

کاهش ابعاد داده‌های ابرطیفی به منظور افزایش جدایی‌پذیری طبقه‌ها و حفظ ساختار داده

مریم ایمانی و حسن قاسمیان*

دانشکده مهندسی برق و کامپیوتر، دانشگاه تربیت مدرس، تهران، ایران



چکیده

امروزه تصویربرداری ابرطیفی به منظور طبقه‌بندی داده‌های سطح زمین با دقت و جزئیات بالا بسیار مورد توجه است. بدلیل کمبود نمونه آموزشی در دسترس، کاهش ابعاد داده ابرطیفی به عنوان یک گام مهم پیش‌بردازش در تحلیل و طبقه‌بندی تصاویر ابرطیفی به شمار می‌رود. در این مقاله یک روش استخراج ویژگی پیشنهاد شده که سعی می‌کند، علاوه‌بر افزایش جدایی‌پذیری طبقه‌ها، ساختار داده را نیز حفظ کند. برای این منظور، دوتابع هدف نخست از نمونه‌های آموزشی برچسب‌دار بهره می‌برد و سعی می‌کند نمونه‌های هم‌طبقه را در فضای کاهش‌یافته تا جای ممکن به هم نزدیک کند. تابع هدف دوم از نمونه‌های بدون برچسب خوش‌بندی شده بهره برده و سعی می‌کند نمونه‌های متعلق به یک خوشه را در فضای کاهش‌یافته، تا جای ممکن به هم نزدیک گرداند. روش پیشنهادی بر روی سه داده ابرطیفی واقعی مورد آزمایش قرار گرفته و برتری آن از نظر دقت طبقه‌بندی نسبت به تعدادی از روش‌های پرکاربرد استخراج ویژگی نشان داده شده است.

واژگان کلیدی: ابعاد بالا، نمونه آموزشی کم، ابرطیفی، طبقه‌بندی، کاهش ویژگی

Feature reduction of hyperspectral data for increasing of class separability and preserving of data structure

Maryam Imani and Hassan Ghasseian*

Faculty of Electrical and Computer Engineering, Tarbiat Modares University, Tehran, Iran

Abstract

Hyperspectral imaging with gathering hundreds spectral bands from the surface of the Earth allows us to separate materials with similar spectrum. Hyperspectral images can be used in many applications such as land chemical and physical parameter estimation, classification, target detection, unmixing, and so on. Among these applications, classification is especially interested. A hyperspectral image is a cube data containing two spatial dimensions and a spectral one. Generally, the Hughes phenomenon is occurred in the supervised classification of hyperspectral images due to the limited available labeled samples and the curse of dimensionality. So, feature reduction is an important preprocessing step for analysis and classification of hyperspectral data. Feature reduction methods are categorized into feature selection approaches and feature extraction ones. Our main focus in this paper is on feature extraction. The feature extraction methods are also divided into three main groups: supervised (with labeled samples), unsupervised (without labeled samples), and semi-supervised (with both labeled and unlabeled samples). The first group of feature extraction methods usually suffers from problems due to limited available training samples. These methods often consider the separability between classes, and so are efficient for classification applications. The second group has no need for training samples, but they often do not consider the separability between

different classes and so, are not appropriate for classification. These methods are usually used for signal representation or preserving the local structure of data. The use of both labeled and unlabeled samples in the third group can increase the abilities of the feature extractor. A feature extraction method is proposed in this paper which belongs to the third group. The proposed method increases the class separability and tries to preserves the structure of data. The proposed feature extraction method uses the ability of unlabeled samples in addition to available limited training samples to improve the classification performance. The experimental results on three real hyperspectral images show the better performance of proposed method compared to some popular feature extraction methods in terms of classification accuracy.

Keywords: high dimension, small training set, hyperspectral, classification, feature reduction.

استاندارد، برای انتخاب ویژگی، به طور معمول از توابع معیار بر مبنای معیار فاصله‌ی آماری که جدایی‌پذیری میان توزیع طبقه‌ها را ارزیابی می‌نمایند، استفاده می‌کنند. از جمله این معیارها می‌توان به واگرایی^۸ و فاصله باتاچاریا^۹ اشاره کرد. بررسی الگوریتم‌های جستجو در انتخاب ویژگی در [8]-[9]-[10] انجام شده است. در [10] یک روش انتخاب ویژگی بر اساس الگوریتم جستجوی ژنتیک پیشنهاد شده است. مراجع [12]-[11] از معیار ارزیابی اطلاعات متقابل برای انتخاب زیرمجموعه مناسب ویژگی‌ها استفاده کرده‌اند. نویسنده‌گان در [13] برای انتخاب زیرمجموعه مناسب باندها از ترکیب چندین معیار طبقه‌بندی از جمله جدایی‌پذیری طیفی شامل فاصله اقلیدسی، زاویه طیفی، همبستگی طیفی و هم‌چنین معیار اطلاعات متقابل شامل همبستگی باندها استفاده کرده‌اند. در [14] برای انتخاب ویژگی علاوه‌بر معیار جدایی‌پذیری طبقه‌ها از معیار دیگری نیز استفاده شده است که بر اساس این عقیده شکل گرفته است: نمونه‌های آموزشی هر طبقه که از جاهای مختلف تصویر انتخاب شده‌اند، در ویژگی‌های مورد نظر ممکن است به هم شبیه یا متفاوت باشند. هر چه تفاوت بین نمونه‌های آموزشی هر طبقه در ویژگی‌های انتخابی کمتر باشد، بهتر است و این باعث افزایش دقت طبقه‌بندی، افزایش پاییوری و قدرت تعیین طبقه‌بندی می‌شود.

دسته دوم روش‌های کاهش ویژگی، روش‌های استخراج ویژگی می‌باشند. در این دسته از روش‌ها، یک تبدیل خطی یا غیر خطی بر روی فضای ویژگی اولیه اعمال می‌شود تا ویژگی‌های مطلوب از آن استخراج شوند. تحلیل مؤلفه‌های اصلی^{۱۰} (PCA) و تحلیل ممیز خطی^{۱۱} (LDA) از جمله معروف‌ترین و پرکاربردترین روش‌های استخراج ویژگی در مسائل شناسایی الگو هستند [15]. اگر یک تصویر N پیکسل

⁷ Hybrid

⁸ Divergence

⁹ Bhattacharyya distance

¹⁰ Principal Component Analysis

¹¹ Linear Discriminant Analysis

۱- مقدمه

با پیشرفت فناوری سنجنده‌های اخذ تصاویر ابرطیفی^۱، امروزه این تصاویر به منظورهای مختلف شناسایی الگو، آشکارسازی سطح زمین، تحلیل نوع خاک، دیده‌بانی و کنترل مناطق جنگی و کشاورزی، مطالعات محیط زیست و غیره مورد استفاده فراوان قرار گرفته‌اند. تصاویر ابرطیفی که تصویر یک منطقه از سطح زمین را با قدرت تفکیک طیفی و مکانی بالا در صدها باند طیفی مجاور فراهم می‌کنند، قادر به تفکیک دقیق پدیده‌های مختلف سطح زمین و تشخیص جزئیات آنها است؛ اما همه باندهای طیفی موجود در تصاویر ابرطیفی نمی‌توانند نقش مهمی در تشخیص و طبقه‌بندی داده ایفا کنند؛ چون باندهای طیفی مجاور، حاوی اطلاعات زائد و هم‌پوشان هستند. به علاوه، برای تحلیل و طبقه‌بندی حجم زیادی از ویژگی‌های طیفی به تعداد زیادی از نمونه‌های آموزشی نیاز است. از طرف دیگر، جمع‌آوری و اخذ داده آموزشی دشوار و نیازمند صرف زمان و هزینه است. تحلیل و طبقه‌بندی داده با ابعاد بالا و نمونه‌ی آموزشی محدود منجر به پدیده‌ی هیوز^۲ خواهد شد [1]. به این معنی که با افزایش بعد داده و نمونه آموزشی ثابت، تا یک جایی دقت افزایش و از آن جا به بعد دقت کاهش می‌یابد. کاهش ویژگی سبب افزایش دقت طبقه‌بندی، کاهش حجم داده و تفسیر راحت‌تر داده ابرطیفی خواهد شد. کاهش بعد به دو روش کلی انتخاب ویژگی^۳ [2] و استخراج ویژگی^۴ [3]-[5] امکان‌پذیر است. در فرآیند انتخاب ویژگی، از میان ویژگی‌های اصلی داده، زیر مجموعه مناسبی از آن‌ها انتخاب می‌شود [6]. روش‌های انتخاب ویژگی به سه گروه کلی دسته‌بندی می‌شوند: ۱- مدل فیلتر^۵-۲- مدل پوشه^۶-۳- مدل ترکیبی^۷ [7]. روش‌های فیلتر

¹ Hyperspectral

² Hughes phenomenon

³ Feature selection

⁴ Feature extraction

⁵ Filter

⁶ Wrapper

به نمونه آموزشی زیاد برای یادگیری، با استفاده از نمونه آموزشی محدود کارا نیست. استخراج توان ویژگی های طیفی و مکانی نیز در [26] پیشنهاد و بررسی شده است.

روش های استخراج ویژگی خطی از طریق نگاشت داده از فضای ویژگی اولیه به فضای ویژگی با بعد بالاتر، می توانند به روش های غیرخطی بسط داده شوند. از توابع هسته^۲ برای محاسبه ضرب داخلی در فضای بعد بالاتر استفاده می شود. LDA تحلیل ممیز تعمیم یافته^۳ (GDA) بسط غیرخطی است [27]. روش GDA هم مانند LDA بیشینه قادر به استخراج $1 - n_c$ ویژگی است. روش استخراج ویژگی وزن دار غیرپارامتریک^۴ (NWFE)، یک روش ناظارت شده و غیرپارامتریک است و اساس آن اختصاص وزن های متفاوت به هر نمونه برای محاسبه میانگین وزن دار و تعریف ماتریس های پراکندگی درون طبقه ای و بین طبقه ای غیرپارامتریک جدید برای استخراج بیش از $1 - n_c$ ویژگی می باشد [28]. عیب اساسی روش NWFE، زمان محاسباتی بسیار زیاد آن است. روش پیشنهادی [29] تحلیل تمیز محلی نیمه ناظرت شده^۵ (SELD) است که سعی می کند هم همسایگی محلی را حفظ و هم تمیز بین طبقه ها را بیشینه کند و برای این کار یک روش بدون ناظارت مثل جاسازی حفظ همسایگی^۶ (NPE) را با یک روش ناظارت شده مثل LDA ترکیب می کند و هیچ پارامتر آزادی که لزوم به تنظیم آن باشد، نیز ندارد.

روش SELD برخلاف روش های نیمه ناظرت شده دیگر، ترکیب ناظرت شده و بدون ناظارت را به صورت خطی انجام نمی دهد. روش SELD به جای این که نمونه های بر چسب دار و بدون بر چسب را با هم استفاده کند، ابتدا نمونه ها را به دو دسته هی بر چسب دار و بدون بر چسب تقسیم می کند و سپس از نمونه های بر چسب دار فقط در روش ناظرت شده و از نمونه های بدون بر چسب فقط در روش بدون ناظرت استفاده می کند. رگرسیون خطی روشی برای مدل کردن رابطه خطی بین متغیر وابسته و یک یا چند متغیر مستقل است. در مدل رگرسیون خطی، داده با استفاده از توابع پیشگوی خطی مدل شده و پارامتر های ناشناخته مدل از داده تخمین زده می شود. به طور معمول این پارامترها با استفاده از روش کمینه مربعات (LS) بدست می آیند. روش استخراج ویژگی بر مبنای رگرسیون ستیغی (FERR^۷) که در [30] پیشنهاد شده است،

⁵ Semi-supervised local discriminant analysis

⁶ Neighborhood preserving embedding

⁷ Least square

⁸ Feature extraction based on ridge regression

و d باند دارد، در بیان برداری N بردار d بعدی یا d بردار N تابی داریم که اولی بیان طیفی و دومی بیان مکانی تصویر هستند. در بیان تنسور، به جای استفاده از بردار، برای بیان تصویر ابر طیفی از یک ماتریس دو بعدی استفاده می کنیم؛ یعنی بیان طیفی و مکانی کنار هم. استخراج ویژگی های طیفی و مکانی با استفاده از بیان تنسور در [16] پیشنهاد شده است. نویسنده گان در [17] منحنی طیفی هر پیکسل از داده ابر طیفی را مانند یک سری زمانی در نظر گرفته و دو ویژگی سری زمانی که یکی ویژگی محلی و دیگری ویژگی کلی را بیان می کند، جایگرین آن کرده اند؛ یعنی ابعاد داده را از d به دو کاهش داده اند. برای استفاده از طبیعت غیرخطی داده ای ابر طیفی، می توان الگوریتم کاهش ویژگی را به جای فضای اقلیدسی در فضای غیر اقلیدسی اعمال کرد. استفاده از فضای کروی برای استخراج ویژگی و طبقه بندی داده ابر طیفی در [18]-[19] بیان شده است. روش پیشنهادی برای استخراج ویژگی در [20] بر اساس بخش بندی منحنی طیفی هر پیکسل است. در این روش، منحنی طیفی هر پیکسل، به چند بخش تقسیم شده و سپس برای هر بخش، دو ویژگی که یکی موقعیت (میانگین) و دیگری شکل (واریانس) آن بخش را تعیین می کنند، استخراج شده است. اگر منحنی طیفی هر نمونه به k بخش تقسیم شود، $2k$ ویژگی برای آن نمونه استخراج خواهد شد. تعداد دیگری از روش های استخراج ویژگی در [21]-[22] بیان شده اند.

استفاده از نمونه های آموزشی مجازی، راه دیگری برای مقابله با تعداد محدود نمونه های آموزشی است. روش پیشنهادی در [23]، جاسازی نزدیک ترین خط ویژگی^۸ (NFLE) نام دارد و از مفاهیم خط ویژگی برای تولید نمونه های آموزشی مجازی استفاده می کند و از این نمونه های مجازی تولید برای تولید ماتریس های پراکندگی درون طبقه ای و بین طبقه ای استفاده می کند. نویسنده گان در [24] برای استخراج ویژگی ناظرت شده از مفهوم اطلاعات متقابل استفاده کرده اند. از آن جایی که تخمین اطلاعات متقابل، نسبت به آمارگان مرتبه نخست و دوم، به نمونه آموزشی بسیار بیشتری احتیاج دارد، در نتیجه، این روش با استفاده از اندازه کوچک نمونه آموزشی، قابل اجرا نخواهد بود. روش استخراج ویژگی ناظرت شده دیگری با استفاده از شبکه های عصبی در [25] پیشنهاد شده است که این روش هم به دلیل نیاز شبکه عصبی

¹ Nearest Feature Line Embedding

² Kernel

³ Generalized Discriminat Analysis

⁴ Nonparametric Weighted Feature Extraction

$$Y = [y_1, y_2, \dots, y_n]_{d \times n} \quad (4)$$

می‌توان تابع Φ را به شکل ماتریسی بازنویسی کرد.

$$\Phi = \text{tr}(Y\mathbf{G}_l Y^T) \quad (5)$$

$$\min_{\mathbf{A}} [\Phi = \text{tr}(\mathbf{A}_l \mathbf{X} \mathbf{G}_l \mathbf{X}^T \mathbf{A}_l^T)] \quad (6)$$

که در روابط بالا، $\mathbf{Y} = \mathbf{A}_l \mathbf{X}$ و $\mathbf{G}_l = \mathbf{D}_l - \mathbf{W}_l$ می‌باشد. \mathbf{W}_l ماتریس شباهت است که عناصر آن را $w_{ij}^l (i=1:n, j=1:n)$ تشکیل می‌دهند و \mathbf{D}_l یک ماتریس قطری است که المان‌های روی قطر آن، مجموع سطری ماتریس \mathbf{W}_l است. برای استخراج m ویژگی از d ویژگی اولیه ($d < m$)، تنها کافی است که m بردار ویژه متناظر با m تا کوچک‌ترین مقادیر ویژه ماتریس $\mathbf{X} \mathbf{G}_l \mathbf{X}^T$ سطرهای ماتریس \mathbf{A}_l را تشکیل دهند.

ماتریس تبدیل \mathbf{A}_u در روش پیشنهادی از حل مسئله بهینه‌سازی زیر به دست می‌آید:

$$\min (\Phi = \sum_{i=1}^n \sum_{j=1}^n \|y_i - y_j\|^2 w_{ij}^u) \quad (7)$$

که

$$w_{ij}^u = \begin{cases} 1 & x_i^u, x_j^u \text{ belong to a cluster} \\ 0 & x_i^u, x_j^u \text{ do not belong to a cluster} \end{cases} \quad (8)$$

در رابطه بالا، x_i^u و x_j^u دو نمونه بدون برچسب هستند. در روش پیشنهادی، ما به همان تعداد نمونه آموزشی (n)، نمونه بدون برچسب در نظر می‌گیریم. هم‌چنین برای انجام خوش بندی از روش پرکاربرد و معمول k-means (بهدلیل سادگی و کارایی خوب آن) با $n_c = k$ بهره برده‌ایم. با توجه به اینکه، نتیجه خوشبندی k-means به انتخاب مراکز خوشی اولیه وابسته است و این مراکز در هر بار اجرای الگوریتم k-means به طور تصادفی از کل داده انتخاب می‌شود، ما ده مرتبه الگوریتم k-means را تکرار کرده و از نتایج خوشبندی که بالاترین دقت طبقه‌بندی را به دست آورده‌اند، بهره برده‌ایم. توجه کنید که در رابطه (۲)، در صورتی که دو نمونه آموزشی، متعلق به یک طبقه باشند، یک لبه با وزن یک بین آن‌ها قرار می‌گیرد و در رابطه (۸)، زمانی که دو نمونه بدون برچسب متعلق به یک خوش باشند، یک لبه با وزن یک بین

بهازای هر باند طیفی یک بردار ویژگی تعریف کرده و رابطه بین بردارهای ویژگی را با استفاده از رگرسیون، مدل می‌کند. روش پیشنهادی استخراج ویژگی در این مقاله سبب افزایش جدایی‌پذیری طبقه‌ها و حفظ ساختار داده در فضای کاهش‌یافته می‌شود. روش پیشنهادی، به عنوان تعداد محدود نمونه‌های آموزشی در دسترس، علاوه‌بر نمونه‌های آموزشی، از قدرت نمونه‌های بدون برچسب نیز به منظور افزایش دقت طبقه‌بندی بهره می‌برد. در ادامه این مقاله در بخش ۲، روش پیشنهادی با جزئیات بیشتر شرح داده می‌شود و در بخش ۳، نتایج آزمایش‌ها بیان خواهد شد. در نهایت، بخش ۴ به جمع‌بندی مقاله خواهد پرداخت.

۲- روش پیشنهادی

در روش پیشنهادی، دو دسته داده خواهیم داشت:

- ۱- مجموعه نمونه آموزشی که ماتریس تبدیل \mathbf{A}_l را با استفاده از آن می‌سازیم.
- ۲- مجموعه نمونه‌های بدون برچسب که ماتریس تبدیل \mathbf{A}_u را با استفاده از آن می‌سازیم.

در ابتدا زیر مجموعه‌ای از نمونه‌های بدون برچسب را به دلخواه و به صورت تصادفی انتخاب می‌کنیم و یک خوشبندی بر روی آن‌ها انجام می‌دهیم. به این ترتیب، مجموعه نمونه‌های بدون برچسب را در چندین خوش جای می‌دهیم. داده در فضای d ورودی را با x_i (یک بردار d بعدی) نشان می‌دهیم که $\mathbf{y}_i = \mathbf{A}x_i$ است و \mathbf{y}_i را تبدیل یافته‌ی x_i با بعد کاهش‌یافته در نظر می‌گیریم. ماتریس تبدیل \mathbf{A}_l در روش پیشنهادی از حل مسئله بهینه‌سازی زیر به دست می‌آید:

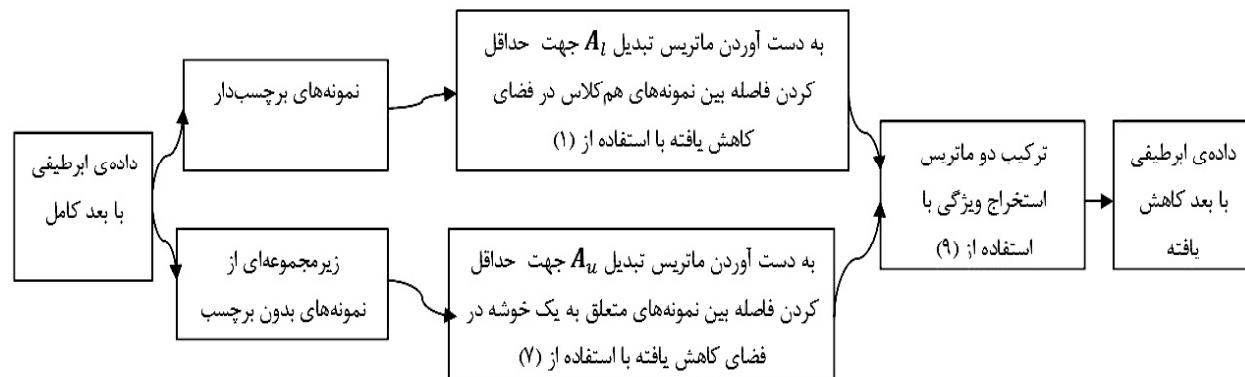
$$\min (\Phi = \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \|y_i - y_j\|^2 w_{ij}^l) \quad (1)$$

که

$$w_{ij}^l = \begin{cases} 1 & x_i, x_j \text{ belong to a class} \\ 0 & x_i, x_j \text{ do not belong to a class} \end{cases} \quad (2)$$

در رابطه بالا، $n = \sum_{c=1}^{n_c} n_{tc}$ تعداد کل نمونه‌های آموزشی، n_c تعداد طبقه‌ها و n_{tc} تعداد نمونه‌های آموزشی کلاس c است. اگر برای داده با بعد بالا در فضای اولیه و داده با بعد کاهش‌یافته در فضای ثانویه، به ترتیب فرم‌های ماتریسی X و Y را به شکل زیر در نظر بگیریم:

$$X = [x_1, x_2, \dots, x_n]_{d \times n} \quad (3)$$



(شکل-۱): نمودار جعبه ای روش پیشنهادی
(Figure-1): Block diagram of the proposed method

ابرطیفی دانشگاه پاویا از محوطه دانشگاه پاویا در ایتالیا با استفاده از سنجنده نوری ROSIS اخذ شده است. این تصویر، دارای تفکیک مکانی $1/3$ متر بر پیکسل و دارای ۱۱۵ باند طیفی در بازه فرکانسی $0.43 / 0.86$ تا $0.4 / 0.86$ میکرومتر بوده و شامل ۹ طبقه است. ابعاد تصویر دانشگاه پاویا 340×610 است. بعد از حذف کانال های نویه ای، آزمایش ها بر روی 10^3 باند باقیمانده انجام شده است. داده ابرطیفی سالیناس توسط سنجنده AVIRIS از دهکده سالیناس در کالیفرنیا جنوبی اخذ شده است. این تصویر 217×512 بوده، شامل شانزده طبقه، و سایز پیکسل 3.7 متر است. داده سالیناس حاوی ۲۲۴ باند طیفی در بازه فرکانسی $0.4 / 0.25$ میکرومتر، با قدرت تفکیک طیفی 10 نانومتر است که بعد از حذف بیست باند جذب آب، 20^4 باند از این تصویر در آزمایش ها مورد استفاده قرار می گیرند.

در این مقاله از چندین معیار مختلف برای ارزیابی کارایی طبقه بندی استفاده می کنیم: دقت متوسط، اعتبار متوسط و ضریب کاپا [31]. دقت متوسط، میانگین دقت به دست آمده برای تمام طبقه ها و اعتبار متوسط برابر میانگین اعتبار به دست آمده برای تمام طبقه ها است. اعتبار برای هر کلاس این گونه تعریف شده است: تعداد نمونه هایی که درست طبقه بندی شده اند، تقسیم بر تعداد کل نمونه هایی که به آن طبقه تعلق گرفته اند.

ضریب کاپا^۳، یکی از پارامترهای دقت است که دقت طبقه بندی را نسبت به یک طبقه بندی به طور کامل تصادفی محاسبه می کند. به این معنی که مقدار کاپا، دقت طبقه بندی را نسبت به حالتی که یک تصویر به طور کامل به صورت تصادفی طبقه بندی شود، به دست می دهد. به این ترتیب، یک کاپا

آنها در نظر گرفته می شود. مشابه روند قبلی انجام شده برای نمونه های آموزشی، ماتریس تبدیل A_u نیز محاسبه می شود. درنهایت ماتریس تبدیل نهایی که برای استخراج ویژگی داده مورد استفاده قرار می گیرد، از رابطه زیر محاسبه می شود:

$$A = \alpha A_l + (1 - \alpha) A_u \quad (9)$$

که در رابطه بالا پارامتر $1 \leq \alpha \leq 0$ به منظور ایجاد مصالحه بین نقش نمونه های آموزشی و نمونه های بدون برچسب در تهییه ماتریس تبدیل استخراج ویژگی استفاده می شود. با استفاده از ماتریس تبدیل A هر نمونه در فضای کاهش یافته، یک بردار m بعدی به شکل $y_{m \times 1} = A_{m \times d} x_{d \times 1}$ خواهد بود. نمودار جعبه ای روش پیشنهادی در شکل (۱) مشاهده می شود.

۳- ارزیابی و آزمایش ها

ما برای انجام آزمایش های خود در این قسمت از سه داده ابرطیفی ایندیانا^۱، دانشگاه پاویا^۲ و سالیناس^۳ استفاده کردیم. داده ابرطیفی ایندیانا مربوط به منطقه ای کشاورزی- جنگلی است که توسط سنجنده AVIRIS از شمال شرقی ایالت ایندیانا گرفته شده است. این داده حاوی 220 باند طیفی با پهنه ای ده نانومتر در بازه فرکانسی $0.4 / 2.5$ میکرومتر، ابعاد 145×145 پیکسل، دقت مکانی بیست متر بر پیکسل و دقت رادیومتریک هشت بیست است. بیست کانال نویه ای این داده حذف شده و آزمایش ها بر روی دویست باند باقیمانده انجام می گیرد. این داده حاوی شانزده طبقه است. داده

³ Salinas

⁴ Kappa Coefficient (KC)

¹ Indian

² University of Pavia

کاهش یافته را توسط طبقه‌بند بردار پشتیبان^۱ (SVM) طبقه‌بندی و نتایج حاصل از آن را بیان کرده‌ایم. همه آزمایش‌ها با استفاده از نرم‌افزار MATLAB 7.1 انجام شده است.

$\alpha = 1$ به معنای استفاده تنها از نمونه‌های آموزشی و $\alpha = 0$ به معنای استفاده تنها از نمونه‌های آزمایشی است. ما مقدار پارامتر α را در باره $0 \dots 1$ تغییر داده و دقت متوسط طبقه‌بندی حاصل را برای هر سه داده ابرطیفی مورد آزمایش، به‌ازای شش ویژگی استخراج شده، در شکل (۲) نشان داده‌ایم. مقدار مناسب پارامتر α برای سه داده‌ی ایندیانا، پاویا و سالیناس به‌ترتیب برابر $0.5, 0.6, 0.4$ به‌دست آمد. همان‌طور که از شکل (۲) پیدا است، کمترین دقت طبقه‌بندی به ازای $\alpha = 0$ به‌دست می‌آید، یعنی زمانی که از هیچ داده آموزشی (اطلاعات با ارزش نمونه‌های برچسب‌دار) بهره‌ای نمی‌گیریم. بهترین دقت طبقه‌بندی حول مقدار $\alpha = 0.5$ به‌دست می‌آید؛ یعنی زمانی که علاوه‌بر اطلاعات با ارزش نمونه‌های برچسب‌دار، از اطلاعات با ارزش موجود در نمونه‌های بدون برچسب خوش‌بندی شده نیز استفاده می‌کنیم. به عنوان نمونه، دقت متوسط طبقه‌بندی را در برابر تعداد ویژگی‌های استخراج شده (m) با استفاده از روش‌های مختلف استخراج ویژگی برای داده ایندیانا به‌دست آورده‌ایم. نتایج حاصل از آزمایش‌ها در شکل (۳) مشاهده می‌شوند.

نتایج طبقه‌بندی داده‌ی ایندیانا، پاویا و سالیناس با شش ویژگی استخراجی به‌ترتیب در جدول‌های (۱) تا (۳) مشاهده می‌شوند. جدول (۴)، نتایج آزمون McNemars را نشان می‌دهد و شکل‌های ۶-۴ نقشه‌ی واقعی زمین^۲ (GTM) و نقشه‌های طبقه به‌دست‌آمده با استفاده از روش‌های مختلف را نمایش می‌دهند. در رابطه با روش‌های استخراج ویژگی مورد مقایسه، توجه به نکات زیر ارزشمند است:

- همان‌طور که در جدول‌های (۱) تا (۳) مشاهده می‌شود، کمترین دقت طبقه‌بندی توسط روش LDA به‌دست آمده است. این روش، با استفاده از تعداد نمونه‌ی آموزشی کم دارای کارایی بسیار ضعیفی است.
- روش‌های LDA، GDA و NWFE روش‌هایی نظارت‌شده هستند که تنها از نمونه‌های آموزشی در دسترس برای استخراج ویژگی استفاده می‌کنند. این روش‌ها با تخمین ماتریس‌های پراکندگی، سعی در کمینه‌کردن فاصله‌های درون گروهی و بیشینه‌کردن فاصله‌های بین گروهی دارند.

² Ground Truth Map

معادل ۷۵ درصد به این معنی است که نتایج طبقه‌بندی ۷۵ درصد بهتر از موقعی است که پیکسل‌ها به‌طور تصادفی برچسب‌دهی شوند. مقدار صفر برای ضربی کاپا به این معنی است که طبقه‌بندی بدون هیچ ضابطه‌ای و به‌طور کامل تصادفی انجام شده است. مقدار یک به معنی یک طبقه‌بندی به‌طور کامل صحیح بر اساس نمونه‌های گرفته شده است. مقادیر منفی کاپا به معنی ضعف طبقه‌بندی و نتایج بسیار بد تفسیر می‌شود. به‌طور معمول این‌گونه عنوان می‌شود که ضربی کاپا برآورده بدبینانه بوده و دقت را کمتر از مقدار واقعی بیان می‌کند. ضربی کاپا به‌شکل زیر محاسبه می‌شود:

$$KC = \frac{N \sum_{c=1}^{n_c} t_{cc} - \sum_{c=1}^{n_c} t_{c+t+c}}{N^2 - \sum_{c=1}^{n_c} t_{c+t+c}} \quad (10)$$

در رابطه بالا، N و n_c به‌ترتیب تعداد نمونه‌های آزمایشی و تعداد طبقه‌ها هستند. t_{cc} تعداد نمونه‌هایی است که به طور صحیح در طبقه c طبقه‌بندی شده‌اند، t_{c+t} تعداد نمونه‌های آزمایشی است که برچسب طبقه c را خورده‌اند. t_{+c} تعداد نمونه‌هایی است که پیش‌گویی می‌شود به طبقه c تعلق دارند. آزمون McNemars برای بیان معناداری تفاوت بین روش‌های طبقه‌بندی از لحاظ آماری مفید است [32]. این آزمون برای مقایسه بین یک جفت طبقه‌بند مورد استفاده قرار می‌گیرد. پارامتر Z_{12} به‌صورت زیر تعریف می‌شود:

$$Z_{12} = \frac{f_{12} - f_{21}}{\sqrt{f_{12} + f_{21}}} \quad (11)$$

f_{12} تعداد نمونه‌هایی است که توسط طبقه‌بند ۱ درست طبقه‌بندی و توسط طبقه‌بند ۲ به‌اشتباه طبقه‌بندی شده‌اند. تفاوت بین طبقه‌بندهای ۱ و ۲ از نظر آماری، با اهمیت گفته می‌شود اگر $|Z_{12}| > 1.96$. علامت پارامتر Z_{12} ، می‌گوید که طبقه‌بند ۱ دقیق‌تر از طبقه‌بند ۲ است ($Z_{12} > 0$) و برعکس ($Z_{12} < 0$).

از آن جایی که به‌طور معمول تعداد نمونه‌های آموزشی در دسترس محدود است، ما در این مقاله برای بررسی کارایی روش‌های استخراج ویژگی با استفاده از مجموعه نمونه‌ی آموزشی کوچک، تنها از شانزده نمونه آموزشی در هر طبقه بهره برده‌ایم. نمونه‌های آموزشی به‌طور تصادفی از کل صحنه انتخاب شده‌اند. هر آزمایش بیست بار تکرار شده (با بیست مجموعه نمونه‌ی آموزشی متفاوت) و میانگین نتایج حاصل از آزمایش‌ها گزارش شده است.

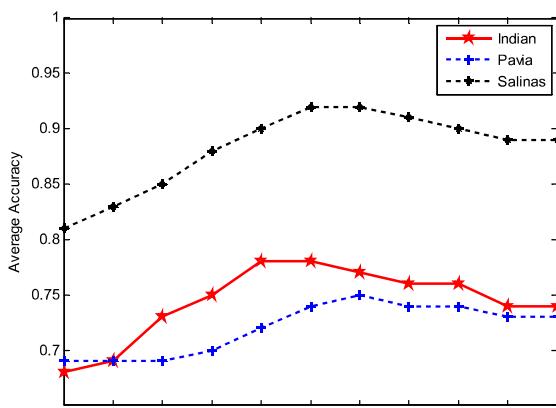
بعد داده‌های ابرطیفی ایندیانا، پاویا و سالیناس را به‌ترتیب از ۲۰۰، ۱۰۳ و ۶ به ۲۰۴ داده و سپس داده با بعد

¹ Support Vector Machine

روش پیشنهادی و سایر روش‌ها هموراه مقداری مثبت و بزرگتر از $1/96$ را حاصل کرده است.

ما علاوه بر روش‌های استخراج ویژگی بیان شده، روش پیشنهادی خود را با دو روش استخراج ویژگی که در همین اواخر پیشنهاد شده‌اند، نیز مقایسه کردایم. روش استخراج ویژگی مورد مقایسه نخست روش SELD است که علاوه بر نمونه‌های برچسب دار از قدرت نمونه‌های بدون برچسب نیز بهره می‌برد و روش دوم مورد مقایسه، روش FERR است که از رگرسیون برای مدل کردن رابطه باندهای طیفی نسبت به یکدیگر عمل می‌کند. دقت متوسط طبقه‌بندی در برابر تعداد ویژگی‌های استخراج شده برای داده پاویا در شکل (۷) نشان داده شده است.

(شکل-۳): دقت طبقه‌بندی در برابر پارامتر m
(Figure-3): Classification accuracy versus parameter m

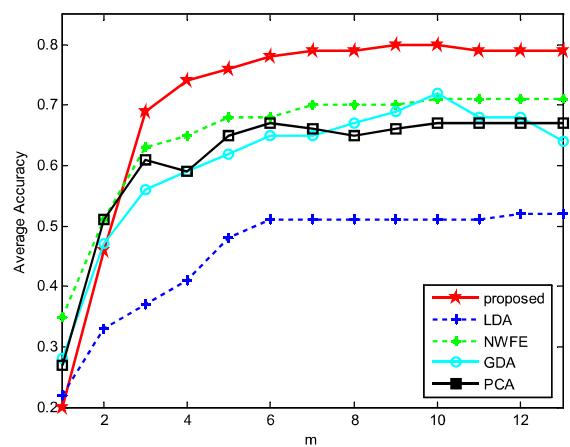


به این ترتیب، این روش‌ها، بر اساس معیار جدایی‌پذیری طبقه‌ها، ویژگی‌ها را استخراج می‌کنند.

- روش PCA یک روش بدون ناظارت است که از اطلاعات نمونه‌های آموزشی بهره‌ای نمی‌برد. روش PCA با استخراج مؤلفه‌های اصلی که بیشترین قدرت و واریانس را دارند، سعی در حفظ ساختار داده در فضای بعد کاهش یافته می‌کند.

- روش پیشنهادی، علاوه بر استفاده از نمونه‌های آموزشی برچسب دار، از قدرت نمونه‌های آموزشی بدون برچسب نیز بهره می‌برد. روش پیشنهادی، با درنظر گرفتن برچسب طبقه‌ها در تولید گراف داده و محاسبه ماتریس شباهت، علاوه بر افزایش جدایی‌پذیری سعی در حفظ ساختار داده می‌کند. به این ترتیب دقت طبقه‌بندی با استفاده از روش پیشنهادی افزایش می‌یابد. نه تنها در جدول‌های (۱) تا (۳)، بالاترین دقت طبقه‌بندی توسط روش پیشنهادی به دست آمده، بلکه اعداد جدول (۴) نشان می‌دهند که این برتری از نظر آماری نیز معنادار و قابل توجه است. پارامتر Z بین

(شکل-۲): دقت طبقه‌بندی در برابر پارامتر α
(Figure-2): Classification accuracy versus parameter α



(جدول-۱): نتایج طبقه‌بندی داده‌ی ایندیانا
(Table-1): Classification results for Indian dataset

No	Name of class	# samples	Proposed		LDA		NWFE		GDA		PCA	
			Acc.	Rel.	Acc.	Rel.	Acc.	Rel.	Acc.	Rel.	Acc.	Rel.
1	بونجه	46	94.0	26.0	70.0	11.0	93.0	14.0	94.0	20.0	81.0	19.0
2	ذرت-بدون شخم	1428	61.0	45.0	32.0	37.0	60.0	56.0	57.0	39.0	45.0	44.0
3	ذرت-کم شخم	830	76.0	57.0	24.0	17.0	40.0	24.0	38.0	30.0	43.0	29.0
4	ذرت	237	79.0	42.0	46.0	14.0	77.0	40.0	58.0	35.0	76.0	43.0
5	سیزه-درختان	483	85.0	78.0	46.0	50.0	58.0	32.0	62.0	48.0	72.0	61.0
6	سیزه-چمنزار	730	91.0	84.0	50.0	51.0	82.0	87.0	65.0	68.0	64.0	74.0
7	سیزه-چمنزار کوتاه	28	00.1	53.0	88.0	13.0	92.0	51.0	92.0	55.0	96.0	58.0
8	کاه و خاشک	478	79.0	00.1	44.0	77.0	79.0	99.0	79.0	99.0	74.0	96.0

9	جو دوسر	20	00.1	63.0	90.0	06.0	00.1	44.0	00.1	16.0	00.1	30.0
10	سویا-بدون شخم	972	60.0	61.0	31.0	22.0	54.0	63.0	74.0	45.0	67.0	54.0
11	سویا-کم شخم	2455	43.0	80.0	18.0	52.0	33.0	63.0	20.0	64.0	40.0	70.0
12	سویا-شخم کامل	593	55.0	57.0	18.0	21.0	55.0	37.0	17.0	24.0	23.0	23.0
13	گندم	205	98.0	95.0	78.0	50.0	89.0	68.0	94.0	72.0	75.0	79.0
14	بیشه	1265	86.0	95.0	58.0	90.0	56.0	83.0	88.0	91.0	88.0	91.0
15	ساختمان-سیزه	386	54.0	54.0	42.0	25.0	27.0	58.0	21.0	56.0	31.0	32.0
16	سنگ-برج	93	91.0	46.0	87.0	26.0	98.0	48.0	87.0	48.0	89.0	40.0
Average Acc. and Average Rel.			0.78	0.65	0.51	0.35	0.68	0.54	0.65	0.51	0.67	0.53
Kappa coefficient			0.62		0.29		0.48		0.47		0.50	

(جدول-۲): نتایج طبقه‌بندی داده دانشگاه پاویا
(Table-2): Classification results for University of Pavia dataset

class			Proposed		LDA		NWFE		GDA		PCA	
No	Name of class	# samples	Acc.	Rel.								
1	آسفالت	6631	0.51	0.89	0.31	0.55	0.64	0.77	0.52	0.84	0.15	0.54
2	چمن‌زار	18649	0.62	0.89	0.53	0.84	0.54	0.82	0.70	0.81	0.75	0.86
3	شن و سنگ ریزه	2099	0.60	0.46	0.49	0.31	0.56	0.49	0.47	0.42	0.71	0.50
4	درختان	3064	0.63	0.81	0.60	0.67	0.65	0.75	0.56	0.74	0.68	0.72
5	صفحات فلزی	1345	1.00	0.98	0.89	1.00	0.99	0.99	0.99	0.86	0.99	0.96
6	زمین دست نخورده	5029	0.89	0.41	0.60	0.22	0.75	0.32	0.54	0.34	0.72	0.47
7	قیر	1330	0.86	0.30	0.28	0.14	0.87	0.40	0.86	0.30	0.86	0.18
8	آخر	3682	0.64	0.64	0.26	0.42	0.59	0.73	0.69	0.68	0.57	0.79
9	سایه	947	0.99	0.98	0.79	0.60	0.99	1.00	1.00	1.00	1.00	1.00
Average Acc. and Average Rel.			0.75	0.71	0.53	0.53	0.73	0.70	0.70	0.67	0.71	0.67
Kappa coefficient			0.58		0.38		0.54		0.55		0.55	

(جدول-۳): نتایج طبقه‌بندی داده سالیناس
(Table-3): Classification results for Salinas dataset

class			Proposed		LDA		NWFE		GDA		PCA	
No	Name of class	# samples	Acc.	Rel.								
1	بروکلی-سیزه-علف هرز۱	2009	0.96	1.00	0.96	0.99	0.98	0.91	0.95	1.00	0.96	0.98
2	بروکلی-سیزه-علف هرز۲	3726	0.99	0.98	0.96	0.98	0.93	0.98	0.99	0.96	0.98	0.97
3	زمین شخم شده	1976	0.95	0.91	0.67	0.55	0.97	0.81	0.84	0.79	0.97	0.93
4	زمین شخم شده-زبر-گاو آهن	1394	0.99	0.97	0.67	0.81	0.98	0.92	0.99	0.94	0.99	0.99
5	زمین شخم شده-هموار	2678	0.95	0.96	0.71	0.72	0.95	0.97	0.92	0.89	0.97	0.98
6	کاه بن	3959	1.00	1.00	0.93	1.00	0.99	1.00	0.99	0.98	0.98	0.99
7	کرفس	3579	0.99	0.93	0.97	1.00	0.98	0.94	0.96	0.93	0.98	0.93
8	انگور	11271	0.74	0.74	0.53	0.70	0.51	0.73	0.77	0.70	0.57	0.67
9	خاک-تاکستان	6203	0.96	0.99	0.69	0.87	0.98	0.98	0.92	0.99	0.92	0.99
10	ذرت-سیزه-پیر-علف هرز	3278	0.89	0.87	0.84	0.43	0.72	0.93	0.84	0.83	0.77	0.81
11	کاهو-۴-هفته	1068	0.98	0.75	0.85	0.94	0.75	0.87	0.93	0.73	0.98	0.71
12	کاهو-۵-هفته	1927	0.98	0.95	0.50	0.39	0.97	0.95	0.90	0.95	1.00	0.89
13	کاهو-۶-هفته	916	0.96	0.97	0.76	0.59	0.97	0.80	0.93	0.96	0.97	0.78
14	کاهو-۷-هفته	1070	0.94	0.94	0.73	0.73	0.94	0.89	0.94	0.93	0.94	0.80
15	تاکستان	7268	0.59	0.63	0.55	0.50	0.70	0.47	0.50	0.61	0.58	0.48
16	تاکستان-شاغلی-داریست	1807	0.86	0.97	0.90	0.99	0.82	0.92	0.83	0.93	0.71	0.98
Average Acc. and Average Rel.			0.92	0.91	0.76	0.76	0.88	0.88	0.89	0.88	0.89	0.87
Kappa coefficient			0.85		0.69		0.79		0.82		0.79	

فصلنی

(شکل-۴): نقشه های طبقه بندی برای داده ایندیان

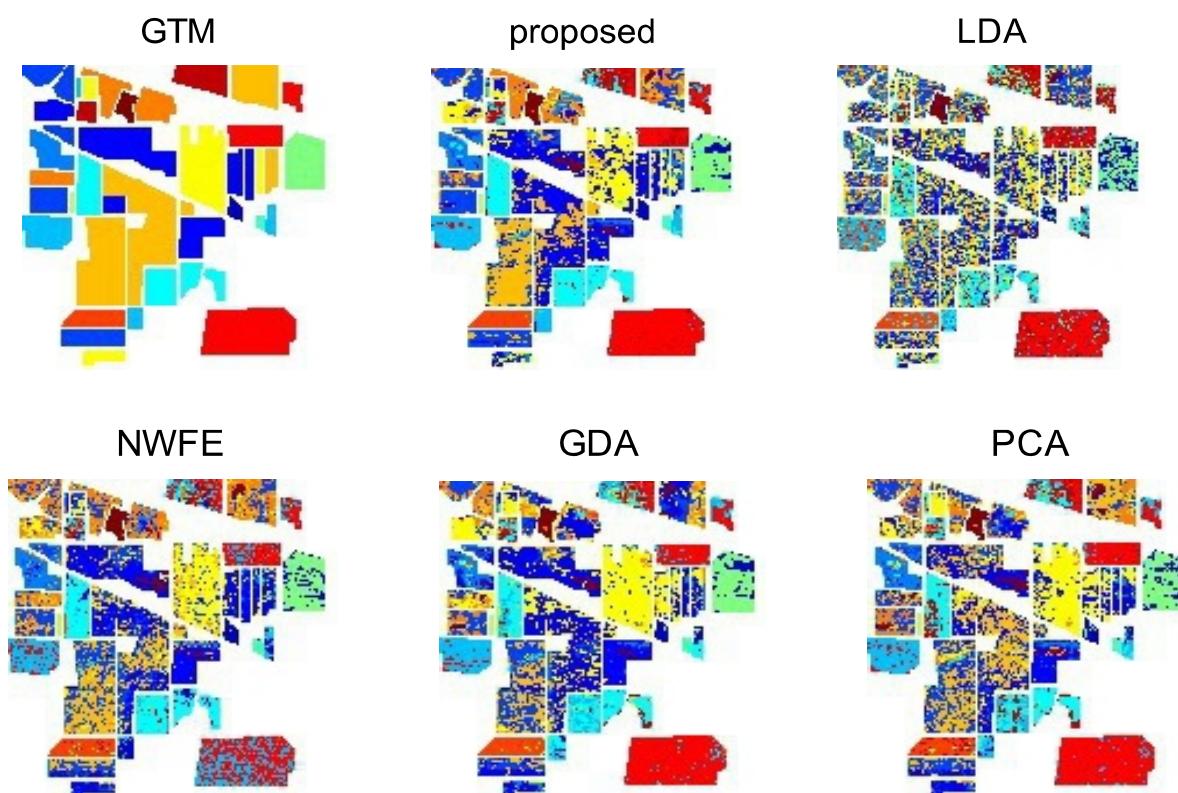
(Figure-4): Classification maps for Indian dataset

جدول-۴: نتایج آزمون MCNemars
(Table-4): MCNemars test results

نتایج داده های دانشگاه پاویا					
	Proposed	LDA	NWFE	GDA	PCA
Proposed	0	54.59	11.88	4.66	6.70
LDA	-54.59	0	-41.46	-48.38	-49.56
NWFE	-11.88	41.46	0	-7.90	-5.54
GDA	-4.66	48.38	7.90	0	1.86
PCA	-6.70	49.56	5.54	-1.86	0

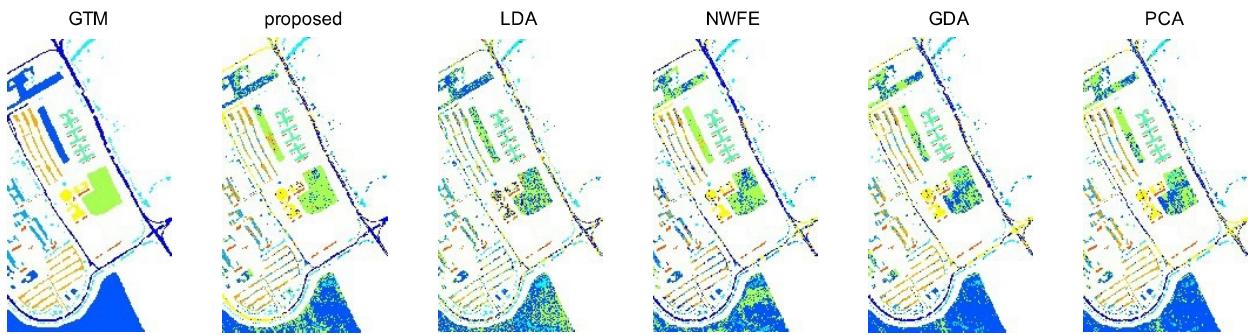
نتایج داده ایندیانا					
	Proposed	LDA	NWFE	GDA	PCA
Proposed	0	85.46	40.23	62.26	35.19
LDA	85.46-	0	02.28-	62.26-	24.31-
NWFE	40.23-	02.28	0	86.2	85.3-
GDA	62.26-	62.26	86.2-	0	31.7-
PCA	35.19-	24.31	85.3	31.7	0

نتایج داده سالیناس					
Proposed	LDA	NWFE		GDA	PCA
Proposed	0	64.24	29.53	17.83	28.66
LDA	-64.24	0	-40.95	-54.92	-41.39
NWFE	-29.53	40.95	0	-12.52	1.78
GDA	-17.83	54.92	12.52	0	14.64
PCA	-28.66	41.39	-1.78	-14.64	0

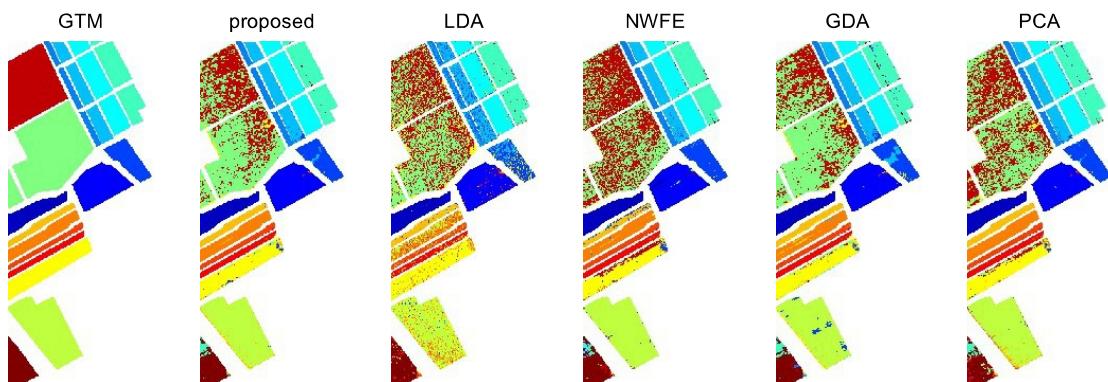


(شکل-۴): نقشه های طبقه بندی برای داده ایندیان

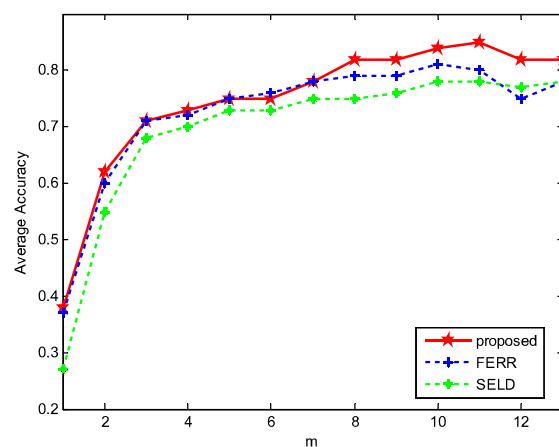
(Figure-4): Classification maps for Indian dataset



(شکل-۵): نقشه‌های طبقه‌بندی برای داده‌ی دانشگاه پاویا
(Figure-5): Classification maps for University of Pavia dataset.



(شکل-۶): نقشه‌های طبقه‌بندی برای داده سالیناس
(Figure-6): Classification maps for Salinas dataset.



(شکل-۷): مقایسه روش پیشنهادی با روش‌های FERR و SELD در تعداد ویژگی‌های استخراج شده مختلف
(Figure-7): Comparison of the proposed method with FERR and SELD in different number of extracted features

برچسب خوشه‌بندی شده، باعث افزایش دقت طبقه‌بندی می‌شود. نتایج آزمایش‌ها بر روی سه داده ابرطیفی ایندیانا، پاویا و سالیناس، برتری روش پیشنهادی را نسبت به سایر روش‌های استخراج ویژگی از نظر معیار دقت، اعتبار، ضریب کاپا و آزمون McNemars نشان می‌دهند.

۴-جمع‌بندی

در این مقاله، یک روش استخراج ویژگی برای طبقه‌بندی داده‌های ابرطیفی پیشنهاد شد که علاوه‌بر افزایش قدرت تفکیک بین طبقه‌ها، ساختار داده را در فضای با بعد کوچک‌تر نیز حفظ می‌کند و با استفاده از اطلاعات موجود در داده بدون

- [11] H. Peng, F. Long, C. and Ding, "Feature Selection Based on Mutual Information: Criteria of Max Dependency, Max-Relevance, and Min-Redundancy", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 27, no. 8, pp. 1226-1238, 2005.
- [12] J.M. Sotoca, and F. Pla, "Band selection using mutual information matrix for hyperspectral data", marmota.dlsi.uji.es/WebBIB/papers, 2006.
- [13] J. Yin, C. Gao, and X. Jia, "Using Hurst and Lyapunov Exponent For Hyperspectral Image Feature Extraction", *IEEE Geoscience and Remote Sensing Letters*, vol. 9, no. 4, pp. 705 – 709, 2012.
- [14] L. Bruzzone, and C. Persello, "A novel approach to the selection of spatially invariant features for the classification of hyperspectral images with improved generalization capability", *IEEE Transactions on Geoscience and Remote Sensing*, vol. 47, no. 9, pp. 3180–3191, 2009.
- [15] K. Fukunaga, *Introduction to Statistical Pattern Recognition*, Academic Press Inc, San Diego, 1990.
- [16] L. Zhang, L. Zhang, D. Tao, and X. Huang, "Tensor Discriminative Locality Alignment for Hyperspectral Image Spectral-Spatial Feature Extraction", *IEEE Transactions on Geoscience and Remote Sensing*, vol. 51, no. 1, pp. 242–256, 2013.
- [17] J. Yin, Y. Wang, and J. Hu, "A new dimensionality reduction algorithm for hyperspectral image data using evolutionary strategy", *IEEE Transactions on Industrial Informatics*, vol. 8, no. 4, pp. 935–943, 2012.
- [18] D. Lunga and O. Ersoy, "Spherical Nearest Neighbor Classification: Application to hyperspectral Data", *ECE Technical Reports*, Purdue University, 2010.
- [19] D. Lunga and O. Ersoy, "Spherical Stochastic Neighbor Embedding of Hyperspectral Data", *IEEE Transactions on Geoscience and Remote Sensing*, vol. 51, no. 2, pp. 857–871, 2013.
- [20] M. Zortea, V. Haertel, and R. Clarke, "Feature Extraction in Remote Sensing High-Dimensional Image Data", *IEEE Geoscience and Remote Sensing Letters*, vol. 4, no. 1, pp. 107 – 111, 2007.
- [21] M. Imani and H. Ghassemian, "Assessment of Performance Improvement in Hyperspectral Image Classification Based on Adaptive Expansion of Training Samples", *Journal of Information Systems and Telecommunication*, vol. 2, no. 2, pp. 63-70, 2014.

5-Refrences

مراجع

- [1] G. F. Hughes, "On the mean accuracy of statistical pattern recognition," *IEEE Transactions on Information Theory*, vol. IT-14, no. 1, pp. 55–63, 1968.
- [2] Q. Zhang, Y. Tian, Y. Yang, and C. Pan, "Automatic Spatial-Spectral Feature Selection for Hyperspectral Image via Discriminative Sparse Multimodal Learning", *IEEE Transactions on Geoscience and Remote Sensing*, vol. 53, no. 1, pp. 261-279, 2015.
- [3] J. Xia, J. Chanussot, P. Du, X. He, "Spectral-Spatial Classification for Hyperspectral Data Using Rotation Forests with Local Feature Extraction and Markov Random Fields", *IEEE Transactions on Geoscience and Remote Sensing*, vol. 53, no. 5, pp. 2532–2546, 2015.
- [4] M. Imani and H. Ghassemian, "Feature Extraction Using Weighted Training Samples", *IEEE Geoscience and Remote Sensing Letters*, vol. 12, no. 7, pp. 1387-1391, 2015.
- [5] X. Kang, S. Li, L. Fang, J. A. Benediktsson, "Intrinsic Image Decomposition for Feature Extraction of Hyperspectral Images", *IEEE Transactions on Geoscience and Remote Sensing*, vol. 53, no. 4, pp. 2241-2253, 2015.
- [6] L. Ladha, and T. Deepa, "Feature Selection Methods and Algorithms", *International Journal on Computer Science and Engineering*, vol. 3, no. 5, pp. 1787–1797, 2011.
- [7] C. Persello, and L. Bruzzone, "Advanced Techniques for the Classification of Very High Resolution and Hyperspectral Remote Sensing Images", PhD Dissertation, university of Trento, 2010.
- [8] D. Korycinski, M. Crawford, J.W. Barnes, J. Ghosh, "Adaptive feature selection for hyperspectral data analysis using a binary hierarchical classifier and tabu search", *IEEE Symposium on Geoscience and Remote Sensing*, vol. 1, pp. 297- 299, 2003.
- [9] S.B. Serpico and L. Bruzzone, "A New Search Algorithm for Feature Selection in Hyperspectral Remote Sensing Images", *IEEE Transactions on Geoscience and Remote Sensing*, vol. 39, no. 7, pp. 1360–1367, 2001.
- [10] S. Li, H. Wu, D. Wan, J. Zhu, "An effective feature selection method for hyperspectral image classification based on genetic algorithm and support vector machine", *Knowledge-Based Systems*, vol. 24, pp. 40-48, 2011.



مریم ایمانی کارشناسی و کارشناسی ارشد خود را در رشته مهندسی برق - گرایش مخابرات به ترتیب در سال های ۱۳۸۸ و ۱۳۹۰ از دانشگاه شاهد دریافت کرد. ایشان در سال ۱۳۹۱ و ۱۳۹۴ به ترتیب در دوره دکتری و پسادکتری در دانشگاه تربیت مدرس به ادامه تحصیل مشغول شد. زمینه های پژوهشی مورد علاقه ایشان، شناسایی آماری الگو، پردازش سیگنال و اطلاعات و مهندسی سنجش از دور است.

نشانی رایانامه ایشان عبارت است از :

maryam.imani@modares.ac.ir



محمد حسن قاسمیان یزدی تحصیلات کارشناسی خود را در رشته مهندسی مخابرات در سال ۱۳۵۸ در دانشکده مخابرات تهران به پایان رساند. ایشان مدرک کارشناسی ارشد و دکتراخود را در رشته مهندسی مخابرات در دانشگاه پردو آمریکا به ترتیب در سال ۱۳۶۳ و ۱۳۶۷ اخذ کرد. ایشان هم‌اکنون استاد دانشکده مهندسی برق و کامپیوتر هستند. آنالیز و پردازش تصاویر از منابع چندگانه، پردازش اطلاعات و شناسایی الگو، مهندسی سنجش از دور، پردازش تصاویر و سیگنال‌های مهندسی پژوهشی از جمله علاقه‌های پژوهشی ایشان است.

نشانی رایانامه ایشان عبارت است از :

ghassemi@modares.ac.ir

- [22] M. Imani and H. Ghassemian, "Band Clustering-Based Feature Extraction for Classification of Hyperspectral Images Using Limited Training Samples", IEEE Geoscience and Remote Sensing Letters, vol. 11, no. 8, pp. 1325 – 1329, 2014.
- [23] Y.-L. Chang, J.-N. Liu, C.-C. Han, and Y.-N. Chen, "Hyperspectral Image Classification Using Nearest Feature Line Embedding Approach", IEEE Transactions on Geoscience and Remote Sensing, vol. 52, no. 1, pp. 278–287, 2014.
- [24] M. Kamandar and H. Ghassemian, "Linear Feature Extraction for Hyperspectral Images Based on Information Theoretic Learning", IEEE Geoscience and Remote Sensing Letters, vol. 10, no. 4, pp. 702 – 706, 2013.
- [25] M. J. Mendenhall and E. Merényi, "Relevance-Based Feature Extraction for Hyperspectral Images", IEEE Transactions on Neural Network, vol. 19, no. 4, pp. 658–672, 2008.
- [26] F. Tsai and J.-S. Lai, "Feature Extraction of Hyperspectral Image Cubes Using Three-Dimensional Gray-Level Cooccurrence", IEEE Transactions on Geoscience and Remote Sensing, vol. 51, no. 6, pp. 3504–3513, 2013.
- [27] G. Baudat, and F. Anouar, "Generalized discriminant analysis using a kernel approach", Neural Comput., vol. 12, pp. 2385–2404, 2000.
- [28] B. C. Kuo, and D. A. Landgrebe, "Nonparametric weighted feature extraction for classification", IEEE Transactions on Geoscience and Remote Sensing, vol. 42, no. 5, pp. 1096-1105, 2004.
- [29] W. Liao, A. Pižurica, P. Scheunders, W. Philips, Y. Pi, "Semisupervised Local Discriminant Analysis for Feature Extraction in Hyperspectral Images," IEEE Transactions on Geoscience and Remote Sensing, vol. 51, no. 1, pp. 184–198, 2013.
- [30] M. Imani and H. Ghassemian, "Ridge regression-based feature extraction for hyperspectral data", International Journal of Remote Sensing, vol. 36, no. 6, pp. 1728–1742, 2015.
- [31] J. Cohen, "A coefficient of agreement from nominal scales", Educational and Psychological Measurement, vol. 20, no. 1, pp. 37–46, 1960.
- [32] G. M. Foody, "Thematic map comparison: Evaluating the statistical significance of differences in classification accuracy", Photogrammetric Engineering and Remote Sensing, vol. 70, no. 5, pp. 627–633, 2004.