده است که در پژوهش‌های پیشین مورد توجه نبوده است.

- در این پژوهش به‌منظور تولید یک بردار ویژگی ترکیبی از اطلاعات طیفی- مکانی برای اولین بار بردار ویژگی‌های مستخرج از ماتریس محلی کرنل وزن‌دار از اطلاعات طیفی و فرکتالی با یکدیگر الصاق می‌شود و یک بردار غنی اطلاعات به‌منظور طبقه‌بندی تصاویر ابرطیفی را تشکیل می‌دهد.

ساختار مقاله به شرح زیر تنظیم شده است. در بخش ۲ پس از مرور مختصر روش تولید ویژگی‌های

در نهایت پارامتر  $E_r$  به صورت زیر محاسبه می‌شود:

$$E_r = e_r \frac{L}{r} \quad \text{رابطه (۳)}$$

با معلوم بودن  $E_r$  و  $r$ ، در مرحله بعدی میان پارامترهای  $\log(E_r)$  و  $\log(r)$  رابطه زیر برقرار است:

$$\log(E_r) - H \times \log(r) = C_0 \quad \text{رابطه (۴)}$$

در معادله بالا پارامتر  $H$  و  $C_0$  را می‌توان به عنوان شیب و عرض از مبدأ رگرسیون خطی میان  $\log(E_r)$  و  $\log(r)$  محاسبه کرد. در نهایت بعد فرکتال با رابطه زیر تعیین می‌شود:

$$\text{fractal dimension} = 1 - H \quad \text{رابطه (۵)}$$

از آنجا که این روش یک روش جهت‌دار محاسبه بعد فرکتال است، چهار جهت مختلف از شمال، جنوب، شمال غرب به جنوب شرق و شمال شرق به جنوب غرب در نظر گرفته می‌شود که به مقادیر مختلفی برای بعد فرکتال منجر می‌شود. به عبارت دیگر در این پژوهش هر باند تصویر ورودی به تولید چهار ویژگی بعد فرکتال در یک ابعاد خاص پنجره در چهار جهت مذکور منجر می‌شود. به طور کلی، ابعاد پنجره یادشده به ابعاد کلاس‌های موجود در تصویر وابسته است. از آنجا که در یک تصویر ابرطیفی کلاس‌های موجود عموماً دارای ابعاد گوناگون هستند، در این پژوهش همانند پژوهش (Beirami and Mokhtarzade, 2022)، به جای استفاده از یک پنجره با ابعاد خاص برای تولید ویژگی‌های فرکتالی از پنجره‌هایی با ابعاد برابر با  $11 \times 11$ ،  $17 \times 17$ ،  $23 \times 23$ ،  $33 \times 33$ ،  $41 \times 41$  استفاده شده است. این روش سبب در نظر گرفتن ویژگی‌های بعد فرکتال جهت‌دار در مقیاس‌های مختلف می‌شود و به شدت صحت طبقه‌بندی را افزایش می‌دهد (Beirami and Mokhtarzade, 2022).

## ۲-۲- ویژگی‌های مستخرج از ماتریس محلی کرنل وزن‌دار

همان‌طور که پیش‌تر عنوان شد، روش ماتریس محلی کوواریانس اطلاعاتی درباره وابستگی‌های غیرخطی که

در طبقه‌بندی تصاویر ابرطیفی مفیدند، نمی‌دهد. از نظر ریاضی اثبات می‌شود که ماتریس کوواریانس را می‌توان به صورت یک تابع کرنل خطی بازنویسی کرد (Wang et al., 2015). از آنجا که پیچیدگی میان ویژگی‌ها در تصاویر ابرطیفی زیاد است و به نظر نمی‌رسد که تابع کرنل خطی مانند کوواریانس بتواند ارتباط و وابستگی میان ویژگی‌ها را به‌طور کامل و مطلوب مدل کند. بنابراین با توجه به پیشینه پژوهش و عملکرد مطلوب روش‌های تولید ویژگی بر مبنای کرنل‌های غیرخطی در حوزه بینایی ماشین، به نظر می‌رسد که استفاده از توابع کرنل غیرخطی به جای کرنل خطی مانند کوواریانس موجب تولید ویژگی‌های بهتری به‌منظور طبقه‌بندی تصاویر ابرطیفی شود. همچنین استفاده از روش ماتریس کرنل که ماتریس کوواریانس را می‌توان حالت خاصی از آن در نظر گرفت، موجب می‌شود که آزادی عمل بیشتری در استفاده از کرنل‌های مختلف وجود داشته باشد که هر کدام می‌تواند از جنبه خاصی روابط میان ویژگی‌ها را مدل کند (Wang et al., 2015). در این مقاله از کرنل تابع پایه شعاعی (RBF) که یک کرنل غیرخطی است و عملکردی مناسب‌تر از بقیه کرنل‌ها برای استخراج ویژگی‌های محلی دارد، استفاده شده است.

در نظر بگیرید  $X_1$  و  $X_2$  و  $X_3$  و ...  $X_L$  هر کدام بردارهای نمایش‌دهنده درجات خاکستری مجموعه پیکسل‌ها در یک پنجره فرضی با ابعاد  $L=L \times L$  که  $L$  تعداد کل پیکسل‌های پنجره است) اطراف هریک از پیکسل‌های تصویر باشد ( $M \times M = X_i$  و  $M$  تعداد باندها 1)، هر کدام از درایه‌های ماتریس کرنل  $\kappa(i, j)$  با ابعاد  $M \times M$  میان دو باند  $i$  و  $j$  در ادامه با استفاده از کرنل تابع پایه شعاعی به صورت زیر محاسبه می‌شود (Wang et al., 2015):

$$\kappa(i, j) = \exp(-\beta \|X_i - X_j\|^2) \quad \text{رابطه (۶)}$$


### 1. Radial Basis Function

برای هر پیکسل طی عملیاتی که خطی‌سازی نامیده می‌شود، عناصر مثلث قطر اصلی و مثلث بالایی (یا پایینی) رابطه (۱۰) در کنار یکدیگر قرار می‌گیرند. به‌طور کلی مجموع ویژگی‌های استخراج‌شده برابر  $\frac{M \times (M+1)}{2}$  است که در آن M تعداد باندهای تصویری است.

### ۳-۲- روش طبقه‌بندی SVM

طبقه‌بندی‌کننده SVM یک روش نظارت‌شده و غیرآزمای طبقه‌بندی است که دارای عملکردی مطلوب در مواجهه با داده‌هایی با ابعاد بالاست (Beirami and Mokhtarzade, 2017). یک مسئله طبقه‌بندی باینری را در نظر بگیرید که در آن داده‌ها فقط به دو کلاس اطلاعاتی تعلق دارند. SVM از یک منطق هندسی به‌منظور تفکیک‌پذیری کلاس‌ها استفاده می‌کند که در آن حاشیه<sup>۲</sup> میان دو کلاس به بیشترین حد خود می‌رسد. P داده آموزشی را به‌صورت  $(X_1, Y_1), (X_2, Y_2), \dots, (X_p, Y_p)$  در نظر بگیرید که در آن  $X_i$  یک بردار N بعدی نشان‌دهنده N ویژگی طیفی-مکانی و  $Y_i$  برچسب کلاس‌ها به‌صورت ۱ یا -۱ است. الگوریتم SVM سعی در پیدا کردن ابرصفحه‌ای دارد که خط میان آن و نزدیک‌ترین داده آموزشی بیشینه شود (شکل ۱). این ابرصفحه به‌وسیله تابع تصمیم‌گیری زیر نشان داده می‌شود (Beirami and Mokhtarzade, 2017):

$$f(x) = w \cdot x + b \quad \text{رابطه (۱۱)}$$



شکل ۱. طبقه‌بندی‌کننده SVM و روش بیشینه کردن حاشیه<sup>۲</sup>

1. positive defined
2. Margin
3. <https://emilemathieu.fr/posts/2018/08/svm/>

به‌منظور سادگی و با استفاده از روش سعی‌وخطا در ادامه مقدار پارامتر  $\beta$  برابر با یک در نظر گرفته شده است. از آنجاکه روش ارائه‌شده یک پنجره میناست و به‌صورت معمول هر چه از پیکسل مرکزی پنجره فاصله گرفته می‌شود احتمال دارد شباهت پیکسل‌های پنجره و پیکسل مرکزی کاهش یابد، می‌توان معادله (۶) را طوری اصلاح کرد که وزن پیکسل‌ها با توجه به فاصله آنها از پیکسل مرکزی در محاسبه  $\kappa(i, j)$  لحاظ شود. اگر مرکز سیستم مختصات روی پیکسل مرکزی پنجره  $I \times I$  قرار گرفته باشد، وزن هر پیکسل در پنجره با مختصات  $(c, r)$  با رابطه (۸) به شرح زیر محاسبه می‌شود:

$$R = \sqrt{r^2 + c^2} \quad \text{رابطه (۷)}$$

$$\text{weight}(r, c) = \frac{1}{(R+1)} \quad \text{رابطه (۸)}$$

۱ در مخرج رابطه (۸) برای اجتناب از بی‌نهایت شدن وزن در پیکسل مرکزی پنجره اعمال شده است. اگر بردار وزن پیکسل‌ها در پنجره با  $W$  نشان داده شود، نسخه وزن دار معادله (۶) با در نظر گرفتن  $\beta = 1$  با معادله (۹) نشان داده می‌شود:

$$\kappa(i, j) = \exp(-\|Wy_i - Wy_j\|^2) \quad \text{رابطه (۹)}$$

رابطه (۹) بیانگر هر المان ماتریس محلی کرنل وزن دار است و ماتریس محلی کرنل به‌صورت کلی با رابطه (۱۰) نمایش داده می‌شود:

$$K = \begin{bmatrix} \kappa(1,1) & \dots & \kappa(1,M) \\ \vdots & \ddots & \vdots \\ \kappa(M,1) & \dots & \kappa(M,M) \end{bmatrix} \quad \text{رابطه (۱۰)}$$

می‌توان به‌منظور تولید ماتریس مثبت تعریف<sup>۱</sup> از ماتریس K از روش‌های مقیدسازی استفاده کرد. در ادامه به‌منظور تولید ویژگی‌هایی با کیفیت بالاتر از عملگر لگاریتم ماتریس کرنل استفاده می‌شود. اگر تجزیه مقادیر ویژه ماتریس K با  $K = U \Sigma U^T$  نشان داده شود، عملگر لگاریتم  $\log_m(K) = U \log(\Sigma) U^T$  را می‌توان با (Fang et al., 2018). پس از محاسبه لگاریتم ماتریس کرنل به‌منظور تولید بردار ویژگی نهایی



بردار ویژگی ترکیبی تولیدشده دارای اطلاعات غنی طیفی- مکانی که وابستگی‌های غیرخطی میان ویژگی‌ها را در نظر می‌گیرد و این امر می‌تواند به صحت‌های بالایی در طبقه‌بندی تصاویر ابرطیفی منجر شود. شکل ۲ روندنمای کلی روش پیشنهادی را نشان می‌دهد.

به‌طور کلی روش ارائه‌شده، دارای شش مرحله به شرح زیر است:

۱. در ابتدا به کمک تبدیل کسر نويز کمینه ابعاد تصویر ابرطیفی اصلی کاهش پیدا می‌کند و بیست مؤلفه اول MNF را در نظر می‌گیریم.

۲. از سه مؤلفه اول MNF ویژگی‌های بعد فرکتال در چهار جهت در پنجره‌هایی با ابعاد مختلف تولید می‌شود. سپس بر روی این ویژگی‌ها مجدداً تبدیل MNF اعمال می‌شود و ۲۰ مؤلفه اول آن انتخاب می‌شود.

۳. در مرحله بعد ماتریس‌های محلی کرنل وزن‌دار (رابطه ۱۰) با در نظر گرفتن یک مقدار معین ابعاد پنجره برای هر دو دسته ویژگی طیفی و فرکتالی تولید و سپس لگاریتم آن ماتریس‌ها محاسبه می‌شود.

۴. در این مرحله عملیات خطی‌سازی خروجی لگاریتم ماتریس‌های محلی وزن‌دار انجام می‌شود. عملیات خطی‌سازی شامل انتخاب مؤلفه‌های قطر اصلی و درایه‌های مثلث بالایی (یا پایینی) ماتریس لگاریتم و تشکیل بردار ویژگی از آن‌هاست.

۵. در نهایت هر دو دسته بردار ویژگی با یکدیگر الصاق می‌شود و یک بردار غنی از اطلاعات طیفی- مکانی تشکیل می‌دهد.

۶. بردارهای ترکیبی تولیدشده در نهایت به کمک طبقه‌بندی‌کننده SVM طبقه‌بندی و ارزیابی نهایی به کمک نمونه‌های آزمون انجام می‌شود.

از آنجاکه بردار ویژگی ترکیبی تولیدشده در بردارنده اطلاعات وابستگی غیرخطی میان ویژگی‌هاست انتظار می‌رود که نتایج صحت طبقه‌بندی بهتر از رویکرد کلاسیک ادغام اطلاعات طیفی- مکانی باشد.

که در رابطه (۱۱)،  $x$  یک نقطه روی ابرصفحه،  $w$  یک بردار  $N$  بعدی عمود بر ابرصفحه و  $b$  بایاس است. فاصله عمودی از ابرصفحه تا مرکز با  $\|w\|/\|b\|$  نمایش داده می‌شود که در این  $\|w\|$  نرم اقلیدسی  $w$  است. سطح تصمیم‌گیری بهینه به وسیله پاسخ دادن به مسئله بهینه‌سازی مقید زیر به دست می‌آید (Beirami and Mokhtarzade, 2017):

$$\text{رابطه (۱۲)} \quad \text{کمینه‌سازی: } \frac{1}{2} \|w\|^2$$

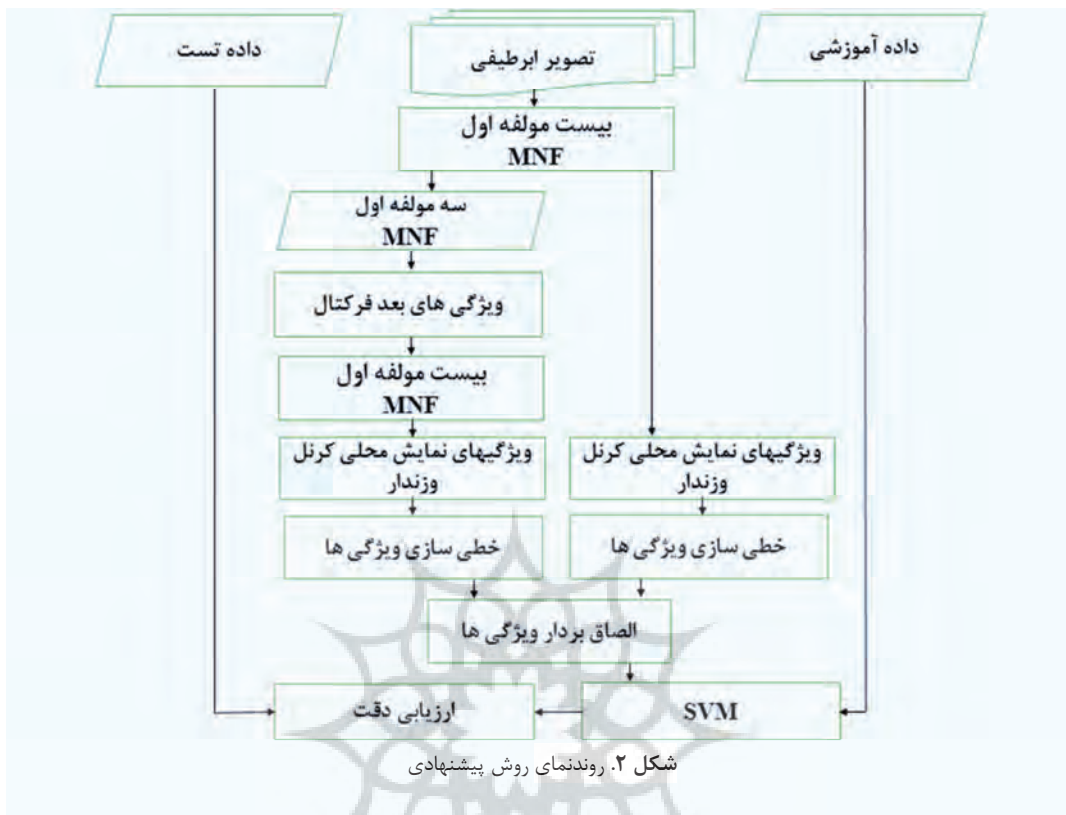
$$\text{نسبت به: } yi(wx_i + b) \geq 1$$

به‌منظور حل مسئله بهینه‌سازی فوق از روش ضرایب لاگرانژ استفاده می‌شود. برای اطلاعات جامع‌تر درباره الگوریتم SVM می‌توان به پژوهش بیرامی و مختارزاده مراجعه کرد (Beirami and Mokhtarzade, 2017). در حالت پایه طبقه‌بندی‌کننده SVM مخصوص تفکیک دو کلاس اطلاعاتی است، اما با استفاده از روش‌های «یک- در برابر- همه»<sup>۱</sup> و «یک- در برابر- یک»<sup>۲</sup> می‌توان از آن را برای مسائل طبقه‌بندی چندکلاسه استفاده کرد (Kallas, Francis et al., 2012). همچنین در نسخه پیشرفته‌تر از الگوریتم SVM به‌منظور حل مسائل طبقه‌بندی غیرخطی می‌توان از روش حقه کرنل<sup>۳</sup> استفاده کرد (Beirami and Mokhtarzade, 2017). در این روش فضای ویژگی اولیه به فضایی با ابعاد بالاتر منتقل می‌شود که در این فضای ثانویه پیکسل‌ها به‌طور خطی تفکیک پذیرند. نسخه کرنلی SVM به‌دلیل عملکرد مطلوب در طبقه‌بندی داده‌های با تعداد ویژگی زیاد (مانند تصاویر ابرطیفی) همواره یکی از الگوریتم‌های پرکاربرد در طبقه‌بندی تصاویر ابرطیفی است که مروری بر مهم‌ترین پژوهش‌های مربوطه را می‌توان در مقاله کال و راینا (۲۰۲۲) یافت (Kaul and Raina, 2022).

#### ۴-۲- روش پیشنهادی

همان‌طور که عنوان شد نوآوری اصلی مقاله حاضر مبتنی بر ادغام ویژگی‌های مستخرج از ماتریس محلی کرنل وزن‌دار تولیدشده از ویژگی‌های طیفی و فرکتالی است.

1. one against all  
2. one against one  
3. Kernel trick



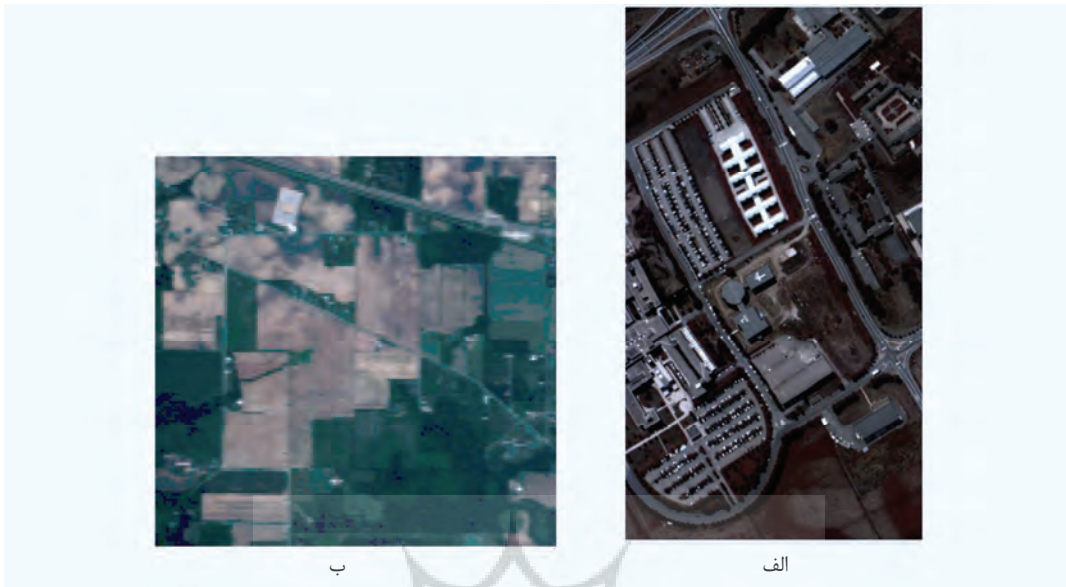
### ۳- معرفی داده‌ها

این‌دین پابین: این تصویر توسط سنجنده هوابرد AVIRIS از شمال غربی این ایندیانا در سال ۱۹۹۲ تهیه شده است. تصویر اصلی دارای ۲۲۴ باند طیفی در محدوده ۰/۴ تا ۲/۵ میکرومتر است که پس از کنار گذاشتن ۲۴ باند نویزی از ناحیه جذبی بخار آب از بقیه باندها در آنالیزها استفاده می‌شود. این تصویر دارای قدرت تفکیک طیفی ۱۰ نانومتر و قدرت تفکیک مکانی ۲۰ متر است و دارای ۱۴۵×۱۴۵ پیکسل است. نقشه واقعیت زمینی<sup>۱</sup> این تصویر دارای ۱۶ کلاس عمدتاً از نوع کشاورزی است که نام آنها و تعداد نمونه هر کلاس در جدول ۱ نمایش داده شده است. وجود کلاس‌هایی با تعداد نامتقارن نمونه برچسب‌دار و پیکسل‌های مخلوط و ابهامات طیفی میان کلاس‌های مختلف کار

طبقه‌بندی این تصویر را با چالش‌های فراوانی مواجه می‌کند. نمونه‌ای از ترکیب رنگی این تصویر در شکل ۳الف آمده است.

دانشگاه پاپویا: این تصویر به کمک سنجنده ROSIS-3 از منطقه شهری دانشگاه پاپویا در شمال ایتالیا در هشتم ژوئن ۲۰۰۲ تهیه شده است. تصویر اصلی دارای ۱۱۵ باند طیفی در محدوده ۰/۴۳ تا ۰/۸۶ میکرومتر است که ۱۲ باند آن نویزی بوده که پس از حذف این باندها از ۱۰۳ باند باقی‌مانده در ادامه پژوهش استفاده شده است. قدرت تفکیک مکانی این تصویر ۱/۳ متر است و دارای ابعاد ۶۱۰×۳۴۰ است. این تصویر دارای ۹ کلاس شهری است که نام آنها و تعداد نمونه هر کلاس در جدول ۲ و نمونه‌ای از ترکیب رنگی این تصویر در شکل ۳ب نشان داده شده است.

1. ground truth



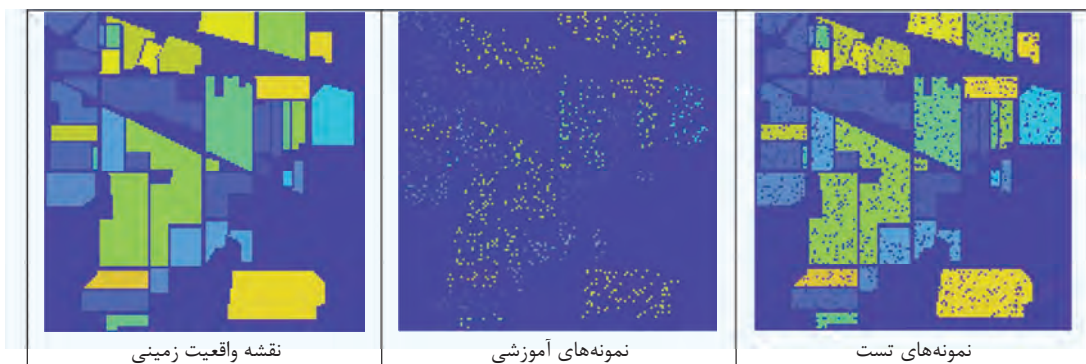
شکل ۳. تصویر ترکیب رنگی. (الف) ایندین پایین (باند ۲۹ رنگ قرمز، باند ۱۵ رنگ سبز و باند ۱۲ رنگ آبی)؛ (ب) داده دانشگاه پاویا (باند ۲۷ رنگ قرمز، باند ۱۹ رنگ سبز و باند ۱۰ رنگ آبی)

#### ۴- تحلیل نتایج

پیشین به صورت نقطه‌ای و تصادفی<sup>۱</sup> است (Fang et al., 2018; Beirami and Mokhtarzade, 2022). تصاویر مربوط به نقشه واقعی زمینی و نقشه پراکندگی نمونه‌های آموزشی و تست برای دو داده ایندین پایین و دانشگاه پاویا به ترتیب در شکل‌های ۴ و ۵ نمایش داده شده است. همچنین نام کلاس‌های موجود و تعداد نمونه‌ها برای هر دو داده نیز در جدول‌های ۱ و ۲ ارائه شده است. برای طبقه‌بندی از روش SVM کرنلی استفاده می‌شود و پارامترهای کرنل به کمک روش اعتبارسنجی متقاطع برآورد می‌شود. به منظور ارزیابی نهایی نیز از چهار معیار مستخرج از ماتریس ابهام با نام‌های دقت کلی (OA)، دقت طبقه‌بندی هر کلاس، متوسط دقت طبقه‌بندی (AA) و ضریب کاپا (Kappa) استفاده می‌شود (Beirami and Mokhtarzade, 2017).

در این بخش، ابتدا درباره تنظیم پارامترهای روش پیشنهادی بحث می‌شود. در ادامه در قسمت دوم عملکرد طبقه‌بندی براساس روش پیشنهادی با چند روش دیگر مقایسه شده است. تمام آزمایش‌ها با CPU: Core i5 4590 Ghz با ۸ گیگ رم در محیط متلب 2020b پیاده‌سازی شده است. به منظور طبقه‌بندی تصاویر ابرطیفی با توجه به نقشه واقعی زمینی موجود، در هر کلاس نمونه‌ها به صورت تصادفی به دو دسته آموزش و تست تقسیم می‌شود. همانند بسیاری از پژوهش‌های پیشین، برای داده ایندین پایین از ۱۰٪ نمونه‌های هر کلاس به عنوان نمونه آموزشی و برای داده دانشگاه پاویا از ۱٪ نمونه‌های موجود برای فرایند آموزش استفاده می‌شود و از الباقی نمونه‌ها به عنوان نمونه‌های تست برای ارزیابی عملکرد طبقه‌بندی کننده استفاده می‌شود (Yu et al., 2021; Beirami and Mokhtarzade, 2022). روش انتخاب نمونه‌ها نیز مانند بسیاری دیگر از پژوهش‌های

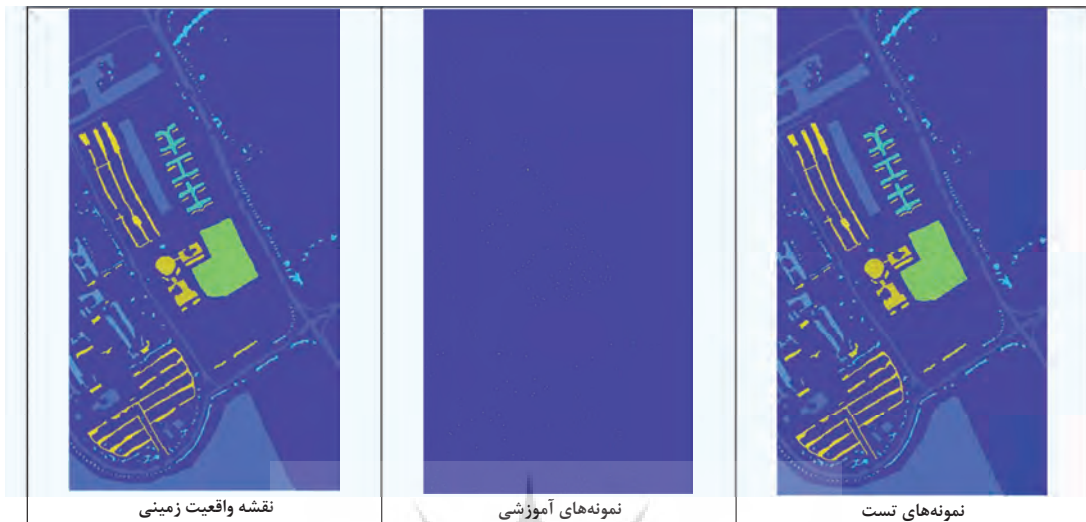
1. random



شکل ۴. تصاویر مربوط به نقشه واقعیت زمینی و نقشه‌های پراکندگی نمونه‌های آموزشی و تست برای داده ایندین پایین

جدول ۱. نوع پوشش زمین و تعداد نمونه‌ها برای داده ایندین پایین

شماره کلاس	نوع پوشش	رنگ نمایش	تعداد نمونه کل	تعداد نمونه آموزشی	تعداد نمونه تست
۱	یونجه	سبز تیره	۴۶	۴	۴۲
۲	ذرت سالم	سبز متوسط	۱۴۲۸	۱۴۲	۱۲۸۶
۳	ذرت آفت‌زده	سبز روشن	۸۳۰	۸۳	۷۴۷
۴	ذرت در ابتدای رشد	سبز بسیار روشن	۲۳۷	۲۳	۲۱۴
۵	چمن- مرتع	زرد سبز	۴۸۳	۴۸	۴۳۵
۶	چمن- درخت	زرد	۷۳۰	۷۳	۶۵۷
۷	چمن- مرتع- دروشده	زرد روشن	۲۸	۳	۲۵
۸	دسته‌های یونجه	نارنجی	۴۷۸	۴۷	۴۳۱
۹	جو	نارنجی روشن	۲۰	۳	۱۷
۱۰	سویای سالم	قرمز نارنجی	۹۷۲	۹۷	۸۷۵
۱۱	سویای آفت‌زده	قرمز	۲۴۵۵	۲۴۵	۲۲۱۰
۱۲	سویا در ابتدای رشد	قرمز تیره	۵۹۳	۵۹	۵۳۴
۱۳	گندم	بنفش	۲۰۵	۲۰	۱۸۵
۱۴	چوب	بنفش روشن	۱۲۶۵	۱۲۶	۱۱۳۹
۱۵	ساختمان- سبزه- درخت- ماشین	بنفش بسیار روشن	۳۸۶	۳۸	۳۴۸
۱۶	برنج سنگ فولاد	بنفش تیره	۹۳	۹	۸۴



شکل ۵. تصاویر مربوط به نقشه واقعیت زمینی و نقشه‌های پراکندگی نمونه‌های آموزشی و تست برای داده دانشگاه پابویا

جدول ۲. نوع پوشش زمین و تعداد نمونه‌ها برای داده دانشگاه پابویا

شماره کلاس	نوع پوشش	رنگ نمایش	تعداد کل نمونه‌ها	تعداد نمونه آموزشی	تعداد نمونه تست
۱	آسفالت	Blue	۶۶۳۱	۶۶	۶۵۶۵
۲	چمن	Light Blue	۱۸۶۴۹	۱۸۶	۱۸۴۶۳
۳	شن و ماسه	Light Blue	۲۰۹۹	۲۰	۲۰۷۹
۴	درخت	Light Blue	۳۰۶۴	۳۰	۳۰۳۴
۵	ورقه‌های فلزی رنگ‌شده	Light Blue	۱۳۴۵	۱۳	۱۳۳۲
۶	خاک	Green	۵۰۲۹	۵۰	۴۹۷۹
۷	قیر	Yellow	۱۳۳۰	۱۳	۱۳۱۷
۸	آجر	Yellow	۳۶۸۲	۳۶	۳۶۴۶
۹	سایه	Yellow	۹۴۷	۸	۹۳۸



#### ۴-۱- بررسی تأثیر پارامترهای روش پیشنهادی در صحت طبقه‌بندی

به‌طور کلی روش طبقه‌بندی طیفی- مکانی ارائه‌شده در این پژوهش دارای سه پارامتر تأثیرگذار به شرح زیر است:

##### - تعداد مؤلفه‌های MNF به‌کاررفته در تولید ویژگی:

در مرحله ابتدایی به‌منظور تولید ویژگی‌های بعد فرکتال از سه مؤلفه اول تبدیل MNF استفاده می‌شود. سه مؤلفه ابتدایی MNF دارای بیشترین اطلاعات موجود به‌منظور تولید ویژگی‌های مکانی است. برای فاز دوم به‌منظور تولید ویژگی‌های ماتریس محلی کرنل وزن‌دار از هر دو ویژگی طیفی و فرکتالی از ۲۰ مؤلفه اول MNF که دارای بیشترین حجم اطلاعات هستند، استفاده می‌شود. باید توجه داشت که این عدد ۲۰ با بررسی‌های بصری و سعی و خطا انتخاب شده است.


##### - ابعاد پنجره اطراف هر پیکسل در تولید ویژگی‌های بعد فرکتال:

به‌طور کلی بر مبنای پژوهش‌های پیشین عملکرد ویژگی‌های فرکتالی در ابعاد پنجره‌های بزرگ بهتر است، اما از آنجاکه در تصاویر ابرطیفی پدیده‌هایی با ابعاد مختلف وجود دارد، به‌منظور افزایش کیفیت عملکرد این ویژگی‌ها می‌توان از پنجره‌هایی با ابعاد مختلف برای تولید ویژگی‌های فرکتالی استفاده کرد (Beirami and Mokhtarzade, 2022). در پژوهش حاضر اندازه‌های در نظر گرفته‌شده برابر با ۱۱×۱۱، ۱۷×۱۷، ۲۳×۲۳،

۳۳×۳۳، ۴۱×۴۱ هستند. برای هر مؤلفه MNF در هر اندازه پنجره چهار ویژگی فرکتالی در چهار جهت تولید می‌شود و اگر تعداد مؤلفه‌های MNF برابر با سه باشد در هر ابعاد پنجره ۱۲ ویژگی بعد فرکتال تولید می‌شود. با در نظر گرفتن پنج اندازه پنجره یادشده، تعداد کل ویژگی‌های فرکتالی موجود به ۶۰ می‌رسد.

##### - ابعاد پنجره اطراف هر پیکسل در تولید ویژگی‌های مستخرج از ماتریس محلی کرنل وزن‌دار:

همان‌طور که پیش‌تر عنوان شد، پس از تولید ویژگی‌های طیفی و بعد فرکتال، ماتریس‌های محلی کرنل وزن‌دار از هر کدام از ویژگی‌ها به‌طور جداگانه تولید می‌شود. همانند بعد فرکتال در این روش نیز ابعاد پنجره در اطراف هر پیکسل نقش مهمی در کیفیت ویژگی‌های نهایی ایفا می‌کند. به‌منظور بررسی این موضوع نمودار دقت طبقه‌بندی به‌ازای مقادیر مختلف ابعاد پنجره برای هر دو مجموعه داده در شکل ۶ نمایش داده شده است. باید توجه داشت که برای سهولت ابعاد پنجره‌ها برای هر دو ویژگی طیفی و بعد فرکتال، ثابت در نظر گرفته شده است. همان‌طور که در شکل‌ها مشخص است برای داده ایندین پایین ابعاد پنجره ۵×۵ و برای داده دانشگاه پاویا ابعاد ۱۳×۱۳ بهینه است. دلیل این موضوع این است که به‌طور کلی داده دانشگاه پاویا دارای کلاس‌هایی با ابعاد بزرگ‌تر است، از این‌رو در ابعاد پنجره‌های بزرگ‌تر به صحت‌های بالاتری می‌توان رسید.



شکل ۶. دقت طبقه‌بندی به‌ازای مقادیر مختلف ابعاد پنجره (w) برای هر دو مجموعه داده

## ۴-۲- مقایسه و تحلیل نتایج

معرفی کردند (Yang et al., 2019). در این روش ماتریس‌های محلی کواریانس ابتدا از پروفایل‌های ویژگی توسعه یافته تولید می‌شوند، سپس به منظور طبقه‌بندی آنها از روش نمایش تنک مشترک مبتنی بر کرنل لگاریتم اقلیدسی استفاده می‌شود. منطق اصلی روش پنجم، Fractal-SVM، مبتنی بر مفاهیم ارائه شده در پژوهش اصغری و مختارزاده است (Beirami and Mokhtarzade 2022). در این روش ویژگی‌های بعد فرکتال از سه مؤلفه اول MNF تصویر اصلی با در نظر گرفتن پنجره‌هایی با ابعاد ۱۱×۱۱، ۱۷×۱۷، ۲۳×۲۳، ۳۳×۳۳، ۴۱×۴۱ تولید و به ویژگی‌های MNF الصاق و به منظور طبقه‌بندی به SVM داده می‌شود. این روش از این جهت حائز اهمیت است که منطقی نزدیک به پژوهش پیشنهادی دارد، با این تفاوت که برخلاف پژوهش پیش رو از ماتریس‌های کرنل برای مدل‌سازی ارتباطات غیرخطی میان ویژگی‌ها استفاده نمی‌کند. پس اگر اثبات شود که روش پیشنهادی بهتر از این روش عمل می‌کند، می‌توان نتیجه گرفت که استفاده از ویژگی‌های مستخرج از ماتریس کرنل باعث افزایش صحت طبقه‌بندی می‌شود. خلاصه‌ای از روش‌های مورد مقایسه در جدول ۳ ارائه شده است.

در این قسمت نتایج طبقه‌بندی به‌دست آمده از روش پیشنهادی با پنج روش دیگر طبقه‌بندی تصاویر ابرطیفی مقایسه می‌شود. روش اول با نام Spectral-SVM طبقه‌بندی تصاویر ابرطیفی با ویژگی‌های طیفی و طبقه‌بندی کننده SVM است. در این روش که فقط از ویژگی‌های طیفی استفاده می‌کند، باندهای اصلی تصویر ابرطیفی به کمک طبقه‌بندی کننده SVM طبقه‌بندی می‌شود. در روش دوم با عنوان LCMR که فانگ و همکاران (۲۰۱۸) ارائه کرده‌اند (Fang et al., 2018)، ابتدا پس از یک مرحله کاهش بعد به وسیله MNF، ماتریس‌های محلی کواریانس در اطراف هر پیکسل محاسبه و در نهایت این ماتریس‌ها توسط الگوریتم SVM با کرنل لگاریتم اقلیدسی طبقه‌بندی می‌شود. روش سوم با عنوان RPNNet الگوریتمی است که شو و همکاران (۲۰۱۸) ارائه کرده‌اند (Xu et al., 2018). در این روش ویژگی‌های مکانی عمیق با استفاده از فیلترهای کانولوشن استخراج شده از تصاویر و تبدیل‌های مؤلفه اصلی (PCA) ایجاد می‌شوند. سپس این ویژگی‌های عمیق با ویژگی‌های طیفی اصلی الصاق شده، به منظور طبقه‌بندی به SVM داده می‌شود. روش چهارم، LogEKJSR، را یانگ و همکاران (۲۰۱۹)

جدول ۳. مشخصات روش‌های طبقه‌بندی به کاررفته

نام روش طبقه‌بندی	نوع روش	مجموع تعداد ویژگی‌های اولیه ورودی به هسته اصلی الگوریتم		روش طبقه‌بندی
		این‌دین پایین	دانشگاه پابوا	
Spectral-SVM	طیفی	۲۰۰	۱۰۳	SVM
LCMR	طیفی- مکانی	۲۰	۲۰	SVM
RPNNet	طیفی- مکانی	۲۰۳	۱۰۶	SVM
LogEKJSR	طیفی- مکانی	۲۰	۲۰	نمایش تنک مشترک کرنلی
Fractal-SVM	طیفی- مکانی	۸۰	۸۰	SVM
روش پیشنهادی	طیفی- مکانی	۸۰	۸۰	SVM

## 1. Principal Components Analysis

## ۴-۲-۱- داده‌آیندین پایین

نتایج دقت به‌دست‌آمده، از جمله دقت کلی (OA)، دقت متوسط (AA) و ضریب کاپا (Kappa) و دقت کلاسی برای داده‌آیندین پایین در جدول ۴ گزارش شده است. نقشه‌های طبقه‌بندی داده‌آیندین پایین به‌دست‌آمده از روش ارائه‌شده و روش‌های دیگر نیز در شکل ۷ آمده است. با توجه به جدول ۴ و شکل ۷ می‌توان دریافت که طبقه‌بندی تنها با اطلاعات طیفی (روش Spectral-SVM) به حصول صحت‌های بالایی منجر نمی‌شود. بنا بر جدول ۴ می‌توان دریافت که دقت کلی و دقت متوسط هر دو زیر ۸۰ درصد هستند و بنا بر شکل ۷ تصویر طبقه‌بندی‌شده مربوطه بسیار نویزی است. یکی از دلایل عمده برای این سطح پایین صحت مشابهت‌های طیفی بین کلاسی و تفاوت‌های طیفی درون کلاسی پیکسل‌هاست. به‌منظور رفع این مشکل در پیشینه پژوهش از ویژگی‌های مکانی استفاده شده است. نتایج جدول ۴ نشان می‌دهد زمانی که از اطلاعات مکانی در فرایند طبقه‌بندی استفاده می‌شود سطح صحت به‌شدت تا حدود ۲۰ درصد افزایش می‌یابد (روش‌های طیفی- مکانی در جدول ۳). نتایج جدول ۴ نشان می‌دهد که روش پیشنهادی بهترین عملکرد را نسبت به سایر روش‌ها داشته است. با توجه به جدول ۴، با مقایسه AAها می‌توان دریافت که روش پیشنهادی به‌طور متوسط در دقت کلاسی بهترین عملکرد را نسبت به سایر روش‌ها داشته است. به‌عنوان یک نتیجه دیگر می‌توان گفت که روش پیشنهادی در طبقه‌بندی کلاس‌هایی با تعداد نمونه‌های بسیار کم مانند کلاس‌های ۱ و ۷ و ۹ و ۱۶ نیز عملکردی مطلوب داشته است. از سوی دیگر، نتایج روش پیشنهادی نشان می‌دهد که ادغام ویژگی‌های طیفی- فرکتالی حاصل از ماتریس محلی کرنل وزن‌دار می‌تواند عملکردی بهتر نسبت به الصاق ساده ویژگی‌های طیفی و فرکتالی داشته باشد. این بدین سبب است که در روش ماتریس محلی کرنل وزن‌دار آماره‌های مرتبه بالا و وابستگی‌های غیرخطی میان ویژگی در نظر گرفته می‌شود که سبب

بهبود صحت طبقه‌بندی می‌شود. مقایسه نقشه‌های طبقه‌بندی‌شده در شکل ۷ نیز نشان می‌دهد که تصاویر طبقه‌بندی‌شده به‌دست‌آمده از روش پیشنهادی بسیار هموارند و تعداد پیکسل‌های با برچسب اشتباه در آن به‌شدت کاهش یافته است.

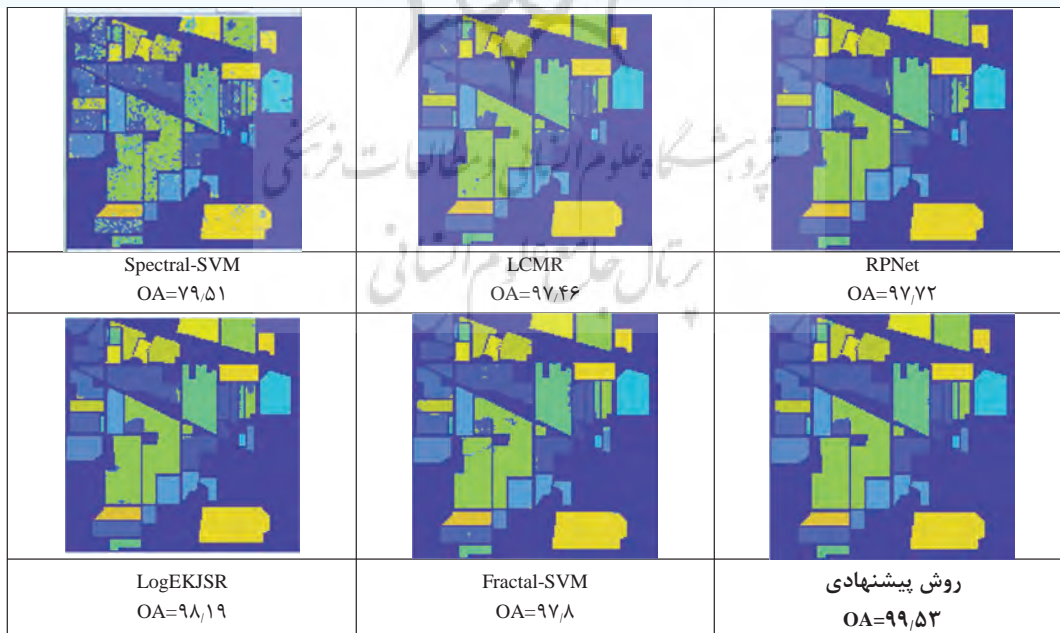
علاوه بر دقت‌های طبقه‌بندی، نتایج تست زمان اجرای برنامه برای هر روش نیز در جدول ۴ ارائه شده است. همان‌طور که مشخص است بهترین زمان اجرا مربوط به روش Spectral-SVM است. علت برتری این است که روش Spectral-SVM برخلاف روش‌های دیگر دارای مرحله تولید ویژگی‌های مکانی نیست و طبقه‌بندی فقط با داده‌های خام طیفی انجام می‌شود. در میان روش‌های طیفی- مکانی در این مجموعه داده بهترین عملکرد مربوط به روش LCMR است. علت این برتری این است که این روش ساختاری ساده‌تر از روش‌های دیگر دارد و فقط از ویژگی‌های طیفی برای تولید ماتریس‌های محلی کوواریانس استفاده می‌کند. بنا بر جدول ۴ می‌توان گفت که هرچند روش پیشنهادی نتوانسته است که پیروزی قطعی را از منظر سرعت اجرای برنامه کسب کند، ولی همچنان نتایج سرعت اجرا معقول بوده و سریع‌تر از بسیاری از الگوریتم‌های جدید مانند LogEKJSR است.

## ۴-۲-۲- داده‌آیندین پایا

نتایج دقت به‌دست‌آمده، از جمله دقت کلی (OA)، دقت متوسط (AA) و ضریب کاپا (Kappa) و دقت کلاسی برای داده‌آیندین پایا در جدول ۵ ارائه شده است. شکل ۸ نیز نقشه‌های طبقه‌بندی حاصل از روش‌های مختلف و روش ارائه‌شده برای داده‌آیندین پایا را نشان می‌دهد. همان‌طور که مشخص است همانند آیندین پایین در داده‌آیندین پایا نیز طبقه‌بندی فقط با ویژگی‌های طیفی به سطوح بالایی از دقت (بالای ۹۵ درصد) منجر نمی‌شود و برای افزایش دقت نیاز به استفاده از اطلاعات مکانی است. روش پیشنهادی در این مجموعه داده نیز از نظر دقت بهترین عملکرد را داشته است.

جدول ۴. نتایج طبقه‌بندی تصویر ابرطیفی ایندین پایین با استفاده از روش‌های مختلف

کلاس	Spectral-SVM	LCMR	RNet	LogEKJSR	Fractal-SVM	روش پیشنهادی
۱	۴۵,۲۳	۶۹,۰۴	۸۵,۷۱	۹۰,۴۷	۹۷,۶۱	۹۷,۶۱
۲	۸۰,۰۱	۹۶,۷۳	۹۷,۸۲	۹۸,۳۶	۹۷,۳۵	۹۹,۷۶
۳	۷۱,۷۵	۹۹,۱۹	۹۹,۴۶	۹۹,۳۳	۹۶,۹۲	۹۸,۹۲
۴	۶۹,۶۲	۹۰,۱۸	۸۸,۷۸	۹۱,۱۲	۹۲,۹۹	۹۹,۵۳
۵	۹۱,۴۹	۹۵,۶۳	۹۵,۸۶	۹۵,۸۶	۹۷,۴۷	۱۰۰
۶	۹۵,۸۹	۹۸,۴۷	۹۸,۹۳	۹۸,۹۳	۹۹,۸۴	۱۰۰
۷	۵۲	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰
۸	۹۶,۰۵	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰
۹	۷۶,۴۷	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰
۱۰	۶۶,۶۲	۹۱,۰۸	۹۷,۳۷	۹۷,۹۴	۹۶,۲۲	۹۹,۷۷
۱۱	۷۵,۴۲	۹۸,۱۹	۹۵,۷۹	۹۶,۸۷	۹۷,۲۸	۹۹,۴۱
۱۲	۷۳,۴۰	۹۹,۴۳	۹۹,۴۳	۹۹,۴۳	۹۶,۶۲	۹۷,۵۶
۱۳	۹۵,۱۳	۱۰۰	۱۰۰	۱۰۰	۹۹,۴۵	۱۰۰
۱۴	۸۹,۹۰	۱۰۰	۱۰۰	۱۰۰	۹۹,۷۳	۱۰۰
۱۵	۶۲,۰۶	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۹۹,۷۱
۱۶	۹۴,۰۴	۹۷,۶	۹۵,۳۳	۹۶,۴۲	۹۶,۴۲	۹۸,۸۱
OA	۷۹,۵۱	۹۷,۴۶	۹۷,۷۲	۹۸,۱۹	۹۷,۸۰	۹۹,۵۳
AA	۷۷,۱۹	۹۵,۹۷	۹۷,۱۵	۹۷,۸	۹۷,۹۹	۹۹,۴۴
Kappa	۰,۷۶	۰,۹۷	۰,۹۷	۰,۹۷۸	۰,۹۷۴	۰,۹۹۴۵
زمان اجرا برحسب ثانیه	۴,۵	۸	۳۲	۶۸۰	۷۸	۱۰۱



شکل ۷. تصاویر طبقه‌بندی برای داده‌های ایندین پایین

نتایج زمان اجرای برنامه که برای داده پاولیا در جدول ۵ گزارش شده است، نتیجه کلی داده ایندین را تأیید می‌کند که در آن روش پیشنهادی سریع‌تر از روش LogEKJSR و کندتر از سایر روش‌ها عمل می‌کند.

#### ۵- نتیجه‌گیری

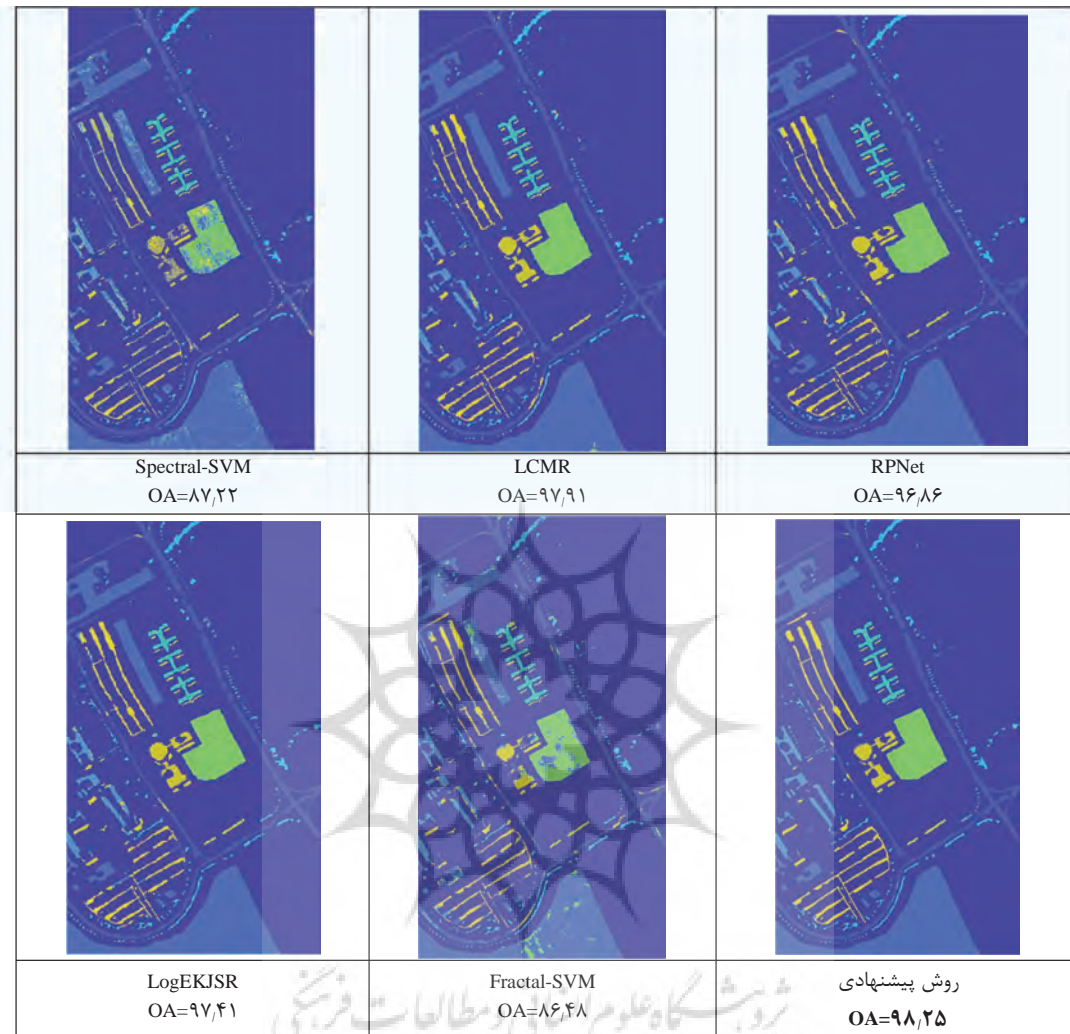
در این مطالعه، یک روش طیفی- مکانی جدید برای طبقه‌بندی ابرطیفی پیشنهاد شده است. روش ارائه شده مبتنی بر ادغام ویژگی‌های ماتریس محلی ماتریس کرنل وزن‌دار مستخرج از دو دسته ویژگی‌های طیفی و فرکتالی است. به‌طور خاص در این روش پس از کاهش ابعاد داده‌های ابرطیفی به کمک تبدیل کسر نویز کمینه، ویژگی‌های بعد فرکتال جهت‌دار تولید شده و در مرحله بعد ویژگی‌های ماتریس محلی کرنل وزن‌دار که بیان‌کننده وابستگی‌های غیرخطی ویژگی‌هاست از هر دو دسته ویژگی‌های طیفی و فرکتالی تولید می‌شود. در آخر نیز این دو دسته بردار ویژگی به یکدیگر الصاق می‌شود و به کمک طبقه‌بندی‌کننده SVM طبقه‌بندی تصویر صورت می‌گیرد.

از نظر دقت کلاسی به‌جز در کلاس شماره ۹، یعنی سایه، بالاترین دقت را در عمده کلاس‌ها دارد. روش پیشنهادی در ۵ کلاس از ۹ کلاس بالاترین دقت را کسب کرده و در دو کلاس ۵ و ۶ به ۱۰۰ درصد دقت رسیده است. همچنین مانند داده ایندین پایین با مشاهده نقشه‌های طبقه‌بندی شده می‌توان دریافت که بیشتر کلاس‌ها به‌خوبی طبقه‌بندی شده‌اند و لبه‌های عوارض موجود و جاده مشخص است. باوجوداین، چند پیکسل طبقه‌بندی نادرست و پراکنده در داخل منطقه آسفالت و سایه وجود دارد که باعث از بین رفتن یکپارچگی نقشه طبقه‌بندی در این دو کلاس می‌شود. به‌طور کلی نتایج نشان می‌دهد که ویژگی‌های مستخرج از ماتریس محلی کرنل وزن‌دار دارای پتانسیل بالایی در بهبود صحت طبقه‌بندی تصاویر ابرطیفی هستند. در روش ارائه شده به کمک ویژگی‌های مستخرج ماتریس محلی کرنل وزن‌دار می‌توان وابستگی‌های غیرخطی را میان هم ویژگی‌های طیفی و هم ویژگی‌های فرکتالی را به‌صورت جداگانه مدل‌سازی کرد و با ادغام آن‌ها به یک بردار غنی از ویژگی‌های طیفی- مکانی رسید که در طبقه‌بندی تصاویر ابرطیفی بسیار موفق عمل می‌کند.

جدول ۵. نتایج طبقه‌بندی تصویر ابرطیفی دانشگاه پاولیا با استفاده از روش‌های مختلف

کلاس	Spectral-SVM	LCMR	RNet	LogEKJSR	Fractal-SVM	روش پیشنهادی
۱	۹۲٫۶۴	۹۵٫۹۹	۹۶٫۸۳	۹۷٫۹۵	۷۹٫۱۳	۹۶٫۳۲
۲	۹۴٫۵۴	۹۹٫۷۴	۹۹٫۹۵	۹۹٫۹۴	۹۳٫۵۶	۹۹٫۹۸
۳	۷۷٫۳۹	۹۵٫۰۹	۸۶٫۴۳	۹۱٫۹۶	۸۰٫۶۱	۹۷٫۶۹
۴	۸۴٫۱۴	۹۶٫۲۷	۸۹٫۴۵	۸۸٫۸۹	۸۰٫۵۵	۹۷٫۴۶
۵	۹۸٫۴۲	۹۹٫۷۷	۹۹٫۶۹	۹۹٫۶۹	۹۶٫۳۲	۱۰۰
۶	۷۳٫۹۱	۹۹٫۴۱	۹۹٫۴۱	۹۹٫۵۹	۸۷٫۲۰	۱۰۰
۷	۶۳٫۷۰	۹۹٫۹۲	۹۱٫۱۱	۹۶٫۵۰	۶۰٫۵۹	۹۶٫۱۲
۸	۶۷٫۸۸	۹۳٫۲۲	۹۱٫۲۵	۹۰٫۵۱	۸۲٫۹۶	۹۶٫۷۶
۹	۹۹٫۸۹	۹۱٫۶۸	۹۵٫۷۲	۹۶٫۶۹	۶۳٫۳۲	۷۸٫۲۵
OA	۸۷٫۲۲	۹۷٫۹۱	۹۶٫۸۶	۹۷٫۳۱	۸۶٫۴۸	۹۸٫۲۵
AA	۸۳٫۶۱	۹۶٫۷۹	۹۴٫۴۲	۹۵٫۷۵	۸۰٫۴۷	۹۵٫۸۵
Kappa	۰٫۸۲	۰٫۹۷۲	۰٫۹۵۸	۰٫۹۶۵	۰٫۸۲	۰٫۹۷۶
زمان اجرا برحسب ثانیه	۱۰	۷۵	۳۴	۱۹۶۰	۷۸۰	۸۰۰





شکل ۸. تصاویر طبقه‌بندی برای داده دانشگاه پاویا

#### ۶- منابع

- Ahmadi, S. A. and N. Mehrshad., 2022, **Spectral-spatial feature extraction method for hyperspectral images classification using multiscale superpixel and covariance map**, Geocarto International 37(2), pp. 678-695. <https://doi.org/10.1080/10106049.2020.1734874>
- Anand, R., S. Veni and J. Aravinth., 2021, **Robust classification technique for hyperspectral images based on 3D-discrete wavelet transform**, Remote Sensing. 13(7), pp. 1255. <https://doi.org/10.3390/rs13071255>

تجزیه و تحلیل نتایج تجربی بر روی دو مجموعه داده ابرطیفی واقعی ایندین پایین و دانشگاه پاویا نشان می‌دهد که عملکرد روش ارائه شده بهتر از سایر روش‌هاست. با توجه به اینکه در مقاله حاضر اثربخشی ویژگی‌های ماتریس محلی کرنل وزن دار مستخرج از ویژگی‌های فرکتالی اثبات شده است، در پژوهش‌های آتی قصد داریم علاوه بر بهبود روش از منظر زمانی، صحت روش خود را با استفاده از دیگر ویژگی‌های فرکتالی بهبود دهیم.

- Asghari Beirami, B. and M. Mokhtarzade., 2020, **Spatial-spectral classification of hyperspectral images based on extended morphological profiles and guided filter**, Computer and Knowledge Engineering, 2(2), pp. 2-8.  
<https://doi.org/10.22067/CKE.V2I2.81519>
- Beirami, B. A. and M. Mokhtarzade., 2017, **SVM classification of hyperspectral images using the combination of spectral bands and Moran's I features**, In IEEE 10th Iranian Conference on Machine Vision and Image Processing (MVIP), Isfahan, Iran  
<https://doi.org/10.1109/IranianMVIP.2017.8342334>
- Beirami, B. A. and M. Mokhtarzade., 2019, **Spatial-Spectral Random Patches Network for Classification of Hyperspectral Images**, Traitement du Signal, 36(5), pp. 399-406.  
<https://doi.org/10.18280/ts.360504>
- Beirami, B. A. and M. Mokhtarzade., 2022, **Spatial-spectral classification of hyperspectral images based on multiple fractal-based features**, Geocarto International, 37(1), pp. 231-245.  
<https://doi.org/10.1080/10106049.2020.1713232>
- Benediktsson, J. A., J. A. Palmason and J. R. Sveinsson., 2005, **Classification of hyperspectral data from urban areas based on extended morphological profiles**, IEEE Transactions on Geoscience and Remote Sensing, 43(3), pp. 480-491.  
<https://doi.org/10.1109/TGRS.2004.842478>
- Cavallaro, G., M. Dalla Mura, J. A. Benediktsson and L. Bruzzone., 2015, **Extended self-dual attribute profiles for the classification of hyperspectral images**, IEEE Geoscience and Remote Sensing Letters, 12(8), pp. 1690-1694.  
<https://doi.org/10.1109/LGRS.2015.2419629>
- Duan, P., P. Ghamisi, X. Kang, B. Rasti, S. Li and R. Gloaguen., 2020, **Fusion of dual spatial information for hyperspectral image classification**, IEEE Transactions on Geoscience and Remote Sensing, 59(9), pp. 7726-7738.  
<https://doi.org/10.1109/TGRS.2020.3031928>
- Falco, N., J. A. Benediktsson and L. Bruzzone., 2015, **Spectral and spatial classification of hyperspectral images based on ICA and reduced morphological attribute profiles**, IEEE Transactions on Geoscience and Remote Sensing, 53(11), pp. 6223-6240.  
<https://doi.org/10.1109/TGRS.2015.2436335>
- Fang, L., N. He, S. Li, A. J. Plaza and J. Plaza., 2018, **A new spatial-spectral feature extraction method for hyperspectral images using local covariance matrix representation**, IEEE Transactions on Geoscience and Remote Sensing, 56(6), pp. 3534-3546.  
<https://doi.org/10.1109/TGRS.2018.2801387>
- Feng, F., Y. Zhang, J. Zhang and B. Liu., 2022, **Small sample hyperspectral image classification based on cascade fusion of mixed spatial-spectral features and second-order pooling**, Remote Sensing, 14(3), pp. 505.  
<https://doi.org/10.3390/rs14030505>
- Gomez, C., R. A. V. Rossel and A. B. McBratney, 2008, **Soil organic carbon prediction by hyperspectral remote sensing and field vis-NIR spectroscopy: An Australian case study**, Geoderma, 146(3-4), pp. 403-411.  
<https://doi.org/10.1016/j.geoderma.2008.06.011>
- He, N., M. E. Paoletti, J. M. Haut, L. Fang, S. Li, A. Plaza and J. Plaza., 2018, **Feature extraction with multiscale covariance maps for hyperspectral image classification**, IEEE Transactions on Geoscience and Remote Sensing, 57(2), pp. 755-769.  
<https://doi.org/10.1109/TGRS.2018.2860464>
- Kallas, M., C. Francis, L. Kanaan, D. Merheb, P. Honeine and H. Amoud, 2012, **Multi-class SVM classification combined with kernel PCA feature extraction of ECG signals**, In IEEE 19th International Conference on Telecommunications (ICT), Jounieh, Lebanon.  
<https://doi.org/10.1109/ICTEL.2012.6221261>
- Kaul, A. and S. Raina., 2022, **Support vector machine versus convolutional neural network for hyperspectral image classification: A systematic review**, Concurrency and Computation: Practice and Experience, 34(15), pp. e6945.  
<https://doi.org/10.1002/cpe.6945>

- Kumar, B. and O. Dikshit, 2015, **Integrating spectral and textural features for urban land cover classification with hyperspectral data**, In IEEE Joint Urban Remote Sensing Event (JURSE), Lausanne, Switzerland. <https://doi.org/10.1109/JURSE.2015.7120517>
- Kumar, B. and O. Dikshit., 2015, **Spectral-spatial classification of hyperspectral imagery based on moment invariants**, IEEE Journal of selected topics in applied earth observations and remote sensing, 8(6), pp. 2457-2463. <https://doi.org/10.1109/JSTARS.2015.2446611>
- Leng, J., T. Li, G. Bai, Q. Dong and H. Dong., 2016, **Cube-CNN-SVM: A novel hyperspectral image classification method**, In IEEE 28th International conference on tools with artificial intelligence (ICTAI), San Jose, CA, USA. <https://doi.org/10.1109/ICTAI.2016.0158>
- Liu, Y., S. Lu, X. Lu, Z. Wang, C. Chen and H. He., 2019, **Classification of urban hyperspectral remote sensing imagery based on optimized spectral angle mapping**, Journal of the Indian Society of Remote Sensing, 47, pp. 289-294. <https://doi.org/10.1007/s12524-018-0929-1>
- Mahdi, M. S. and A. A. A. Hassan., 2016, **Satellite images classification in rural areas based on fractal dimension**, Journal of Engineering, 22(4), pp. 147-157. <https://doi.org/10.31026/j.eng.2016.04.10>
- Mirzapour, F. and H. Ghassemian., 2015, **Improving hyperspectral image classification by combining spectral, texture, and shape features**, International Journal of Remote Sensing, 36(4), pp. 1070-1096. <https://doi.org/10.1080/01431161.2015.1007251>
- Myint, S., 2003, **Fractal approaches in texture analysis and classification of remotely sensed data: Comparisons with spatial autocorrelation techniques and simple descriptive statistics**, International Journal of remote sensing, 24(9), pp. 1925-1947. <https://doi.org/10.1080/01431160210155992>
- Pang, Y., Y. Yuan and X. Li., 2008, **Gabor-based region covariance matrices for face recognition**, IEEE Transactions on circuits and systems for video technology, 18(7), pp. 989-993. <https://doi.org/10.1109/TCSVT.2008.924108>
- Peyghambari, S. and Y. Zhang, 2021, **Hyperspectral remote sensing in lithological mapping, mineral exploration, and environmental geology: an updated review**, Journal of Applied Remote Sensing, 15(3), pp. 031501-031501. <https://doi.org/10.1117/1.JRS.15.031501>
- Qin, H., L. Qin, L. Xue and C. Yu., 2012, **Gabor-based weighted region covariance matrix for face recognition**, Electronics letters, 48(16), pp. 992-993. <https://doi.org/10.1049/el.2012.1519>
- Singh, P., P. C. Pandey, G. P. Petropoulos, A. Pavlides, P. K. Srivastava, N. Koutsias, K. A. K. Deng and Y. Bao., 2020, **Hyperspectral remote sensing in precision agriculture: Present status, challenges, and future trends**, Hyperspectral remote sensing: Theory and Applications, Elsevier, ISBN: 978-0-08-102894-0, pp. 121-146. <https://doi.org/10.1016/B978-0-08-102894-0.00009-7>
- Sun, Y., Z. Fu and L. Fan., 2019, **A novel hyperspectral image classification pattern using random patches convolution and local covariance**, Remote Sensing, 11(16), pp. 1954. <https://doi.org/10.3390/rs11161954>
- Tuzel, O., F. Porikli and P. Meer., 2006, **Region covariance: A fast descriptor for detection and classification**, Computer Vision-ECCV 2006: 9th European Conference on Computer Vision, Graz, Austria, May 7-13, 2006. Proceedings, Part II 9, Springer. [https://doi.org/10.1007/11744047\\_45](https://doi.org/10.1007/11744047_45)
- Wang, L., J. Zhang, L. Zhou, C. Tang and W. Li., 2015, **Beyond covariance: Feature representation with nonlinear kernel matrices**, Proceedings of the IEEE international conference on computer vision, Santiago, Chile. <https://doi.org/10.1109/ICCV.2015.519>
- Xu, Y., B. Du, F. Zhang and L. Zhang, 2018, **Hyperspectral image classification via a**

- random patches network**, ISPRS journal of photogrammetry and remote sensing, 142, pp. 344-357.  
<https://doi.org/10.1016/j.isprs.2018.05.014>
- Yang, W., J. Peng, W. Sun and Q. Du, 2019, **Log-euclidean kernel-based joint sparse representation for hyperspectral image classification**, IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 12(12), pp. 5023-5034.  
<https://doi.org/10.1109/JSTARS.2019.2952408>
- Yu, X., Y. Feng, Y. Gao, Y. Jia and S. Mei., 2021, **Dual-weighted kernel extreme learning machine for hyperspectral imagery classification**, Remote Sensing, 13(3), pp. 508.  
<https://doi.org/10.3390/rs13030508>
- Zheng, J., Y. Feng, C. Bai and J. Zhang., 2020, **Hyperspectral image classification using mixed convolutions and covariance pooling**, IEEE Transactions on Geoscience and Remote Sensing, 59(1), pp. 522-534.  
<https://doi.org/10.1109/TGRS.2020.2995575>
- Zhu, J., J. Shi, H. Chu, J. Hu, X. Li and W. Li., 2011, **Remote sensing classification using fractal dimensions over a subtropical hilly region**, Photogrammetric Engineering & Remote Sensing 77(1), pp. 65-74.  
<https://doi.org/10.14358/PERS.77.1.65>

