

استخراج ویژگی در تصاویر ابرطیفی به کمک برازش منحنی با توابع گویا

سید ابوالفضل حسینی و محمدحسن قاسمیان یزدی*

آزمایشگاه پردازش تصویر و آنالیز اطلاعات، دانشکده مهندسی برق و کامپیوتر، دانشگاه تربیت مدرس، تهران، ایران



چکیده

در این مقاله روشی برای کاهش ویژگی در تصاویر ابرطیفی به منظور طبقه‌بندی این داده‌ها معرفی شده است که بر مبنای استخراج ویژگی‌های جدید با ابعادی بسیار کمتر از ابعاد ویژگی‌های نخستین عمل می‌کند. برای هر پیکسل از یک تصویر ابرطیفی، یک تابع تقریب کسری گویای مجزا از طریق برازش بر منحنی پاسخ طیفی آن پیکسل تولید می‌شود. ضرایب چندجمله‌ای‌های صورت و مخرج این تابع به عنوان ویژگی‌های جدید انتخاب می‌شوند. روش پیشنهادی بر ماهیت هندسی منحنی‌های پاسخ طیفی تأکید و تمرکز دارد و بر این واقعیت تکیه می‌کند که ترتیب توالی نقاط در این منحنی‌ها حاوی اطلاعات مفیدی است که با غالب روش‌های استخراج ویژگی موجود، مورد توجه قرار نگرفته است. نتایج طبقه‌بندی با طبقه‌بند، بیشینه احتمال حکایت از برتری صحت نتایج طبقه‌بندی به وسیله ویژگی‌های معرفی شده در مقایسه با روش‌های متعدد مورد بررسی دارد. به علاوه روش پیشنهادی، قابلیت اعمال به تمام پیکسل‌های تصویر را به صورت همزمان دارد. واژگان کلیدی: استخراج ویژگی، تصاویر ابرطیفی، برازش منحنی، تقریب Padé، طبقه‌بندی.

Hyper-Spectral Data Feature Extraction Using Rational Function Curve Fitting

S. Abolfazl Hosseini & Hassan Ghassemian*

Image Processing and Information Analysis Lab, Faculty of Electrical and Computer Engineering, Tarbiat Modarres University, Tehran, Iran

Abstract

In this paper, with due respect to the original data and based on the extraction of new features by smaller dimensions, a new feature reduction technique is proposed for Hyper-Spectral data classification. For each pixel of a Hyper-Spectral image, a specific rational function approximation is developed to fit its own spectral response curve (SRC) and the coefficients of the numerator and denominator polynomials of this function are considered as new extracted features. The method focuses on geometrical nature of SRCs and relies on the fact that the sequence discipline - ordinance of reflectance coefficients in spectral response curve - contains some information which has not been addressed by many other existing methods based on the statistical analysis of data. Maximum likelihood classification results demonstrate that our method provides better classification accuracies in comparison with many competing feature extraction algorithms. In addition, the proposed algorithm has the possibility of being applied to all pixels of image individually and simultaneously as well.

Keywords: Feature extraction, Hyper-Spectral imagery, curve fitting, Padé approximation, classification.

* نویسنده عهده‌دار مکاتبات

سال ۱۳۹۵ شماره ۳ پیاپی ۲۹

(NWFE)^۹ [7]، تبدیل موجک^{۱۰} [8]، تبدیل حداقل میزان نوفه^{۱۱} (MNF) [9]، استخراج ویژگی تحلیل ممیز^{۱۲} (DAFE) [1] (DAFE)، تحلیل مؤلفه‌های مستقل^{۱۳} (ICA) [10]، تحلیل اختلاط طیفی [11] و افکنش بیشینه حاشیه^{۱۴} (MMP) [12] به‌عنوان روش استخراج ویژگی معرفی شده‌اند. به‌علاوه، بهینه‌سازی مسئله انتخاب باند نیز به‌طور گسترده مورد پژوهش قرار دارد [13].

روش‌های استخراج ویژگی بدون نظارت اغلب به جای تأکید بر تفکیک طبقه‌ای، بر برآورده‌ساختن یک معیار برای بازتوصیف جدیدی از داده‌ها در یک زیر فضای با ابعاد پایین‌تر تأکید دارند. به‌عنوان مثال PCA داده‌ها را با کمینه‌کردن حداقل مربعات نوفه بازسازی به یک زیرفضای جدید می‌نگارد. با این حال و به‌رغم وجود محدودیت‌های تئوریک در به‌کارگیری PCA برای داده‌های ابرطیفی، نتایج حاصل از استفاده از آن در طبقه‌بندی به‌طور کامل قابل رقابت با سایر روش‌هاست [14]. اگرچه، بار محاسباتی کم و نبود هرگونه پارامتر از ویژگی‌های مثبت PCA محسوب می‌شوند، از این جهت که تنها از آمارگان مرتبه دوم داده‌ها استفاده می‌کند، تأثیرگذاری آن محدود است. توجه به بخشی از آمارگان مرتبه بالاتر با بهره‌گیری از نسخه غیرخطی PCA منجر به نتایج بهتری در تحلیل داده‌های ابرطیفی شده است [15]. این مزیت البته به قیمت بار محاسباتی بیشتر به‌دست می‌آید. در استخراج ویژگی با نظارت، اطلاعات نقاط آموزشی نیز مد نظر قرار می‌گیرد. تحلیل ممیز خطی^{۱۵} (LDA) یک روش استخراج ویژگی با نظارت است که به‌طور گسترده در مسائل طبقه‌بندی مورد استفاده قرار گرفته است و از بردار میانگین و ماتریس کوواریانس تک‌تک طبقه‌ها در استخراج ویژگی‌های جدید سود می‌جوید و از نسبت ماتریس‌های پراکندگی^{۱۶} درون طبقه‌ای به برون طبقه‌ای برای فرمول‌بندی یک معیار مناسب در جداسازی طبقه‌ای استفاده می‌برد [16]. البته LDA سه نقص ذاتی دارد. نخست این که فقط وقتی عملکرد خوبی دارد که توزیع آماری طبقه‌ها شبه‌نرمال باشد و زمانی که این توزیع چندمده^{۱۷} و یا غیر نرمال باشد، عملکرد LDA رضایت‌بخش نیست.

یک تصویر ابرطیفی^۱ مجموعه‌ای از تعداد زیادی تصویر است که همگی از یک منظره زمینی واحد، اما در طول موج‌ها (باند‌ها)ی متفاوت و مجاور هم و اغلب در تمام یا بخشی از بازه طول موج‌های ۴۰۰ تا ۲۵۰۰ نانومتر اخذ شده‌اند. داده‌های مربوط به این تصاویر به‌صورت یک مکعب داده، قابل نمایش هستند که ابعاد این مکعب برابر تعداد سطرها، ستون‌ها و باند‌های اخذ تصویر است. برای هر پیکسل از یک تصویر ابرطیفی با تعداد N باند، منحنی حاصل از رسم مقادیر شدت روشنایی در باند‌های متفاوت $(y = [y_1, y_2, \dots, y_N]^T)$ بر حسب شماره باند^۲ $(x = [1, 2, \dots, N])$ به امضای طیفی پیکسل یا منحنی پاسخ طیفی پیکسل^۳ (SRC) مشهور است. دقت طبقه‌بندی^۴ این تصاویر در حضور تعداد نمونه‌های آموزشی^۵ محدود با افزایش تعداد باند‌های تصویر، ابتدا افزایش، ولی پس از رسیدن به یک مقدار بیشینه به نحو بارزی کاهش می‌یابد. از این موضوع تحت نام نفرین ابعاد^۶ یا پدیده هیوز^۷ یاد می‌شود [1].

برای مقابله با این مشکل، چهار راهبرد اساسی موجود است: استفاده از داده‌های نیمه‌آموزشی [2]، [3]، به‌کارگیری اطلاعات مکانی در کنار اطلاعات طیفی [4]، [5]، بهره‌گیری از طبقه‌بندیهایی نظیر ماشین بردار پشتیبان که در شرایط کم‌بودن تعداد نمونه‌های آموزشی نیز جواب‌های قابل قبول‌تری دارند [6]، و درنهایت کاهش تعداد ویژگی‌ها [1].

منظور از کاهش ویژگی (به شکل انتخاب یا استخراج ویژگی) به‌طورعمومی یافتن تبدیلاتی است که داده‌ها را به یک فضای با تعداد ابعاد پایین‌تر می‌نگارد؛ با این شرط که اطلاعات اساسی تفکیک‌کننده داده‌ها حفظ شوند. تلاش‌های وسیعی که با هدف بهبود دقت طبقه‌بندی صورت گرفته منجر به طراحی و توسعه تکنیک‌های متنوع کاهش ویژگی با / بدون نظارت شده است. به‌منظور کاهش افزونگی در داده‌های سنجش از دور ره‌یافته‌های متعددی نظیر تحلیل مؤلفه‌های اساسی^۸ (PCA) [1]، استخراج ویژگی مرز تصمیم^۹ (DBFE) [1]، استخراج ویژگی ناپارامتری وزن‌یافته

¹⁰ Wavelet Transform

¹¹ Minimum Noise Fraction

¹² Discriminant Analysis Feature Extraction

¹³ Independent Component Analysis

¹⁴ Maximum Margin Projection

¹⁵ Linear Discriminant Analysis

¹⁶ Scattering

¹⁷ Multi modal

¹ Hyper-Spectral

² Spectral Response Curve

³ Classification

⁴ Training Samples

⁵ Curse of Dimensionality

⁶ Hughes phenomena

⁷ Principal Component Analysis

⁸ Decision Boundary Feature Extraction

⁹ Non Parametric Weighted feature Extraction

با استفاده از اطلاعات طبقه‌ای و اطلاعات همسایگی، به دو بخش گراف درون طبقه‌ای و گراف بین طبقه‌ای تقسیم می‌شود. دو نقطه از فضای داده‌ها در گراف درون طبقه‌ای با هم مرتبط خواهند بود، اگر برچسب یکسانی داشته باشند یا به حد کافی به هم نزدیک باشند. نقاط داده‌ای که برچسب‌های متفاوت دارند، در گراف بین طبقه‌ای به هم متصل هستند؛ سپس یک ماتریس تبدیل خطی برای نگاشت تصویر به زیرفضای جدیدی که اطلاعات همسایگی محلی را به همراه اطلاعات جداکننده طبقه‌ای به نحو بهینه حفظ می‌کند، محاسبه می‌شود [12].

تمام روش‌های استخراج ویژگی که در بالا به آن‌ها اشاره شد، به هنگام به کارگیری، به منظور طبقه‌بندی تصاویر ابرطیفی از یک نقص مشترک رنج می‌برند و آن این است که ویژگی‌های جبری - هندسی منحنی پاسخ طیفی را در نظر نمی‌گیرند و منبع غنی از اطلاعاتی که در ترتیب و توالی ویژگی‌های اولیه است، مورد غفلت واقع می‌شود. برای هر پیکسل از تصویر ابرطیفی، یک بردار از مقادیر اندازه‌گیری شده وجود دارد که متناظر با ضرایب بازتاب طیفی در بازه‌های متوالی از طول موج‌های مختلف طیف الکترومغناطیس است. بنابراین، ترتیب مقادیر اندازه‌گیری شده به یقین حاوی اطلاعاتی است که در فرآیند طبقه‌بندی می‌توانند مفید واقع شوند. یک نمونه از روش‌هایی که از این گونه اطلاعات سود می‌جویند در [21]، [22] معرفی شده‌اند که بر مبنای ویژگی‌های فرکتالی SRCها که به توالی دنباله‌ها مرتبط است به انتخاب ویژگی مبادرت می‌کنند. از سوی دیگر، هیچ یک از روش‌های موجود استخراج ویژگی به جنبه‌های جبری - هندسی SRCهای تک تک پیکسل‌ها توجه نمی‌کنند. نوآوری اصلی پژوهش حاضر، معرفی یک روش استخراج ویژگی نوین بر مبنای طبیعت هندسی SRCها و اطلاعات مربوط به ترتیبی که در این خ‌ها موجود است. درواقع خ‌های پاسخ طیفی یا همان امضای طیفی پیکسل‌ها به صورت اعضای یک سری زمانی در نظر گرفته می‌شوند. در روش معرفی شده، کوشش بر این است که با برازش یک منحنی کسری گویا (کسری با صورت و مخرج چندجمله‌ای) به هر SRC، از ضرایب چندجمله‌ای‌های صورت و مخرج به عنوان اعضای بردار ویژگی جدید استفاده شود. این بردار ویژگی‌های استخراجی به عنوان ورودی به یک طبقه‌بند پیشینه احتمال (ML) که به صورت گسترده‌ای در طبقه‌بندی

ایراد دیگر آن، این است که رتبه ماتریس پراکندگی بین طبقه‌ای همواره کمتر از تعداد طبقه‌هاست. نتیجه آن که حداکثر تعداد ویژگی‌های جدید استخراجی، یکی کمتر از تعداد طبقه‌هاست و به کارگیری این تعداد ویژگی در طبقه‌بندی تصاویر ابرطیفی ممکن است، کافی نباشد [7]. سوم این که وقتی ماتریس کوواریانس درون طبقه‌ای تکین باشد (امری که اغلب در مسائل با ابعاد زیاد و تعداد نقاط آموزشی کم اتفاق می‌افتد) عملکرد LDA در طبقه‌بندی به شدت ضعیف می‌شود. برای رفع این مشکلات الگوریتم‌هایی نظیر DBFE و NWFE معرفی شده‌اند. تبدیل DBFE به دنبال یافتن ویژگی‌های جدیدی است که اطلاعات مفید و زائد برای جداسازی طبقه‌ها را از هم تفکیک کند [17]. همین ایده در NWFE مورد استفاده قرار می‌گیرد تا محل مرزهای تصمیم‌گیری بر اساس داده‌های آموزشی تعیین شود. ایده پایه‌ای در NWFE تخصیص وزن‌های متفاوت به نمونه‌ها و محاسبه میانگین موزون و سپس محاسبه فاصله بین نمونه‌ها و میانگین موزون آن‌ها و در نهایت محاسبه ماتریس‌های پراکندگی درون طبقه‌ای و بین طبقه‌ای است که طی این مراحل، به نمونه‌های نزدیک‌تر به مرز تصمیم وزن بیشتری داده می‌شود تا نمونه‌های دورتر [7]. تعمیم‌های غیر خطی LDA نیز با استفاده از حقه هسته^۱ پیشنهاد شده‌اند. تحلیل ممیز هسته فیشر^۲ (KFD) [18] و تحلیل ممیز توسعه‌یافته^۳ (GDA) [۱۹] به طور مستقل به عنوان بسط‌های غیرخطی مبتنی بر هسته برای LDA معرفی شدند. در این روش‌ها تلاش شده تا مشکل تکینگی ماتریس پراکندگی کل به ترتیب با استفاده از تکنیک تجزیه مقادیر تکین و اعمال تکنیک تنظیم‌سازی برطرف شود. هر دو ره‌یافت دربرگیرنده تکنیک تجزیه مقادیر ویژه ماتریس هسته هستند که به لحاظ محاسباتی حجیم است [20].

افکنش بیشینه حاشیه (MMP) می‌کوشد تا ویژگی‌های ممیز را با حفظ ساختارهای هندسی خمینه^۴ دربرگیرنده داده‌ها بیابد. از آنجا که در برخی کاربردها، تخمین دقیق ساختارهای عمومی خمینه دربرگیرنده داده‌ها (نظیر ژئودزی‌ها^۵) مشکل است، تخمین آمارگان محلی همچون ماتریس کوواریانس محلی و فضای مماس به عنوان جایگزین مطرح می‌شوند. در این الگوریتم یک گراف نزدیک‌ترین همسایگی ساخته می‌شود تا ساختار هندسی محلی خمینه دربرگیرنده داده را مدل کند؛ سپس این گراف،

¹ Kernel Trick

² Kernel Fisher Discriminant

³ Generalized Discriminant Analysis

⁴ Manifold

⁵ Geodesy

تصاویر ابرطیفی به کار می‌رود [23] داده می‌شود. نتایج حاصل با آنچه که از اعمال روش‌های PCA, LDA, KPCA, KDA, MMP و NWFE به دست آمده‌اند مقایسه می‌شود. یک مزیت دیگر روش پیشنهادی در این است که بر خلاف روش‌های رقیب، نحوه تولید ویژگی‌های جدید آن پیکسل به پیکسل است و بنا بر این، نیازی به انتقال یک‌باره کل داده‌ها به فضای جدید نیست. این ویژگی باعث می‌شود تا پیاده‌سازی الگوریتم، به صورت موازی امکان‌پذیر باشد. به علاوه از آنجا که تبدیل پیشنهادی معکوس‌پذیر است، قابلیت بهره‌گیری به عنوان یک روش فشرده‌سازی تصاویر ابرطیفی را دارد [24].

۲- برازش منحنی، تقریب پده و قابلیت تفکیک‌کنندگی آن

۱-۲- برازش منحنی

در بسیاری از مسائل مربوط به اندازه‌گیری، رابطه‌ای ریاضی بین مقادیر مشاهده و متغیر، نشان‌دهنده دفعات اندازه‌گیری می‌توان یافت. برازش منحنی ره‌یافتی معمول برای یافتن این رابطه ریاضی است. به علاوه، برازش منحنی به منظورهایی نظیر کاهش نوفه و هموارسازی داده‌ها، جبران‌سازی خطا، درون‌یابی و برون‌یابی داده‌ها نیز قابل استفاده است.

هدف از برازش منحنی، یافتن تابعی مانند $f(\lambda)$ از یک دسته از پیش مشخص شده توابع برای مجموعه نقاطی به صورت $\{(\lambda, I_\lambda) | \lambda = 1, 2, \dots, N\}$ است؛ به نحوی که فاصله وزن‌دار بین نقاط مشاهده و مقادیر حاصل از $f(\lambda)$ کمینه شود (فانگ و گسارد ۱۹۹۵). معیارهای متعدد برازش نظیر حداقل مربعات^۱ (LS)، حداقل مطلق مانده‌ها^۲ (LAR)، یا برازش مربعی دوگانه^۳ می‌تواند برای انجام برازش خطی یا غیرخطی (نمایی و یا گونه‌ای دیگر) به کار رود. در روش حداقل مربعات، تابع $f(\lambda)$ از طریق کمینه‌سازی عبارت میانگین خطای مربعی وزن‌دار که در معادله (۱) مشاهده می‌کنید، به دست می‌آید:

$$\frac{1}{N} \sum_{\lambda=1}^N w_\lambda (f(\lambda) - I_\lambda)^2 \quad (1)$$

در روش‌های LAR و برازش مربعی دوگانه از فرایندی بر پایه تکرار برای یافتن $f(\lambda)$ بهره برده می‌شود که مقاوم‌تر و در عوض پیچیده‌تر است.

مدل‌های متنوعی از برازش منحنی نظیر چندجمله‌ای، خطی، اسپلاین و ... وجود دارد. در این پژوهش یک مدل خاص از برازش غیرخطی با استفاده از توابع کسری گویا مد نظر قرار گرفته که تعداد پارامترهای آن از تعداد نقاط مشاهده، به میزان قابل توجهی کمتر است. مدل مذکور با الهام از تقریب‌زن چندجمله‌ای Padé پیشنهاد شده است.

۲-۲- تقریب چندجمله‌ای پده

در میان تمام تقریب‌های به فرم کسر گویا و از مرتبه‌ای خاص از یک تابع معلوم $f(\lambda)$ ، تابع تقریب‌زن معرفی‌شده توسط هنری پده^۴، بهترین تقریب را ارائه می‌دهد، به گونه‌ای که سری توانی تابع تقریب‌زن و تابع تقریب‌زده‌شده بر هم منطبق می‌شوند [25]. این تابع تقریب‌زن، در بسیاری موارد از سری تیلور نیز، بهتر عمل می‌کند و حتی در مواقعی که سری تیلور واگرا می‌شود، می‌تواند همچنان تقریب خوبی ارائه دهد. تابع f و پارامترهای صحیح $L \geq 0$ و $M \geq 0$ را در نظر بگیرید. تابع تقریب‌زن چندجمله‌ای پده از مرتبه (L, M) به صورت تابع کسری گویای زیر تعریف می‌شود:

$$[L/M]_f(\lambda) \triangleq \hat{f}(\lambda) = \frac{\sum_{j=0}^L c_{j+M+1} \lambda^j}{1 + \sum_{j=1}^M c_j \lambda^j} \quad (2)$$

این تقریب بر $f(\lambda)$ با نهایت دقت ممکن منطبق است، به گونه‌ای که:

$$f^{(i)}(\cdot) = \hat{f}^{(i)}(\cdot) \quad i = 0, 1, \dots, M+L \quad (3)$$

که در آن عبارت $f^{(i)}(\cdot)$ از مشتق i ام تابع f به بیان دیگر، اگر تابع تقریب‌زن را به صورت سری مک لورن بسط دهیم، نخستین $M+L$ جمله آن با جملات متناظر در بسط مک لورن $f(\lambda)$ منطبق است. درحالی‌که M صفر باشد، تقریب‌زن پده همان بسط مک لورن تابع $f(\lambda)$ خواهد بود. برخلاف ره‌یافت‌های مرسوم نظیر تفاضل‌های منقطع یا مشتق‌گیری متوالی، در بخش بعد ره‌یافتی عملیاتی‌تر برای محاسبه ضرایب تابع کسری پده معرفی می‌شود. مزیت ره‌یافت پیشنهادی با مثال‌های عملی مشاهده خواهد شد.

³ Bisquare fitting

⁴ Henri Padé

¹ Least squares

² Least Absolute Residuals

۳-۲- قابلیت برازش منحنی برای اهداف طبقه‌بندی

در بخش‌های قبلی مسئله برازش منحنی و تقریب پده توضیح داده شدند. از آنجا که تفاوت بین منحنی‌های مختلف، موجب تفاوت در ضرایب تابع تقریب‌زن پده متناظر با آنها می‌شود؛ به نظر می‌رسد که این ضرایب می‌توانند به‌عنوان ویژگی‌هایی ممیز برای تفکیک منحنی‌هایی از خانواده‌های مختلف از یکدیگر عمل کنند. برای مثال در شکل (۱-الف) دو خانواده مختلف از منحنی‌ها (داده شبیه‌سازی شده) به نمایش درآمده‌اند و تقریب پده به‌ازای $L=0$ و $M=4$ برای تک‌تک آنها اجرا و آمارگان ضرایب حاصله در شکل‌های (۱-ب) تا (۱-و) نشان داده شده است. درواقع هر منحنی به‌وسیله پنج ضریب مخصوص به خود (یک ضریب در صورت و چهار ضریب در مخرج، معادل $L=0$ و $M=4$ در رابطه (۲) قابل توصیف است و توزیع‌های آماری هر ضریب در تمام چندجمله‌ای‌هایی که برای برازش منحنی‌های اعضای دو خانواده مختلف محاسبه شده‌اند، در شکل (۱) نشان داده شده‌اند. چنان که در این شکل مشهود است، هیستوگرام بعضی از این ضرایب به‌تنهایی توانایی تفکیک دو خانواده منحنی را دارد. این واقعیت انگیزه اولیه برای استفاده از ضرایب پده را به‌عنوان ویژگی ممیز در امر طبقه‌بندی تصاویر ابرطیفی فراهم می‌کند.

۳- روش استخراج ویژگی پیشنهادی

اشاره شد که برای هر پیکسل از یک تصویر ابرطیفی، نمودار حاصل از رسم مقادیر شدت روشنایی در باندهای مختلف بر حسب شماره باند را امضای طیفی یا نمودار پاسخ طیفی پیکسل (SRC) می‌نامند. به بیانی دیگر، هر SRC را می‌توان به‌صورت نمودار تابعی به فرم $f(\lambda)$ در نظر گرفت. اگر چه رابطه ریاضی دقیق $f(\lambda)$ بر ما آشکار نیست؛ اما مقادیر تابع در N نقطه متوالی اندازه‌گیری شده است که می‌تواند به ما برای برازاندن یک منحنی بر این منحنی کمک کند. نشان خواهیم داد که می‌توان با روشی مبتنی بر حداقل مربعات خطا، تقریبی ریاضی از $f(\lambda)$ به فرم یک تابع کسری گویا با چندجمله‌ای‌هایی در صورت و مخرج به دست آورد؛ سپس نشان داده خواهد شد که ضرایب این چندجمله‌ای‌ها قابلیت این را دارند که به‌عنوان ویژگی‌های استخراجی جدید برای یک طبقه‌بند آماری (نظیر طبقه‌بند حداکثر احتمال) به کار

روند و نتایج رضایت‌بخشی را در رقابت با برخی دیگر از روش‌های استخراج ویژگی خطی و حتی غیرخطی اعم از بانظارت و بدون نظارت تولید کنند. به‌علاوه درقبل همین مؤلفان نشان داده‌اند که چنین ویژگی‌هایی توانایی مناسبی برای فشرده‌سازی تصاویر ابرطیفی را دارند؛ و امکان بازسازی تصاویر در باندهای مختلف با نسبت PSNR خوب فراهم است [24].

تقریب کسری برای تابع $f(\cdot)$ متناظر با SRC پیکسل متعلق به مختصات (x,y) به‌صورت زیر در نظر گرفته می‌شود:

$$\hat{f}_{(x,y)}\left(\frac{\lambda}{N}\right) = \sum_{j=1}^L c_{j+M+1} \left(\frac{\lambda}{N}\right)^j \bigg/ 1 + \sum_{j=1}^M c_j \left(\frac{\lambda}{N}\right)^j \quad (4)$$

که در آن λ/N شماره باند به‌هنگار شده است. بردار ضرایب $C = [c_1 \ c_2 \ \dots \ c_{M+L+1}]^T$ از طریق کمینه‌سازی میانگین مربعات خطا به‌صورت زیر تعیین می‌شوند:

$$E = \frac{1}{N} \sum_{\lambda=1}^N \left(f\left(\frac{\lambda}{N}\right) - \hat{f}\left(\frac{\lambda}{N}\right) \right)^2 \quad (5)$$

با محاسبه و برابر صفر قرار دادن مشتق عبارت بالا نسبت به ضرایب خواهیم داشت:

$$\frac{\partial E}{\partial c_i} = 0 \quad i = 1, \dots, M \quad (6)$$

$$\sum_{\lambda=1}^N \frac{-2\left(\frac{\lambda}{N}\right)^i}{\left(1 + \sum_{j=1}^M c_j \left(\frac{\lambda}{N}\right)^j\right)^2} \left(\sum_{j=1}^L c_{j+M+1} \left(\frac{\lambda}{N}\right)^j \right) \times \left(\hat{f}\left(\frac{\lambda}{N}\right) - f\left(\frac{\lambda}{N}\right) \right) = 0 \quad (7)$$

$$\frac{\partial E}{\partial c_i} = 0 \quad i = M+1, \dots, M+L+1 \quad (8)$$

$$\sum_{\lambda=1}^N \frac{2\left(\frac{\lambda}{N}\right)^{i-M-1}}{1 + \sum_{j=1}^M c_j \left(\frac{\lambda}{N}\right)^j} \left(\hat{f}\left(\frac{\lambda}{N}\right) - f\left(\frac{\lambda}{N}\right) \right) = 0 \quad (9)$$

یک شرط لازم و نه کافی برای حل دستگاه معادلات غیرخطی بالا عبارت است از این که بردار C را به‌گونه‌ای بیابیم که:


$$\frac{\sum_{j=1}^L c_{j+M+1} \left(\frac{\lambda}{N}\right)^j}{1 + \sum_{j=1}^M c_j \left(\frac{\lambda}{N}\right)^j} = f\left(\frac{\lambda}{N}\right); \quad \lambda = 1, \dots, N \quad (10)$$

منطقی به نظر می‌رسد که $M+L+1 \ll N$ تا تعداد ویژگی‌های استخراجی در مقایسه با ویژگی‌های اولیه کاهش قابل توجهی داشته باشد، بنا بر این، ماتریس A مربعی نخواهد بود و دستگاه معادلات خطی (۱۲) نمی‌تواند پاسخی یکتا داشته باشد و حتی ممکن است، پاسخی نداشته باشد. با این حال، می‌توان با بهره‌گیری از شبه‌وارون‌ها بردار C را به‌گونه‌ای یافت که نرم ماتریس $AC-B$ کمینه شود. در این مقاله ما از شبه‌وارون مور-پن روز^۱ استفاده می‌کنیم.

فرآیند مذکور در بالا برای تک‌تک پیکسل‌های یک تصویر ابرطیفی اجرا می‌شود و مکعب تصویر جدید با جایگزینی بردارهای C به جای داده‌های اولیه تولید می‌شود. بنابراین، بعد سوم مکعب تصویر از N به $M+L+1$ کاهش داده می‌شود که متناظر با نسبت فشرده‌سازی $N/(M+L+1)$ است. با توجه به این که فرایند محاسبه ضرایب تابع تقریب‌زن برای هر SRC مستقل از سایر SRCهاست، الگوریتم قابلیت اجرا به‌صورت هم‌زمان برای تمام پیکسل‌ها را دارد. به زبان دیگر، روش پیشنهادی امکان اجرا به‌صورت موازی را دارد و نیازی ندارد که مانند بسیاری از روش‌های استخراج ویژگی همچون PCA و ICA و LDA و... تمام حجم داده ابتدا به یک فضای جدید منتقل و سپس ویژگی‌های جدید تولید شوند. به‌علاوه، پس از تولید مکعب جدید تصویر، مکعب داده اولیه با استفاده از رابطه (۴) قابل بازسازی است. یعنی این الگوریتم می‌تواند به‌عنوان یک روش فشرده‌سازی با تلفات برای داده‌های ابرطیفی به کار رود [25]. همچنین خاطر نشان می‌شود که روش پیشنهادی که ما آن را از این پس استخراج ویژگی از طریق برازش منحنی با توابع گویا^۲ (RFCF-FE) خواهیم نامید، یک روش استخراج ویژگی بدون نظارت است.

۴- نتایج تجربی

به‌منظور ارزیابی توانایی ویژگی‌های RFCF در طبقه‌بندی تصاویر ابرطیفی، عملکرد این روش با برخی روش‌های معمول نظیر PCA، LDA، KPCA، KDA، MMP و NWFE و با استفاده از طبقه‌بند، احتمال بیشینه مقایسه شد. چنان که در بخش بعد مشاهده خواهد شد، روش پیشنهادی از روش‌های رقیب عملکرد دقیق‌تری بروز می‌دهد. در زیربخش‌های پیش رو، ابتدا مجموعه داده‌های ابرطیفی به‌کارگرفته شده در این پژوهش به‌صورت مختصر معرفی



(شکل- ۱): دو خانواده از منحنی‌ها (داده شبیه‌سازی شده) و هیستوگرام ضرایب تقریب پده آن‌ها: (الف) منحنی‌ها در دو گروه خطوط ساده و نقطه خطها، (ب) هیستوگرام ضرایب یک جمله‌ای صورت کسرهای تقریب پده، (ج) تا (و) هیستوگرام هر کدام از چهار ضرایب چندجمله‌ای‌های مخرج این کسرها.

(Figure- 1): Two families of curves; and the histograms of the coefficients of their corresponding Padé approximants, (a) Curves, blue (solids) and red (dotted) lines (b) The numerator coefficient distribution, (c)-(f) the denominator coefficients distribution

بدین ترتیب یک دستگاه از N معادله خطی با $M+L+1$ مجهول خواهیم داشت که به‌صورت زیر قابل بازنویسی است:

$$\sum_{j=0}^L c_{j+M+1} (\lambda / N)^j - f(\lambda / N) \sum_{j=1}^M c_j (\lambda / N)^j \quad (11)$$

$$= f(\lambda / N) ; \lambda = 1, \dots, N$$

و با نمایش آن به‌صورت ماتریسی، خواهیم داشت:

$$A_{N \times (M+L+1)} C_{(M+L+1) \times 1} = B_{N \times 1} \quad (12)$$

که در آن

$$A_{N \times (M+L+1)} = [a_{\lambda j}]$$

$$a_{\lambda j} = \begin{cases} -f(\frac{\lambda}{N}) (\frac{\lambda}{N})^j & j = 1, \dots, M \\ (\frac{\lambda}{N})^j & j = M+1, \dots, M+L+1 \end{cases} \quad (13)$$

$$B = [f(\frac{1}{N}), f(\frac{2}{N}), \dots, f(\frac{N}{N})]^T \quad (14)$$

² Rational Function Curve Fitting Feature Extraction

¹ Moore-Penrose

۴-۲- آزمایش‌ها و نتایج

روش استخراج ویژگی پیشنهادی برای هر دو مجموعه داده ابرطیفی پیاده‌سازی شد و ویژگی‌های استخراج‌شده به طبقه‌بند، احتمال بیشینه اعمال شد. نتایج طبقه‌بندی با آنچه از اعمال ویژگی‌های حاصل از روش‌های LDA، PCA، KPCA، KDA، MMP و NWFE به دست می‌آید، مقایسه شد. پارامترهای متعلق به روش‌های به کار گرفته شده در جدول (۳) ذکر شده‌اند. در روش پیشنهادی با فرض انتخاب D ویژگی، پارامتر L - رابطه (۴) - در بازه صفر تا $D-1$ تغییر داده می‌شود و هر بار پارامتر M با توجه به قید $M+L+1 = D$ انتخاب می‌شود. برای هر مقدار از D ، آن مقادیری از L و M که بهترین نتایج صحت کل طبقه‌بندی را تولید می‌کنند برای مقایسه با سایر روش‌های رقیب انتخاب شدند. همچنین، با توجه به این که ۱۰٪ از کل نقاط نقشه مرجع هر یک از مجموعه‌های ابرطیفی و با شرط حداقل پانزده نقطه از هر طبقه به عنوان نقاط آموزشی برای طبقه‌بند مورد استفاده قرار گرفته‌اند، به جهت اجتناب از تکینگی ماتریس کوواریانس در طبقه‌بند حداکثر احتمال بازه تغییرات تعداد ویژگی‌ها بین ۲ تا ۱۴ انتخاب شد ($2 \leq D \leq 14$). در شکل‌های (۳) و (۴) میانگین و انحراف معیار معیارهای چهارگانه ارزیابی صحت طبقه‌بندی برای ده بار اجرای طبقه‌بندی به شیوه مونت کارلو و برای مقادیر متوالی از تعداد ویژگی‌های استخراجی به ترتیب برای دو مجموعه داده IPS و KSC آورده شده‌اند. مقادیر بهینه برای L و M در روش RFCF-FE به ازای مقادیر مختلف D و نیز در تکرارهای مختلف، متفاوتند. اگرچه، در غالب موارد بهترین نتایج طبقه‌بندی وقتی حاصل شده که مقدار L برابر صفر، یک، $D-2$ و $D-1$ بوده است. توجه داشته باشید که برخلاف سایر روش‌های رقیب در این آزمایش‌ها، حداکثر تعداد ویژگی‌های استخراجی در روش‌های LDA و KDA برابر $Nc-1$ است (Nc تعداد کلاس‌های تصویر است). برتری روش RFCF-FE در مقایسه با روش‌های رقیب از شکل‌های (۳) و (۴) آشکار است. تمامی معیارهای ارزیابی (صحت متوسط، اعتبار متوسط، صحت کل و آماره کاپا) به نحو بارزی توسط این روش بهبود یافته‌اند. این بهبود، البته برای تصویر ابرطیفی، این که روشی را نسبت به سایر روش‌ها برتر بدانیم، لزوماً به معنی برتری آن در تمام طبقه‌ها نیست. به همین دلیل، به طور معمول برای مقایسه کارایی روش‌ها از معیارهای میانگین (معیارهای ارزیابی مذکور) استفاده می‌شود. نقشه

می‌شوند؛ سپس آزمایش‌های انجام گرفته و نتایج حاصل به صورت مفصل آورده می‌شوند و در نهایت در خصوص نتایج به دست آمده، بحث لازم صورت خواهد گرفت.

۴-۱- داده‌های ابرطیفی مورد استفاده

نخستین مجموعه ابرطیفی مورد استفاده که به تصویر ایندیانا مشهور است، متعلق به یک ناحیه کشاورزی-جنگلی است که به وسیله سنجنده AVIRIS و به صورت هوایی اخذ شده است و ما از آن با عنوان IPS^۱ یاد می‌کنیم [26]. ابعاد تصویر ۱۴۵ در ۱۴۵ پیکسل و تعداد باندهای طیفی اولیه آن ۲۲۰ باند در بازه طیفی ۴۰۰ تا ۲۵۰۰ نانومتر است. دقت طیفی تصویر ده نانومتر و دقت مکانی آن بیست متر است. با حذف بیست باند متعلق به ناحیه طیفی جذب مولکولهای آب، $N = 200$ باند حفظ شدند. نقشه مرجع این داده شامل شانزده کلاس متفاوت از پوشش‌های زمینی است (شکل ۲ و جدول ۱). تصویر ابرطیفی دیگر به مرکز فضایی کندی در فلوریدا تخصیص دارد (KSC). این تصویر که در سال ۱۹۹۶ و باز هم توسط سنجنده AVIRIS اخذ شده، ابعاد 512×614 پیکسل دارد و تعداد باندهای طیفی اولیه آن ۲۲۴ باند در بازه ۴۰۰ تا ۲۵۰۰ نانومتر و دقت مکانی آن نیز هیجده متر است [26]. با حذف باندهای نوفه‌ای تصویر نهایی حاوی $N=176$ باند است. این مجموعه داده دارای سیزده طبقه پوشش زمینی است (شکل ۲) و جدول (۲).

(جدول - ۱): پوشش‌های زمینی ۱۶ گانه تصویر ایندیانا

(Table- 1): 16 land-cover classes of IPS

تعداد پیکسل	پوشش زمینی	تعداد پیکسل	پوشش زمینی
20	Oats	46	Alfalfa
972	Soybeans-no till	1428	Corn-no till
2455	Soybeans-min till	830	Corn-min till
593	Soybeans-clean till	237	Corn
205	Wheat	478	Grass/Pasture
1265	Woods	730	Grass/Trees
386	Bldg.-Grass-Tree-Drives	28	Grass/pasture-mowed
93	Stone-steel towers	483	Hay-windowed

(جدول - ۲): پوشش‌های زمینی ۱۳ گانه تصویر مرکز فضایی کندی

(Table- 2): 13 land-cover classes of KSC.

تعداد پیکسل	پوشش زمینی	تعداد پیکسل	پوشش زمینی
105	Hardwood swamp	431	Graminoid marsh
243	Willow	520	Spartina marsh
256	CP Hammock	404	Cattail Marsh
252	CP/Oak	419	Salt marsh
161	Slash Pine	503	Mud flats
229	Oak/Broadleaf	927	water
761	scrub		

¹ Indian Pine Site

طبقه‌بندی حاصل از روش‌های مختلف استخراج ویژگی، به ازای تعداد ویژگی برابر دوازده و برای یک اجرای تصادفی طبقه‌بندی، در شکل‌های (۵) و (۶) آورده شده‌اند. جداول (۴) و (۵) نیز حاوی میانگین معیارهای ارزیابی برای تک تک طبقه‌ها برای ده بار اجرای برنامه به شیوه مونت کارلو و به ازای دوازده ویژگی برای دو مجموعه داده ابرطیفی هستند.

۴-۳- بحث در نتایج

شکل (۳) (نتایج آزمایش‌ها بر روی داده IPS) نشان می‌دهد که عملکرد روش RFCF-FE به‌نحو بارزی نسبت به روش‌های رقیب در این آزمایش بهتر است. برتری روش پیشنهادی برای داده KSC نیز در شکل (۴) مشهود است، اگرچه این برتری به قوت مورد قبل نیست. داده IPS به‌عنوان یک مورد سخت برای طبقه‌بندی شناخته می‌شود که این موضوع به دلیل شباهت زیاد SRCهای غالب پوشش‌های سطحی موجود در این تصویر است. به همین خاطر بسیاری از روشهای استخراج ویژگی نمی‌توانند طبقه‌های این تصویر را خیلی خوب از هم تفکیک کنند و نتایج استفاده از آنها چندان رضایت‌بخش نیست؛ با وجود این، عملکرد RFCF-FE در اینجا بسیار بالاست. از سویی دیگر، داده KSC به لحاظ طبقه‌بندی به پیچیدگی IPS نیست و امضاهای طیفی طبقه‌های مختلف تصویر خیلی شبیه به هم نیستند. به این دلیل، غالب تکنیک‌های استخراج ویژگی موفق به تفکیک رضایت‌بخش طبقه‌های این تصویر می‌شوند؛ اما در این مورد نیز عملکرد روش پیشنهادی برتر است (شکل ۴ را ببینید). یک مزیت دیگر روش پیشنهادی حساسیت کمتر به مجموعه نقاط آموزشی است. این نکته به آسانی با توجه به انحراف معیار نمودارهای شکل‌های (۳) و (۴) قابل دریافت است.

توانایی روش RFCF-FE در شکل‌های (۵) و (۶) که حاوی نقشه طبقه‌ای تمام الگوریتم‌های آزمایش‌شده به ازای دوازده ویژگی انتخابی به ترتیب برای داده‌های IPS و KSC هستند نیز قابل مشاهده و تأیید است. نتایج روش پیشنهادی نسبت به نزدیک‌ترین رقیبانش (NWFE و LDA) به عنوان مثال در بخش‌هایی که بر روی نقشه مرجع هر دو شکل با پیکان مشخص شده‌اند، به وضوح بهتر است.

چنان که در بالا گفته شد، جدول (۴) مقادیر صحت

طبقه‌بندی را به ازای دوازده ویژگی انتخابی برای داده IPS و برای تمام روش‌های مورد آزمایش در بر دارد. روش RFCF-FE علاوه بر برتری در صحت کل و آماره کاپا، از لحاظ صحت طبقه‌ای نیز در ده طبقه از شانزده طبقه موجود در تصویر به پیروزی رسیده است. به علاوه عملکرد آن در طبقه‌های ۲، ۱۲ و ۱۵ به‌نحو بارزی از سایر روش‌ها برتر است. همچنین تعداد پیکسل‌های برچسب‌دار در برخی طبقه‌ها (۱، ۷، ۹، ۱۶) بسیار کم است.

بنابر این در این طبقه‌ها به دلیل کم بودن تعداد نمونه آموزشی و آزمایشی به‌طور تقریبی همه روش‌ها عملکرد ضعیفی دارند.

در مورد طبقه شماره ۱۰ نیز، اگرچه عملکرد روش پیشنهادی سرآمد نبوده است، تفاوت قابل توجهی هم با روش برتر در این طبقه ندارد.

به‌نحو مشابه، جدول (۵) دربردارنده مقادیر صحت طبقه‌بندی در شرایط قبلی و این بار برای داده KSC است.

در این مورد نیز روش RFCF-FE علاوه بر صحت کل و آماره کاپا، در شش طبقه از سیزده طبقه موجود در تصویر نیز برتری خود را نشان می‌دهد. همچنین در مورد طبقه‌های شماره ۴ و ۱۲ این برتری با فاصله قابل توجهی نسبت به رقیبان محقق می‌شود.


(جدول - ۳): پارامترهای روشهای استخراج ویژگی در آزمایش‌ها.

D تعداد ویژگیها برای تمام روش‌هاست و در بازه ۲ تا ۱۴


تغییر می‌کند.

(Table- 3): Parameters of FE methods used in the experiments. D is the number of features for all FE methods, and $D = 2, \dots, 14$

پارامتر	روش استخراج ویژگی
-	PCA
-	LDA
هسته گوسی	KPCA
هسته گوسی	KDA
هسته گوسی	MMP
پارامتر تنظیم $\gamma = 0.5$	NWFE
$L = 0, \dots, D-1, M = D-L-1$	RFCF (پیشنهادی)




(شکل - ۲): (الف) تصویر رنگ کاذب ایندیانا (ب) نقشه مرجع آن (ج) تصویر رنگ کاذب مرکز فضایی کندی (د) نقشه مرجع آن
(Figure- 2): (a) False colour image of IPS, (b) its ground truth map (GTM), (c) False colour image of KSC, (d) its ground truth map (GTM)



(شکل - ۳): معیارهای ارزیابی طبقه‌بندی برای تصویر IPS به ازای روش‌های مختلف استخراج ویژگی و تعداد متفاوت ویژگی‌ها (الف) صحت متوسط (ب) اعتبار متوسط (ج) صحت کل (د) آماره کاپا
(Figure- 3): Classification accuracy measures for IPS data set using different FE methods and various numbers of features, (a) Average accuracy (b) Average validity (c) Overall accuracy (d) Kappa statistic

(جدول - ۴): صحت کل (OA)، آماره کاپا و صحت طبقه‌بندی طبقه‌ای برای شانزده‌گانه تصویر IPS و به ازای $D = 12$
(Table- 4): The overall-accuracy (OA), Kappa-statistic, and class-specific accuracies for 16 classes in IPS data set ($D = 12$)

FE method	OA	Kappa	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
PCA	63.87	57.91	13.26	47.86	60.21	31.10	75.12	93.00	10.26	98.56	8.89	77.32	50.58	34.98	58.32	94.01	57.12	24.64
LDA	66.00	60.19	6.45	47.55	56.33	33.44	73.28	92.85	15.38	99.07	11.11	76.60	59.22	44.92	63.06	93.39	55.24	28.63
KPCA	61.12	53.68	13.26	43.19	67.53	43.72	23.09	91.21	20.51	98.81	4.44	79.48	43.20	44.94	70.09	94.34	49.33	41.31
KDA	66.90	58.40	17.20	50.24	68.56	45.12	29.60	92.47	19.66	99.54	8.89	72.94	59.41	57.80	66.43	94.04	56.83	49.72
MMP	56.44	50.76	6.09	38.50	47.42	36.03	76.83	90.75	6.84	98.58	17.78	76.72	33.34	26.11	72.49	94.87	40.29	24.64
NWFE	68.09	60.87	8.60	47.43	55.85	46.00	74.81	89.23	11.11	98.53	11.11	80.53	65.45	44.71	59.58	93.72	53.64	31.62
RFCF (proposed)	75.06	70.84	10.04	72.01	69.43	49.01	78.93	93.62	11.97	99.78	13.33	78.49	66.16	77.13	59.52	95.15	63.44	10.04




(شکل - ۴): معیارهای ارزیابی طبقه‌بندی برای تصویر KSC به ازای روش‌های مختلف استخراج ویژگی و تعداد متفاوت ویژگی‌ها (الف) صحت متوسط (ب) اعتبار متوسط (ج) صحت کل (د) آماره کاپا


(Figure- 4): Classification accuracy measures for KSC data set using different FE methods and various numbers of features (a) Average accuracy (b) Average validity (c) Overall accuracy (d) Kappa statistic

(جدول - ۵): صحت کل (OA)، آماره کاپا و صحت طبقه‌بندی طبقه‌ای برای سیزده‌گانه تصویر KSC و به ازای $D = 12$
(Table- 5): The overall-accuracy (OA), Kappa-statistic, and class-specific accuracies for 13 classes in KSC data set ($D = 12$)

FE method	OA	Kappa	1	2	3	4	5	6	7	8	9	10	11	12	13
PCA	43.20	35.78	83.65	46.58	42.42	40.53	12.41	25.12	12.22	80.41	74.15	3.85	97.09	4.19	2.52
LDA	84.71	82.18	88.76	91.78	86.15	62.56	55.17	57.97	37.78	90.21	99.36	95.05	98.41	49.45	99.64
KPCA	44.88	37.71	83.36	52.51	53.68	31.28	28.97	44.93	7.78	73.71	85.04	1.65	96.03	3.75	1.44
KDA	77.68	74.03	88.91	91.78	72.73	49.78	44.83	43.48	32.22	87.63	98.29	93.13	96.30	8.61	98.92
MMP	81.28	78.19	91.09	88.58	69.26	59.03	31.03	44.93	45.56	88.14	91.88	96.43	97.62	43.27	99.76
NWFE	79.85	76.53	89.05	91.78	63.64	56.39	9.66	47.34	18.89	87.11	94.44	90.38	99.47	47.02	99.64
RFCF (proposed)	87.14	84.99	92.78	93.15	70.13	70.04	29.66	54.59	34.44	83.76	99.86	86.81	92.33	94.48	100.00



(شکل - ۵): نمونه‌ای از نقشه‌های کلاسی حاصل از طبقه‌بندی داده IPS با به کار گیری روشهای مختلف استخراج ویژگی و به ازای $D = 12$.
(Figure- 5): Sample classification maps of IPS data set for different FE methods used for 12 features



(شکل - ۶): نمونه‌ای از نقشه‌های طبقه‌ای حاصل از طبقه‌بندی داده KSC با به کارگیری روش‌های مختلف استخراج ویژگی و به ازای $D = 12$.
(Figure- 6): Sample classification maps of KSC data set for different FE methods used for 12 features

۵- نتیجه‌گیری

یک روش نوین برای استخراج ویژگی در داده‌های ابرطیفی بر مبنای برازش منحنی به کمک توابع کسری معرفی شد. این روش طبیعت و ویژگی‌های هندسی خم‌های پاسخ طیفی تک‌تک پیکسل‌های تصویر ابرطیفی را مورد توجه قرار می‌دهد. مدل برازش منحنی مورد استفاده از تئوری تقریب تابع Padé الهام گرفته شده است. تابع برازش، به صورت کسری گویا انتخاب شده و رهیافتی تحلیلی به منظور کمینه کردن مجموع مربعات خطای برازش امضای طیفی هر پیکسل به کار گرفته شده است. انگیزه و محرک اصلی برای استفاده از رهیافت برازش منحنی به منظور استخراج ویژگی

در این دسته از تصاویر، بهره‌بردن از اطلاعاتی بوده است که در ویژگی‌های اولیه وجود دارد؛ وقتی به عنوان یک دنباله مرتب به آنها نگریسته می‌شود. بدین معنی که ترتیب توالی مقادیر شدت روشنایی اندازه‌گیری شده در باندهای مجاور حاوی اطلاعاتی است که توسط عموم روش‌های استخراج ویژگی موجود مورد غفلت واقع می‌شود. در روش پیشنهادی، این مقادیر اندازه‌گیری شده، به عنوان نمونه‌هایی از یک منحنی که رابطه ریاضی حاکم بر آن برای ما مشخص نیست، در نظر گرفته شده‌اند؛ سپس تلاش می‌شود تا این رابطه به صورت یک تابع کسری گویا با چند جمله‌ای‌هایی بر حسب شماره باند در صورت و مخرج مدل شود. پس از محاسبه

support vector machines, IEEE Trans. Geosci. Remote Sens. 42 (2004) 1778–1790.

- [7]. B.-C. Kuo and D. A. Landgrebe, Nonparametric weighted feature extraction for classification, IEEE Trans. Geosci. Remote Sens. 42 (2004) 1096–1105.
- [8]. R. Pu and P. Gong, Wavelet transform applied to EO-1 hyperspectral data for forest LAI and crown closure mapping, Remote Sens. Environ. 91 (2004) 212–224.
- [9]. J. R. Harris, D. Rogge, R. Hitchcock, O. Ijewliw and D. Wright, Mapping lithology in Canada's Arctic: Application of hyperspectral data using the minimum noise fraction transformation and matched filtering, Can. J. Earth Sci. 42 (2005) 2173–2193.
- [10]. W. Jing and I. C. Chein, Independent component analysis-based dimensionality reduction with applications in hyperspectral image analysis, IEEE Trans. Geosci. Remote Sens. 44 (2006) 1586–1600.
- [11]. I. Dopido, M. Zorte, A. Villa, A. Plaza and P. Gamba, Unmixing prior to supervised classification of remotely sensed hyperspectral images, IEEE Geosci. Remote Sens. Lett. 8 (2011) 760–764.
- [12]. X. He, D. Cai and J. Han, Learning a maximum margin subspace for image retrieval, IEEE Trans. Knowl. Data Eng. 20 (2008) 189–201.
- [13]. S. Theodoridis and K. Koutroumbas, Feature selection, in Pattern Recognition, 4th edn. (Academic Press, 2009).
- [14]. L. Journaux, X. Tizon, I. Foucherot and P. Gouton, Dimensionality reduction techniques: An operational comparison on multispectral satellite images using unsupervised clustering, in Proc. 7th Nordic Signal Processing Symp. 2006, NORSIG 2006, Rejkjavik. pp. 242–245.
- [15]. M. Fauvel, J. Chanussot and J. A. Benediktsson, Kernel principal component analysis for the classification of hyperspectral remote sensing data over urban areas, EURASIP J. Adv. Signal Process. 2009 (2009) 783194.
- [16]. K. Fukunaga, Introduction to Statistical Pattern Recognition (Academic Press, 1990).
- [17]. D. A. Landgrebe, Signal Theory Methods in Multispectral Remote Sensing 29, Vol. 29 (John Wiley & Sons, 2003).
- [18]. S. Mika, G. Ratsch, J. Weston, B. Scholkopf and K. Muller, Fisher discriminant analysis with kernels, in Proc. 1999 IEEE Signal Processing Society Workshop: Neural Networks for Signal

ضرایب چندجمله‌ای‌ها به روش تحلیلی، این ضرایب به‌عنوان ویژگی‌های جدید استخراجی برای فرایند طبقه‌بندی در نظر گرفته می‌شوند. عملکرد طبقه‌بند حداکثر احتمال برای این ویژگی‌ها و ویژگی‌های تولیدی توسط پاره‌ای از روش‌های کلاسیک و مدرن مورد بررسی قرار گرفت و نتایج حاکی از برتری روش پیشنهادی هستند. روش پیشنهادی، پیکسل به پیکسل اعمال می‌شود و نیازی به انتقال کل داده‌ها به فضای جدید به‌صورت یک جا نیست. بنابر این قابلیت اجرا به‌صورت موازی برای تمام پیکسل‌ها را دارد. همچنین تمام باندهای داده اولیه از طریق یک فرایند نمونه‌برداری از منحنی‌های برازش‌شده قابل بازیابند و این به معنی توانایی خوب در فشرده‌سازی داده‌هاست. به‌علاوه، این روش ره‌یافتی، نوین است که می‌تواند به‌عنوان پایه‌ای قدرتمند برای ایجاد روش‌های استخراج ویژگی مؤثرتر مورد استفاده قرار گیرد.

سیاس‌گزاری

این پژوهش با قرارداد شماره ت ۱۸۱۳۳/۵۰۰ با کد شناسایی ۹۰-۰۱-۰۳ تحت حمایت‌های مرکز تحقیقات مخابرات ایران بوده است. بدین‌وسیله از حمایت‌های آن مرکز تشکر و قدردانی می‌شود.

6-Reference

۶-مراجع

- [1]. D. Landgrebe, Hyperspectral image data analysis as a high dimensional signal processing problem, IEEE Signal Process. Mag. 19 (2002) 17–28.
- [2]. B. M. Shahshahani and D. A. Landgrebe, The effect of unlabeled samples in reducing the small sample size problem and mitigating the Hughes phenomenon, IEEE Trans. Geosci. Remote Sens. 32 (1994) 1087–1095.
- [3]. M. Marconcini, G. Camps-Valls, and L. Bruzzone, A composite semi supervised SVM for classification of hyperspectral images, IEEE Geosci. Remote Sens. Lett. 6 (2009) 234–238.
- [4]. H. Ghassemian and D. A. Landgrebe, Object-oriented feature extraction method for image data compaction, IEEE Control Syst. Mag. 8 (1988) 42–48.
- [5]. G. Camps-Valls, N. Shervashidze and K. M. Borgwardt, Spatio-spectral remote sensing image classification with graph kernels, IEEE Geosci. Remote Sens. Lett. 7 (2010), 741–745.
- [6]. F. Melgani and L. Bruzzone, Classification of hyperspectral remote sensing images with

سنجش از دور، پردازش گفتار و فیلترهای افقی را در بر می گیرد.

نشانی رایانامه ایشان عبارت است از:

abolfazl.hosseini@modares.ac.ir



محمدحسن قاسمیان یزدی تحصیلات

کارشناسی خود را در رشته مهندسی مخابرات در سال ۱۳۵۸ در دانشکده مخابرات ایران به پایان رساند. ایشان مدارک کارشناسی ارشد و دکترای خود را در رشته مخابرات از دانشگاه پردو ایالات

متحده آمریکا به ترتیب در سال های ۱۳۶۳ و ۱۳۶۷ اخذ کردند و پس از آن به عنوان عضو هیئت علمی دانشگاه تربیت مدرس به تدریس و پژوهش پرداختند. در حال حاضر ایشان به عنوان استاد گروه مخابرات در زمینه آنالیز و پردازش تصویر، بازشناسی الگو، مهندسی سنجش از دور و نیز پردازش تصاویر و سیگنال های پزشکی فعالیت دارند. نشانی رایانامه ایشان عبارت است از:

ghassemi@modares.ac.ir

Processing IX, 1999, Madison, WI, August 1999, pp. 41–48.

- [19]. G. Baudat and F. Anouar, Generalized discriminant analysis using a kernel approach, Neural Comput. 12 (2000) 2385–2404.
- [20]. X. Jia, B.-C. Kuo and M. M. Crawford, Feature mining for hyperspectral image classification, Proc. IEEE 101 (2013) 676–697.
- [21]. S. A. Hosseini and H. Ghassemian, Classification of hyperspectral and multispectral images by using fractal dimension of spectral response curve, in 2012 20th Iranian Conf. Electrical Engineering (ICEE) (2012), pp. 1452–1457.
- [22]. S. A. Hosseini and H. Ghassemian, A new hyperspectral image classification approach using fractal dimension of spectral response curve, in 2013 21st Iranian Conf. Electrical Engineering (ICEE) (2013), pp. 1–6.
- [23]. M. Pal and P. M. Mather, An assessment of the effectiveness of decision tree methods for land cover classification, Remote Sens. Environ. 86 (2003) 554–565.
- [24]. S. A. Hosseini and H. Ghassemian, A new approach to hyperspectral data compression using rational function approximation for spectral response curve fitting, in 2014 7th Int. Symp. Telecommunications (IST 2014), Tehran, Iran, pp. 844–848.
- [25]. G. Baker and P. Graves-Morris, Pade Approximants Encyclopedia of Mathematics and its Applications, Vol. 59, (Cambridge University Press, Cambridge, 1996).
- [29]. Universidad-del-Pais-Vasco, Hyperspectral remote sensing scenes (2014), [http://www.ehu.es/ccwintco/index.php?title=Hyperspectral Remote Sensing Scenes](http://www.ehu.es/ccwintco/index.php?title=Hyperspectral_Remote_Sensing_Scenes).



سید ابوالفضل حسینی دانش آموخته

کارشناسی مهندسی برق-کنترل از دانشگاه صنعتی شریف و کارشناسی ارشد مهندسی برق-مخابرات از دانشگاه صنعتی خواجه نصیرالدین طوسی است. وی هم اکنون دانشجوی دوره دکترای

برق مخابرات در دانشگاه تربیت مدرس بوده، همچنین به عنوان عضو هیئت علمی دانشگاه آزاد اسلامی واحد یادگار امام خمینی، مشغول به خدمت است. زمینه های پژوهشی وی مباحثی نظیر بازشناسی الگو، پردازش تصویر، مهندسی

