

ادغام ویژگی‌های طیفی و مکانی تصاویر

ابریطیفی به کمک طبقه‌بند شبکه عصبی

فاطمه سادات میری، سید ابوالفضل حسینی* و رامین شقاقی کندوان

* گروه مهندسی برق، مرکز تحقیقات توسعه فناوری‌های پیشرفته صنعت برق و الکترونیک، واحد یادگار امام خمینی (ره) شهرری، دانشگاه آزاد اسلامی، تهران، ایران

چکیده

یکی از مباحث مهم و چالش‌برانگیز در سنجش از دور طبقه‌بندی تصاویر ابریطیفی است. برخلاف آن‌که داده‌های مربوط به تصاویر ابریطیفی علاوه بر اطلاعات ویژگی طیفی، دارای اطلاعات ویژگی مکانی هم هستند که کمتر، از این ویژگی‌های مکانی در روش‌های سنتی قدیمی استفاده شده‌است. در حالت کلی، به منظور طبقه‌بندی این گونه داده‌ها از یک طبقه‌بند بر پایه اطلاعات طیفی و ایجاد یک نقشه با این هدف استفاده می‌شود. با توجه به این‌که این اطلاعات طیفی مربوط به پیکسل‌های تصویر است و در طبقه‌بندی این پیکسل‌ها اطلاعات مکانی لحاظ نمی‌شود، می‌تواند اطلاعات مکانی در طبقه‌بندی پیکسل‌ها مدنظر قرار بگیرد. بنابراین، مسأله و چالش مهم در این مبحث، نحوه ادغام این ویژگی‌های طیفی و مکانی به منظور دستیابی به دقت بالاتر طبقه‌بندی است. ادغام اطلاعات طیفی و مکانی در رسیدن به دقت طبقه‌بندی بهتر، مؤثر است. در این مقاله از روش طبقه‌بند شبکه عصبی در طبقه‌بندی تصاویر ابریطیفی به کمک ادغام ویژگی طیفی و مکانی در دو روش پشته و مبتنی بر گراف دودویی استفاده شده‌است. غیر از روش متداول پشته یا stack، از روش گراف دودویی ناحیه‌ای به منظور ادغام مناسب اطلاعات طیفی و مکانی نیز استفاده شده که برای استفاده هم‌زمان از اطلاعات طیفی در کنار اطلاعات مکانی (Feature Fusion) در طبقه‌بندی تصویر ابریطیفی مناسب است. در ابتدای الگوریتم از تحلیل مؤلفه اصلی جهت استخراج مؤلفه‌های اصلی تصاویر ابریطیفی استفاده می‌شود؛ سپس، از روش‌های فیلتر گابور، پروفایل ریخت‌شناسی و مورفولوژی روی باند پیکسل تصویر ابریطیفی اطلاعات مکانی تصویر استخراج می‌شود و در نهایت، تصویر به کمک طبقه‌بند، طبقه‌بندی می‌شود. در هر یک از این روش‌ها طبقه‌بند شبکه عصبی روی ویژگی‌های طیفی و مکانی ادغام‌شده، به کار گرفته شده، سپس، با عملکرد طبقه‌بند ماشین بردار پشتیبان در شرایط مشابه مقایسه می‌شود. نتایج طبقه‌بندی بیانگر برتری طبقه‌بند شبکه عصبی است.

واژگان کلیدی: طبقه‌بندی، ادغام ویژگی، طیفی و مکانی، شبکه عصبی، تصاویر ابریطیفی

Spectral-Spatial Feature Fusion by Neural Network classification in remotely sensed hyperspectral images

Fatemeh sadat Miri, S. Abolfazl Hosseini* & Ramin Shaghghi kandovan

Department of the Electrical Engineering, Research Center for Developing Advanced Technologies of Electrical and Electronics Industry, Yadegar-e-Imam Khomeini (RAH) Shahr-e Rey Branch, Islamic Azad University, Tehran, Iran

Abstract

Hyper-spectral image classification is a popular topic in the field of remote sensing. Hyperspectral images (HSI) have rich spectral information and spatial information. Traditional hyperspectral image (HSI) classification methods typically use the spectral features and do not make full use of the spatial or other features of the HSI. In general, the classification approaches classify input data by considering the spectral information of the data to produce a classification map in order to discriminate different classes

* Corresponding author

* نویسنده عهده‌دار مکاتبات

سال ۱۴۰۲ شماره ۲ پیاپی ۵۶

• تاریخ ارسال مقاله: ۱۳۹۸/۹/۲۸ • تاریخ پذیرش: ۱۴۰۰/۹/۱۵ • تاریخ انتشار: ۱۴۰۱/۷/۷ • نوع مطالعه: پژوهشی



فصلنامه



۱۶۳

of interest. The pixel-wise classification approaches classify each pixel autonomously without considering information about spatial structures, further enhancement of classification results can be obtained by considering spatial dependences between pixels. However, how to fuse and utilize spectral-spatial features more efficiently, is a challenging task. So, the combination of spectral information and spatial information has become an effective means to obtain good classification results. Specifically, firstly, the principal component analysis (PCA) algorithm is used to extract the first principal component in the original hyperspectral image. Secondly, the residual network Gabor, GLCM and MP are introduced for each band to extract the spatial information of the image. Thirdly, the image is classified by using SVM to get the final classification result. In this paper, we have used the neural network classifier in the classification of hyperspectral images by integrating spectral and spatial properties in two methods stack and the method based on binary graphs. In spite of the traditional stack method, the use of local binary graph method to properly integrate spectral and spatial information is a desirable method for the simultaneous use of spectral information along with spatial information (Feature Fusion) in hyperspectral image classification. In each of these methods, the neural network classifier is applied to the spectral and spatial features separately and then compared with the performance of the support vector machine classifier in similar conditions. The classification results show that the proposed method can outperform other traditional classification techniques.

Keywords: feature fusion, spectral, spatial, neural network, SVM, classification

۱- مقدمه

استفاده از فناوری سنجش از دور، بر مبنای تفاوت مقادیر بازتابندگی مواد مختلف است. امضای طیفی، مقادیر بازتابندگی را در طول موج‌های مختلف نشان می‌دهد. سنجش از دور به کمک اندازه‌گیری امضای طیفی، مواد مختلف را شناسایی می‌کند. در سنجش از دور مجموعه‌ای از پیکسل‌ها که در یک طول موج از زمین دریافت شده‌اند، باند را تشکیل می‌دهند و بر اساس تعداد باندهای یک تصویر، تصاویر سنجش از دور به سه دسته تک‌باندی، چندطیفی و ابرطیفی تقسیم می‌شوند. تصاویر ابرطیفی سطح زمین را با تعداد زیادی باند برای هر پیکسل تصویربرداری می‌کنند؛ بنابراین ارزش طیفی تصاویر ابرطیفی بالاست، اطلاعات ارزشمندی را فراهم می‌کنند و یکی از مسائل مهم در تصاویر ابرطیفی نحوه طبقه‌بندی این تصاویر است. طبقه‌بندی تصاویر ابرطیفی با ایجاد یک نقشه طبقه‌بندی جهت تشخیص رده‌های مختلف، داده‌های ورودی را با توجه به اطلاعات طیفی‌شان طبقه‌بندی می‌کند.

همچنین، در روش‌های متداول سنتی طبقه‌بندی مبتنی بر پیکسل، پیکسل‌ها با نادیده گرفتن اطلاعات مکانی طبقه‌بندی می‌شوند. اگر از وابستگی‌های مکانی بین پیکسل‌ها استفاده شود، می‌توان به نتایج بهتری در

طبقه‌بندی دست پیدا کرد. به این روش طبقه‌بندی طیفی مکانی گفته می‌شود. با این که روش‌های گوناگون و متعددی برای استفاده هم‌زمان از اطلاعات طیفی در کنار اطلاعات مکانی به منظور طبقه‌بندی داده‌های ابرطیفی وجود دارند، و با وجود پیشرفت‌های چشم‌گیر اخیر، همچنان مسئله چالش‌برانگیزی محسوب می‌شود. کارهای پژوهشی متعددی در پردازش تصاویر ابرطیفی انجام شده، که در ادامه به برخی از این موارد اشاره می‌شود. طبقه‌بندی مبتنی بر پیکسل تصویر به کمک ادغام اطلاعات [۱]، کاهش ابعاد تصویر [۲، ۳]، شناسایی هدف در تصویر [۴، ۵]، شناسایی تغییرات تصویر [۶، ۷]، به‌کارگیری روش برازش خم در استخراج ویژگی تصاویر و سیگنال‌ها [۸] و تفکیک طیفی [۹، ۱۰، ۱۱]. الگوریتم ECHO یکی از ابتدایی‌ترین روش‌هایی است که با استفاده از اطلاعات مکانی برای طبقه‌بندی تصاویر ابرطیفی معرفی شده است. پس از آن، روش‌های دیگری مانند AMICA نیز معرفی شدند [۱۲]. از دیگر روش‌های استفاده از میدان‌های تصادفی مارکوف نیز از ویژگی‌های مکانی در طبقه‌بندی تصاویر ابرطیفی است [۱۳]. همچنین به‌کارگیری پروفایل ریخت‌شناسی یکی از روش‌های مهم در شناسایی و استخراج ویژگی‌های مکانی تصویر و استفاده آن در طبقه‌بندی تصاویر ابرطیفی است [۱۴].

ویژگی و ساختار مکانی است، در نظر گرفته می‌شود. از این رو، به این روش‌ها، روش‌های طبقه‌بندی طیفی می‌گویند. به‌منظور کاهش خطاهای تعیین رده‌ها در طبقه‌بندی، از اطلاعات مکانی همچون اندازه و شکل ساختاری پیکسل‌ها می‌توان بهره گرفت. به‌عنوان مثال، در طبقه‌بندی‌های طیفی، پیکسل‌های مربوط به خیابانی که آسفالت شده‌است، با خانه‌ای که پشت‌بام آن به رنگ مشکی است، در یک رده یا دسته قرار می‌گیرند؛ در صورتی‌که، اگر از ویژگی‌ها یا اطلاعات مربوط به شکل و اندازه هم استفاده شود، این دو دسته فرصت تفکیک بیشتری خواهند داشت. بنابراین، به‌منظور دستیابی به نتایج مطلوب‌تر در طبقه‌بندی به‌طور معمول، از روش‌های مکانی طیفی به صورت هم‌زمان استفاده می‌کنند [۱۶]. در این روش‌ها، هر پیکسل از تصویر بر اساس ویژگی‌های طیفی خود پیکسل و اطلاعات استخراج‌شده از ویژگی‌های پیکسل‌های اطراف آن طبقه‌بندی می‌شود. در جدول (۱) تعدادی از روش‌های ادغام طیفی و مکانی آمده‌است. در مرجع [۱۷] طبقه‌بندی روش‌های مختلف ادغام ویژگی‌های طیفی- مکانی مطابق با شکل (۱) آمده‌است. در ادامه، مقایسه دو روش مرسوم زیر هم چیدن ویژگی‌های طیفی- مکانی و روش ادغام اطلاعات طیفی- مکانی با استفاده از گراف دودویی ناحیه‌ای که در ادغام ویژگی طیفی مکانی بررسی شده، ارائه می‌شود.



(شکل-۱): روش‌های ادغام ویژگی‌های طیفی- مکانی [۱۴]
(Figure 1): spectral-spatial feature fusion methods [17]

۱-۱ زیر هم چیدن ویژگی‌های طیفی- مکانی

یکی از روش‌های رایج در به‌کارگیری توأم اطلاعات طیفی و مکانی زیر هم چیدن این ویژگی‌هاست. [۱۸] پس از به‌دست‌آوردن مؤلفه اول اصلی^۱ از تصویر ابرطیفی اولیه به کمک روش‌هایی مثل ماتریس GLCM، پروفایل ریخت‌شناسی، فیلتر گابور ویژگی‌های مکانی این تصویر تک‌باند را استخراج می‌کنیم و ویژگی‌های طیفی نیز به‌طور مستقیم از خود داده ابرطیفی استخراج می‌شود. در پایان

^۱ PC

در [۱۵] از یک تبدیل‌کننده شبکه عصبی کانولوشنال در استخراج و ادغام اطلاعات طیفی مکانی استفاده شده‌است. در این روش به کمک یک رمزگذار و رمزگشا استخراج و ادغام ویژگی‌ها صورت می‌گیرد و در انتها، این ویژگی‌های جدید به طبقه‌بند اعمال می‌شود.

در این مقاله، از بانک‌های اطلاعاتی استاندارد شامل تصاویر ابرطیفی سنجنش از دور و طبقه‌بند بانظارت استفاده می‌کنیم. داده‌های آموزشی در طبقه‌بندی‌های با نظارت به‌صورت پراکنده و تصادفی از هر رده انتخاب می‌شوند.

به‌منظور مقایسه طبقه‌بندی‌های طیفی- مکانی پیشنهادی و مقایسه آن با دیگر روش‌های موجود از پایگاه داده‌های Indian Pines کمک گرفته شده‌است. در این مقاله روش ادغام اطلاعات ویژگی طیفی- مکانی با استفاده از طبقه‌بند شبکه عصبی با روش ادغام ویژگی با استفاده از طبقه‌بند SVM مقایسه و همچنین روش ادغام اطلاعات طیفی- مکانی گراف دودویی ناحیه‌ای با استفاده از طبقه‌بند شبکه عصبی با روش ادغام اطلاعات ویژگی طیفی- مکانی گراف دودویی ناحیه‌ای با استفاده از طبقه‌بند SVM مقایسه می‌شود. هدف مهم در طبقه‌بندی تصاویر ابرطیفی، افزایش دقت طبقه‌بندی در این تصاویر است. بنابراین، با استفاده هم‌زمان از ویژگی‌های طیفی در کنار ویژگی‌های مکانی می‌توان به این مهم دست پیدا کرد. بنابراین، مسأله اصلی در این روش‌ها، نحوه ادغام ویژگی‌های طیفی و مکانی مستخرج از تصویر ابرطیفی است. روش‌های مختلف و متعددی برای ادغام ویژگی‌های طیفی- مکانی معرفی شده‌است. یکی از روش‌های مرسوم جهت ادغام ویژگی‌های طیفی- مکانی زیر هم چیدن ویژگی‌هاست که به نام روش پشته معروف است.

۲- پیشینه روش‌های طبقه‌بندی تصاویر ابرطیفی

یکی از روش‌هایی که در طبقه‌بندی تصاویر ابرطیفی در نظر قرار می‌گیرد، به‌کارگیری ویژگی‌های مکانی نقاط تصویر است. با به‌کارگیری از اطلاعات همسایگی مکانی نقاط مختلف تصویر در طبقه‌بندی داده‌ها می‌توان به نتایج مطلوب‌تری دست پیدا کرد. در روش‌های عادی و سنتی طبقه‌بندی، وابستگی بین پیکسل‌ها با ویژگی‌های مکانی مد نظر قرار نمی‌گیرد و داده ابرطیفی فقط به شکل تعدادی بردار طیفی که فاقد


مناسبی ادغام ویژگی‌های طیفی- مکانی صورت پذیرد [۱۸].

با زیر هم چیدن این ویژگی‌ها به‌طور توأم از اطلاعات طیفی مکانی برای ورودی طبقه‌بند بردار پشتیبان ماشین حالت استفاده می‌شود که در شکل (۲) مشاهده می‌کنید.

(جدول ۱- روش‌های ادغام ویژگی‌های طیفی- مکانی [۱۹])

(Table 1): spectral-spatial feature fusion methods [19]

| معایب | مزایا | روش و سال | گروه زیر گروه |
|--|--|---|---|
| پیکسل‌های ناهنجاری ممکن است حذف شوند. ناهنجاری‌ها مهم هستند اما پیکسل‌های کمیاب با امضای طیفی متفاوت یا توجه پس‌زمینه حذف می‌شوند. تعیین ابر پیکسل‌ها یا اشیا با شکل و اندازه مناسب و حفظ لبه یک مسئله چالش‌برانگیز است. | پیکسل‌های نوفه‌های در نقشه‌های پیکسل‌های حذف می‌شوند و یک نقشه هموار و قابل‌اجرا برای پوشش زمین به‌دست می‌آید. | Pixon-based classifier MRF (2016) Relaxation HSRM (2016) | روش‌های مبتنی بر تقسیم‌بندی طبقه‌بندی مبتنی بر شی Relaxation نقشه طبقه‌بندی |
| ابعاد بالای بردار ویژگی ادغام شده ممکن است به کاهش ویژگی نیاز داشته باشند. محاسبات بالا | اجرای ساده در صورت انتخاب مکانی کاهش ویژگی نیاز مناسب، کارآمد است. | APFSDA (2017) | ادغام ویژگی انباشته شدن ویژگی‌ها (feature stacking) |
| محاسبات بالا | استفاده از هم‌بستگی بالا در بین اطلاعات طیفی و مکانی | MSPP (2019) | ادغام ویژگی استخراج ادغام ویژگی‌های طیفی- مکانی |
| حساس به شاخص‌ها | نسبت به تعداد نمونه‌های آموزشی حساسیت کمتری دارد. داشتن یک عملکرد هزینه محذب آموزش سریع | GCK (2013) | ادغام ویژگی طبقه‌بندی بر اساس کرنل |
| محاسبات بالا برای حل مسئله بهینه‌سازی بخصوص اگر از l_0 یا l_1 -norm استفاده شود. | بدون هیچ فرضی در مورد توزیع آماری داده‌ها استفاده از روابط بین پیکسل‌ها از نظر محلی و جهانی | WJCR-AS (2017) | ادغام ویژگی طبقه‌بندی بر اساس Representation |
| محاسبات بالا | ساختار ذاتی 3D تصویر فراطیفی را حفظ کنید. | 3D-Gabor (2010) | ادغام ویژگی استخراج ادغام ویژگی‌های طیفی- مکانی سه بعدی |
| مشکل بیش از حد با نمونه‌های آموزش ناکافی اگر شبکه مورد استفاده عمیق باشد، محاسبات بالا در مرحله آموزش انجام می‌شود. | هم‌زمان ویژگی استخراج و طبقه‌بندی در یک چارچوب واحد را دارد. توانایی بالا در استخراج ویژگی دقیق در لایه‌های کم عمق و معنایی در لایه‌های عمیق | RPNNet (2018) | ادغام ویژگی طبقه‌بندی بر اساس یادگیری عمیق |
| انتخاب استخراج‌کننده‌ها یا طبقه‌بندی‌کننده‌های مناسب (تصمیم‌گیرندگان) یا کمینه هم‌پوشانی و فزونگی، یک مسئله چالش‌برانگیز است. | استفاده از اطلاعات تکمیلی و آرای چندین طبقه‌بندی‌کننده قدرتمند | MBFSDA (2018) | ادغام تصمیم ادغام تصمیم |



(شکل ۲- زیر هم چیدن ویژگی‌های طیفی و مکانی [۱۵])

(Figure 2): stacked spectral and spatial Features [18]

۲-۱- روش‌های ادغام ویژگی‌های طیفی- مکانی

روشهای ادغام ویژگی‌های طیفی- مکانی در سه گروه اصلی دسته‌بندی می‌شوند. گروه نخست شامل روش‌های بر اساس تقسیم‌بندی، ابرپیکسل است که در آن از اشیا (ابر پیکسل‌ها) یا از نقشه تقسیم‌بندی به‌دست‌آمده به‌جای پیکسل برای طبقه‌بندی استفاده می‌شود. گروه دوم متشکل از روشهای ادغام ویژگی‌هاست که به شش زیرگروه تقسیم می‌شوند: پشته‌سازی ویژگی‌ها، استخراج ویژگی‌های طیفی- مکانی مشترک، طبقه‌بندی‌های مبتنی بر هسته، طبقه‌بندی‌های نمایی، استخراج ویژگی‌های طیفی- مکانی سه‌بعدی و طبقه‌بندی‌های مبتنی بر یادگیری عمیق. روش‌های ادغام سوم، رویکردهای مبتنی بر ادغام تصمیم‌گیری هستند که در آن اطلاعات تکمیلی چندین طبقه‌بندی برای دستیابی به نقشه طبقه‌بندی نهایی نقش دارند. مروری بر روش‌های مختلف در هر گروه، در جدول (۱) ارائه شده‌است. علاوه بر این، درباره مزایا و معایب هر گروه بحث شده‌است [۱۹].

۳- روش ادغام اطلاعات طیفی- مکانی به کمک گراف دودویی ناحیه‌ای

به‌منظور ادغام اطلاعات طیفی- مکانی، روش گراف دودویی ناحیه‌ای (LBG) به‌کارگرفته شده‌است تا به شکل مطلوب و بهینه‌تری اطلاعات طیفی- مکانی را با هم ادغام کند. استفاده از این روش منجر به بهبود ۵ تا ۱۵ درصدی نتیجه طبقه‌بندی شده‌است که از روی آزمایش‌های متعدد روی داده‌های ابرطیفی مشاهده شده‌است [۱۸].

در این روش پیکسل‌هایی از تصویر را، که با یکدیگر نوعی ارتباط دارند، مشابه یک گراف در نظر می‌گیریم که با تشکیل آن می‌توان میان پیکسل‌های تصویر نوعی ارتباط (یالهای گراف) تشکیل داد تا در نهایت، به روش

نحوه پیاده‌سازی روش ادغام ویژگی‌های طیفی- مکانی، با استفاده از الگوی دودویی ناحیه‌ای (LBG)، شامل هفت مرحله می‌شود که به ترتیب عبارتند از ۱- به‌کارگیری ویژگی‌های طیفی و ویژگی‌های مکانی استخراج‌شده ۲- محاسبه و شناسایی K تا از نزدیک‌ترین همسایگی‌های طیفی و مکانی در یک پنجره همسایگی ۳- استخراج نزدیک‌ترین همسایگی‌های طیفی و مکانی مشترک در یک پنجره همسایگی برای به‌دست‌آوردن ماتریس ارتباط بین رأس‌های گراف ۴- محاسبه ماتریس ارتباط بین رأس‌های گراف کل تصویر با کمک رابطه (۲)

$$A_{i,j} = \begin{cases} E_{i,j}^{fus} & , if j \in N^{fus}(i), j \in [1, \dots, N] \\ 0 & , otherwise \end{cases} \quad (2)$$

۵- به‌دست‌آوردن ماتریس انتقال W با کمک معادله

$$\arg \min \left(\sum_{i,j=1}^N \|W^T \cdot x_i^{Stak} - W^T \cdot x_j^{Stak}\|^2 \cdot A_{ij} \right) \quad (3)$$

۶- حل معادله بهینه‌سازی

$$W^t \cdot (X^{stack}) \cdot D^{fusion} \cdot (X^{stack})^t = I \quad (4)$$

که در آن

$$D^{fusion} = \sum_{j=1}^n A_{ij} \quad (5)$$


در این معادله ماتریس انتقال W با حل مقدار ویژه پیشرفته به‌دست‌می‌آید.

۷- استخراج ویژگی‌های جدید ادغام‌شده با استفاده از رابطه (1) که در این رابطه W ماتریس انتقال، Z_i ویژگی‌های ادغام‌شده پس از کاهش باند هستند [۱۷].

۵- روش پیشنهادی

در این مقاله به‌عنوان روش پیشنهادی، از طبقه‌بند شبکه عصبی در روش‌های زیر هم چیدن اطلاعات طیفی و مکانی و ادغام اطلاعات طیفی- مکانی با استفاده از گراف دودویی ناحیه‌ای استفاده می‌شود. با توجه به اینکه در هر دو روش متداول زیر هم چیدن اطلاعات طیفی و مکانی و ادغام اطلاعات طیفی- مکانی با استفاده از گراف دودویی ناحیه‌ای از طبقه‌بند بردار پشتیبان حالت استفاده شده است، به‌کارگیری طبقه‌بند شبکه عصبی و جایگزینی آن با طبقه‌بند بردار پشتیبان حالت می‌تواند منجر به بهبود کارایی روش‌های یادشده شود.

بر روی هر یک از پیکسل‌های تصویر ابرطیفی شروطی اعمال می‌شود. بین هر پیکسل، با سایر پیکسل‌های تصویر یک گراف تشکیل می‌شود و ماتریس ارتباط بین رأس‌های گراف به‌دست‌می‌آید [۱۹]. ماتریس ارتباط بین رأس‌های گراف را با شرط‌های مختلف می‌توان به‌دست‌آورد؛ به‌عنوان مثال، فرض شود که ماتریس ارتباط بین رأس‌های گراف به صورت «پیکسل‌های هم‌مرده با پیکسل i م به گراف متعلق به پیکسل i م مربوط هستند». پس از آن، از ایده کمینه‌کردن فاصله درون‌گروهی پیکسل‌هایی که به هر گراف مربوط هستند، در فضای جدید استفاده می‌شود و سپس، با حل یک مسئله، بهینه‌سازی ارتباط پیکسل‌ها در فضای ادغام‌شده به‌دست‌می‌آید. (شکل ۳).



(شکل ۳): نمای کلی روش ادغام با استفاده از گراف [۱۳]

(Figure 3): an overview of graph method in [13] feature fusion

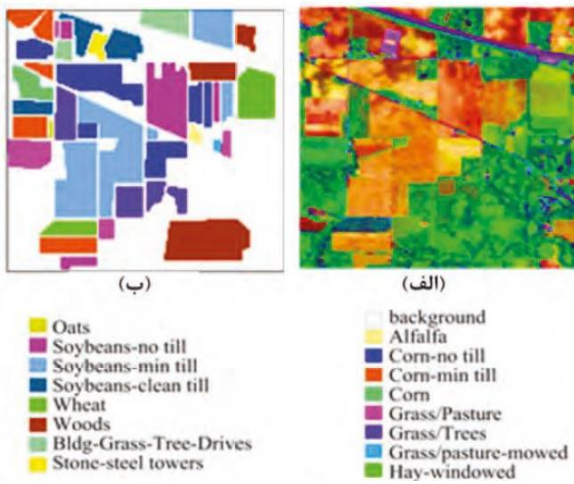
با فرض $X^{spec} = \{x_i^{spec}\}_{i=1}^N$ بیانگر ویژگی‌های طیفی و $X^{spat} = \{x_i^{spat}\}_{i=1}^N$ بیانگر ویژگی‌های مکانی، بعد از نرمالیزه‌شدن، در بازه $[0, 1]$ هستند، $x_i^{spec} \in R^B$ که بیانگر تعداد ابعاد ویژگی‌های طیفی و $x_i^{spat} \in R^D$ که بیانگر تعداد ابعاد ویژگی‌های مکانی و N تعداد کل پیکسل‌های تصویر ابرطیفی هستند. هدف به‌دست‌آوردن ماتریس انتقال و $w \in R^{(D+B)*d}$ است و d تعداد ابعادی است که کاهش یافته و بعد از ادغام ویژگی‌ها برای به‌دست‌آوردن ماتریس انتقال W از رابطه (۱) استفاده می‌کنیم.

$$Z_i = W^T \cdot x_i^{Stak} \quad (1)$$

در رابطه (۱) $Z_i \in R^d$ ویژگی‌های ادغام‌شده پس از کاهش باند است که در آن $d \leq (B + D)$ است [۱۶].

۴- مراحل ادغام ویژگی‌های طیفی- مکانی با استفاده از الگوی دودویی ناحیه‌ای (LBG)

در این قسمت مراحل مختلف روش ادغام ویژگی‌های طیفی مکانی با استفاده از الگوی دودویی ناحیه‌ای (LBG) تشریح می‌شود، که عبارتند از:



(شکل ۶- الف) تصویر شکل کاذب ایندیانا

(ب) نقشه مرجع آن [۲۰]

(Figure 6): Indian pines data and GTM

۲-۶- معرفی شبیه‌سازی


در کلیه مراحل پیاده‌سازی‌ها از داده Indian pines استفاده شده‌است. در رده‌های «چمن/ مرتع»، «یونجه» و «جو» فقط ده نمونه از هر رده، به‌عنوان نمونه‌های آموزشی انتخاب می‌شوند و در دیگر رده‌ها پنجاه نمونه به‌عنوان نمونه آموزشی انتخاب شده‌اند. نیاز به ذکر است که نمونه‌های آموزشی در هر داده به‌طور تصادفی انتخاب شده‌اند.

در همه شبیه‌سازی‌ها ویژگی‌های طیفی به‌طور مستقیم از داده ابرطیفی استخراج شده و استخراج ویژگی‌های مکانی با استفاده از فیلتر گابور، ماتریس سطوح هم‌رخداد و پروفایل ریخت‌شناسی گسترش‌یافته صورت می‌پذیرد. از تصویر ورودی تک‌باند ($PC1$) برای تولید این ویژگی‌ها مطابق با یک الگوریتم خاص استفاده می‌شود. شاخص‌هایی که برای استخراج ویژگی مکانی با استفاده از این فیلتر استفاده می‌شود، طبق جدول (۲) است. به‌این‌ترتیب، طول بردار ویژگی به‌دست‌آمده برای فیلتر گابور برابر با $Nd \times Ns = 24$ خواهد بود.

ویژگی‌های مکانی استخراج‌شده با استفاده از ماتریس GLCM بدین گونه به‌دست‌می‌آید که یک ماتریس GLCM با استفاده از شاخص‌های ($d=1$, $\theta=0$) در پنجره همسایگی مربع شکل با ابعاد 11×11 برای هر پیکسل (از باند $PC1$) محاسبه می‌شود. آنگاه ۱۶ ویژگی GLCM را از هر ماتریس استخراج می‌کنیم.

تعداد ویژگی‌های مکانی که با استفاده از پروفایل ریخت‌شناسی استخراج می‌شود، ۱۵۰ ویژگی است و مانند سایر ویژگی‌های مکانی، از تصویر تک‌باند ورودی به‌منظور استخراج ویژگی با استفاده از پروفایل ریخت‌شناسی


طبقه‌بند شبکه عصبی دارای ده لایه مخفی بوده و کارایی آن به کمک آنتروپی متقابل و ماتریس‌های سردرگمی مشخص می‌شود. همچنین از شناسایی الگوی شبکه عصبی دارای نورون‌های مخفی sigmoid و softmax برای طبقه‌بندی رده‌های تصاویر ابرطیفی استفاده شده‌است. در شکل زیر روندنمای به‌کارگیری طبقه‌بند شبکه عصبی در دو روش متداول زیرهم‌چیدن اطلاعات طیفی و مکانی و ادغام اطلاعات طیفی- مکانی با استفاده از گراف دودویی ناحیه‌ای آمده‌است.



(شکل ۴): استفاده از طبقه‌بند شبکه عصبی در روش زیر هم

چیدن اطلاعات طیفی- مکانی

(Figure- 4): neural network classifier in stack method



(شکل ۵): استفاده از طبقه‌بند شبکه عصبی در روش ادغام

اطلاعات طیفی- مکانی با استفاده از گراف دودویی ناحیه‌ای

(Figure- 5): neural network classifier in local graph method

نتایج شبیه‌سازی در قسمت بعدی میزان کارایی روش پیشنهادی را نشان می‌دهد.

۶- شبیه‌سازی

۶-۱- ویژگی‌های داده مورد استفاده

داده تصاویر ابرطیفی ۱۹۹۲ از منطقه‌ای آزمایشی در قسمتی از ایالت ایندیانا و از یک منطقه کشاورزی جنگلی گرفته شده‌است. تصویر ایندیانا شامل 145×145 پیکسل و 224 باند، با پهنای باند ده نانومتر در محدوده طول موج 0.4 تا 0.5 میکرومتر، با دقت مکانی بیست متر بر پیکسل و دقت رادیومتریک هشت بیت است. این داده دارای نقشه مرجعی با ۱۶ کلاس متفاوت از پوشش‌های زمینی است (شکل ۶). پوشش گیاهی ایندیانا دارای یک‌سوم گیاهان جنگلی و دوسوم گیاهان کشاورزی چندساله است.

از کل ۱۰۲۴۹ نمونه داده‌های ایندیانا در ۱۶ رده مختلف مقادیر ۱۷ و ۳ و ۸۰ درصد به ترتیب جهت داده‌های آموزشی، اعتبارسنجی و آزمون به کار گرفته شده‌اند.

(جدول - ۲): روش‌های ادغام ویژگی‌های طیفی - مکانی

(Table- 2): feature extraction elements

| نوع ویژگی | المان‌های استخراج ویژگی |
|----------------------|--|
| Spectral Feature | HS Data |
| GLCM For PC1 | Winlen = ۷ 16 feature extracted from GLCM |
| Gabor Filter for PC1 | Winlen = ۸۰ UI = 0/01 Uh = 0/8 Ns = 6 Nd = 2 |
| EMP For PC1 to PCn | SE Disk, Square, Rectangle Step: 1-10 |

پس از معرفی ویژگی‌های مکانی و طیفی استفاده شده در آزمایش‌ها (جدول ۲)، نمای کلی ویژگی‌های استخراج شده را در ادامه نشان می‌دهیم (شکل ۶). در این روند برای استخراج ویژگی‌های مکانی در تمامی آزمایش‌ها، نخست، بر روی تصویر ابر طیفی، تبدیل مؤلفه‌های اصلی را اعمال و پس از کاهش باندها ویژگی‌های مکانی را از روش‌های مطرح شده مطابق شکل (۶) استخراج می‌کنیم. همچنین ویژگی‌های طیفی را نیز به‌طور مستقیم، از خود داده ابر طیفی دریافت می‌کنیم.

به‌طور کلی، در استخراج ویژگی‌های مکانی و طیفی در آزمایش‌ها از ۹۹ درصد سطح انرژی داده‌ها برای استخراج پروفایل ریخت‌شناسی استفاده شده‌است. همچنین، داده ایندیانا و برای استخراج ویژگی‌های ریخت‌شناسی از عملگر ساختاری مربعی و در سایر داده‌ها از عملگر ساختاری دایره‌ای استفاده کردیم.

۳-۶- تنظیمات شاخص در پیاده‌سازی روش

گراف

برای به‌دست‌آوردن نقشه طبقه‌بندی در روش پیشنهادی (نقشه طبقه‌بندی اول)، در هر رده پنج درصد نمونه‌ها به‌عنوان نمونه آموزشی در نظر گرفته شده و نقشه طبقه‌بندی به‌دست‌می‌آید. همچنین، در روش پیشنهادی و

استفاده شده‌است. به‌منظور استخراج این بردار از المان دایره‌ای، مستطیلی و مربعی با اندازه‌های یک تا ده استفاده می‌شود.

در این آزمایش‌ها ویژگی‌های طیفی به‌طور مستقیم، از داده ابر طیفی استخراج شده‌است که برای داده‌های مختلف تعدادشان متفاوت است. تعداد این ویژگی‌ها برای داده‌های Indian Pines، ۲۲۰ است که در تمامی داده‌ها برای استخراج پروفایل ریخت‌شناسی ۹۹ درصد سطح انرژی داده‌ها لحاظ شده‌است. همچنین، در داده ایندیانا برای استخراج ویژگی‌های ریخت‌شناسی از عملگر ساختاری مربعی و در سایر داده‌ها از عملگر ساختاری دایره‌ای استفاده شده‌است.

تعداد ویژگی‌های مقایسه‌شده در چهار روش مطابق با جدول (۳)، برابر با ۴۱۰ در روش پشته و ۲۰۰ در گراف دودویی ناحیه‌ای است [21].

طبقه‌بند بردار پشتیبان یک نوع طبقه‌بند بانظارت و دوره‌ای است که برای طبقه‌بندی تصاویر ابر طیفی استفاده می‌شود [۲۰]. این طبقه‌بند با حل یک مسئله بهینه‌سازی و استفاده از مرز خطی که برای دو رده در نظر می‌گیرد، فاصله بین نزدیک‌ترین نمونه‌های آموزشی را در جهت عمود بر مرز حداقل می‌کند. در این طبقه‌بند به فاصله بین نزدیک‌ترین نمونه‌های آموزشی بردار پشتیبان می‌گویند که این بردارها در طی فرایند طبقه‌بندی طراحی و آموزش داده می‌شوند و در ادامه فرایند، فقط این بردارها اهمیت دارند. در حقیقت، در طبقه‌بند ماشین بردار پشتیبان فاصله بین بردارهای پشتیبان را در جهت عمود بر مرز خطی کمینه می‌کند [۲۰].


این طبقه‌بند یک طبقه‌بند دوره‌ای است. اگر تعداد رده‌ها بیشتر از دو تا باشند، از روش یکی در مقابل همه (OAA) استفاده می‌کنیم [۲۰].

در این آزمایش‌ها، همواره از هسته چندجمله‌ای استفاده شده‌است. در طبقه‌بند شبکه عصبی ده لایه مخفی در نظر گرفته شده‌است. تابع هزینه استفاده شده $trainscg^1$ است. برنامه تشخیص الگو شبکه عصبی در نرم‌افزار متلب می‌تواند کارایی خودش را به کمک ماتریس‌های سردرگمی^۲ و آنتروپی متقابل ارزیابی کند. همچنین، برنامه تشخیص الگوی شبکه عصبی متلب دارای نورون‌های مخفی sigmoid و نورون‌های خروجی softmax بهره می‌برد. این طبقه‌بند شبکه عصبی به کمک تابع $trainscg$ آموزش داده می‌شود.

¹ Scaled conjugate gradient


² confusion matrix

مناسبتی در مقایسه با روش مبتنی بر گراف دودویی نیست.




(شکل - ۸): مقایسه عملکرد طبقه‌بند SVM و NN در Stack با تعداد ویژگی ۲۰۰

(Figure- 8): performance comparison of SVM and NN classifier in stack with 200 feature number



(شکل - ۹): مقایسه عملکرد طبقه‌بند SVM و NN در LBG با تعداد ویژگی ۴۱۰

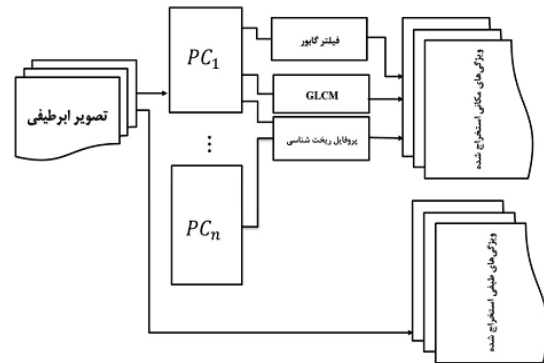
(Figure-9): performance comparison of SVM and NN classifier in LBG with 400 feature number



(شکل - ۱۰): مقایسه زمان اجرای مراحل آموزش و آزمایش در هر کدام از دسته‌بندهای SVM و NN

(Figure-10): comparison in implementation time of the training and test phases in the SVM, NN classification

روش گراف ناحیه‌ای اندازه پنجره همسایگی 15×15 در نظر گرفته، و در هر پنجره همسایگی مقدار ۱۵ تا از نزدیک‌ترین همسایگی‌ها برای به دست آوردن گراف لحاظ می‌شود. برای محاسبه آماره نقشه طبقه‌بندی روش پیشنهادی در تمامی آزمایش‌ها با سایر روش‌ها مقایسه شد. همچنین، تمام دقت‌ها به جز آماره در جداول به صورت درصد هستند.



(شکل - ۷): نمودار ویژگی‌های طیفی و مکانی استخراج شده (Figure 7): diagram of extracted spectral spatial feature

۴-۶- نتایج طبقه‌بندی برای مجموعه داده‌های Indian Pines

به منظور مقایسه بین روش پیشنهادی به کارگیری طبقه‌بند شبکه عصبی در روش‌های ادغام ویژگی طیفی و مکانی در دو روش پشته و روش مبتنی بر گراف دودویی با روش متداول طبقه‌بند بردار ماشین حالت از داده‌های Indian Pines بهره گرفته‌ایم و دقت طبقه‌بندی به کارگیری دو طبقه‌بند با یکدیگر و با دیگر روش‌ها مطابق با شاخص‌های ویژگی‌های طبقه‌بند، تعداد ویژگی‌ها، OA، AV، AA در جدول (۳) مقایسه شده است.

- همان‌طور که انتظار می‌رفت، به کارگیری توأم و هم‌زمان، از ویژگی‌های طیفی در کنار ویژگی‌های مکانی در بهبود دقت طبقه‌بندی مؤثر است.
- برای بیشتر رده‌ها، با توجه به جدول (۳)، روش پیشنهادی مبتنی بر شبکه عصبی بهترین عملکرد را دارد.
- با توجه به جدول (۳) مشاهده می‌شود که با ادغام اطلاعات طیفی- مکانی (با استفاده از روش گابور سه‌بعدی، گراف ناحیه‌ای و روش پیشنهادی مبتنی بر شبکه عصبی) دقت بیشتر شده است. بنابراین، نتایج بیانگر این است که به کارگیری طبقه‌بندی SVM در روش زیرهم‌چیدن ویژگی‌های طیفی- مکانی روش

(جدول-۳): نتایج پیاده‌سازی برای مجموعه داده
ابرطیفی Indian Pines با استفاده از طبقه‌بند SVM.

طبقه‌بند شبکه عصبی

(Table- 3): implementation results of SVM and NN classifier
Indian pines data

| Case | Input Features to Classifier | Number of features | OA (%) | AA (%) | AV (%) | Kappa (%) |
|-----------------------------|---------------------------------|--------------------|-----------|-----------|-----------|-----------|
| Spectral | "HS" to SVM | ۲۲۰ | .۷۲ ۶ | .۸۳ ۲ | .۷۲ ۲ | ۷۹ |
| | "GLCM+ Gabor + EMP" to SVM | ۱۹۰ | .۷۳ ۱ | .۸۵ ۸ | .۷۸ ۷ | ۹.۷۸ |
| Stack | "HS+ GLCM+ Gabor + EMP" to SVM | ۴۱۰ | .۸۲ ۳ | .۸۹ ۲۲ | .۸۰ ۷ | ۵.۸۴ |
| LBG | Feature Fusion using LBP to SVM | ۲۰۰ | .۸۸ ۶ | .۹۳ ۵ | .۸۷ ۹۷ | ۰۶.۹۱ |
| Proposed NN in stack Method | "HS+ GLC M+ Gabor + EMP" to NN | ۴۱۰ | .۹۹ ۳۸ | .۹۸ ۹ | .۹۹ ۴۹ | ۹۹ |
| Proposed NN in LBG Method | Feature Fusion using LBG to NN | ۲۰۰ | .۹۶ ۸۶ | .۹۶ ۱۳ | .۹۷ ۳۱ | ۷۷.۹۶ |

روی ویژگی‌های طیفی- مکانی، نسبت به سایر روش‌ها از جمله روش گراف ناحیه‌ای سبب بهبود نتایج می‌شود. شکل (۱۱) و (۱۲) نتایج به‌دست‌آمده از نرم‌افزار متلب را نشان می‌دهد. در شکل (۱۱) نقشه روش stack با طبقه‌بند شبکه عصبی شباهت بیشتری به نقشه داده اصلی دارد و همچنین، در شکل (۱۲) نقشه گراف دودویی با طبقه‌بند شبکه عصبی بسیار نزدیک به نقشه داده اصلی است.


(جدول-۴): دقت رده‌های مجموعه داده Indian Pines با

استفاده از طبقه‌بند SVM و NN به‌ازای روش‌های مختلف
(Table- 4): class accuracy of Indian pines dataset with SVM and NN classifier

| روش | طیفی SVM | مکانی SVM | پشته SVM | گراف دودویی SVM | NN پشته | NN گراف دودویی |
|-------------|-----------------|-----------|----------|-----------------|---------|----------------|
| تعداد ویژگی | 200 | 70 | 270 | 20 | 210 | 200 |
| شماره رده | دقت رده‌ای درصد | | | | | |
| 1 | 95.7 | 99.1 | 97.7 | 97.9 | 97.7 | 97.7 |
| 2 | 69.2 | 59.6 | 76.8 | 78.2 | 98.1 | 95.2 |
| 3 | 69.3 | 78.7 | 88.1 | 89.2 | 98.2 | 95.3 |
| 2 | 82 | 93.2 | 92.7 | 92.7 | 93.7 | 85.2 |
| 5 | 90.9 | 85.8 | 93 | 93.6 | 97.6 | 92.2 |
| 6 | 92.8 | 90.9 | 97.6 | 97.2 | 99.2 | 97.2 |
| 7 | 92.1 | 96.8 | 98.2 | 98.2 | 100 | 100 |
| 8 | 93.7 | 99.3 | 99.2 | 99 | 99.8 | 99.6 |
| 9 | 92.5 | 99.5 | 99 | 100 | 100 | 72.6 |
| 10 | 68.5 | 68.5 | 80.9 | 81.2 | 97.3 | 93.8 |
| 11 | 52.6 | 53.2 | 70.3 | 69.2 | 98.3 | 92.6 |
| 12 | 70.6 | 50.3 | 78.2 | 80.3 | 95.7 | 95.2 |
| 13 | 98.7 | 99.1 | 99.1 | 99.2 | 100 | 99.5 |
| 12 | 82.1 | 91.6 | 95 | 95.2 | 99.7 | 98.2 |
| 15 | 67.2 | 95.8 | 95.2 | 95.5 | 99.1 | 92 |
| 16 | 97.8 | 99.2 | 98.5 | 99 | 100 | 97.6 |
| دقت متوسط | 85.8 | 83.2 | 91.9 | 91.9 | 98.3 | 95.5 |

در شکل (۸) به مقایسه عملکرد طبقه‌بند SVM و NN در Stack با تعداد ویژگی ۲۰۰ پرداخته‌شد. نتایج نشان می‌دهد که با به‌کارگیری طبقه‌بند شبکه عصبی در روش Stack بهبود شایانی حاصل شده‌است. همچنین، شکل (۹) مقایسه عملکرد طبقه‌بند SVM و NN در LBG با تعداد ویژگی ۴۱۰ را نشان می‌دهد، که در این مورد نیز، استفاده از طبقه‌بند شبکه عصبی باعث بهبود عملکرد شده‌است. در شکل (۱۰) مقایسه زمان اجرای مراحل آموزش و آزمایش در هرکدام از دسته‌بندهای NN و SVM نشان داده شده‌است.

در ادامه، همان‌طور که از جدول (۴) مشاهده می‌شود، در



(شکل-۱۱): الف) نقشه روش stack با طبقه‌بند SVM ب) نقشه گراف دودویی با طبقه‌بند SVM ج) نقشه روش stack با طبقه‌بند شبکه عصبی د) نقشه داده اصلی GTM
 (Figure- 11): a) stack map with SVM b) Binary graph map with SVM c) Binary map with NN d) Main map GTM

روش‌های متداول دیگر که در به‌کارگیری هم‌زمان اطلاعات طیفی- مکانی برای طبقه‌بندی استفاده می‌شوند، دارای برتری است.

۷- نتیجه‌گیری

در این مقاله روش‌های مختلف طبقه‌بندی تصاویر ابرطیفی بررسی و با یکدیگر مقایسه شد. برای طبقه‌بندی تصاویر ابرطیفی از به‌کارگیری توأم ویژگی طیفی و ویژگی مکانی بهره بردیم. در طرح پیشنهادی با به‌کارگیری و جایگزینی طبقه‌بند شبکه عصبی در دو روش رایج پشته و گراف ناحیه‌ای که از طبقه‌بند بردار پشتیبان حالت بهره می‌برند، به نتایج مطلوب‌تری دست پیدا کردیم. باتوجه‌به آزمایش‌های انجام‌داده‌شده مشاهده شد که روش پیشنهادی ما در تمامی داده‌های آزمایش‌شده نسبت‌به

8-Refrence

۷- مراجع

- [1] M. Imani and H. Ghassemian, "Pansharpening optimisation using multiresolution analysis and sparse representation," International Journal of Image and Data Fusion, vol. 12, no. 4, pp. 1-23, 2017.
- [2] M. Imani and H. Ghassemian, "Feature reduction of hyperspectral images Discriminant analysis and the first principal component,"

- [14] Mathieu Fauvel, Mathieu Fauvel, Jocelyn Chanussot, Jocelyn Chanussot, Jon Atli Benediktsson, Jon Atli Benediktsson, Johannes R. Sveinsson, Johannes R. Sveinsson "Spectral and spatial classification of hyperspectral data using SVMs and morphological profiles", "IEEE Transactions on Geoscience and Remote Sensing 46, 11 - part 2 (2008) 3804-3814"
- [15] Siyuan Hao, Yufeng Xia, Lijian Zhou, etc Yuanxin Ye; Wei Wang "Spectral and Spatial Feature Fusion for Hyperspectral Image Classification" Journals & Magazines, IEEE Geoscience and Remote Sensing Letters, Volume: 19, 2022
- [16] W. Liao, M. Dalla Mura and J. Chanussot, "Fusion of Spectral and Spatial Information for Classification of Hyperspectral Remote-Sensed Imagery by Local Graph," IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, vol. 9, no. 2, pp. 583 - 594, 2016.
- [17] Maryam Imani, Hassan Ghassemian, "An overview on spectral and spatial information fusion for hyperspectral image classification: Current trends and challenges" Elsevier Information Fusion 59 (2020) 59-83, 2020.
- [18] M. Imani and H. Ghassemian, "GLCM, Gabor, and morphology profiles fusion for hyperspectral image classification," 2016 24th Iranian Conference on Electrical Engineering (ICEE), pp. 460 - 465, 2016.
- [19] Maryam Imani, Hassan Ghassemian, "An overview on spectral and spatial information fusion for hyperspectral image classification: Current trends and challenges", journal Elsevier Information Fusion 59 (2020) 59-83
- [20] Hosseini S Abolfazl, Beitollahi Mersedeh, "Using Savitsky-Golay filter and interval curve fitting in order to hyperspectral data compression", IEEE 2017.
- [21] Debaleena Datta, Pradeep Kumar Mallick, Akash Kumar Bhoi, Muhammad Fazal Ijaz, Jana Shafi, and Jaeyoung Choi, "Hyperspectral Image Classification: Potentials, Challenges, and Future Directions "Hindawi Computational Intelligence and Neuroscience Volume 2022.
- [2] Journal of AI and Data Mining, vol. 3, no. 5, pp. 1-9, 2015.
- [3] M. Imani and H. Ghassemian, "Feature space discriminant analysis for hyperspectral data feature reduction," ISPRS Journal of Photogrammetry and Remote Sensing, vol. 102, no. 5, pp. 1-13, 2015.
- [4] A. Taghipour, H. Ghassemian, and F. Mirzapour, "Anomaly detection of hyperspectral imagery using differential morphological profile" in Electrical Engineering (ICEE), 2016 24th Iranian Conference on, 2016, vol. 12, no. 4, pp. 1219-1223, 2016.
- [5] A. Taghipour and H. Ghassemian, "Hyperspectral Anomaly Detection Using Attribute Profiles" IEEE Geoscience and Remote Sensing Letters, vol. 12, no. 4, pp. 13-15, 2017.
- [6] Z. Zhu, "Change detection using landsat time series: A review of frequencies, preprocessing, algorithms, and applications" ISPRS Journal of Photogrammetry and Remote Sensing, vol. 130, no. 13, pp. 370-384, 2017.
- [7] Maryam Vafadar; Hassan Ghassemian, "Hyperspectral anomaly detection using Modified Principal component analysis reconstruction error" ,2017 Iranian Conference on Electrical Engineering (ICEE), DOI:10.1109/Iranian CEE. 2017. 7985332.
- [8] Hamid Nourollahi, S. Abolfazl Hosseini*, Ali Shahzadi & Ramin Shaghghi Kandovan, Signal detection Using Rational Function Curve Fitting, Signal and Data Processing Journal Serial 54, Volume 19, Number 4 (3-2023), jsdp.rcisp.ac.ir
- [9] R. Rajabi and H. Ghassemian, "Sparsity constrained graph regularized NMF for spectral unmixing of hyperspectral data," Journal of the Indian Society of Remote Sensing, vol. 43, no. 13, pp. 269-278, 2015.
- [10] F. Kowkabi, H. Ghassemian, and A. Keshavarz, "Hyperspectral endmember extraction and unmixing by a novel spatial-spectral preprocessing module," in Geoscience and Remote Sensing Symposium (IGARSS), 2016 IEEE International, vol. 12, no. 4, pp. 33823385, 2016.
- [11] Hongmin Gao; Zhonghao Chen ; Feng Xu " Adaptive spectral-spatial feature fusion network for hyperspectral image classification using limited training samples" ; International Journal of Applied Earth Observation and Geoinformation Volume 107, March 2022
- [12] H. Ghassemian and D. A. Landgrebe, "object-oriented feature extraction method for image data compaction," IEEE Control Systems Magazine, vol. 8, no. 3, pp. 42 - 48, 1988.
- [13] M. Fauvel, Y. Tarabalka and J. A. Benedi, "Advances in Spectral-Spatial Classification of Hyperspectral Images," Proceedings of the IEEE, vol. 101, no. 3, pp. 652 - 675, 2013.



فاطمه سادات میری دانش‌آموخته

کارشناسی برق الکترونیک از دانشگاه آزاد زاهدان و کارشناسی ارشد مهندسی برق مخابرات از دانشگاه آزاد اسلامی، واحد یادگار امام خمینی (ره)

شهری است. وی هم‌اکنون دانشجوی دکترای برق مخابرات در واحد دانشگاه آزاد است. زمینه‌های پژوهشی فعلی ایشان شبکه‌های عصبی، یادگیری عمیق و پردازش سیگنال‌های مخابراتی و پردازش تصویر است.

نشانی رایانامه ایشان عبارت است از:

Stud.miri@iausr.ac.ir



سیدابوالفضل حسینی تحصیلات

کارشناسی مهندسی برق کنترل را در دانشگاه صنعتی شریف و کارشناسی ارشد مهندسی برق مخابرات را در دانشگاه صنعتی

خواجه نصیر به پایان رساند. همچنین، ایشان دارای مدرک دکتری برق مخابرات از دانشگاه تربیت مدرس است. ایشان عضو هیئت علمی دانشگاه آزاد اسلامی واحد یادگار امام خمینی (ره) است. زمینه‌های پژوهشی ایشان مباحث نظیر یادگیری ماشین، پردازش تصویر، مهندسی سنجش از دور، رمزنگاری و فیلترهای وفقی را در برمی‌گیرد. نشانی رایانامه ایشان عبارت است از:

abolfazl.hosseini@modares.ac.ir



رامین شقاقی کندوان تحصیلات

کارشناسی مهندسی الکترونیک را در دانشگاه تهران و کارشناسی ارشد و دکترای مهندسی برق مخابرات را در دانشگاه آزاد اسلامی به پایان رساند. ایشان عضو هیئت علمی

دانشگاه آزاد اسلامی واحد یادگار امام (ره) و زمینه‌های پژوهشی ایشان در زمینه‌های بهینه‌سازی شبکه، یادگیری عمیق، شبکه‌های مخابرات بی‌سیم است. نشانی رایانامه ایشان عبارتند از:

Ramin.shaghghi@gmail.com