

## Original Article

Iranian Remote Sensing & GIS  
Journal of

# An Improved Approach for Spectral-spatial Classification of Hyperspectral Images using Weighted Genetic and Neural Network Algorithms

Davood Akbari<sup>1\*</sup>, Ali Ashrafi<sup>2</sup>, Mostafa Yaghoobzadeh<sup>3</sup>

**Affiliation**

1. Associate Professor,  
Department of Geomatic  
Engineering, Faculty of  
Engineering, University of  
Zabol, Zabol, Iran
2. Assistant Professor,  
Department of Geography,  
Faculty of Literature and  
Humanities, University of  
Birjand, Birjand, Iran
3. Associate Professor,  
Department of Science and  
Water Engineering, Faculty  
of Agriculture, University  
of Birjand, Birjand, Iran

**ABSTRACT**

**Introduction:** Hyperspectral remote sensing technology has seen significant progress in the last two decades. This progress is very evident in the design and construction of sensors as well as in the development and implementation of data processing methods. Today, most researches in the field of hyperspectral remote sensing technology emphasize on the classification of these images. Classification methods of hyperspectral images are divided into two categories: spectral or pixel-based classification and spectral-spatial or object-based classification. In this research, the spectral-spatial classification of hyperspectral image in an urban environment has been discussed. Since an urban environment has complex features in terms of elements, hyperspectral data effectively help to identify, extract and produce a map of their constituent elements. Identification of different materials in urban environments is very important in various applications, such as mobile phone communications, virtual reality, architecture and urban modeling, and planning and management of cities.

**Material and methods:** In this research, two hyperspectral images of Pavia and Berlin, which are part of the standard images in the field of hyperspectral remote sensing, were used to evaluate the proposed method. In the proposed method, the dimensions of the hyperspectral image are first reduced with the help of the PCA algorithm. Then, ten spatial features mean, standard deviation, degree of variation, homogeneity, correlation, dissimilarity, energy, entropy, wavelet transform and Gabor filter are extracted from the reduced bands. Then, the weighted genetic algorithm is applied to the obtained spectral and spatial features and finally the obtained features are classified with the help of MLP algorithm.

**Results and discussion:** In the tests conducted for the genetic algorithm, chromosomes have genes equal to the number of spectral and spatial features. In these tests, the crossover and mutation rates were considered as 0.5 and 0.05, respectively. Also, to create a balance between the two parameters of accuracy and calculation time, the initial population size was 30 and the maximum number of repetitions for stopping was 100. However, in practice for both hyperspectral images, since the active condition is used to stop the algorithm, the iteration process does not reach step 100 and before that the algorithm reaches a stable state and stops. The MLP classification algorithm was implemented with 3 hidden layers consisting of 5, 6 and 8 neurons and evaluated with 500 iterations. The proposed classification method was compared with SVM, MLP and MSF algorithms. In both hyperspectral images, the map obtained by the proposed method includes single nova regions in comparison with other algorithms. In the Pavia image, the proposed method has caused an increase of 13, 7, and 6 percent, and in the Berlin image, it has caused an increase of 9, 6, and 5 percent, in the Kappa coefficient parameter, respectively, compared to the SVM, MLP, and MSF algorithms. The reason for this increase in the accuracy of the proposed method can be the use of nearest neighbor information and two stages of dimensionality reduction.

**Conclusion:** In this research, a new method for spectral-spatial classification of hyperspectral images was introduced. In the proposed method, the dimensions of the hyperspectral image were first reduced and ten features were extracted as the nearest neighborhood information from the reduced bands. Then, a weighted genetic algorithm was applied to the obtained features to reduce the dependence between them. Genetic algorithm is one of the most efficient and effective methods in reducing the dimensionality of hyperspectral images. In the binary genetic algorithm, each chromosome has values of one and zero, while in the weighted genetic algorithm, the weight values are between zero and one. The proposed method was implemented on two hyperspectral images of Pavia and Berlin, and the quantitative and qualitative experiments show the superiority of the proposed method. The lower accuracy of the results in the Berlin image may be due to the complexity of this image compared to the Pavia image.

**Keywords:** Hyperspectral images, Spectral-spatial classification, Neural network, Spatial features, Weighted genetic algorithm.

**Citation:** Akbari, D., Ashrafi, A., Yaghoobzadeh, M., An Improved Approach for Spectral-spatial Classification of Hyperspectral Images using Weighted Genetic and Neural Network Algorithms, *Iran J Remote Sens GIS*, 16(4):1-16.

\* Corresponding Author: davoodakbari@uoz.ac.ir  
DOI: <https://doi.org/10.48308/GISJ.2023.103395>

Received: 2022.04.12  
Accepted: 2023.04.04





# روشی بهبود یافته به منظور طبقه‌بندی طیفی- مکانی تصاویر ابرطیفی به کمک الگوریتم‌های ژنتیک وزن دار و شبکه عصبی

داود اکبری<sup>۱\*</sup>، علی اشرفی<sup>۲</sup>، مصطفی یعقوبزاده<sup>۳</sup>

## سمت

۱. دانشیار گروه مهندسی نقشه برداری، دانشکده مهندسی، دانشگاه زابل، زابل، ایران
۲. استادیار گروه جغرافیا، دانشکده ادبیات و علوم انسانی، دانشگاه بیرجند، بیرجند، ایران
۳. دانشیار گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه بیرجند، بیرجند، ایران

## چکیده

**سابقه و هدف:** فناوری سنجش از دور ابرطیفی، در دو دهه گذشته، شاهد پیشرفت چشمگیری بوده است. این پیشرفت در طراحی و ساخت سنجنده‌ها و همچنین در توسعه و اجرای روش‌های پردازش داده بسیار مشهود است. امروزه بیشتر تحقیقات، در زمینه فناوری سنجش از دور ابرطیفی، بر طبقه‌بندی این تصاویر تأکید دارد. روش‌های طبقه‌بندی تصاویر ابرطیفی در دو دسته طبقه‌بندی طیفی یا مبتنی بر پیکسل و طبقه‌بندی طیفی- مکانی یا مبتنی بر شیء قرار می‌گیرند. در این تحقیق، به طبقه‌بندی طیفی- مکانی تصاویر ابرطیفی، در محیطی شهری، پرداخته شده است. از آنجاکه محیط‌های شهری، از نظر عناصر به کاررفته در آنها، ویژگی‌های پیچیده‌ای دارند، داده‌های ابرطیفی به شناسایی و استخراج و تولید نقشه از عناصر سازنده آنها کمک مؤثری می‌کنند. شناسایی مواد گوناگون در محیط‌های شهری اهمیت بسیاری در زمینه کاربردهای گوناگون، همچون ارتباط تلفن‌های همراه، واقعیت مجازی، معماری و مدل‌سازی شهری و برنامه‌ریزی و مدیریت شهرها دارد.

**مواد و روش‌ها:** در این تحقیق، برای ارزیابی روش پیشنهادی از دو تصویر ابرطیفی پاولیا و برلین، که جزء تصاویر معیار در حوزه سنجش از دور ابرطیفی است، استفاده شد. در روش پیشنهادی، ابتدا ابعاد تصویر ابرطیفی به کمک الگوریتم PCA کاهش می‌یابد؛ سپس ده ویژگی مکانی میانگین، انحراف معیار، درجه تباین، یکنواختی، همبستگی، نبود تشابه، انرژی، آنترپی، تبدیل موجک و فیلتر گابور از روی باندهای کاهش یافته استخراج می‌شود. در ادامه، الگوریتم ژنتیک وزن دار بر ویژگی‌های طیفی و مکانی به دست آمده اعمال می‌شود و در انتها، ویژگی‌های حاصل به کمک الگوریتم MLP طبقه‌بندی می‌شود.

**نتایج و بحث:** در آزمون‌های انجام شده در زمینه الگوریتم ژنتیک، کروموزوم‌ها دارای ژن‌هایی برابر با تعداد ویژگی‌های طیفی و مکانی‌اند. در این آزمون‌ها، میزان تقاطع و جهش به ترتیب برابر با ۰/۵ و ۰/۵ در نظر گرفته شد. همچنین، برای ایجاد تناسب بین دو پارامتر دقت و زمان محاسبات، تعداد جمعیت اولیه ۳۰ و حداکثر تعداد تکرار، برای توقف، ۱۰۰ در نظر گرفته شد. البته در عمل، در مورد هر دو تصویر ابرطیفی با توجه به استفاده از شرط فعال برای توقف الگوریتم، روند تکرار به مرحله ۱۰۰ نمی‌رسد و قبل از آن، الگوریتم به وضعیت پایدار می‌رسد و متوقف می‌شود. الگوریتم طبقه‌بندی MLP با سه لایه پنهان، شامل ۶ و ۸ نورون، اجرا و با پانصد تکرار ارزیابی شد. روش طبقه‌بندی پیشنهادی بیان شده با الگوریتم‌های SVM، MLP و MSF مقایسه شد. در هر دو تصویر ابرطیفی، نقشه حاصل از روش پیشنهادی در مقایسه با سایر الگوریتم‌ها مناطق یکنواخت‌تری را در برمی‌گیرد. روش پیشنهادی، در تصویر پاولیا، باعث افزایش ۱۳، ۷ و ۶ درصدی و در تصویر برلین، باعث افزایش ۹، ۶ و ۵ درصدی پارامتر ضریب کاپا، در قیاس با به ترتیب الگوریتم‌های SVM، MLP و MSF شده است. دلیل این افزایش دقت روش پیشنهادی می‌تواند استفاده از اطلاعات نزدیک‌ترین همسایگی و دو مرحله کاهش ابعاد باشد.

**نتیجه‌گیری:** در این تحقیق، روشی جدید به منظور طبقه‌بندی طیفی- مکانی تصاویر ابرطیفی معرفی شد. در روش پیشنهادی، ابتدا ابعاد تصویر ابرطیفی کاهش یافت و ده ویژگی، به منزله اطلاعات نزدیک‌ترین همسایگی‌ها، از باندهای کاهش یافته استخراج شد. در ادامه، الگوریتم ژنتیک وزن دار روی ویژگی‌های به دست آمده، به منظور کاهش وابستگی بین آنها، اعمال شد. الگوریتم ژنتیک یکی از کارآمدترین و مؤثرترین روش‌ها در کاهش ابعاد تصاویر ابرطیفی است. در الگوریتم باینری ژنتیک، هر کروموزوم دارای مقادیر یک و صفر است؛ در حالی که در الگوریتم ژنتیک وزن دار، مقادیر وزنی بین صفر و یک است. روش پیشنهادی روی دو تصویر ابرطیفی پاولیا و برلین اجرا شد که آزمایش‌ها برتری کمی و کیفی به کارگیری این روش را نشان می‌دهد. کمبودن دقت نتایج در تصویر برلین می‌تواند به دلیل پیچیدگی این تصویر، در مقایسه با تصویر پاولیا باشد.

**کلیدواژه‌ها:** تصویر ابرطیفی، طبقه‌بندی طیفی- مکانی، شبکه عصبی، ویژگی‌های مکانی، الگوریتم ژنتیک وزن دار.

\*استناد: اکبری، د.، اشرفی، ع.

یعقوبزاده، م.، روشی بهبود یافته به منظور طبقه‌بندی طیفی- مکانی تصاویر ابرطیفی به کمک الگوریتم‌های ژنتیک وزن دار و شبکه عصبی، نشریه سنجش از دور و GIS ایران، سال ۱۶، شماره ۴، زمستان ۱۴۰۳: ۱-۱۶.

دریافت: ۱۴۰۱/۰۱/۲۳

پذیرش: ۱۴۰۲/۰۱/۱۵

\* نویسنده عهده‌دار مکاتبات: davoodakbari@uoz.ac.ir

شناسه دیجیتال مقالات: https://doi.org/10.48308/GISJ.2023.103395



Copyright: © 2025 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license https://creativecommons.org/licenses/by/4.0/.

## ۱- مقدمه

طی دو دهه گذشته، فناوری سنجش از دور ابرطیفی شاهد پیشرفت چشمگیری بوده است. این پیشرفت در طراحی و ساخت سنجنده‌ها و همچنین در توسعه و اجرای روش‌های پردازش داده بسیار مشهود است (Varshney & Arora, 2004; Chang, 2003). هرچند توانایی تولید داده‌هایی با ویژگی‌های طیفی، مکانی و رادیومتریکی بالا به تجزیه و تحلیل بهتر این داده‌ها منجر می‌شود، مشکلاتی نیز پدید می‌آید که، در مقایسه با داده‌های چندطیفی، تجربه جدیدی است (Chan et al., 2020). اولین مشکل حجم نسبتاً زیاد این داده‌هاست؛ این میزان معتنا به داده، برای پردازش، به سخت‌افزار و نرم‌افزارهای ویژه نیاز دارد. زمان لازم برای پردازش این نوع داده‌ها از دیگر مشکلات پیش روست (Homayouni & Roux, 2003).

روش‌هایی که در پردازش داده‌های ابرطیفی استفاده می‌شوند همگی در زمره روش‌های شناسایی الگو قرار می‌گیرند (Theodoridis & Koutroumbas, 2006). بر این اساس و با توجه به سطح دانش به‌کاررفته، می‌توان به روش‌هایی همچون کشف، طبقه‌بندی، شناسایی و تفکیک اشیا اشاره کرد. امروزه بیشتر تحقیقات، در زمینه فناوری سنجش از دور ابرطیفی، بر طبقه‌بندی این تصاویر تأکید دارد. طبقه‌بندی یا تبدیل تصاویر به نقشه موضوعی بر اثر عواملی، از جمله پیچیدگی منطقه مورد مطالعه، انتخاب داده، پردازش تصویر و الگوریتم مورد استفاده، در معرض چالش جدی قرار دارد و ممکن است در موفقیت طبقه‌بندی تأثیر بگذارد (Gonzalez & Woods, 2002; Acquarelli et al., 2018). تصاویر ابرطیفی، به دلیل داشتن تعداد زیاد باند، دارای مشکل کمبود نمونه‌های برجسب‌گذاری شده در فرایند طبقه‌بندی‌اند. یکی از راه‌حل‌های رفع این مشکل کاهش تعداد باندهاست. بدین منظور روش‌های گوناگونی، مانند انتخاب ویژگی و استخراج ویژگی، مطرح شده است (Chang, 2003). در دسته انتخاب ویژگی، با انتخاب زیرمجموعه‌ای

(نیمه)بهبینه از مجموعه باندهای طیفی در دسترس، ابعاد فضا کاهش می‌یابد. در سال‌های اخیر، انتخاب ویژگی از داده‌های ابرطیفی با استفاده از الگوریتم‌های ابتکاری مانند الگوریتم ژنتیک، به‌منزله روش جست‌وجو در الگوریتم‌های انتخاب ویژگی، بسیار مورد توجه قرار گرفته است (Zhuo & Zheng, 2008). در دسته استخراج ویژگی، با انتقال فضا به فضایی با ابعاد کمتر، طبقه‌بندی در فضای جدید انجام می‌شود. از بین الگوریتم‌های این دسته می‌توان به الگوریتم پرکاربرد آنالیز مؤلفه‌های اصلی (PCA) اشاره کرد (Theodoridis & Koutroumbas, 2006).

به‌طور کلی روش‌های طبقه‌بندی تصاویر ابرطیفی در دو دسته قرار می‌گیرند؛ دسته نخست روش‌های طبقه‌بندی طیفی یا مبتنی بر پیکسل‌اند که در آنها هر پیکسل، فقط با استفاده از اطلاعات طیفی خود و بدون در نظر گرفتن اطلاعات موجود در پیکسل‌های همسایه، به کلاسی مشخص اختصاص می‌یابد (Vapnik, 1995). از جمله این روش‌ها می‌توان به الگوریتم‌های ماشین بردار پشتیبان (SVM) و شبکه عصبی پرسپترون چندلایه (MLP) اشاره کرد. دسته دوم روش‌های طبقه‌بندی طیفی- مکانی یا مبتنی بر شیء است که، علاوه بر اطلاعات طیفی پیکسل‌ها، از اطلاعات پیکسل‌های همسایه در آنها استفاده می‌شود (Tarabalka et al., 2010; Fauvel et al., 2013). به دلیل حساسیت فراوان سنجنده‌های ابرطیفی، معمولاً سیگنال‌های ناشناخته زیادی در تصاویر ثبت می‌شوند که هیچ‌گونه اطلاعاتی درباره آنها وجود ندارد. به‌ویژه بسیاری از این سیگنال‌ها متعلق به اجسامی دارای ابعادی کوچک است که با چشم دیده نمی‌شوند. شناسایی این اهداف با روش‌های رایج طبقه‌بندی که فقط از اطلاعات طیفی استفاده می‌کنند، در چنین شرایطی امکان‌پذیر نیست و علاوه بر این باید پردازش‌ها

1. Pattern Recognition
2. Principal Component Analysis
3. Support Vector Machines
4. Multilayer Perceptron

متشکل از ویژگی‌های ساختاری و طیفی، به ترتیب براساس داده‌های لیدار و ابرطیفی، ایجاد شد. در این روش، با توجه به پایداری SVM در فضای دارای ابعاد بالا، SVM به‌منزله طبقه‌بندی‌کننده انتخاب شد. اکبری (۲۰۱۹) ابتدا ابعاد تصویر ابرطیفی را با الگوریتم ژنتیک وزن‌دار کاهش داد و سپس، با ترکیب دو الگوریتم سلسله‌مراتبی<sup>۱۹</sup> و MLP، آن را طبقه‌بندی کرد. لی<sup>۲۰</sup> و همکاران (۲۰۱۹) از شبکه‌های عصبی کانولوشنی (CNNs)<sup>۲۱</sup> برای طبقه‌بندی تصاویر ابرطیفی بهره بردند. CNNها از طریق در نظر گرفتن ارتباطات محلی می‌توانند اطلاعات مکانی را استخراج کنند. همچنین در این شبکه‌ها، استراتژی اشتراک وزن باعث کاهش چشمگیری در پارامترهای آموزش دادنی شبکه می‌شود. دینگ<sup>۲۲</sup> و همکاران (۲۰۲۰) ساختاری برای طبقه‌بندی تصاویر ابرطیفی مطرح کردند که آمیزه روش چندین رمزگذار خودکار (SAE)<sup>۲۳</sup> و طبقه‌بندی‌کننده SVM بود. این ساختار روی ویژگی‌های طیفی و مکانی استخراج شده از ماتریس GLCM اعمال شد. احمد<sup>۲۴</sup> و همکاران (۲۰۲۲) چند استراتژی را به‌منظور بهبود

به کمک ویژگی‌های مکانی اهداف انجام شود (Hong et al., 2020). بندیکتسون<sup>۱</sup> و همکاران (۲۰۰۳) روش نیم‌رخ ریخت‌شناسی<sup>۲</sup> را پیشنهاد کردند. این شیوه شامل ترکیب فیلترهای باز کردن<sup>۳</sup> و بستن<sup>۴</sup> می‌شود. اعمال این روش روی باندهای متفاوت تصویر با نام نیم‌رخ ریخت‌شناسی توسعه‌یافته<sup>۵</sup> شناخته می‌شود (Pesaresi & Benediktsson, 2001). ایجاد نیم‌رخ ریخت‌شناسی توسعه‌یافته روی تمامی باندهای تصویر ابرطیفی نادرست است و باعث ایجاد ویژگی‌های وابسته می‌شود؛ از این رو کاهش تعداد باندهای تصویر ابرطیفی، پیش از اعمال نیم‌رخ ریخت‌شناسی، الزامی است. بنابراین بندیکتسون (۲۰۰۵) روش نیم‌رخ ریخت‌شناسی توسعه‌یافته را روی چندین ویژگی به‌دست‌آمده از تبدیل PCA، که بیشترین واریانس را دارند، اعمال کرد. هوانگ و جانگ<sup>۶</sup> (۲۰۰۹) اطلاعات مکانی به‌دست‌آمده از ماتریس هم‌وقوع درجات خاکستری (GLCM)<sup>۷</sup> را برای طبقه‌بندی داده ابرطیفی به کار بردند. در روش پیشنهاد شده، ابتدا ویژگی‌های بافت<sup>۸</sup> از روی ماتریس GLCM و با استفاده از چهار اندازه‌گیری، یعنی مؤلفه دوم زاویه‌ای<sup>۹</sup>، درجه تباین<sup>۱۰</sup>، آنتروپی<sup>۱۱</sup> و یکنواختی<sup>۱۲</sup> استخراج شد؛ سپس الگوریتم PCA روی ویژگی‌های به‌دست‌آمده اعمال شد و مؤلفه‌های اصلی به‌منزله ویژگی‌های ورودی برای طبقه‌بندی‌کننده بیشترین شباهت<sup>۱۳</sup> انتخاب شدند. تارابالکا<sup>۱۴</sup> و همکاران (۲۰۱۰) از الگوریتم جنگل پوشای مینیمم (MSF)<sup>۱۵</sup> به‌منظور طبقه‌بندی طیفی- مکانی تصاویر ابرطیفی استفاده کردند. MSF، براساس ویژگی‌هایی مانند یکنواختی، اشیای داخل تصویر (مجموعه پیکسل‌هایی با ویژگی یکسان) را شناسایی می‌کند (Tarabalka et al., 2011). اکبری<sup>۱۶</sup> (۲۰۱۷)، با به‌کارگیری الگوریتم ژنتیک وزن‌دار و به کمک الگوریتم MSF، تصویر ابرطیفی را طبقه‌بندی کرد. حسنی<sup>۱۷</sup> و همکاران (۲۰۱۷) طبقه‌بندی ترکیبی بهینه‌ای از تصاویر ابرطیفی و لیدار، براساس جست‌وجوی فاخته<sup>۱۸</sup>، پیشنهاد کردند. برای ادغام تصاویر ابرطیفی و لیدار، فضای ویژگی ترکیبی‌ای

1. Benediktsoon
2. Morphological Profiles
3. Opening
4. Closing
5. Extended Morphological Profiles
6. Huang & Zhang
7. Gray Level Co-occurrence Matrix
8. Texture Features
9. Angular Second Moment
10. Contrast
11. Entropy
12. Homogeneity
13. Maximum Likelihood
14. Tarabalka
15. Minimum Spanning Forest
16. Akbari
17. Hasani
18. Cuckoo Search
19. Hierarchical Algorithm
20. Li
21. Convolutional Neural Networks
22. Ding
23. Several Automatic Encoders
24. Ahmad

۳، آزمون‌های عملی مطرح می‌شود و در بخش پایانی نیز، نتیجه‌گیری موارد می‌آید.

## ۲- مواد و روش‌ها

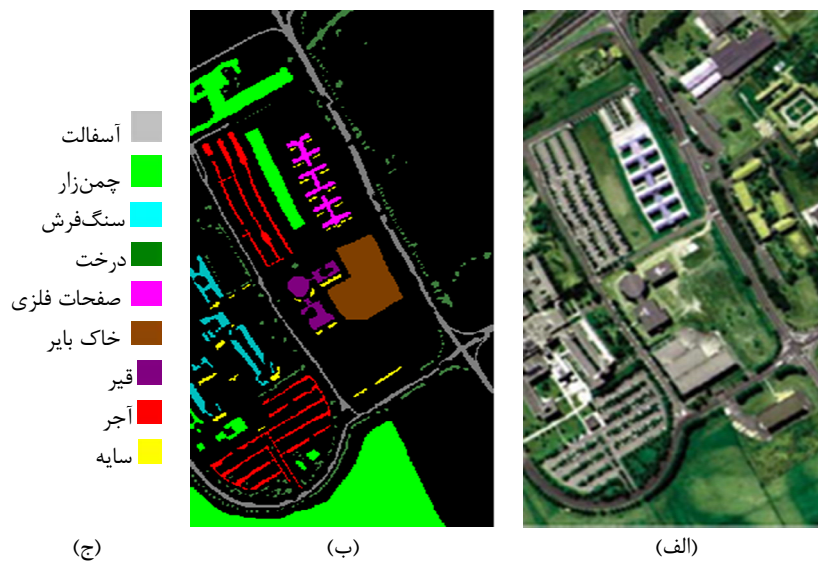
### ۲-۱- داده‌های مورد آزمون

در این تحقیق برای ارزیابی روش پیشنهادی، از دو تصویر ابرطیفی پائویا<sup>۱</sup> و برلین<sup>۲</sup>، که جزء تصاویر معیار در حوزه سنسجس از دور ابرطیفی‌اند و برای بررسی الگوریتم‌های طبقه‌بندی پیشنهادی به کار می‌روند، استفاده شد (Amigo, 2019). تصویر پائویا با استفاده از سنسجده ROSIS-03 و از منطقه شهری پائویا در کشور ایتالیا دریافت شده است (Chi et al., 2009). تصاویر این مجموعه داده دارای نه کلاس و قدرت تفکیک مکانی ۱/۳ متر است. شکل ۱ ترکیب رنگی و نقشه واقعیت زمینی تصویر پائویا را نشان می‌دهد. این تصویر شامل ۶۱۰×۳۴۰ پیکسل و ۱۰۳ باند طیفی و همچنین دربرگیرنده کلاس‌های آسفالت، چمن‌زار، سنگ‌فرش، درخت، صفحات فلزی، خاک بایر، قیر، آجر و سایه است. مجموعه داده برلین شامل پنج کلاس پوشش گیاهی، ساختمان، سنگ‌فرش، خاک و آب می‌شود که (دستیابی در آدرس <http://www.dlr.de>) از طریق سنسجده HyMap دریافت شده است. تصویر مورد نظر دارای قدرت تفکیک مکانی ۳/۵ متر و شامل ۱۱۴ باند طیفی در ابعاد ۳۰۰×۳۰۰ پیکسل است. ترکیب رنگی از این تصویر، به همراه نقشه واقعیت زمینی آن، در شکل ۲ نشان داده شده است.

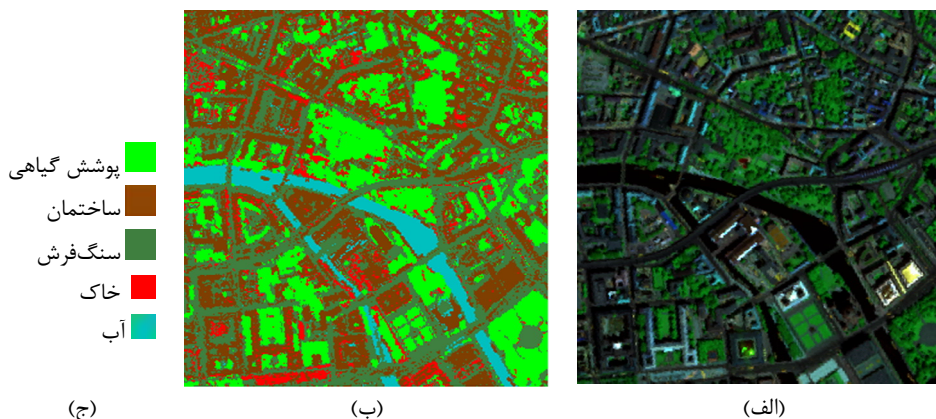
عملکرد روش یادگیری عمیق<sup>۱</sup> در تصاویر ابرطیفی مطرح کردند. آنها، با این هدف، روش یادگیری عمیق را در سه حالت ویژگی‌های طیفی، ویژگی‌های مکانی و ویژگی‌های طیفی- مکانی تجزیه و تحلیل کردند. با توجه به مطالعات انجام شده، نتایجی که الگوریتم طبقه‌بندی MLP تا کنون به آنها دست یافته بهتر از دیگر الگوریتم‌های طبقه‌بندی در تصاویر ابرطیفی بوده است (Lin et al., 2022; Tan & Xue, He, 2021; Wang et al., 2022). در تحقیقات پیشین از تکنیک‌های کاهش ابعاد و استخراج برخی ویژگی‌های مکانی، در طبقه‌بندی تصاویر ابرطیفی، به صورت مستقل استفاده شده بود. حال آنکه در این تحقیق سعی می‌شود، به صورت هم‌زمان و به کمک تکنیک‌های کاهش ابعاد و استخراج ده ویژگی مکانی، الگوریتم MLP بهبود داده شود.

در پژوهش حاضر، تصویر ابرطیفی در محیطی شهری طبقه‌بندی شده است. محیط‌های شهری، از لحاظ عناصری که در آنها به کار رفته است، ویژگی‌های پیچیده‌ای دارند و بنابراین داده‌های ابرطیفی به شناسایی، استخراج و تولید نقشه از عناصر سازنده آنها کمک مؤثری می‌کنند. شناسایی مواد گوناگون در محیط‌های شهری، در زمینه‌های گوناگون همچون ارتباطات تلفن‌های همراه، واقعیت مجازی، معماری و مدل‌سازی شهری و برنامه‌ریزی و مدیریت شهرها، اهمیت بسیاری دارد (Pan et al., 2020). در روش پیشنهادی، ابتدا ابعاد تصویر ابرطیفی به کمک الگوریتم PCA کاهش می‌یابد، سپس ده ویژگی مکانی میانگین<sup>۲</sup>، انحراف معیار<sup>۳</sup>، درجه تباین، یکنواختی، همبستگی<sup>۴</sup>، نبود تشابه<sup>۵</sup>، انرژی<sup>۶</sup>، آنتروپی، تبدیل موجک<sup>۷</sup> و فیلتر گابور<sup>۸</sup> از روی باندهای کاهش یافته استخراج می‌شود. در ادامه، الگوریتم ژنتیک وزن‌دار بر ویژگی‌های طیفی و مکانی به دست آمده اعمال می‌شود؛ در انتها نیز، ویژگی‌های حاصل به کمک الگوریتم MLP طبقه‌بندی می‌شود. در بخش ۲ این پژوهش، روش طبقه‌بندی طیفی- مکانی پیشنهادی بیان و در بخش

1. Deep Learning
2. Mean
3. Standard Deviation
4. Correlation
5. Dissimilarity
6. Energy
7. Wavelet Transform
8. Gabor Filter
9. Pavia
10. Berlin



شکل ۱. ترکیب رنگی- کاذب تصویر پاولیا (الف)؛ نقشه واقعیت زمینی به منظور ارزیابی کمی- کیفی (ب)؛ راهنما (ج)



شکل ۲. ترکیب رنگی- کاذب تصویر برلین (الف)؛ نقشه واقعیت زمینی به منظور ارزیابی کمی- کیفی (ب)؛ راهنما (ج)

داده‌های ابرطیفی، کاربردی چشمگیر دارد. این تبدیل خطی، در واقع، عبارت است از تکنیک ساده‌سازی داده‌ها از طریق کاهش مجموعه داده‌های چندبعدی (Theodoridis & Koutroumbas, 2006). در مرحله دوم، پس از استخراج ویژگی‌های مکانی، ویژگی‌های طیفی و مکانی به دست آمده به کمک الگوریتم ژنتیک وزن دار کاهش می‌یابد. در انتها، ویژگی‌های حاصل به کمک الگوریتم MLP طبقه بندی می‌شوند.

### ۲-۲-۱- ویژگی‌های مکانی

ویژگی‌های گوناگونی را می‌توان از پیکسل‌های تصویر،

کلاس‌های مشخص شده در هر تصویر با نوع و عوارض در آن تصویر متناسب است. برای هر یک از کلاس‌ها در هر دو داده تصویری، به صورت تصادفی حدود ۱۰٪ از نمونه‌های برچسب گذاری شده به منزله داده آموزشی و مابقی آنها، یعنی حدود ۹۰٪، به منزله داده تست انتخاب شدند.

### ۲-۲- روش تحقیق

در روش پیشنهادی، ابتدا ابعاد تصویر ابرطیفی به کمک الگوریتم PCA کاهش می‌یابد. الگوریتم PCA روش آماری رایجی است که، در تجزیه و تحلیل و فشرده سازی

$$Sd_x = \sqrt{\frac{\sum x(x-Nx)^2}{M} - \mu_x^2} \quad \text{رابطه (۳)}$$

$$Sd_y = \sqrt{\frac{\sum y(y-Ny)^2}{M} - \mu_y^2} \quad \text{رابطه (۴)}$$

در این روابط،  $\mu_x$  میانگین در جهت سطرها و  $\mu_y$  میانگین در جهت ستون‌هاست.

### درجه تباین

هرچه عناصر اطراف قطر اصلی GLCM بیشتر باشند، یعنی میزان روشنایی پیکسل‌های هم‌جوار شباهت بیشتری با هم دارند؛ در صورتی که اگر عناصر غیرصفر ماتریس از قطر اصلی فاصله بگیرند، پیکسل‌های هم‌جوار اختلاف زیادی را نشان می‌دهند. درجه تباین برای اندازه‌گیری کمی این شباهت‌ها یا اختلاف‌ها پیشنهاد شده است و مطابق رابطه (۵) محاسبه می‌شود (Gonzalez & Woods, 2002).

$$C = \sum_x \sum_y (x - y)^2 P_d(x, y) \quad \text{رابطه (۵)}$$

$P_d(x, y)$  برابر است با تعداد تکرار جفت درجه خاکستری  $x$  و  $y$  که با فاصله  $d$  از یکدیگر قرار گرفته‌اند.

### یکنواختی

پارامتر یکنواختی میزان پراکندگی GLCM را از عناصر قطری آن نشان می‌دهد و براساس رابطه (۶) محاسبه می‌شود (Huang & Zhang, 2009).

$$H = \sum_x \sum_y \frac{P_d(x, y)}{1 + |x - y|} \quad \text{رابطه (۶)}$$

محدوده تغییرات یکنواختی بین صفر تا یک است. زمانی که ماتریس GLCM قطری باشد، یکنواختی برابر یک است؛ در این حالت، پیکسل‌های بسیاری با مقادیر درجه خاکستری یکسان یا خیلی مشابه در تصویر وجود دارند.

### همبستگی

این پارامتر میزان همبستگی بین پیکسل را با همسایگی‌های خود در کل تصویر نشان می‌دهد و با رابطه (۷) تعریف می‌شود (Haralick et al., 1973).

به‌منزله داده‌های پیکسل پایه، استخراج و از آنها در طبقه‌بندی بهره برد (Gonzalez & Woods, 2002). با در نظر گرفتن پنجره‌ای همسایگی با اندازه مناسب در اطراف هر پیکسل و انتخاب یکی از جهات معین، روابط درجات خاکستری پیکسل‌ها از فضای تصویر به فضای ماتریس هم‌رخداد منتقل می‌شود. سپس با توجه به اندازه پنجره همسایگی و جهت انتخاب‌شده، مقادیر توصیفگرهای بافت شناخته‌شده‌ای در فضای GLCM اندازه‌گیری می‌شوند (Huang & Zhang, 2009). در روش پیشنهادی، ده ویژگی مکانی میانگین، انحراف معیار، درجه تباین، یکنواختی، همبستگی، نبود تشابه، انرژی، آنتروپی، تبدیل موجک و فیلتر گابور از اطلاعات همسایگی پیکسل‌های تصویر استخراج شد.

### میانگین

از آنجاکه GLCM ماتریسی دوبعدی است، می‌توان میانگین را در دو جهت افقی و عمودی (سطرها و ستون‌ها) محاسبه کرد. مقدار میانگین طبق روابط (۱) و (۲)، به ترتیب، در دو جهت سطرها و ستون‌ها محاسبه می‌شود (Haralick et al., 1973).

$$\mu_x = \frac{\sum x(x-Nx)^2}{M} \quad \text{رابطه (۱)}$$

$$\mu_y = \frac{\sum y(y-Ny)^2}{M} \quad \text{رابطه (۲)}$$

در این معادلات،  $x$  و  $y$  به ترتیب، شماره سطر و ستون،  $N_x$  مجموع تعداد پیکسل‌ها در سطر  $x$ ،  $N_y$  مجموع تعداد پیکسل‌ها در ستون  $y$  و  $M$  تعداد کل پیکسل‌هاست.

### انحراف معیار

مقدار پارامتر انحراف معیار، وقتی مقادیر درجه روشنایی از میانگین درجات روشنایی داخل پنجره فاصله زیادی داشته باشند، افزایش می‌یابد. بنابراین بافت‌هایی که یکنواخت و متجانس‌اند انحراف معیار پایینی دارند. انحراف معیار در دو جهت سطرها و ستون‌ها طبق این روابط محاسبه می‌شوند (Haralick et al., 1973).

### آنتروپی

میزان بی‌نظمی در تصویر را اندازه‌گیری می‌کند و بدین صورت تعریف می‌شود (Huang & Zhang, 2009):

$$E = - \sum_x \sum_y P_d(x, y) \log P_d(x, y) \quad (10)$$

اگر عناصر GLCM خیلی کوچک باشند، مقدار آنتروپی افزایش می‌یابد؛ بنابراین آنتروپی بالا نشان‌دهنده ناهمگنی و آنتروپی پایین دلیل وجود یکنواختی در بافت است. حداقل مقدار آنتروپی صفر است که بیانگر بافت کاملاً یکنواخت است.

### تبدیل موجک

تبدیل موجک مطابق رابطه (11) محاسبه می‌شود (Mallat, 1999).

$$(W)_{\psi_f(a, b)} = \langle f(x), \psi_{a,b}(x) \rangle = \int f(x) \psi_{a,b}(x) dx$$

رابطه (11)

در ایسن معادله،  $\psi_{a,b}(x) = |a|^{-\frac{1}{2}} \psi(\frac{x-b}{a})$ ،  $\int \psi(t) dx = 0$  و  $b$  به ترتیب، منطقه فرکانس و زمان سیگنال را تعیین می‌کنند.

### فیلتر گابور

این فیلتر یک موج صفحه‌ای سینوسی با فرکانس و جهت خاص و با پوش گاوسی مدوله شده‌ای است که در معادلات (12) و (13) آورده شده است (Shaw & Manolakis, 2002).

$$f_{mn}^{real}(x, y) = \frac{1}{2\pi\sigma_m^2} \exp\left\{-\frac{x^2+y^2}{2\sigma_m^2}\right\} \times \cos(2\pi(u_m x \cos\theta_n + u_m y \sin\theta_n))$$

رابطه (12)

$$f_{mn}^{imag}(x, y) = \frac{1}{2\pi\sigma_m^2} \exp\left\{-\frac{x^2+y^2}{2\sigma_m^2}\right\} \times \sin(2\pi(u_m x \cos\theta_n + u_m y \sin\theta_n))$$

رابطه (13)

$m$  و  $n$  به ترتیب، شاخص‌های مقیاس و جهت‌اند و فرکانس مرکزی مقیاس است.

$$Co = \frac{1}{\sigma_x \sigma_y} \sum_x \sum_y (x - \mu_x)(y - \mu_y) P_d(x, y)$$

رابطه (7)

مقادیر  $\mu_x$ ،  $\mu_y$ ،  $\sigma_x$  و  $\sigma_y$  به ترتیب، متوسط و واریانس  $P_d(x)$  و  $P_d(y)$  هستند و برای محاسبه این مقادیر، از روابط  $P_d(x) = \sum_y P_d(x, y)$  و  $P_d(y) = \sum_x P_d(x, y)$  استفاده می‌شود.

### نبود تشابه

این پارامتر همانند پارامتر درجه تباین است و به صورت تغییر جفت مقادیر خاکستری در تصویر تعریف می‌شود؛ با این تفاوت که، در درجه تباین، مقادیر وزن به صورت مربعی رشد می‌کند. پارامتر نبود تشابه با رابطه (8) محاسبه می‌شود (Gonzalez & Woods, 2002).

$$Dis = \sum_x \sum_y |x - y| P_d(x, y) \quad (8)$$

با توجه به روابط (5) و (8)، انتظار می‌رود که دو اندازه‌گیری درجه تباین و نبود تشابه، در برخورد با ناحیه بافتی مشابه، رفتاری یکسان داشته باشند چون کمیت یکسانی را فقط با مقادیر وزن متفاوت اندازه می‌گیرند؛ به گونه‌ای که درجه تباین همواره مقادیر بزرگ‌تری را، در مقایسه با نبود تشابه، ایجاد می‌کند. مقادیر نبود تشابه بین صفر تا یک متغیر است و زمانی که مقدار خاکستری پیکسل مرجع با پیکسل همسایه برابر با حد نهایی مقادیر خاکستری موجود در بافت تصویر باشد، مقداری ماکزیمم دارد.

### انرژی

پارامتر انرژی اطلاعات بافت مفیدی را در زمینه تشخیص عوارض شهری ایجاد می‌کند. با استفاده از این پارامتر، مجموع مربعات مقادیر ماتریس GLCM محاسبه و به کمک رابطه (9) تعریف می‌شود (Gonzalez & Woods, 2002).

$$SM = \sum_x \sum_y P_d(x, y)^2 \quad (9)$$

وقتی تصویر یکنواختی خوبی داشته باشد یا پیکسل‌ها خیلی شبیه هم باشند، مقدار این پارامتر بالاست.



## ۲-۲-۲- الگوریتم ژنتیک وزن دار

الگوریتم ژنتیک یکی از روش‌های بهینه‌سازی جست‌وجوی عمومی تطابقی است که مستقیماً بر پایه انتخاب داروین و ژنتیک در سیستم‌های بیولوژیک بنا شده است. این الگوریتم جایگزین خوبی برای روش‌های جست‌وجوی اکتشافی معمول شمرده می‌شود. الگوریتم ژنتیک رویه‌ای تکراری دارد. طی هر بار تکرار الگوریتم (نسل)، افراد موجود در جمعیت فعلی براساس میزان شایستگی‌شان مرتب می‌شوند و با استفاده از عملگرهای ژنتیک انتخاب<sup>۱</sup>، تقاطع<sup>۲</sup> و جهش<sup>۳</sup>، جمعیت جدیدی از راه‌حل‌ها به وجود می‌آید. این رویه، تا زمان برقراری شرط خاتمه الگوریتم، ادامه می‌یابد (Zhuo & Zheng, 2008).

در الگوریتم ژنتیک، هر راه‌حل با یک رشته به نام کروموزوم نمایش داده می‌شود و لازم است تابع هدف، برای هدایت الگوریتم به سوی پاسخ بهینه، تعریف شود (Zhuo & Zheng, 2008; Huang & Wang, 2006).

الگوریتم باینری ژنتیک، هر زیرمجموعه از ویژگی‌ها با استفاده از یک رشته باینری، به منزله کروموزومی با ابعاد  $n$  نمایش داده می‌شود که در آن اعداد ۱ و ۰، به ترتیب، بیانگر حضور یا نبود ویژگی خاصی اند (Zhuo & Zheng, 2008)؛ در صورتی که این رشته، در الگوریتم ژنتیک وزن دار، دارای مقادیر بین صفر و یک است. سپس هر کروموزوم با استفاده از تابع برازندگی ارزیابی می‌شود که احتمال هر کروموزوم برای بقا و انتقال به نسل بعد را نشان می‌دهد. در این تحقیق، از پارامتر ضریب کاپای<sup>۴</sup> طبقه‌بندی MLP به منظور تعیین ارزش هر کروموزوم استفاده شده و علاوه بر این، روش چرخ رولت<sup>۵</sup> برای عملگر انتخاب به کار رفته است. در این روش، احتمال انتخاب هر کروموزوم متناسب با مقدار شایستگی آن است. از عملگر تقاطع با یک نقطه برش<sup>۶</sup> و نیز عملگر جهش، برای جلوگیری از انتخاب بهینه‌های محلی استفاده شد. شرط توقف در این تحقیق به صورت شرط پویا در نظر گرفته شد؛ بدین صورت که اگر تا قبل از تکرار مشخص — که صد نسل در نظر گرفته شده است — بهبودی در میزان تابع هدف رخ

ندهد، الگوریتم متوقف می‌شود و در غیر این صورت، تکرار تا نسل صدم ادامه می‌یابد.

## ۲-۲-۳- الگوریتم MLP

یکی از پایه‌ای‌ترین مدل‌های عصبی در دسترس مدل پرسپترون چندلایه یا MLP است که عملکرد انتقالی مغز انسان را شبیه‌سازی می‌کند. در این نوع شبکه عصبی، بیشتر رفتار شبکه‌ای مغز انسان و انتشار سیگنال در آن مد نظر بوده است و از این رو، گه‌گاه با نام شبکه‌های پیش‌خورد<sup>۷</sup> نیز خوانده می‌شوند. هر یک از سلول‌های عصبی مغز انسان، موسوم به نورون<sup>۸</sup>، پس از دریافت ورودی (از سلول عصبی یا غیرعصبی دیگر)، روی آن پردازشی انجام می‌دهد و نتیجه را به سلولی دیگر (عصبی یا غیرعصبی) انتقال می‌دهد. این رفتار تا حصول نتیجه‌ای مشخص ادامه دارد که احتمالاً در نهایت، منجر به تصمیم، پردازش، تفکر و یا حرکتی خواهد شد. در MLP، حداقل سه لایه از نورون وجود خواهد داشت: لایه ورودی<sup>۹</sup>، لایه پنهان<sup>۱۰</sup> و لایه خروجی<sup>۱۱</sup>. نورونهای شبکه عصبی واحدهای محاسباتی در شبکه عصبی محسوب می‌شوند. در این شبکه عصبی، از خروجی‌های لایه اول (ورودی) به صورت ورودی‌های لایه بعدی (پنهان) استفاده می‌شود؛ این کار به همین شیوه ادامه پیدا می‌کند تا اینکه، پس از تعداد خاصی از لایه‌ها، خروجی‌های آخرین لایه پنهان به منزله ورودی‌های لایه خروجی استفاده می‌شود. به لایه‌هایی که بین لایه‌های ورودی و خروجی قرار می‌گیرند لایه‌های پنهان گفته می‌شود. MLP، مانند

1. Select
2. Crossover
3. Mutation
4. Kappa Coefficient
5. Roulette Wheel
6. Single Point
7. Feedforward Networks
8. Neuron
9. Input Layer
10. Hidden Layer
11. Output Layer

می‌شود، ابعاد تصویر ابرطیفی به کمک الگوریتم PCA کاهش یافت. تمرکز PCA روی اجزای اصلی ماتریس ویژگی‌هاست که بیشترین واریانس را حفظ می‌کنند. جدول ۱ تعداد باندها برای دو تصویر ابرطیفی مورد استفاده را، بعد از اجرای الگوریتم PCA نشان می‌دهد. سپس ده ویژگی مکانی اشاره شده در بخش ۲، در مورد ویژگی‌های طیفی به دست آمده از مرحله قبل، استخراج شد. در ادامه، ابعاد ویژگی‌های طیفی- مکانی حاصل به کمک الگوریتم ژنتیک وزن دار کاهش یافت.

شبکه‌های عصبی پرسپترون تک‌لایه، حاوی مجموعه‌ای از وزن‌ها نیز است که باید برای آموزش و یادگیری شبکه عصبی، تنظیم شوند.


شکل ۳ مراحل روش طبقه‌بندی طیفی- مکانی پیشنهادی را نشان می‌دهد. همان‌طور که ملاحظه می‌شود، نوآوری‌های اصلی این تحقیق شامل استخراج اطلاعات مکانی و به کارگیری تکنیک کاهش ابعاد، در دو مرحله قبل و پس از استخراج اطلاعات مکانی در فرایند طبقه‌بندی، با کمک الگوریتم MLP است.

### ۳- نتایج و بحث

در آزمایش‌های انجام شده، روش طبقه‌بندی طیفی- مکانی پیشنهادی روی دو تصویر ابرطیفی پاویا و برلین اجرا شد. در اولین گام، همان‌طور که در شکل ۳ ملاحظه

جدول ۱. تعداد باندهای انتخاب شده با به کارگیری الگوریتم PCA

در دو تصویر ابرطیفی	
تعداد باندهای انتخاب شده	داده تصویری
۵۳	پاویا
۴۷	برلین



شکل ۳. مراحل روش پیشنهادی

شد و سپس پارامترهای دقت کلی (OA)<sup>۱</sup>، ضریب کاپا (K)، نویز (N)<sup>۲</sup> و دقت تولیدکننده<sup>۳</sup>، مختص هر کلاس، استخراج شد.

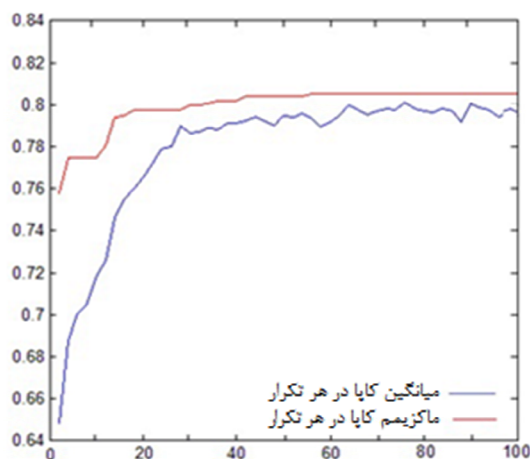
#### الف) تصویر ابرطیفی پاویا

شکل ۵ نقشه‌های طبقه‌بندی حاصل از به‌کارگیری روش پیشنهادی و الگوریتم‌های SVM، MLP و MSF را نشان می‌دهد. همان‌طور که ملاحظه می‌شود، نقشه حاصل از روش پیشنهادی در مقایسه با سایر الگوریتم‌ها، شامل مناطق یکنواخت‌تری است.

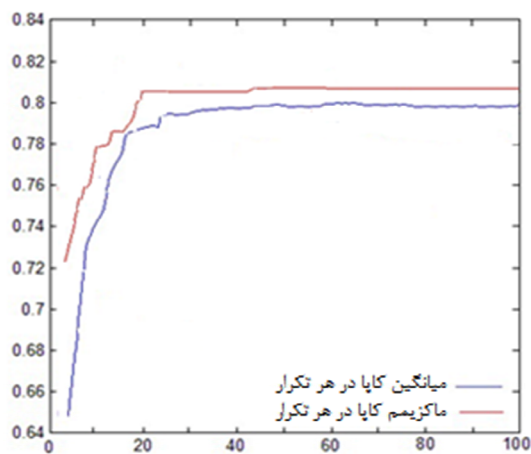
جدول ۲ مقادیر پارامترهای دقت نقشه‌های طبقه‌بندی به‌دست‌آمده از تصویر ابرطیفی پاویا را نشان می‌دهد. همان‌طور که ملاحظه می‌شود، روش پیشنهادی باعث افزایش ۱۳، ۷ و ۶ درصدی پارامتر ضریب کاپا، به‌ترتیب در قیاس با الگوریتم‌های SVM، MLP و MSF شده است. دقت همه کلاس‌ها نیز، به‌جز کلاس‌های سنگ‌فرش و قیر، با استفاده از روش پیشنهادی به‌بیشتر از ۹۰٪ رسیده است. دلیل این افزایش دقت روش پیشنهادی ممکن است استفاده از اطلاعات نزدیک‌ترین همسایگی و دو مرحله کاهش ابعاد باشد.

در آزمون‌های انجام‌شده برای الگوریتم ژنتیک، کروموزوم‌ها دارای ژن‌هایی برابر با تعداد ویژگی‌های طیفی و مکانی‌اند. در این آزمون‌ها، میزان تقاطع و جهش به‌ترتیب، برابر با ۰/۵ و ۰/۰۵ در نظر گرفته شد. همچنین برای ایجاد تناسب بین دو پارامتر دقت و زمان محاسبات، تعداد جمعیت اولیه ۳۰ و حداکثر تعداد تکرار برای توقف ۱۰۰ در نظر گرفته شد. البته در عمل، در مورد هر دو تصویر ابرطیفی، با توجه به اینکه شرط فعال برای توقف الگوریتم به کار رفته است، روند تکرار به مرحله ۱۰۰ نمی‌رسد و پیش از آن، الگوریتم به وضعیت پایدار می‌رسد و متوقف می‌شود. شکل ۴ نمودار همگرایی الگوریتم ژنتیک را برای دو تصویر ابرطیفی مورد استفاده نشان می‌دهد.

الگوریتم طبقه‌بندی MLP با سه لایه پنهان که شامل ۵، ۶ و ۸ نورون است، اجرا شد و ارزیابی آن با ۵۰۰ تکرار انجام شد. روش طبقه‌بندی پیشنهادی بیان‌شده، با الگوریتم‌های SVM، MLP و MSF مقایسه شد. به‌منظور ارزیابی دقت آزمون‌های انجام‌شده نیز، ابتدا ماتریس خطا به کمک داده واقعی زمینی تشکیل




(ب)



(الف)

شکل ۴. نمودار همگرایی الگوریتم ژنتیک در تصویر پاویا (الف)؛ برلین (ب)

1. Overall Accuracy
2. Noise
3. Producer Accuracy



(الف) (ب) (ج) (د)

■ آسفالت ■ چمن‌زار ■ سنگ‌فرش ■ درخت ■ صفحات فلزی ■ خاک بایر ■ قیر ■ سایه ■ آجر

شکل ۵. نقشه‌های طبقه‌بندی حاصل از الگوریتم SVM (الف)؛ الگوریتم MLP (ب)؛ الگوریتم MSF (ج)؛ روش پیشنهادی (د)

جدول ۲. مقادیر پارامترهای دقت آزمون‌های انجام شده در مورد تصویر ابرطیفی پاولیا

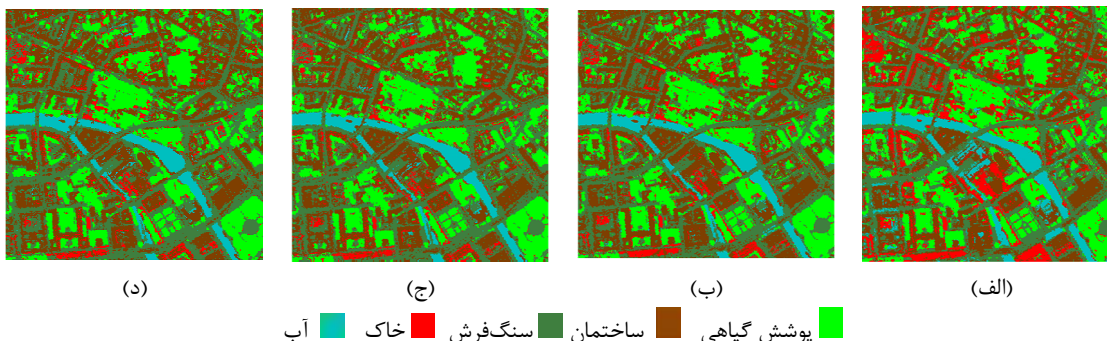
روش پیشنهادی	MSF	MLP	SVM	
۹۳/۴	۸۸/۶	۸۷/۸	۸۰/۱	OA
۹۱/۲	۸۵/۲	۸۴/۲	۷۸/۰	(%)K
۰/۰۴	۰/۰۷	۰/۰۷	۰/۱۰	N
۹۳/۱	۸۸/۸	۸۶/۴	۸۰/۰	آسفالت
۹۶/۷	۹۰/۳	۸۷/۲	۸۴/۲	چمن‌زار
۸۴/۲	۷۳/۷	۷۴/۲	۶۴/۲	سنگ‌فرش
۹۲/۹	۸۷/۹	۸۸/۰	۷۸/۴	درخت
۹۵/۴	۸۸/۲	۸۷/۸	۸۶/۲	صفحات فلزی
۹۰/۲	۹۰/۲	۸۹/۴	۸۴/۹	خاک بایر
۸۹/۹	۸۵/۵	۸۳/۳	۸۰/۳	قیر
۹۰/۳	۸۴/۲	۸۴/۵	۷۷/۲	آجر
۹۳/۵	۸۲/۰	۸۶/۳	۸۰/۵	سایه

### ب) تصویر ابرطیفی برلین

شکل ۶ نقشه‌های طبقه‌بندی را برای تصویر ابرطیفی برلین نشان می‌دهد. مشاهده می‌شود که نقشه روش پیشنهادی، در مقایسه با سایر الگوریتم‌ها، نویز کمتری دارد.

### جدول ۳ مقادیر پارامترهای دقت نقشه‌های

طبقه‌بندی به دست آمده از تصویر ابرطیفی برلین را نشان می‌دهد. در این تصویر نیز، روش پیشنهادی باعث افزایش دقت شده است. این افزایش در پارامتر ضریب کاپا به میزان ۹، ۶ و ۵٪ به ترتیب نسبت به الگوریتم‌های SVM، MLP و MSF است.



شکل ۶. نقشه‌های طبقه‌بندی حاصل از الگوریتم SVM (الف)؛ الگوریتم MLP (ب)؛ الگوریتم MSF (ج)؛ روش پیشنهادی (د)

جدول ۳. مقادیر پارامترهای دقت آزمون‌های انجام شده در مورد تصویر ابرطیفی برلین

روش پیشنهادی	MSF	MLP	SVM	
	۸۸/۳	۸۷/۰	۸۵/۶	OA
	۸۳/۰	۸۲/۰	۷۹/۰	(%)K
	۰/۰۴	۰/۰۷	۰/۰۹	N
پوشش گیاهی	۹۴/۶	۹۴/۶	۹۳/۹	
ساختمان	۸۹/۸	۹۲/۰	۷۸/۶	
سنگ فرش	۸۳/۸	۸۵/۶	۸۰/۳	
خاک	۸۶/۷	۸۶/۷	۸۵/۹	
آب	۹۵/۰	۹۰/۲	۹۶/۷	

#### ۴- نتیجه‌گیری

مقادیر وزنی، در الگوریتم ژنتیک وزن‌دار، بین صفر و یک است. روش پیشنهادی روی دو تصویر ابرطیفی پلویا و برلین اجرا شد و آزمایش‌ها برتری کمی و کیفی استفاده از این روش را نشان می‌دهد. این برتری در تصویر پلویا، ۷٪ و در تصویر برلین، ۶٪ بیشتر از الگوریتم MLP در پارامتر ضریب کاپا است. به‌طور کلی کم‌بودن دقت در تصویر برلین ممکن است ناشی از پیچیدگی این تصویر، در مقایسه با تصویر پلویا باشد.

#### ۵- سپاسگزاری

لازم می‌دانیم از دانشگاه زابل (IR-UOZ-GR-4685)، به دلیل حمایت مالی در انجام شدن این تحقیق، تشکر و قدردانی داشته باشیم.

در این تحقیق، روشی جدید به منظور طبقه‌بندی طیفی- مکانی تصاویر ابرطیفی معرفی شد. در این روش پیشنهادی، برای کاهش ابعاد از الگوریتم PCA استفاده و ده ویژگی میانگین، انحراف معیار، درجه تباین، یکنواختی، همبستگی، نبود تشابه، انرژی، آنتروپی، تبدیل موجک و فیلتر گابور به‌منزله اطلاعات نزدیک‌ترین همسایگی‌ها از باندهای کاهش‌یافته، استخراج شد. در ادامه، الگوریتم ژنتیک وزن‌دار روی ویژگی‌های به‌دست آمده اعمال شد تا وابستگی بین آنها کاهش یابد. الگوریتم ژنتیک یکی از کارآمدترین و مؤثرترین روش‌ها در کاهش ابعاد تصاویر ابرطیفی شمرده می‌شود. در الگوریتم باینری ژنتیک، هر کروموزوم دارای مقادیر یک و صفر است؛ در حالی که

- 62, PP. 790–807. <https://doi.org/10.1007/s10851-019-00925-9>.
- Chang, C.-I., 2003, **Hyperspectral Imaging: Techniques for Spectral Detection and Classification**, Orlando, FL: Kluwer Academic. <https://doi.org/10.1007/978-1-4419-9170-6>.
- Chi, M., Kun, Q., Benediktsson, J.A. & Feng, R., 2009, **Ensemble Classification Algorithm for Hyperspectral Remote Sensing Data**, IEEE Geosci. Remote Sens. Lett., 6, PP. 762–766. <https://doi.org/10.1109/LGRS.2009.2024624>.
- Ding, H., Xu, L., Wu, Y. & Shi, W., 2020, **Classification of Hyperspectral Images by Deep Learning of Spectral-Spatial Features**, Arab. J. Geosci., 13, PP. 464. <https://doi.org/10.1007/s12517-020-05487-4>.
- Fauvel, M., Tarabalka, Y., Benediktsson, J.A., Chanussot, J. & Tilton, J.C., 2013, **Advances in Spectral-Spatial Classification of Hyperspectral Images**, Proceedings of the IEEE, 101, PP. 652-675. <https://doi.org/10.1109/JPROC.2012.2197589>.
- German Aerospace Centre (DLR), <http://www.dlr.de>.
- Gonzalez, R.C. and Woods, R.E., 2002, **Digital Image Processing**, Prentice Hall, pp. 617-626.
- Haralick, R.M., Shanmugam, K. & Dinstein, I., 1973, **Textural Features for Image Classification**, IEEE Trans. on Systems, Man, and Cybernetics, SMC-3, PP. 610-621. <https://doi.org/10.1109/TSMC.1973.4309314>.
- Hasani, H., Samadzadegan, F. & Reinartz, P., 2017, **A Metaheuristic Feature-Level Fusion Strategy in Classification of Urban Area Using Hyperspectral Imagery and LiDAR Data**, European Journal of Remote Sensing, 50, PP. 222-236. <https://doi.org/10.1080/22797254.2017.1314179>.
- He, X. & Chen, Y., 2021, **Modifications of the Multi-Layer Perceptron for Hyperspectral Image Classification**, Remote Sensing, 13, P. 3547. <https://doi.org/10.3390/rs13173547>.
- Homayouni, S. & Roux, M., 2003, **Material Mapping from Hyperspectral Images Using Spectral Matching in Urban Area**, IEEE Workshop on Advances in Techniques for analysis of Remotely Sensed Data, NASA Goddard center, Washington DC, USA.
- ۶- منابع
- Acquarelli, J., Marchiori, E., Buydens, L.M.C., Tran, T. & Laarhoven, T.V., 2018, **Spectral-Spatial Classification of Hyperspectral Images: Three Tricks and a New Learning Setting**, Remote Sens., 10. <https://doi.org/10.3390/rs10071156>.
- Ahmad, M., Shabbir, S., Roy, S.K., Hong, D., Wu, X., Yao, J., Khan, A.M., Mazzara, M., Distefano, S. & Chanussot, J., 2022, **Hyperspectral Image Classification—Traditional to Deep Models: A Survey for Future Prospects**, IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens., 15. <https://doi.org/10.1109/JSTARS.2021.3133021>.
- Akbari, D., 2017, **Improving Spectral-Spatial Classification of Hyperspectral Imagery Using Spectral Dimensionality Reduction Based on Weighted Genetic Algorithm**, J. Indian Soc. Remote Sens., 45, PP. 927-937. <https://doi.org/10.1007/s12524-016-0652-8>.
- Akbari, D., 2019, **Improved Neural Network Classification of Hyperspectral Imagery Using Weighted Genetic Algorithm and Hierarchical Segmentation**, IET Image Process., 13, PP. 2169-2175. <https://doi.org/10.1049/iet-ipr.2018.5693>.
- Amigo, J.M., 2019, **Hyperspectral Imaging**, View Series: Data Handling in Science and Technology, 32, PP. 0-630.
- Benediktsson, J.A., Pesaresi, M. & Amason, K., 2003, **Classification and Feature Extraction for Remote Sensing Images from Urban Areas Based on Morphological Transformations**, IEEE Trans. Geos. and Remote Sens., 41, PP. 1940–1949. <https://doi.org/10.1109/TGRS.2003.814625>.
- Benediktsson, J.A., Palmason, J.A. & Sveinsson, J.R., 2005, **Classification of Hyperspectral Data from Urban Areas Based on Extended Morphological Profiles**, IEEE Trans. Geos. and Remote Sens., 43, PP. 480-491. <https://doi.org/10.1109/TGRS.2004.842478>.
- Chan, R.H., Kan, K.K., Nikolova, M. & Plemmons, R.J., 2020, **A Two-Stage Method for Spectral-Spatial Classification of Hyperspectral Images**, J. Math Imaging Vis.,

- Hong, D., Wu, X., Ghamisi, P., Chanussot, J., Yokoya, N. & Zhu, X.X., 2020, **Invariant Attribute Profiles: A Spatial-Frequency Joint Feature Extractor for Hyperspectral Image Classification**, IEEE Trans. Geosci. Remote Sens., 58, PP. 3791–3808. <https://doi.org/10.48550/arXiv.1912.08847>.
- Huang, C.-L. & Wang, C.-J., 2006, **A GA-Based Feature Selection and Parameter Optimization for Support Vector Machines**, Expert Systems with Application, PP. 231-240. <https://doi.org/10.1016/j.eswa.2005.09.024>.
- Huang, X. & Zhang, L., 2009, **A Comparative Study of Spatial Approaches for Urban Mapping Using Hyperspectral Rosis Images over Pavia City, Northern Italy**, International Journal of Remote Sensing, 30, PP. 3205–3221. <https://doi.org/10.1080/01431160802559046>.
- Li, S., Song, W., Fang, L., Chen, Y., Ghamisi, P. & Benediktsson, J.A., 2019, **Deep Learning for Hyperspectral Image Classification: An Overview**, IEEE Trans. Geosci. Remote Sens., PP. 1-20. <https://doi.org/10.1109/TGRS.2019.2907932>.
- Lin, M., Jing, W., Di, D., Chen, G. & Song, H., 2022, **Multi-Scale U-Shape MLP for Hyperspectral Image Classification**, IEEE Geoscience and Remote Sensing Letters, 19, PP. 1-5. <https://doi.org/10.1109/LGRS.2022.3141547>.
- Mallat, S., 1999, **A Wavelet Tour of Signal Processing**, Academic Press, San Diego.
- Pan, E., Mei, X., Wang, Q., Ma, Y. & Ma, J., 2020, **Spectral-Spatial Classification for Hyperspectral Image Based on a Single GRU**, Neurocomputing, 387, PP. 150–160. <https://doi.org/10.1016/j.neucom.2020.01.029>.
- Pesaresi, M. & Benediktsson, J.A., 2001, **A New Approach for the Morphological Segmentation of High-Resolution Satellite Imagery**, IEEE Trans. Geosci. Remote Sens., 39, PP. 309–320. <https://doi.org/10.1109/36.905239>.
- Shaw, G. & Manolakis, D., 2002, **Signal Processing for Hyperspectral Image Exploitation**, IEEE Signal Process. Mag., 19. <https://doi.org/10.1109/79.974715>.
- Tan, X. & Xue, Z., 2022, **Spectral-Spatial Multi-Layer Perceptron Network for Hyperspectral Image Land Cover Classification**, European Journal of Remote Sensing, 55, PP. 409-419. <https://doi.org/10.1080/22797254.2022.2087540>.
- Tarabalka, Y., Chanussot, J. & Benediktsson, J.A., 2010, **Segmentation and Classification of Hyperspectral Images Using Minimum Spanning Forest Grown from Automatically Selected Markers**, IEEE Trans. Syst., Man, Cybern. B, Cybern., 40, PP. 1267–1279. <https://doi.org/10.1109/TSMCB.2009.2037132>.
- Tarabalka, Y., Tilton, J.C., Benediktsson, J.A. & Chanussot, J., 2011, **A Marker-Based Approach for the Automated Selection of a Single Segmentation from a Hierarchical Set of Image Segmentations**, IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing. <https://doi.org/10.1109/JSTARS.2011.2173466>.
- Theodoridis, S. & Koutroumbas, K., 2006, **Pattern Recognition**, United states of America, Academic Press, PP. 266-271. <https://doi.org/10.1109/TNN.2008.929642>.
- Vapnik, V., 1995, **The Nature of Statistical Learning Theory**, New York, NY: Springer-Verlag.
- Varshney, P.K. & Arora, M.K., 2004, **Advanced Image Processing Techniques for Remotely Sensed Hyperspectral Data**, Springer Berlin Heidelberg New York. <https://doi.org/10.1007/978-3-662-05605-9>.
- Wang, A., Li, M. & Wu, H., 2022, **A Novel Classification Framework for Hyperspectral Image Data by Improved Multilayer Perceptron Combined with Residual Network**, Symmetry, 14, P. 611. <https://doi.org/10.3390/sym14030611>.
- Zhou, H., Mao, Z. & Wang, D., 2005, **Classification of Coastal Areas by Airborne Hyperspectral Image**, in Proc.

SPIE Opt. Technol. Atmos., Ocean, Environ. Stud., 5832, PP. 471-476.

Zhuo, L. & Zheng, J., 2008, **A Genetic Algorithm Based Wrapper Feature Selection Method for Classification of Hyperspectral Image Using Support Vector Machine**, The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, PP. 397-402. <https://doi.org/10.1117/12.813256>.