

طبقه‌بندی طیفی-مکانی تصاویر ابرطیفی با ترکیب الگوریتم‌های سلسله مراتبی و جنگل پوشای کمینه مبتنی بر نشانه

داود اکبری^{1*}، کامیل رکنی²

¹استادیار سنجش‌ازدور، گروه مهندسی نقشه برداری، دانشکده فنی، دانشگاه زابل

davoodakbari@uoz.ac.ir

²استادیار سنجش‌ازدور، گروه مهندسی نقشه برداری، دانشکده فنی و مهندسی، دانشگاه گنبدکاووس

rokni@gonbad.ac.ir

(تاریخ دریافت: بهمن 1400، تاریخ تصویب: شهریور 1401)

چکیده

فن‌آوری سنجش‌ازدور ابرطیفی دارای کاربردهای فراوان در طبقه‌بندی پوشش‌های زمین و بررسی تغییرات آن‌ها است. پیشرفت‌های اخیر و ایجاد تصاویری با قدرت تفکیک مکانی بالا، لزوم استفاده توأم از اطلاعات طیفی و مکانی را در طبقه‌بندی تصاویر ابرطیفی ایجاب می‌کند. در این تحقیق، روشی جدید جهت طبقه‌بندی طیفی-مکانی تصاویر ابرطیفی معرفی شده‌است. در روش پیشنهادی ابتدا ده ویژگی مکانی، میانگین، انحراف معیار، کنتراست، یکنواختی، همبستگی، عدم تشابه، انرژی، آنتروپی، تبدیل موجک و فیلتر گابور، از پیکسل‌های همسایگی تصویر ابرطیفی استخراج شده‌است. سپس، ابعاد ویژگی‌های طیفی و مکانی بدست‌آمده با الگوریتم ژنتیک وزن‌دار کاهش یافته و در ادامه به صورت موازی دو الگوریتم قطعه‌بندی سلسله مراتبی و طبقه‌بندی جنگل پوشای کمینه (MSF) مبتنی بر نشانه بر روی ویژگی‌های کاهش یافته اعمال و در نهایت نتایج با قانون تصمیم رای اکثریت ترکیب گردیده‌است. روش پیشنهادی بر روی دو تصویر ابرطیفی پیاده‌سازی شد، نتایج بررسی‌های انجام‌شده برتری و افزایش دقت روش پیشنهادی را نسبت به روش طبقه‌بندی ماشین بردار پشتیبان (SVM) نشان می‌دهد، که این افزایش برای تصویر Indiana Pine حدود 10 درصد و برای تصویر Washington DC Mall حدود 7 درصد در معیار دقت کلی می‌باشد.

واژگان کلیدی: تصویر ابرطیفی، طبقه‌بندی طیفی-مکانی، ویژگی‌های مکانی، الگوریتم ژنتیک وزن‌دار، قطعه‌بندی سلسله مراتبی، MSF مبتنی بر نشانه.

1- مقدمه

فن‌آوری سنجش‌ازدور ابرطیفی، در دهه‌ی گذشته شاهد پیشرفت چشمگیری بوده‌است. این پیشرفت در طراحی و ساخت سنجنده‌ها و همچنین، در توسعه و پیاده‌سازی روش‌های پردازش داده بسیار مشهود می‌باشد [1 و 2]. اگرچه توانایی تولید داده‌هایی با خصوصیات طیفی، مکانی و رادیومتریکی بالا منجر به تجزیه و تحلیل بهتر آن‌ها می‌شود، ولی مشکلاتی نیز پدید می‌آید که در مقایسه با داده‌های چندطیفی تجربه جدیدی است [3].

امروزه اکثر تحقیقات در زمینه فن‌آوری سنجش‌ازدور ابرطیفی، بر روی طبقه‌بندی این تصاویر معطوف است. طبقه‌بندی یا تبدیل تصاویر به نقشه موضوعی در مواجهه با عواملی از جمله پیچیدگی منطقه مورد مطالعه، انتخاب داده، پردازش تصویر و الگوریتم مورد استفاده، در معرض چالش جدی بوده و ممکن است بر موفقیت طبقه‌بندی تاثیر بگذارد [4، 5 و 6]. تصاویر ابرطیفی به دلیل داشتن تعداد باندهای زیاد، دارای مشکل کمبود نمونه‌های برچسب‌گذاری شده در فرآیند طبقه‌بندی هستند. یکی از راه‌حل‌ها جهت رفع این مشکل، کاهش تعداد باندها می‌باشد. برای این منظور روش‌های مختلفی مانند استخراج ویژگی و انتخاب ویژگی ارائه شده‌است [2].

به طور کلی، روش‌های طبقه‌بندی تصاویر ابرطیفی، به دو دسته تقسیم‌بندی می‌شوند. دسته اول، روش‌های طبقه‌بندی مبتنی بر پیکسل بوده که در آن هر پیکسل فقط با استفاده از اطلاعات طیفی خود و بدون در نظر گرفتن اطلاعات موجود در پیکسل‌های همسایه به یک کلاس مشخص اختصاص می‌یابد [7]. از جمله این روش‌ها می‌توان به الگوریتم‌های ماشین بردار پشتیبان (SVM^1) و شبکه عصبی پرسپترون چند لایه (MLP^2) اشاره کرد. دسته دوم روش‌های طبقه‌بندی، روش‌های طبقه‌بندی طیفی-مکانی بوده که علاوه بر اطلاعات طیفی پیکسل‌ها از اطلاعات پیکسل‌های همسایه نیز استفاده می‌نمایند [8، 9 و 10]. به دلیل حساسیت بالای سنجنده‌های ابرطیفی، معمولاً

سیگنال‌های ناشناخته زیادی در تصاویر ثبت می‌شوند که هیچگونه اطلاعات قبلی درباره آن‌ها وجود ندارد. به ویژه، بسیاری از این سیگنال‌ها مربوط به اجسامی هستند که دارای ابعاد کوچکی بوده و به صورت بصری قابل شناسایی نیستند. در این شرایط، شناسایی این اهداف با روش‌های رایج طبقه‌بندی که تنها از اطلاعات طیفی استفاده می‌نمایند، معمولاً امکانپذیر نبوده و علاوه بر آن‌ها، پردازش‌ها بایستی با لحاظ ویژگی‌های مکانی اهداف انجام گیرد [11]. در این خصوص بندیکسون (2003) روش نیمرخ همسایگی³ را پیشنهاد داد [12]. نیمرخ همسایگی از ترکیب فیلترهای بازکردن⁴ و بستن⁵ تشکیل یافته‌است. اعمال روش فوق بر روی باندهای مختلف تصویر به نام نیمرخ همسایگی توسعه‌یافته⁶ شناخته می‌باشد [13]. اما از آنجایی که ایجاد نیمرخ همسایگی توسعه‌یافته بر روی تمام باندهای یک تصویر ابرطیفی باعث ایجاد ویژگی‌های وابسته می‌گردد، از این رو کاهش تعداد باندهای تصویر ابرطیفی قبل از اعمال نیمرخ همسایگی الزامی است. در همین راستا، در [14] روش نیمرخ همسایگی توسعه یافته بر روی چندین ویژگی بدست‌آمده از تبدیل آنالیز مولفه‌های اصلی (PCA^7) که دارای بیشترین واریانس می‌باشند، پیشنهاد گردید. هانگ و ژانگ (2009) اطلاعات مکانی بدست‌آمده از ماتریس هم-وقوع سطح خاکستری ($GLCM^8$) را برای طبقه‌بندی داده ابرطیفی به کار گرفت [15]. در روش پیشنهادشده توسط هانگ و ژانگ ابتدا ویژگی‌های بافت⁹ از روی ماتریس $GLCM$ و با استفاده از چهار اندازه‌گیری، مولفه دوم زاویه‌ای¹⁰، کنتراست¹¹، آننتروپی¹² و یکنواختی¹³ استخراج گردید، سپس، الگوریتم PCA بر روی ویژگی‌های بدست آمده اعمال گشته و مولفه‌های اصلی به عنوان ویژگی‌های ورودی برای طبقه‌بندی‌کننده حداکثر احتمال¹⁴ انتخاب شدند. یکی دیگر از روش‌های استخراج اطلاعات مکانی، روش‌های قطعه‌بندی¹⁵ است که در آن بر اساس ویژگی‌هایی مانند یکنواختی، اشیاء موجود در تصویر (مجموعه‌ای از پیکسل‌ها با ویژگی یکسان) شناسایی می‌شوند [16]. از جمله این روش‌ها می‌توان به الگوریتم سلسله‌مراتبی¹⁶ [17]

9 Texture Features

10 Angular Second Moment

11 Contrast

12 Entropy

13 Homogeneity

14 Maximum Likelihood

15 Segmentation

16 Hierarchical algorithm

1 Support Vector Machines

2 Multilayer Perceptron

3 Morphological Profiles

4 Opening

5 Closing

6 Extended Morphological Profiles

7 Principal Component Analysis

8 Gray Level Co-occurrence Matrix

مرحله کاهش ابعاد در تصویر Indian Pines نشان می‌دهد. اکبری و همکاران (2015) جهت طبقه‌بندی طیفی-مکانی تصویر ابرطیفی ابتدا ابعاد تصویر ابرطیفی را به کمک الگوریتم ژنتیک کاهش داده، سپس، جهت انتخاب نشانه‌ها از نقشه طبقه‌بندی SVM استفاده نمودند. در مرحله بعد، بر روی نشانه‌های بدست‌آمده الگوریتم‌های طبقه‌بندی واثرشد⁴، سلسله‌مراتبی و MSF اعمال گشته و در نهایت به کمک قانون تصمیم رای اکثریت⁵ نقشه‌های طبقه‌بندی با نقشه طبقه-بندی SVM ترکیب گردید [24]. گلی‌پور و همکاران (2015) یک روش طبقه‌بندی طیفی-مکانی جدید بر مبنای طبقه‌بندی سلسله‌مراتبی و میدان تصادفی مارکوف (MRF⁶) ارائه نمودند [25]. آن‌ها همچنین جهت برآورد توزیع احتمال شرطی هر کلاس از دو طبقه بندی SVM و رگرسیون منطقی چندجمله‌ای (MLR⁷) استفاده کردند. اکبری و همکاران (2016) در تحقیق دیگری برای انتخاب نشانه‌ها از ترکیب طبقه‌بندی واثرشد و طبقه‌بندی SVM استفاده نمودند. در ادامه، بر روی نشانه‌های بدست‌آمده، الگوریتم طبقه‌بندی سلسله‌مراتبی پیاده‌سازی شد. سپس، نقشه طبقه‌بندی بدست‌آمده به کمک قانون تصمیم رای اکثریت با نقشه طبقه‌بندی SVM ترکیب گردید [26]. اکبری (2017) با به‌کارگیری الگوریتم ژنتیک وزن‌دار و الگوریتم MSF به طبقه‌بندی تصویر ابرطیفی پرداخت [27]. لی و همکاران (2019) از روش یادگیری عمیق (DL⁸) برای طبقه‌بندی تصاویر ابرطیفی استفاده کردند [28]. یادگیری عمیق یکی از شاخه‌های یادگیری ماشین است که هدف آن یاد گرفتن چکیده‌ای سطح بالا از داده‌ها با استفاده از معماری‌های سلسله‌مراتبی است و یک رویکرد در حال ظهور است که به طور گسترده در حوزه هوش مصنوعی مانند پردازش زبان طبیعی و بینایی ماشینی استفاده شده‌است. اکبری (2020) در تحقیق دیگر ابتدا ابعاد تصویر ابرطیفی را با الگوریتم کسر حداقل نویز (MNF⁹) کاهش داده، سپس، پنج ویژگی مکانی کنتراست، آنتروپی، میانگین¹⁰، تبدیل موجک¹¹ و فیلتر گابور¹² از باندهای بدست‌آمده استخراج و در ادامه، به کمک الگوریتم سلسله‌مراتبی مبتنی بر نشانه به طبقه‌بندی ویژگی‌های

اشاره کرد. یک روش معمول جهت داشتن نتایج طبقه‌بندی دقیق، طبقه‌بندی مبتنی بر نشانه¹ است [16 و 18]، که در آن برای هر ناحیه مکانی از تصویر یک یا چند پیکسل به عنوان نشانه انتخاب شده، سپس، نشانه‌های بدست‌آمده در فرآیند طبقه‌بندی رشد یافته و منجر به ناحیه‌ای مشخص در نقشه طبقه‌بندی می‌شود. در تحقیقات اولیه صورت گرفته، نشانه‌ها عموماً از روی مناطق یکنواخت یعنی مناطقی با مقادیر پیکسل یکسان یا بافت یکنواخت انتخاب می‌شدند [18]. گومز در [19] به کمک هیستوگرام تصویر، پیکسل‌های با مقادیر یکسان را به عنوان نشانه اختیار نمود. نویل و همکارانش با انجام طبقه‌بندی تصویر ابرطیفی و سپس فیلتر نمودن آن به کمک عملگرهای همسایگی، مناطق مکانی بزرگ را به عنوان نشانه انتخاب نمودند [20 و 21]. تارابالکا و همکاران (2010) از الگوریتم جنگل پوشای کمینه (MSF²) مبتنی بر نشانه جهت طبقه‌بندی طیفی-مکانی تصاویر ابرطیفی استفاده نمودند [8]. آن‌ها با نقشه طبقه‌بندی SVM پیکسل‌هایی با درجه تعلق بالا به هر کلاس را به عنوان نشانه انتخاب کردند. برای این منظور ابتدا روی نقشه طبقه‌بندی SVM آنالیز برچسب‌گذاری مولفه‌های متصل صورت گرفته، سپس، برای نواحی بزرگ ایجادشده، p درصد از پیکسل‌های با بالاترین احتمال و برای نواحی کوچک پیکسل‌هایی با درجه احتمال بیشتر از حدآستانه‌ای مشخص به عنوان نشانه در نظر گرفته شد. سیلوا و پدرینی (2015) روشی متشکل از سه مرحله جهت طبقه‌بندی تصاویر ابرطیفی پیشنهاد دادند [22]. در روش پیشنهادی ابتدا تصویر ابرطیفی به کمک الگوریتم SVM طبقه‌بندی شده سپس، در مرحله‌ی بعد به کمک تکنیک K-نزدیکترین همسایگی (KNN³) پیکسل‌های با بالاترین درجه تعلق به یک کلاس به عنوان نشانه انتخاب می‌شوند. در نهایت، در مرحله سوم، الگوریتم MSF بر روی پیکسل‌های نشانه بدست‌آمده اعمال می‌گردد. اکبری و همکاران (2015) تاثیر کاهش ابعاد تصاویر ابرطیفی را در الگوریتم طبقه‌بندی MSF مبتنی بر نشانه در سه مرحله قبل و بعد از انتخاب نشانه‌ها و به صورت همزمان بررسی نمودند [23]. نتایج آزمایشات بدست‌آمده افزایش دقت طبقه‌بندی را در هر سه

7 Multinomial Logistic Regression
8 Deep Learning
9 Minimum Noise Fraction
10 Mean
11 Wavelet transform
12 Gabor Filter

1 Marker
2 Minimum Spanning Forest
3 K-Nearest Neighbor
4 Watershed segmentation
5 Majority Voting
6 Markov Random Field

2-1- ویژگی‌های مکانی

ویژگی‌های مختلفی را می‌توان از پیکسل‌های تصویر به عنوان داده‌های پیکسل پایه استخراج و از آن‌ها جهت انجام طبقه‌بندی استفاده نمود [4]. از بین ده ویژگی انتخاب‌شده در این تحقیق، هشت ویژگی میانگین، انحراف معیار، کنتراست، یکنواختی، همبستگی، عدم تشابه، انرژی، آنتروپی، از روی ماتریس GLCM محاسبه گردید. از آنجایی که GLCM یک ماتریس دوبعدی است، دو پارامتر میانگین و انحراف معیار در دو جهت افقی و عمودی (سطرها و ستون‌ها) محاسبه شد [30]. پارامتر کنتراست برای اندازه‌گیری کمی شباهت‌ها یا اختلاف‌های پیکسل‌های همجوار پیشنهاد شده‌است [4]. هر چقدر که عناصر اطراف قطر اصلی GLCM بیشتر باشند، نشان‌دهنده این است که درجه روشنایی پیکسل‌های همجوار شباهت بیشتری را با هم دارند، در حالی که اگر عناصر غیر صفر ماتریس از قطر اصلی فاصله بگیرند، پیکسل‌های همجوار اختلاف زیادی را نشان می‌دهند. پارامتر یکنواختی میزان پراکندگی المان‌های GLSM را نسبت به عناصر قطری آن نشان می‌دهد [15]. پارامتر همبستگی بیان‌کننده میزان همبستگی بین یک پیکسل با همسایگی‌های خود در کل تصویر است [30]. پارامتر عدم تشابه مشابه کنتراست بوده و به صورت تغییر جفت مقادیر خاکستری در تصویر تعریف می‌شود با این تفاوت که در کنتراست، مقادیر وزن به صورت مربعی رشد می‌نمایند [4]. با استفاده از پارامتر انرژی، مجموع مربعات مقادیر ماتریس GLCM محاسبه می‌شود [4]. پارامتر آنتروپی میزان بی‌نظمی موجود در یک تصویر را اندازه‌گیری می‌کند، با اعمال این پارامتر می‌توان مجموع حاصلضرب مقادیر GLCM را در لگاریتم آن محاسبه نمود [15]. جدول (1) این هشت ویژگی را به همراه روابط ریاضی آن‌ها نشان می‌دهد.

فیلترهای حوزه مکان روشی دیگر جهت بیان کردن ویژگی‌های بافت است که در آن معرفی وابستگی‌های مکانی با تحلیل فوریه انجام می‌شود [31]. در تبدیل موجک، به جای استفاده از توابع سینوسی و کسینوسی مانند تبدیل فوریه، از توابعی به نام موجک استفاده می‌شود که در طول سیگنال، جابه‌جا شده و نیز در طی جابه‌جا شدن، فشرده و باز می‌شود

حاصل‌شده پرداخت. وی برای انتخاب نشانه‌ها از نقشه حاصل از ترکیب دو الگوریتم SVM و MLP استفاده نمود [29]. با توجه به مطالعات صورت‌گرفته، الگوریتم قطعه‌بندی سلسله‌مراتبی و الگوریتم طبقه‌بندی MSF مبتنی بر نشانه در مقایسه با سایر الگوریتم‌های قطعه‌بندی و طبقه‌بندی در تصاویر ابرطیفی به بهترین نتایج دست یافته‌است. همچنین، در بین الگوریتم‌های کاهش ابعاد، الگوریتم ژنتیک وزن‌دار، که در آن اطلاعاتی حذف نشده و به هر باند اطلاعاتی وزنی بین صفر تا یک می‌دهد، به بهترین نتیجه رسیده‌است [27]. در مطالعات گذشته، سه روش استفاده از اطلاعات مکانی، یعنی نزدیکترین همسایگی‌ها، نیمرخ همسایگی و قطعه‌بندی، هر یک به‌تنهایی جهت طبقه‌بندی طیفی-مکانی تصاویر ابرطیفی به کار گرفته شده و در مورد روش نزدیکترین همسایگی فقط به تعداد محدودی از ویژگی‌ها اشاره شده‌است. حال آنکه در این تحقیق از دو تکنیک نزدیکترین همسایگی و قطعه‌بندی به صورت همزمان استفاده و از ده ویژگی در روش نزدیکترین همسایگی به کار گرفته می‌شود. از این‌رو، در این تحقیق سعی شده‌است با لحاظ تکنیک‌های استخراج ویژگی‌های مکانی و کاهش ابعاد تصاویر ابرطیفی و با ترکیب الگوریتم‌های سلسله‌مراتبی و MSF مبتنی بر نشانه روشی جدید جهت طبقه‌بندی طیفی-مکانی تصاویر ابرطیفی ارائه شود.

در روش پیشنهادی ابتدا ده ویژگی مکانی میانگین، انحراف معیار¹، کنتراست، یکنواختی، همبستگی²، عدم تشابه³، انرژی⁴، آنتروپی، تبدیل موجک و فیلتر گابور از باندهای اولیه تصویر ابرطیفی استخراج و سپس با الگوریتم ژنتیک وزن‌دار ویژگی‌های طیفی و مکانی بهینه انتخاب شد. در ادامه دو الگوریتم قطعه‌بندی سلسله‌مراتبی و طبقه‌بندی MSF مبتنی بر نشانه به صورت موازی پیاده‌سازی و در انتها نتایج آن‌ها با قانون تصمیم رای اکثریت ترکیب گردید.

2- مبانی نظری تحقیق

در این بخش به معرفی ویژگی‌های مکانی استخراج شده، الگوریتم ژنتیک وزن‌دار، الگوریتم قطعه‌بندی سلسله‌مراتبی، الگوریتم طبقه‌بندی MSF پرداخته شد.

3 Dissimilarity
4 Energy

1 Standard deviation
2 Correlation

و بدین ترتیب، کل سیگنال را در می‌نوردد. هنگامی که تابع
هسته گوسی باشد، تبدیل یک تبدیل گابور خواهد بود [32].
این ویژگی‌ها به همراه روابط ریاضی آن‌ها در جدول (2) نشان
داده شده‌است.

جدول 1- ویژگی‌های مکانی بدست‌آمده از ماتریس GLCM و روابط ریاضی آن‌ها

ویژگی‌های مکانی	روابط ریاضی	توضیحات
میانگین [30]	$\mu_x = \frac{\sum_x (x - N_x)^2}{M}$ $\mu_y = \frac{\sum_y (y - N_y)^2}{M}$	N_x مجموع تعداد پیکسل‌ها در سطر x ، N_y مجموع تعداد پیکسل‌ها در ستون y M تعداد کل زوج پیکسل‌ها
انحراف معیار [30]	$Sd_x = \sqrt{\frac{\sum_x (x - N_x)^2}{M} - \mu_x^2}$ $Sd_y = \sqrt{\frac{\sum_y (y - N_y)^2}{M} - \mu_y^2}$	μ_x میانگین در جهت سطرها μ_y میانگین در جهت ستون‌ها
کنتراست [4]	$C = \sum_x \sum_y (x - y)^2 P_d(x, y)$	
یکنواختی [15]	$H = \sum_x \sum_y \frac{P_d(x, y)}{1 + x - y }$	
همبستگی [30]	$Co = \frac{1}{\sigma_x \sigma_y} \sum_x \sum_y (x - \mu_x)(y - \mu_y) P_d(x, y)$	$P_d(x)$ به ترتیب متوسط و واریانس σ_y و σ_x ، μ_y ، μ_x $P_d(y)$ و $P_d(x) = \sum_y P_d(x, y)$ $P_d(y) = \sum_x P_d(x, y)$
عدم تشابه [4]	$Dis = \sum_x \sum_y x - y P_d(x, y)$	
انرژی [4]	$SM = \sum_x \sum_y P_d(x, y)^2$	
آنتروپی [15]	$E = - \sum_x \sum_y P_d(x, y) \log P_d(x, y)$	

جدول 2- ویژگی‌های مکانی بدست‌آمده از فیلترهای حوزه مکان و روابط ریاضی آن‌ها

ویژگی‌های مکانی	روابط ریاضی	توضیحات
تبدیل موجک [31]	$\psi_{a,b}(x) = a ^{-\frac{1}{2}} \psi\left(\frac{x-b}{a}\right)$ $\int \psi(t) dx = 0$ $(W)_{\psi f}(a, b) = \langle f(x), \psi_{a,b}(x) \rangle = \int f(x) \psi_{a,b}(x) dx$	a و b به ترتیب منطقه فرکانس و زمان سیگنال
فیلتر گابور [32]	$f_{mn}^{real}(x, y) = \frac{1}{2\pi\sigma_m^2} \exp\left\{-\frac{x^2 + y^2}{2\sigma_m^2}\right\} \times \cos(2\pi(u_m x \cos\theta_n + u_m y \sin\theta_n))$ $f_{mn}^{imag}(x, y) = \frac{1}{2\pi\sigma_m^2} \exp\left\{-\frac{x^2 + y^2}{2\sigma_m^2}\right\} \times \sin(2\pi(u_m x \cos\theta_n + u_m y \sin\theta_n))$	m و n به ترتیب شاخص‌های مقیاس و جهت u_m فرکانس مرکزی مقیاس

2-2- الگوریتم ژنتیک وزن دار

الگوریتم ژنتیک که جزء تکنیک‌های بهینه‌سازی فرا ابتکاری می‌باشد، متداول‌ترین نوع الگوریتم‌های تکاملی است که رویه واحدی برای آن وجود نداشته و دارای رویه‌ای تکراری است. در طی هر بار تکرار الگوریتم (نسل)، هر یک از افراد موجود در جمعیت فعلی بر اساس میزان شایستگی مرتب شده و با استفاده از عملگرهای ژنتیک انتخاب¹، تقاطع² و جهش³، جمعیت جدیدی از راه حل‌ها تولید می‌گردد. این رویه تا زمان برقراری شرط خاتمه الگوریتم ادامه می‌یابد [33]. در الگوریتم ژنتیک هر راه‌حل توسط یک رشته به نام کروموزوم نمایش داده شده و لازم است تابع هدف برای هدایت الگوریتم به سمت جواب بهینه، تعریف گردد [33] و [34]. در الگوریتم باینری ژنتیک، هر کروموزوم دارای مقادیر یک و صفر است، در حالی که در الگوریتم ژنتیک وزن‌دار، مقادیر وزنی بین صفر و یک است. در این تحقیق از پارامتر ضریب کاپا⁴ طبقه‌بندی MLP جهت تعیین ارزش هر کروموزوم استفاده شد. همچنین، از روش چرخ رولت⁵ برای عملگر انتخاب استفاده شده است. در این روش احتمال انتخاب هر کروموزوم متناسب با مقدار شایستگی آن می‌باشد [34]. از عملگر تقاطع با یک نقطه برش⁶ و نیز عملگر جهش جهت جلوگیری از انتخاب بهینه‌های محلی استفاده گردید. همچنین، شرط توقف در این تحقیق بصورت شرط پویا در نظر گرفته شد، بدین صورت که اگر بهبودی در میزان تابع هدف تا قبل از تکرار مشخص که صد نسل در نظر گرفته شده است رخ ندهد، الگوریتم متوقف می‌شود و در غیر اینصورت تکرار تا نسل صدم ادامه می‌یابد.

2-3- الگوریتم سلسله مراتبی

الگوریتم سلسله‌مراتبی مبتنی بر روش رشد ناحیه و بهینه‌سازی هرمی بوده [17] و امکان ترکیب نواحی مکانی غیرمجاور را به وسیله پارامتر ورودی S_{wght} فراهم می‌سازد. پارامتر S_{wght} اهمیت نسبی خوشه‌بندی طیفی را در مقابل رشد ناحیه نشان می‌دهد. برای $S_{wght} = 0$ الگوریتم سلسله مراتبی فقط نواحی مکانی مجاور را با یکدیگر ترکیب می‌کند

و برای $S_{wght} = 1$ نواحی مجاور و غیر مجاور دارای وزن یکسانی در ترکیب می‌باشند و در نهایت برای مقادیر S_{wght} بین صفر و یک، ترکیب نواحی مجاور در مقایسه با نواحی غیرمجاور دارای برتری $\frac{1}{S_{wght}}$ می‌باشد. به‌طور کلی، الگوریتم سلسله‌مراتبی شامل مراحل زیر می‌شود [17]:

- (1) شروع قطعه‌بندی با تخصیص برچسب یک ناحیه مجزا برای هر پیکسل. اگر قطعه‌بندی از قبل وجود داشته باشد می‌توان برچسب هر پیکسل را بر اساس آن انجام داد.
 - (2) محاسبه مقدار معیار عدم تشابه برای هر جفت از نواحی مکانی مجاور ($S_{wght} = 0$)
 - (3) پیدا کردن جفت نواحی مجاور با کوچکترین مقدار معیار عدم تشابه و ترکیب آن‌ها
 - (4) اگر پارامتر $S_{wght} > 0$ باشد، همه جفت‌نواحی غیر مجاور با مقدار معیار عدم تشابه کمتر یا مساوی حاصلضرب S_{wght} در کوچکترین مقدار معیار عدم تشابه برای جفت‌نواحی مجاور، ترکیب می‌گردد.
 - (5) پایان مراحل، در صورتی که ترکیب دیگری نیاز نباشد، در غیر این صورت مراحل 2 به بعد تکرار می‌شود.
- لازم به ذکر است، جهت محاسبه عدم تشابه در الگوریتم سلسله‌مراتبی اندازه‌گیری‌های مختلفی مانند نرم بردار⁷، اندازه‌گیری زاویه طیفی (SAM^8) و دیورژانس اطلاعات طیفی (SID^9) مورد استفاده قرار می‌گیرد. همچنین، این الگوریتم دارای انعطاف برای انتخاب سطح مناسبی از جزئیات در نقشه قطعه‌بندی است، هر چند، ترکیب نواحی غیر مجاور نیاز به محاسبات بالایی داشته، از این رو جهت کاهش محاسبات، تخمینی از آن به صورت الگوریتم سلسله‌مراتبی بازگشتی ($RHSE^{10}$) به کار گرفته می‌شود.

2-4- الگوریتم MSF

در الگوریتم MSF، هر پیکسل به صورت یک راس از گراف $G = (V, E)$ که در آن V و E به ترتیب مجموعه رئوس و یال‌های گراف هستند، در نظر گرفته می‌شود، به‌طوری که هر یال $e_{i,j} \in E$ دو راس i و j مربوط به پیکسل‌های همسایگی را به هم وصل می‌کند. علاوه بر این، هر یال $e_{i,j}$ دارای وزن $w_{i,j}$ بوده که بیانگر عدم تشابه رئوس مربوطه می‌باشد. در این

6 Cut-off Point

7 Vector Norms

8 Spectral Angle Measure

9 Spectral Information Divergence

10 Recursive HSEG

1 Select

2 Crossover

3 Mutation

4 Kappa Coefficient

5 Roulette Wheel

تحقیق، از هشت راس همسایگی و اندازه‌گیری عدم تشابه SAM جهت محاسبه وزن یال‌ها، استفاده شد [8].

با در نظر گرفتن گراف $G = (V, E)$ ، درخت پوشا $T = (V, E_T)$ عبارت است از گرافی متصل و بدون چرخش با $E_T \subset E$ و جنگل پوشا $F = (V, E_F)$ گرافی منفصل و بدون چرخش با $E_F \subset E$ می‌باشد [8]. همچنین، درخت پوشای مینیمم به صورت درخت پوشا $T^* = (V, E_{T^*})$ ، به‌طوری که مجموع وزن یال‌های آن کمترین باشد، تعریف می‌گردد (رابطه 1).

$$T^* \in \operatorname{argmin}_{T \in ST} \left\{ \sum_{e_{i,j} \in E_T} w_{i,j} \right\} \quad (1)$$

در رابطه (1)، ST مجموعه تمام درخت‌های پوشا گراف G می‌باشد.

از طرف دیگر MSF روی m راس مجزا $\{t_1, \dots, t_m\}$ شامل پیدا کردن جنگل پوشا $F^* = (V, E_{F^*})$ بوده به‌طوری که هر درخت مجزا F^* ، از ریشه t_i رشد یافته و مجموع وزن یال‌های آن کمترین است (رابطه 2).

$$F^* \in \operatorname{argmin}_{F \in SF} \left\{ \sum_{e_{i,j} \in E_F} w_{i,j} \right\} \quad (2)$$

در رابطه (2)، SF مجموعه تمام جنگل‌های پوشا G رشد یافته روی ریشه‌های $\{t_1, \dots, t_m\}$ می‌باشد.

3- روش پیشنهادی

شکل (1) مراحل روش طبقه‌بندی طیفی-مکانی پیشنهادی را نشان می‌دهد. همانطوری که ملاحظه می‌گردد در روش پیشنهادی ابتدا ده ویژگی مکانی میانگین، انحراف معیار، کنتراست، یکنواختی، همبستگی، عدم تشابه، انرژی، آنتروپی، تبدیل موجک و فیلتر گابور از اطلاعات همسایگی پیکسل‌های تصویر، استخراج گردید. سپس، ویژگی‌های طیفی و مکانی بدست‌آمده با بکارگیری الگوریتم ژنتیک وزن‌دار کاهش می‌یابد. در مرحله بعد، بر روی ویژگی‌های کاهش‌یافته، الگوریتم‌های طبقه‌بندی سلسله مراتبی و طبقه‌بندی MSF مبتنی بر نشانه اعمال می‌شود. خروجی الگوریتم سلسله‌مراتبی برخلاف اکثر الگوریتم‌های طبقه‌بندی، به صورت مجموعه‌ای از


قطعه‌بندی‌ها در سطوح مختلف جزئیات بوده که باید با استفاده از یکی از روش‌های بهینه‌سازی، خروجی بهینه را انتخاب نمود. در نهایت، با قانون تصمیم رای اکثریت، نقشه قطعه‌بندی سلسله‌مراتبی با نقشه طبقه‌بندی MSF مبتنی بر نشانه ترکیب می‌گردد. در قانون تصمیم رای اکثریت، مطابق شکل (2) هر شی در نقشه قطعه‌بندی به کلاسی که اکثر پیکسل‌های آن در نقشه طبقه‌بندی دارند، اختصاص می‌یابد.

4- ارزیابی نتایج

4-1- داده‌های ابرطیفی مورد استفاده

در این تحقیق، برای ارزیابی روش پیشنهادی از دو تصویر ابرطیفی Indiana Pine و Washington DC Mall که جزء تصاویر پنج‌مارک در حوزه سنجش‌ازدور ابرطیفی بوده، استفاده شد. تصویر Indiana Pine، از یک منطقه کشاورزی در شمال غربی ایندیانا توسط سنجنده AVIRIS با توان تفکیک مکانی 20 متر در سال 1992 اخذ شده‌است [35]. تصویر دارای 220 باند طیفی با پهنای 10 نانومتر در محدوده طیفی 0/4 تا 2/5 میکرومتر است. شکل (3) ترکیب رنگی و نقشه واقعیت زمینی تصویر Indiana Pine را نشان می‌دهد، همانطور که ملاحظه می‌گردد، این تصویر شامل 16 کلاس می‌باشد. مجموعه داده Washington DC Mall، توسط سنجنده HYDICE با توان تفکیک مکانی 3 متر اخذ شده‌است [36]. تصویر فوق دارای 7 کلاس سایه، درخت، چمنزار، آب، جاده، پشت بام و پیاده‌رو بوده و شامل 210 باند در محدوده طیفی 0/4 تا 2/4 میکرومتر می‌باشد. ترکیب رنگی از این تصویر به همراه نقشه واقعیت زمینی آن در شکل (4) نشان داده شده‌است.


کلاس‌های مشخص‌شده در هر تصویر متناسب با نوع و عوارض موجود در آن تصویر می‌باشد. برای هر یک از کلاس‌ها در هر دو داده تصویری، به صورت تصادفی حدود 10 درصد از نمونه‌های برچسب‌گذاری‌شده را به عنوان داده آموزشی و باقی آن‌ها یعنی حدود 90 درصد را به عنوان داده تست انتخاب نمودیم.




شکل 1- مراحل روش پیشنهادی



شکل 2- مثالی از قانون تصمیم رای اکثریت در نواحی قطعه‌بندی شده



شکل 3- (الف) ترکیب رنگی - کاذب تصویر Indiana Pine (ب) نقشه واقعیت زمینی به منظور ارزیابی کمی-کیفی (ج) راهنما



شکل 4- (الف) ترکیب رنگی- کاذب تصویر Washington DC Mall (ب) نقشه واقعیت زمینی به منظور ارزیابی کمی-کیفی (ج) راهنما

2-4- نتایج و بحث

در آزمون‌های صورت گرفته برای الگوریتم ژنتیک وزن دار، کروموزوم‌ها دارای ژن‌هایی برابر با تعداد باندهای تصویر و ویژگی‌های مکانی استخراج شده، 230 ژن برای تصویر Indiana Pine و 220 ژن برای تصویر Washington DC Mall، می‌باشند. در این آزمون‌ها، میزان نرخ تقاطع و جهش به ترتیب برابر با 0/5 و 0/05 در نظر گرفته شد. همچنین، برای ایجاد تناسب بین دو پارامتر دقت و زمان محاسبات، اندازه جمعیت اولیه 30 و حداکثر تعداد تکرار برای توقف 100 در نظر گرفته شد. البته در عمل برای هر دو تصویر ابرطیفی، با توجه به این که شرط فعال برای توقف الگوریتم استفاده گردیده است، پروسه تکرار به مرحله 100 نرسیده و قبل از آن الگوریتم به وضعیت پایدار رسیده و متوقف می‌شود.

در الگوریتم MSF مبتنی بر نشانه، برای انتخاب نشانه‌ها از نقشه طبقه‌بندی SVM و کرنل پایه شعاعی گوسین¹ استفاده شد [37]. مقادیر دو پارامتر تنبیه² (C) و کرنل گوسین (γ) در الگوریتم SVM با تکنیک اعتبارسنجی متقابل³ تعیین گردید. به‌طوری که مقادیر نهایی پارامترهای فوق برای تصویر Indiana Pine برابر با C=108 و γ=0/2 و تصویر Washington DC Mall برابر با C=88 و γ=0/01 بدست آمد. سپس، آنالیز برچسب‌گذاری مولفه‌های متصل بر اساس 8 پیکسل همسایگی بر روی نقشه طبقه‌بندی SVM انجام گرفت و برای نواحی با بیشتر از 20 پیکسل، 5 درصد از پیکسل‌های با بیشترین احتمال تعلق به یک کلاس به عنوان پیکسل‌های نشانه انتخاب شد. برای نواحی کوچک یعنی کمتر از 20 پیکسل، پیکسل‌های با درجه احتمال بیشتر از یک حد آستانه به عنوان پیکسل‌های نشانه انتخاب گردید.


حد آستانه انتخابی برابر با کمترین احتمال در بین 2 درصد از بیشترین احتمالات کل تصویر می‌باشد [38]. در آزمون‌های صورت گرفته برای الگوریتم سلسله‌مراتبی، به دلیل پیچیدگی مناطق شهری تصاویر ابرطیفی مورد استفاده، مقدار پارامتر S_{wght} برابر با 0/2 در نظر گرفته شد [16]. روش طبقه‌بندی پیشنهادی بیان شده، با الگوریتم‌های MLP، SVM، DL، MSF مبتنی بر نشانه و سلسله‌مراتبی توسعه یافته [29] مقایسه گردید. الگوریتم طبقه‌بندی MLP با 3 لایه پنهان که شامل 5، 6 و 8 نورون می‌باشد، پیاده‌سازی شده و ارزیابی آن با 500 تکرار انجام گرفت. همچنین، به منظور ارزیابی دقت آزمون‌های صورت گرفته، ابتدا ماتریس خطا را با لحاظ داده واقعیت زمینی تشکیل داده، سپس، پارامترهای دقت کلی⁴ (OA)، ضریب کاپا (K) و دقت تولیدکننده⁵ مربوط به هر کلاس استخراج گردید [8]. همچنین، از آماره Z، جهت ارزیابی تفاوت بین روش پیشنهادی با سایر روش‌های طبقه‌بندی استفاده شد [39].

(a) تصویر ابرطیفی Indiana Pine

شکل (5) نقشه‌های طبقه‌بندی حاصل از به کارگیری روش پیشنهادی و الگوریتم‌های SVM، MLP، DL، MSF مبتنی بر نشانه و سلسله‌مراتبی توسعه یافته را نشان می‌دهد. همانطوری که ملاحظه می‌گردد، نقشه حاصل از روش پیشنهادی در مقایسه با سایر الگوریتم‌ها شامل مناطق یکنواخت‌تری است. جدول (3) و شکل (6) مقادیر پارامترهای دقت نقشه‌های طبقه‌بندی بدست آمده از تصویر ابرطیفی Indiana Pine را نشان می‌دهد.

4 Overall Accuracy
5 Producer Accuracy


1 Gaussian Radial Basis Kernel
2 Penalty parameter
3 Cross validation



شکل 5- نقشه‌های طبقه‌بندی حاصل از (الف) الگوریتم SVM (ب) الگوریتم MLP (ج) الگوریتم DL (د) الگوریتم MSF مبتنی بر نشانه (و) الگوریتم سلسله مراتبی توسعه یافته و (ز) روش پیشنهادی

جدول 3- مقادیر پارامترهای دقت آزمون‌های صورت گرفته برای تصویر ابرطیفی Indiana Pine

روش پیشنهادی	سلسله مراتبی توسعه یافته	MSF مبتنی بر نشانه	DL	MLP	SVM	
95/0	94/5	88/6	90/8	85/8	84/8	OA
94/2	92/3	86/2	89/3	83/7	82/6	K
93/5	91/8	88/8	90/8	80/4	87/0	ذرت کشت نشده
92/6	91/4	90/3	91/1	83/5	84/1	ذرت کشت شده
93/0	93/0	83/7	86/3	79/8	77/9	ذرت
92/4	92/6	90/9	93/5	92/8	89/4	سویا کشت نشده
98/3	97/1	94/0	96/2	95/0	94/0	سویا کشت شده
99/6	98/4	97/2	96/9	96/7	95/6	سویا تمیز شده
95/9	96/0	96/1	96/4	92/9	92/9	یونجه
100	99/9	99/4	99/2	97/5	99/4	چمنزار
88/0	88/2	82/0	84/4	65/0	65/0	درخت
98/5	98/5	94/7	95/2	84/3	80/7	مرتع
91/0	91/8	90/9	90/2	73/2	70/8	علف خشک
98/1	97/7	94/0	94/0	87/5	87/5	جو
99/5	99/2	98/8	99/2	99/5	98/5	گندم
94/0	93/1	89/1	91/9	85/8	86/6	چوب
97/1	96/8	92/4	90/9	80/3	79/8	علفزار
97/8	97/6	97/8	97/7	97/8	97/8	سنگ



شکل 6- مقادیر دقت کلی و ضریب کاپا برای الگوریتم‌های طبقه‌بندی مختلف

افزایش در پارامتر ضریب کاپا به میزان 6، 9 و 5 درصد به ترتیب نسبت به الگوریتم‌های SVM، MLP، DL، MSF مبتنی بر نشانه و سلسله‌مراتبی توسعه یافته‌است. پایین بودن دقت در تصویر Washington DC Mall می‌تواند به دلیل پیچیدگی این تصویر در مقایسه با تصویر Indiana Pine باشد. همانطوری که از جدول (4) مشخص است، دقت مولد تمامی کلاس‌ها به جز کلاس آب در روش پیشنهادی به طور معناداری افزایش یافته‌است. این کاهش دقت در کلاس آب می‌تواند به دلیل پراکندگی بالا و تراکم کم آن در تصویر باشد.


علاوه بر معیارهای ذکر شده، معیار سوم دقت، یعنی آماره Z، برای مقایسه ماتریس‌های خطا برای روش پیشنهادی و روش‌های دیگر استفاده می‌شود. جدول (5) نتایج این آزمون را نشان می‌دهد. همانطور که ملاحظه می‌شود، روش پیشنهادی به طور قابل توجهی در مقایسه با روش‌های طبقه‌بندی دیگر برای هر دو مجموعه داده متفاوت است.

جدول (6) مدت زمان اجرای الگوریتم‌های طبقه‌بندی مورد استفاده در این تحقیق را نشان می‌دهد. همانطور که ملاحظه می‌شود، کمترین زمان مربوط به الگوریتم SVM و بیشترین زمان مربوط به روش پیشنهادی در دو تصویر ابر طیفی مورد استفاده می‌باشد. لازم به ذکر است، در روش پیشنهادی اجرای الگوریتم ژنتیک وزن‌دار زمان زیادی را به خود اختصاص می‌دهد.

همانطور که ملاحظه می‌شود، روش پیشنهادی به ترتیب باعث افزایش حدود 12، 11 و 8 درصدی پارامتر ضریب کاپا نسبت به الگوریتم‌های SVM، MLP، DL، MSF مبتنی بر نشانه و سلسله‌مراتبی توسعه یافته شده‌است. همچنین، دقت همه کلاس‌ها به جز کلاس درخت توسط روش پیشنهادی به بالای 90 درصد رسیده‌است. دلیل این افزایش، دقت روش پیشنهادی می‌تواند استفاده از اطلاعات نزدیکترین همسایگی، کاهش ابعاد و قانون تصمیم رای اکثریت باشد. در جدول (3)، مقادیر دقت مولد همه کلاس‌ها در روش پیشنهادی به جزء کلاس‌های سوپا کشت نشده و یونجه افزایش یافته‌است. در مورد کلاس‌های سوپای کشت نشده و یونجه، این کاهش می‌تواند به دلیل تعداد کم و پیچیدگی طیفی پیکسل‌های آن‌ها باشد.

(b) تصویر ابرطیفی Washington DC Mall


شکل (7) نقشه‌های طبقه‌بندی را برای تصویر ابرطیفی Washington DC Mall نشان می‌دهد. همانطوری که ملاحظه می‌گردد، نقشه روش پیشنهادی در مقایسه با سایر الگوریتم‌ها دارای نویز کمتری است. جدول (4) و شکل (8) مقادیر پارامترهای دقت نقشه‌های طبقه‌بندی بدست‌آمده از تصویر ابرطیفی Washington DC Mall را نشان می‌دهد. در این تصویر نیز روش پیشنهادی باعث افزایش دقت شده‌است. این



شکل 7- نقشه‌های طبقه‌بندی حاصل از (الف) الگوریتم SVM (ب) الگوریتم MLP (ج) الگوریتم DL (د) الگوریتم MSF مبتنی بر نشانه (و) الگوریتم سلسله مراتبی توسعه یافته و (ر) روش پیشنهادی

جدول 4- مقادیر پارامترهای دقت آزمون‌های صورت گرفته برای تصویر ابرطیفی Washington DC Mall

روش پیشنهادی	سلسله مراتبی توسعه یافته	MSF مبتنی بر نشانه	DL	MLP	SVM	
93/0	92/6	87/0	86/8	85/6	85/9	OA
88/0	88/0	83/0	81/9	79/0	82/1	K
96/8	96/6	94/6	94/5	93/9	94/5	سایه
94/8	93/3	92/0	89/7	78/6	81/4	درخت
92/1	91/4	85/6	83/9	80/3	80/8	چمنزار
86/2	86/1	86/7	86/7	85/9	86/0	آب
96/7	96/2	90/2	89/7	96/7	92/7	جاده
93/0	92/4	87/0	86/6	85/6	85/9	پشت بام
88/0	88/7	82/0	82/1	79/0	81/7	پیاده‌رو



شکل 8- مقادیر دقت کلی و ضریب کاپا برای الگوریتم‌های طبقه‌بندی مختلف

جدول 5- نتایج تحلیل کاپا برای مقایسه زوجی ماتریس‌های خطا برای مجموعه داده‌های مختلف

آماره Z	مقایسه زوجی	داده تصویری
9/02	روش پیشنهادی و SVM	Indiana Pine
8/06	روش پیشنهادی و MLP	
4/18	روش پیشنهادی و DL	
6/22	روش پیشنهادی و MSF مبتنی بر نشانه	
0/31	روش پیشنهادی و سلسله مراتبی توسعه یافته	
6/36	روش پیشنهادی و SVM	Washington DC Mall
8/70	روش پیشنهادی و MLP	
5/26	روش پیشنهادی و DL	
5/11	روش پیشنهادی و MSF مبتنی بر نشانه	
0/27	روش پیشنهادی و سلسله مراتبی توسعه یافته	

جدول 6- مدت زمان اجرای الگوریتم‌های طبقه‌بندی مورد استفاده در دو تصویر ابرطیفی (اعداد برحسب ثانیه می‌باشند).

داده تصویری	SVM	MLP	DL	MSF مبتنی بر نشانه	سلسله مراتبی توسعه یافته	روش پیشنهادی
Indiana Pine	58	102	114	248	368	408
Washington DC Mall	34	84	99	152	255	372

5- نتیجه‌گیری

همبستگی، عدم تشابه، انرژی، آنتروپی، تبدیل موجک و فیلتر گابور به عنوان اطلاعات نزدیکترین همسایگی‌ها از تصویر ابرطیفی اولیه استخراج گردید. سپس، در مرحله بعد از الگوریتم ژنتیک وزن‌دار جهت انتخاب ویژگی‌های بهینه استفاده شد. الگوریتم قطعه‌بندی سلسله‌مراتبی مورد استفاده در این تحقیق جزء دقیق‌ترین الگوریتم‌های استخراج اطلاعات مکانی در تصاویر ابرطیفی می‌باشد. همچنین، الگوریتم MSF مبتنی بر نشانه نیز جزء دقیق‌ترین الگوریتم‌های طبقه‌بندی

در این تحقیق، روشی جدید جهت طبقه‌بندی طیفی- مکانی تصاویر ابرطیفی معرفی گردید. در روش پیشنهادی سه فاکتور اطلاعات نزدیکترین همسایگی‌ها، کاهش ابعاد و قانون تصمیم رای اکثریت در مورد الگوریتم‌های سلسله‌مراتبی و MSF مبتنی بر نشانه به کار گرفته شد. در روش پیشنهادی ده ویژگی میانگین، انحراف معیار، کنتراست، یکنواختی،

طیفی-مکانی در تصاویر ابرطیفی است. روش پیشنهادی بر روی دو تصویر ابرطیفی بنچ مارک Indiana Pine و Washington DC Mall پیاده‌سازی شد. آزمایشات عملی صورت گرفته برتری کمی و کیفی به‌کارگیری روش پیشنهادی را در مقایسه با الگوریتم MSF مبتنی بر نشانه نشان می‌دهد. این برتری به میزان 8 و 5 درصد در پارامتر ضریب کاپا به ترتیب در تصاویر

منابع

Washington DC Mall و Indiana Pine می‌باشد.
سپاسگزاری
 از دانشگاه زابل (IR-UOZ-GR-4685) به دلیل حمایت مالی صورت گرفته در انجام این تحقیق کمال تشکر را داریم.

- [1] P. K. Varshney, and M. K. Arora, "Advanced Image Processing Techniques for Remotely Sensed Hyperspectral Data", Springer Berlin Heidelberg New York, 2004.
- [2] C. I. Chang, *Hyperspectral Imaging: Techniques for spectral Detection and Classification*. Orlando, FL: Kluwer Academic, 2003.
- [3] R. H. Chan, K. K. Kan, M. Nikolova, and R. J. Plemmons, "A two-stage method for spectral-spatial classification of hyperspectral images", *J. Math Imaging Vis.*, Vol. 62, pp. 790–807, 2020.
- [4] R. C. Gonzalez, and R. E. Woods, *Digital Image Processing*. Prentice Hall, pp. 617 – 626, 2002.
- [5] J. Acquarelli, E. Marchiori, L. M. C. Buydens, T. Tran, and T. V. Laarhoven, "Spectral-spatial classification of hyperspectral images: three tricks and a new learning setting", *Remote Sens.*, Vol. 10, pp. 1156, 2018.
- [6] H. Hasani, F. Samadzadegan, and P. Reinartz, "A metaheuristic feature-level fusion strategy in classification of urban area using hyperspectral imagery and LiDAR data", *European Journal of Remote Sensing*, Vol. 50., No. 1, pp. 222-236, 2017.
- [7] V. Vapnik, *The Nature of Statistical Learning Theory*. New York, NY: Springer-Verlag, 1995.
- [8] Y. Tarabalka, J. Chanussot, and J. A. Benediktsson, "Segmentation and classification of hyperspectral images using minimum spanning forest grown from automatically selected markers", *IEEE Trans. Syst., Man, Cybern. B, Cybern.*, Vol. 40, pp. 1267–1279, 2010.
- [9] M. Fauvel, Y. Tarabalka, J. A. Benediktsson, J. Chanussot, and J. C. Tilton, "Advances in Spectral-Spatial Classification of Hyperspectral Images", *Proceedings of the IEEE*, Vol. 101, No. 3, pp. 652-675, 2013.
- [10] E. Pan, X. Mei, Q. Wang, Y. Ma, and J. Ma, "Spectral-spatial classification for hyperspectral image based on a single GRU", *Neurocomputing*, Vol. 387, pp. 150–160, 2020.
- [11] D. Hong, X. Wu, P. Ghamisi, J. Chanussot, N. Yokoya, X. X. Zhu, "Invariant attribute profiles: a spatial-frequency joint feature extractor for hyperspectral image classification", *IEEE Trans. Geosci. Remote Sens.*, Vol. 58, pp. 3791–3808, 2020.
- [12] J. A. Benediktsson, M. Pesaresi, and K. Arnason, "Classification and feature extraction for remote sensing images from urban areas based on morphological transformations", *IEEE Trans. Geos. and Remote Sens.*, Vol. 41, No. 9, pp. 1940–1949, 2003.
- [13] M. Pesaresi, and J. A. Benediktsson, "A new approach for the morphological segmentation of high-resolution satellite imagery", *IEEE Trans. Geosci. Remote Sens.*, Vol. 39, No. 2, pp. 309–320, 2001.
- [14] J. A. Benediktsson, J. A. Palmason, and J. R. Sveinsson, "Classification of hyperspectral data from urban areas based on extended morphological profiles", *IEEE Trans. Geos. and Remote Sens.*, Vol. 43, No. 3, pp. 480–491, 2005.
- [15] X. Huang, and L. Zhang, "A comparative study of spatial approaches for urban mapping using hyperspectral rosis images over pavia city, northern Italy", *International Journal of Remote Sensing*, Vol. 30, No. 12, pp. 3205–3221, 2009.
- [16] Y. Tarabalka, J. C. Tilton, J. A. Benediktsson, and J. Chanussot, "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*, 2011.

- [17] J. Tilton, "Analysis of hierarchically related image segmentations", in Proc. IEEE Workshop Adv. Tech. Anal. Remotely Sensed Data, pp. 60–69, 2003.
- [18] P. Soille, *Morphological Image Analysis*. 2nd ed. Berlin, Germany: Springer-Verlag, 2003.
- [19] O. Gómez, J. A. González, and E. F. Morales, "Image segmentation using automatic seeded region growing and instance-based learning", in Proc. 12th Iberoamerican Congress Pattern Recognition, Valparaiso, Chile, pp. 192–201, 2007.
- [20] G. Noyel, "Filtrage, Réduction de Dimension, Classification et Segmentation Morphologique Hyperspectrale", Ph.D. dissertation, Ctr. Mathematical Morphology, Paris Sch. Mines, Paris, France, 2008.
- [21] G. Noyel, J. Angulo, and D. Jeulin, "Morphological segmentation of hyperspectral images", *Image Anal. Stereol.*, Vol. 26, pp. 101–109, 2007.
- [22] R. D. Silva, and H. Pedrini, "Hyperspectral Data Classification Improved by Minimum Spanning Forests," *IEEE Geoscience and Remote Sensing Letters*, Vol. 12, No. 7, 2015.
- [23] D. Akbari, A. Safari, S. Khazai, and S. Homayouni. "Improved Spectral-Spatial Classification Minimum Spanning Forest by Reducing the Spatial Dimensions of Hyperspectral Images", *JGST.*, Vol. 5, No. 2, pp. 219-229, 2015 (in Persian).
- [24] D. Akbari, A. Safari, and S. Khazai, "The effect of feature selection using genetic algorithms on spectral-spatial classification of hyperspectral imagery", *jgit.*, Vol. 3, No. 1, pp. 45-60, 2015, (in Persian).
- [25] M. Golipour, H. Ghassemian, and F. Mirzapour, "Integrating Hierarchical Segmentation Maps With MRF Prior for Classification of Hyperspectral Images in a Bayesian Framework," *IEEE Transactions on Geoscience and Remote Sensing*, 2015.
- [26] D. Akbari, A. Safari, and S. Homayouni, "Improving the spectral-spatial classification of hyperspectral images using spatial information in selecting markers", *Scientific-Research Quarterly of Geographical Data (SEPEHR)*, Vol. 25, No. 98, pp. 5-14, 2016, (in Persian).
- [27] D. Akbari, "Improving Spectral-spatial Classification of Hyperspectral Imagery Using Spectral Dimensionality Reduction Based on Weighted Genetic Algorithm", *J. Indian Soc. Remote Sens.*, Vol. 45, No. 6, pp. 927–937, 2017.
- [28] S. Li, W. Song, L. Fang, Y. Chen, P. Ghamisi, J. A. Benediktsson, "Deep Learning for Hyperspectral Image Classification: An Overview", *IEEE Transactions on Geoscience and Remote Sensing*, pp. 1-20, 2019.
- [29] D. Akbari, "A novel method for spectral-spatial classification of hyperspectral images with a high spatial resolution", *Arabian Journal of Geosciences*, Vol. 13, pp. 1–10, 2020.
- [30] R. M. Haralick, K. Shanmugam, and I. Dinstein, "Textural Features for Image Classification", *IEEE Trans. on Systems, Man, and Cybernetics*, Vol. SMC-3, pp. 610-621, 1973.
- [31] S. Mallat, *A Wavelet Tour of Signal Processing*. Academic Press, San Diego, 1999.
- [32] G. Shaw, and D. Manolakis, "Signal processing for hyperspectral image exploitation", *IEEE Signal Process. Mag.*, Vol. 19, pp. 12, 2002.
- [33] L. Zhuo, and J. Zheng, "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, 2008.
- [34] C. L. Huang, and C. J. Wang, "A GA-based feature selection and parameter optimization for support vector machines", *Expert Systems with Application*, pp. 231-240, 2006.
- [35] D. A. Landgrebe, "Signal Theory Methods in Multispectral Remote Sensing", John Wiley & Sons, Inc., 2003.
- [36] F. Camastra, "Signal Theory Methods in Multispectral Remote Sensing", DC Mall image and band specifications for the HYDICE Washington D.C. Mall image provided on the CD with. [Online]. Available: http://www.lars.purdue.edu/home/image_data/hydice_dc_wavelengths.html.
- [37] N. Cristianini, and J. Shawe-Taylor, "An Introduction to Support Vector Machines and Other Kernel-based Learning Methods", Cambridge University Press, 2000.

- [38] F. Van der Meer, "The effectiveness of spectral similarity measures for the analysis of hyperspectral imagery", Int. J. Appl. Earth Observation Geoinformation, Vol. 8, No. 1, pp. 3–17, 2006.
- [39] D. Akbari, A. Safari, and S. Homayouni, "Object-Based Hyperspectral Classification of Urban Areas by Using Marker-Based Hierarchical Segmentation", Photogrammetric Engineering and Remote Sensing, Vol. 80, No. 10, pp. 963–970, 2014.