


بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ



وزارت علوم ، تحقیقات و فناوری

## دانشگاه تفرش

دانشکده مهندسی نقشه برداری

### پایان نامه کارشناسی ارشد

عنوان

**طبقه بندی تصاویر ابرطیفی مبتنی بر تلفیق ویژگی های مستخرج  
از روش های کدگذاری تنک، تبدیلات خطی و غیر خطی**

نگارش

سمیرا اله یاری بک

اساتید راهنما

دکتر روح اله کریمی

دکتر علیرضا صفدری نژاد

زمستان ۱۳۹۸

تاریخ: ۹۸/۱۱/۲۸  
شماره: ۴۹۰۱۸۰۹۶



### صور تجلسه دفاعیه پایان نامه کارشناسی ارشد

نام و نام خانوادگی: سمیرا اله یاری بک  
شماره دانشجویی: ۹۶۳۱۹۱۰۰۱  
رشته تحصیلی/گرایش: نقشه برداری - فتوگرامتری  
عنوان پروژه: طبقه بندی تصاویر ابر طیفی مبتنی بر تلفیق ویژگی های مستخرج از روش های کدگذاری تنک، تبدیلات خطی و غیر خطی  
تعداد واحد: ۶  
تاریخ تصویب: ۱۳۹۷/۱۲/۲۰  
تاریخ دفاع: ۱۳۹۸/۱۱/۲۸

درجه:

عالی (۱۹-۲۰)  خیلی خوب (۱۸-۱۸/۹۹)  خوب (۱۶-۱۷/۹۹)  متوسط (۱۴-۱۵/۹۹)  مردود (کمتر از ۱۴)

نام و نام خانوادگی	سمت	رتبه	محل اشتغال	محل امضاء
دکتر روح اله کریمی	استاد راهنمای اول	استادیار	دانشگاه تفرش	
دکتر علیرضا صفدری نژاد	استاد راهنمای دوم	استادیار	دانشگاه تفرش	
-	استاد مشاور	-	-	
دکتر حدیثه سادات حسینی	داور داخلی	استادیار	دانشگاه تفرش	
دکتر محمدجواد عبدالمهی فرد	داور خارجی	استادیار	دانشگاه تفرش	
دکتر حدیثه سادات حسینی	نماینده تحصیلات تکمیلی	استادیار	دانشگاه تفرش	

مدیر گروه: دکتر بهزاد به نیان

امضاء و مهر:

تاریخ: ۹۸/۱۱/۲۸

مدیر تحصیلات تکمیلی دانشگاه: دکتر علی حسین میرزایی

امضاء و مهر:

تاریخ:

۹۸/۱۱/۲۹



وزارت علوم، تحقیقات و فناوری

دانشگاه تفرش

بناام خدا

### تعهدنامه اصالت اثر

تاریخ: ۹۸/۱۱/۲۹

اینجانب **سیدالهدی بیک** به شماره دانشجویی **۹۴۳۱۹۱۰۰۰۰۱** دانش آموخته مقطع کارشناسی ارشد در رشته **نقشه برداری** گرایش **فتوگرامتری** که در تاریخ **۱۳۹۸/۱۱/۲۸** از پایان نامه خود تحت عنوان **پایان نامه: بررسی تطبیقی روش‌های استخراج از پویش لیزر در نقشه برداری** دفاع کرده ام متعهد می‌شوم:

که مطالب مندرج در این پایان نامه حاصل کار پژوهشی اینجانب تحت نظارت و راهنمایی اساتید دانشگاه تفرش بوده و به دستاوردهای دیگران که در این پژوهش از آنها استفاده شده است مطابق مقررات و روال متعارف ارجاع و در فهرست منابع و مأخذ ذکر گردیده است. این پایان نامه قبلاً برای احراز هیچ مدرک هم سطح یا بالاتر ارائه نگردیده است.

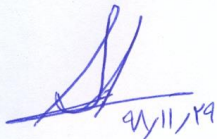
در صورت اثبات تخلف در هر زمان، مدرک تحصیلی صادر شده توسط دانشگاه از درجه اعتبار ساقط بوده و دانشگاه حق پیگیری قانونی خواهد داشت.

کلیه نتایج و حقوق حاصل از این پایان نامه متعلق به دانشگاه تفرش بوده و هرگونه استفاده از نتایج علمی و عملی واگذاری اطلاعات به دیگران یا چاپ و تکثیر، نسخه برداری، ترجمه و اقتباس از این پایان نامه با کسب اجازه از استاد (استادان) راهنما باشد.

نقل مطالب با ذکر مأخذ بلامانع است.

نام و نام خانوادگی: **سیدالهدی بیک**

امضا و تاریخ:

  
۹۸/۱۱/۲۹

تقدیم به پدر و مادر عزیزم که وجودم جز هدیه وجودشان نیست.

## تقدیر و تشکر

خداوند سبحان را سپاسگذارم که به بنده حقیر توفیق انجام و اتمام پژوهش حاضر را عنایت فرمود. از اساتید گرانقدرم دکتر روح اله کریمی و دکتر علیرضا صفدری نژاد که وجودشان همیشه قوتی برای انجام کارهایم بوده و بدون شک انجام این پایان نامه بدون کمک و راهنمایی های ارزنده آنها امکان پذیر نبوده است، کمال تشکر را دارم.

## چکیده

طبقه‌بندی یکی از مهم‌ترین روش‌های استخراج اطلاعات از تصاویر ابرطیفی است. در این پژوهش، راهکاری نوین با هدف تولید ویژگی به‌منظور طبقه‌بندی این تصاویر پیشنهاد شده است. این راهکار تلفیقی از تبدیلات خطی، غیرخطی و نمایش تنک به‌منظور تولید ویژگی‌های موثر در فرایند طبقه‌بندی تصاویر ابرطیفی است. در روند پیشنهادی، ابتدا با رویکردی جدید و نظارت شده از تبدیل غیرخطی تحلیل مؤلفه‌های اصلی (NLPCA) به‌منظور انتقال داده‌های طیفی به فضایی با ابعاد بالاتر استفاده شده است. در مرحله دوم، به کمک تبدیل تحلیل تفکیک‌پذیری خطی (LDA) فرامکعب حاصل از مرحله قبل به فضایی با بعد کمتر انتقال می‌یابد. در ادامه با هدف هم‌مقیاس کردن ویژگی‌های تولیدی و بهره‌گیری از پتانسیل تمامی داده‌های آموزشی، داده‌ها از طریق روش‌های تخمین تنک سیگنال به فضای ویژگی جدیدی با بعدی متناظر با تعداد کلاس‌های طبقه‌بندی منتقل می‌شوند. در این تحقیق از طبقه‌بندی کننده‌ی  $k$  نزدیکترین همسایه‌ی وزندار برای طبقه‌بندی فضای ویژگی استفاده شده است. این راهکار در دو داده‌ی ابرطیفی پیاده‌سازی شده و به طور متوسط بهبود دقت ۶ درصدی را نسبت به باندهای طیفی و سایر زیر مجموعه‌های حاصل از تلفیق ویژگی‌های استخراج شده در روش پیشنهادی نشان داده است. کسب دقت کلی تا ۹۹ درصد و همچنین دقت بالاتر کلاس‌های با داده‌های آموزشی اندک از ویژگی‌های این روش محسوب می‌شود.

**واژگان کلیدی:** تصویر ابرطیفی، طبقه‌بندی، نمایش تنک، استخراج ویژگی

---

## فهرست مطالب

---

ز	فصل اول (مقدمه)
۱-۱	مقدمه
۵	۲-۱- طرح مسأله، ضرورت و جایگاه تحقیق
۸	۳-۱- اهداف تحقیق
۸	۴-۱- ساختار پایان نامه
۱۰	فصل دوم (مبانی نظری و پیشینه‌ی تحقیق)
۱۱	۱-۲- مقدمه
۱۶	۲-۲- تبدیلات خطی
۱۷	۱-۲-۲- تبدیل تحلیل مؤلفه اصلی (PCA)
۲۰	۲-۲-۲- تبدیل تحلیل تفکیک پذیری خطی (LDA)
۲۳	۳-۲- تبدیلات غیرخطی
۲۴	۱-۳-۲- تبدیل تحلیل مؤلفه اصلی هسته (KPCA)
۲۶	۲-۳-۲- تحلیل مؤلفه اصلی غیرخطی (NLPCA)
۲۹	۴-۲- استخراج ویژگی مبتنی بر تخمین تنک
۲۹	۱-۴-۲- نمایش تنک
۳۵	۲-۴-۲- الگوریتم‌های رایج در تعیین نمایش تنک
۳۷	۳-۴-۲- طبقه‌بندی با استفاده از نمایش تنک
۳۸	۱-۳-۴-۲- الگوریتم SRC
۴۱	۲-۳-۴-۲- الگوریتم JSRC
۴۲	۳-۳-۴-۲- الگوریتم KNN-SRC
۴۴	۵-۲- جمع بندی
۴۵	فصل سوم (روش تحقیق و پیاده سازی)
۴۶	۱-۳- مقدمه



۴۶	.....منطقه‌ی مورد مطالعه و داده‌های مورد استفاده.....
۴۹	.....۳-۳-روش پیشنهادی.....
۵۰	.....۳-۳-۱-گام اول (پیش‌پردازش).....
۵۱	.....۳-۳-۲-گام دوم(تولید ویژگی مبتنی بر NLPCA).....
۵۲	.....۳-۳-۳-گام سوم (کاهش بعد به روش LDA).....
۵۲	.....۳-۳-۴-گام چهارم (تولید ویژگی به کمک تخمین تنک).....
۵۴	.....۳-۳-۵-گام پنجم (طبقه‌بندی کننده KNN وزن دار).....
۵۵	.....۳-۳-۶-گام ششم (پس‌پردازش).....
۵۷	.....فصل چهارم (بررسی نتایج حاصل از پیاده سازی).....
۶۵	.....فصل پنجم (نتیجه‌گیری و پیشنهادات).....

### فهرست جداول

۴۷	.....جدول ۳-۱- نام و تعداد نمونه‌های آزمایشی و آزمون هر کلاس داده ایندیانا.....
۴۸	.....جدول ۳-۲- نام و تعداد نمونه‌های آزمایشی و آزمون هر کلاس داده‌ی پاپویا.....
۶۱	.....جدول ۴-۱- نتایج طبقه‌بندی تصویرپاپویا حاصل از روش‌های تولید ویژگی.....
۶۱	.....جدول ۴-۲- نتایج طبقه‌بندی تصویر ایندیانا حاصل از روش‌های تولید ویژگی.....

### فهرست شکل‌ها

۳	.....شکل ۱-۱- تصویر ابرطیفی و مکعب داده‌ی ابرطیفی به همراه امضای طیفی مواد مختلف.....
۱۲	.....شکل ۱-۲- الگوریتم k-نزدیکترین همسایگی.....

- شکل ۲-۲- نمایش بعد حقیقی داده با روش کاهش بعد ..... ۱۴
- شکل ۳-۲- انتقال داده به سیستم مختصات جدید در تبدیل **PCA** ..... ۱۸
- شکل ۴-۲- تبدیل تحلیل تفکیک پذیری خطی ..... ۲۱
- شکل ۵-۲- نمایش شاخص فیشر بین دو کلاس ..... ۲۲
- شکل ۶-۲- مقایسه روش‌های خطی (الف) و غیرخطی (ب) استخراج ویژگی ..... ۲۶
- شکل ۷-۲- تحلیل مؤلفه‌های اصلی غیرخطی ..... ۲۷
- شکل ۸-۲- تابع نگاشت (چپ) و تابع بازسازی (راست) ..... ۲۸
- شکل ۹-۲- نمایش نرم‌های مختلف ..... ۳۲
- شکل ۱۰-۲- نمایش تنک سیگنال **s** به کمک دیکشنری **D** ..... ۳۵
- شکل ۱-۳- تصویر نمونه باند داده‌ی ایندیانا ..... ۴۷
- شکل ۲-۳- تصویر داده‌ی دانشگاه پاویا ..... ۴۸
- شکل ۳-۳- الگوریتم روش پیشنهادی ..... ۵۰
- شکل ۴-۳- روند پیش پردازش در الگوریتم پیشنهادی ..... ۵۱
- شکل ۵-۳- تولید ماتریس دیکشنری ..... ۵۳
- شکل ۱-۴- نتایج طبقه‌بندی داده‌های دانشگاه **Pavia**؛ (الف) داده خام، (ب) **LDA**، (ج) **SNLPCA**، (د) **SRC**، (ه) **SNLPCA+LDA**، (ی) الگوریتم پیشنهادی، (و) نقشه واقعیت زمینی. .... ۵۸
- شکل ۲-۴- نتایج طبقه‌بندی داده‌های **Indiana Pine**؛ (الف) داده خام، (ب) **LDA**، (ج) **SNLPCA**، (د) **SRC**، (ه) **SNLPCA+LDA**، (ی) الگوریتم پیشنهادی، (و) نقشه واقعیت زمینی. .... ۵۹
- شکل ۳-۴- مقایسه دقت طبقه‌بندی روش‌های استخراج ویژگی در داده ایندیانا ..... ۶۴
- شکل ۴-۴- مقایسه دقت طبقه‌بندی روش‌های استخراج ویژگی در داده پاویا ..... ۶۴

# فصل اول

## مقدمه

سنجش از دور<sup>۱</sup> به عنوان علم و هنر به دست آوردن اطلاعات فیزیکی درباره‌ی یک شیء، منطقه یا پدیده، بدون تماس مستقیم و با استفاده از سنسور تعریف می‌شود. واژه سنجش از دور اولین بار در سال ۱۹۵۰ در ایالات متحده آمریکا توسط اولین پروت<sup>۲</sup> از اداره تحقیقات نیروی دریایی آمریکا به کار رفت [۱]. اولین تصویربرداری از سطح زمین مربوط به اوایل قرن ۱۸ است. در این زمان شخصی به نام لوئیس داگور گزارش تصاویری از تجربیات عکس‌برداری خود را ارائه کرد [۲]. در سال ۱۸۵۸ نخستین عکس هوایی توسط شخصی به نام گاسپارد فلیکس<sup>۳</sup> با استفاده از دوربینی که بر یک بالون نصب شده بود گرفته شد [۳]. در سال ۱۹۰۸ ویلبر رایت اولین پرواز با هواپیما را رهبری نمود که نقطه آغازی برای عکس‌برداری هوایی بود [۴]. بیشترین استفاده از عکاسی هوایی در طول جنگ‌های جهانی اول و دوم بوده است. کاربرد عکس‌های هوایی در جنگ جهانی اول بیشتر نظامی بوده و برای شناسایی تحرکات دشمن به کار گرفته می‌شد. در زمان جنگ جهانی دوم برای اولین بار از طیف الکترومغناطیسی به منظور مشاهده‌ی پدیده‌های غیرقابل دید، استفاده شد و تکنولوژی رادار معرفی گردید. در سال ۱۹۶۰ اولین ماهواره‌های هواشناسی پرتاب شد [۵]. برای نخستین بار، در سال ۱۹۷۲ با پرتاب اولین ماهواره‌ی مشاهده زمین به نام ERTS-1 که بعدها به نام لندست شناخته شد [۶]، تصاویر ماهواره‌ای به دست آمد. مأموریت‌های اختصاصی مشاهده زمین با این ماهواره ادامه یافت. در این مرحله که تصویربرداری از حالت آنالوگ خارج و به صورت رقومی درآمد، دریچه‌ای جدید برای پردازش تصاویر و نهایتاً تعبیر و تفسیر آن‌ها به روی بشر گشوده شد. در سال ۱۹۸۰ ناسا شروع به پیشرفت در زمینه‌ی تجهیزات تولیدکننده‌ی تصاویر با تفکیک‌پذیری طیفی بالا (تصاویر ابرطیفی)<sup>۴</sup> کرد و توسط آن‌ها

<sup>۱</sup>Remote Sensing

<sup>۲</sup>Evelyn Pruitt

<sup>۳</sup>Louis Daguerre

<sup>۴</sup>Gaspard Felix(Nadar)

<sup>۵</sup>Landsat

<sup>۶</sup>Hyperspectral Images

قادر به پوشاندن قسمت‌های غیرقابل دید و وابسته به اشعه مادون قرمز موج کوتاه، از طیف الکترومغناطیس گردید.


بهره‌گیری از فناوری سنجش از دور و انواع تصاویر ماهواره‌ای در طی سال‌های اخیر به عنوان یکی از مهم‌ترین منابع جمع‌آوری اطلاعات به‌منظور مطالعه و بررسی منابع زمینی و بهره‌برداری بهینه از آن‌ها شناخته شده است. این فناوری توجه بسیاری از کارشناسان و متخصصان علوم مختلف از جمله زمین‌شناسی، معدن، محیط‌زیست، هواشناسی، کشاورزی، هیدرولوژی و ... را به خود جلب نموده است. از سوی دیگر، امروزه امکان طراحی و ساخت سنجنده‌هایی با توان تفکیک مکانی و طیفی مطلوب به‌منظور اخذ داده‌هایی دقیق‌تر و با ارزش اطلاعاتی بالاتری فراهم شده است. یکی از انواع این داده‌ها که از قابلیت تفکیک طیفی بسیار بالایی برخوردار است، تصاویر ابرطیفی می‌باشند.

دستیابی به داده‌های ابرطیفی به عنوان یکی از تحولات مهم و اساسی در فناوری سنجش از دور، طی سال‌های اخیر پیشرفت قابل توجهی داشته و طراحی و توسعه الگوریتم‌های مختص پردازش این نوع داده‌ها در سطوح گوناگون، امروزه از جمله جذاب‌ترین و مهم‌ترین موضوعات تحقیقاتی در زمینه‌ی سنجش از دور محسوب می‌شود.

تصویربرداری ابرطیفی به جمع‌آوری و پردازش اطلاعات به دست آمده از امواج الکترومغناطیس می‌پردازد. مهم‌ترین مرحله پیشرفت و تحول این فناوری، در سال ۱۹۸۹ و هم‌زمان با ساخت سنجنده هوابرد آویریس توسط مرکز جی‌پی‌ال ناسا صورت گرفت که قادر به نمونه برداری در ۲۲۴ باند طیفی بود [۷]. پس از آن انواع سنجنده‌های ابرطیفی هوابرد و فضایی دیگری نیز طراحی و ساخته شدند.

در تصویربرداری ابرطیفی باندهای طیفی باریک و نسبتاً پیوسته‌ای در محدوده‌ی ۴۰۰ تا ۲۵۰۰ نانومتر ثبت می‌گردد. از آنجا که مواد و پدیده‌ها از پاسخ طیفی منحصر به فردی در طیف الکترومغناطیسی برخوردارند؛ پردازش تصاویر ابرطیفی امکان شناسایی مواد و پدیده‌ها را با اتکاء به تمایز پاسخ طیفی آن‌ها فراهم می‌آورد. این پاسخ طیفی به مثابه‌ی اثرانگشت هر پدیده و به عنوان امضای طیفی شناخته می‌شود.

به عبارتی دیگر یک تصویر ابرطیفی مجموعه‌ای از تعداد زیادی تصویر است، که همگی از یک منظره زمینی واحد اما در طول موج‌ها (باندها)ی متفاوت و مجاور هم و غالباً در تمام یا بخشی از بازه‌ی طول موج‌های ۴۰۰ تا ۲۵۰۰ نانومتر اخذ شده‌اند. داده‌های مربوط به این تصاویر به صورت یک مکعب داده قابل نمایش هستند که ابعاد این مکعب برابر تعداد سطرها، ستون‌ها و باندهای اخذ تصویر است. با این قابلیت، برای هر پیکسل از یک تصویر ابرطیفی با تعداد N باند، نمودار حاصل از رسم مقادیر شدت بازتابندگی در باندهای متفاوت برحسب شماره‌ی باندها به امضای طیفی پیکسل یا بازتاب طیفی پیکسل مشهور است. شکل (۱-۱) بیانگر مفهوم تصاویر ابرطیفی و نمونه‌ای از مکعب داده‌های ابرطیفی به همراه امضای طیفی مواد مختلف موجود در آن را نمایش می‌دهد.



شکل ۱-۱- تصویر ابرطیفی و مکعب داده‌ی ابرطیفی به همراه امضای طیفی مواد مختلف

از محدودیت‌های اصلی تصویربرداری ابرطیفی هزینه و پیچیدگی زیاد و ظرفیت بالای مورد نیاز برای ذخیره‌سازی اطلاعات می‌باشد. بدین منظور کامپیوترهای سریع و ظرفیت‌های ذخیره داده‌ی بزرگ برای تحلیل داده‌های ابرطیفی مورد نیاز هستند.

در پردازش تصاویر ابرطیفی مشکلاتی موجود است که از آن جمله می‌توان به موارد زیر اشاره کرد:

- باندهای نویزی: در تصاویر ابرطیفی، تعدادی از باندها تحت اثرات نامطلوب جو زمین قرار گرفته و حاوی نویز هستند؛ بنابراین باید خطای حاصل از جو زمین را در این تصاویر به‌گونه‌ای تصحیح کرد.

- حجم بسیار زیاد تصاویر ابرطیفی: بسترهای داده‌ای که دارای ابعاد بالایی هستند علی‌رغم فرصت‌هایی که به وجود می‌آورند، چالش‌های محاسباتی زیادی را ایجاد می‌کنند. یکی از مشکلات داده‌های با ابعاد بالا آن است که در بیشتر مواقع تمام ویژگی‌های داده‌ها برای استخراج اطلاعات از داده‌ها مهم و حیاتی نمی‌باشند. به همین دلیل در بسیاری از زمینه‌ها کاهش ابعاد داده‌ها یکی از مباحث قابل توجه باقی مانده است.

- کم بودن تعداد داده‌های آموزشی در طبقه‌بندی: یکی از کاربردهای تصاویر ابرطیفی شناسایی پوشش‌های زمینی با استفاده از طبقه‌بندی نظارت شده‌ی آن‌ها می‌باشد. با انتخاب تعدادی کلاس و جمع‌آوری نمونه‌های آموزشی برای هر کلاس و استفاده از یک طبقه‌بندی کننده‌ی مناسب، هر یک از پیکسل‌های تصویر به یکی از این کلاس‌ها نسبت داده می‌شود. هر قدر طیف مواد با دقت بیشتری اندازه‌گیری شود می‌توان کلاس‌های بیشتر با دقت بیشتری را از یکدیگر متمایز نمود [۸]. دقت طبقه‌بندی این تصاویر در حضور تعداد نمونه‌های آموزشی محدود با افزایش تعداد باندهای تصویر ابتدا افزایش می‌یابد، ولی پس از رسیدن به یک مقدار بیشینه به نحو بارزی کاهش می‌یابد. در واقع بین ابعاد بالای تصویر و تعداد محدود داده‌های آموزشی ناهم‌هنگی وجود دارد که این پدیده هیوز نام دارد و بیشتر در طبقه‌بندی کننده‌های پارامتریک رخ می‌دهد [۹]. از طرفی جمع‌آوری داده‌های آموزشی در کاربردهای سنجش از دور بسیار پرهزینه و زمان‌بر و در بعضی مکان‌ها غیرممکن می‌باشد. زیرا باید زمان اخذ تصویر و جمع‌آوری داده‌های آموزشی با فاصله‌ی زمانی کمی از هم انجام شود. کاهش تعداد ویژگی‌ها یک راه‌برد اساسی برای مقابله با این مشکل است. البته باید توجه

داشت که کم کردن بعد داده‌ها باید به‌گونه‌ای صورت گیرد که در باندهای باقیمانده اطلاعات لازم برای جداسازی کلاس‌ها از بین نرود.

از جمله کاربردهای تصویربرداری ابرطیفی می‌توان به استخراج اطلاعات از طریق روش‌هایی مانند آشکارسازی ناهنجاری<sup>۱</sup>، آشکارسازی هدف<sup>۲</sup>، طبقه‌بندی<sup>۳</sup> و تجزیه طیفی به عناصر خالص<sup>۴</sup> اشاره داشت [۸].

در ادامه‌ی مطالب ارائه شده در فصل پیش رو، مسأله‌ی طبقه‌بندی به عنوان یکی از پرکاربردترین روش‌های استخراج اطلاعات از تصاویر ابرطیفی مطرح شده است. سپس به انواع روش‌های طبقه‌بندی و چالش‌های موجود در آن اشاره شده است. بعد از طرح این مسائل، به ارائه‌ی راهکارهایی برای مواجه شدن با این مشکلات پرداخته شده است. نهایتاً اهداف تحقیق و ساختار پایان‌نامه به عنوان آخرین بخش‌های این فصل ارائه شده است.

## ۱-۲- طرح مسأله، ضرورت و جایگاه تحقیق

طبقه‌بندی یکی از پرکاربردترین و مهم‌ترین روش‌های استخراج اطلاعات از تصاویر ابرطیفی است. اهمیت طبقه‌بندی به عنوان یک رویکرد پردازشی با هدف تولید نقشه‌های موضوعی مطرح می‌شود. تنوعی که روش‌های طبقه‌بندی دارند، به کاربران امکان تولید اطلاعات گوناگون (نظیر تولید نقشه‌های پوششی و کاربری، محاسبه حجم تراکم پوشش‌های گیاهی و...) را می‌دهد. روش‌های طبقه‌بندی تصویر هم‌چنین در زمینه‌های نظامی، کشاورزی، کانی‌شناسی [۱۰، ۱۱، ۱۲] و غیره اهمیت می‌یابند.

به‌منظور دستیابی به یک طبقه‌بندی کننده با دقت بالا برای تصاویر ابرطیفی تحقیقات گسترده‌ای انجام شده است. هم‌اکنون نیز روش‌هایی در حال توسعه بوده که بتوانند دقت طبقه‌بندی کننده‌های داده‌های ابرطیفی را افزایش دهند. با افزایش دقت طبقه‌بندی، زمین با دقت بیشتری به نقشه‌های موضوعی تبدیل شده است و می‌توان اطلاعات بیشتری از تصاویر ابرطیفی استخراج کرد. بدیهی است که رسیدن به دقت‌های

---

<sup>۱</sup>Anomaly Detection

<sup>۲</sup>Target detection

<sup>۳</sup>Classification

<sup>۴</sup>Unmixing



بالتر در تولید نقشه‌های موضوعی از داده‌های ابرطیفی می‌تواند در افزایش اعتماد استفاده‌کنندگان نهایی و به تبع آن صحت اطلاعات استخراج شده از داده‌های سنجش از دوری مؤثر باشد.

به‌طور کلی می‌توان گفت که کلیه روش‌های طبقه‌بندی به دنبال کشف کلاسی هستند که پیکسل موردنظر را با حداکثر اطمینان به آن نسبت دهد و یا درصد تعلق یک کلاس به یک پیکسل تشخیص داده شود. این تعریف گرچه یک تعریف دقیق و کامل نیست ولی جنبه‌های مختلفی از فرآیند طبقه‌بندی را آشکار می‌سازد.

روش‌های طبقه‌بندی به‌طور مرسوم به دو دسته طبقه‌بندی‌های نظارت شده<sup>۱</sup> و نظارت نشده<sup>۲</sup> تقسیم می‌شوند. روش‌های نظارت شده به اطلاعات اولیه‌ای نظیر تعداد کلاس‌ها، خصوصیات آن‌ها و همچنین تعدادی نمونه‌ی معلوم از هر کلاس نیاز دارند. در مقابل روش‌های نظارت نشده به نمونه‌های معلوم نیاز نداشته و بر اساس مقادیر خود پیکسل‌ها در مورد خوشه‌بندی آن‌ها تصمیم‌گیری می‌کنند.

طبقه‌بندی موفق داده‌های سنجش از دوری یک چالش بزرگ است. چراکه عواملی همچون انتخاب مناسب داده‌های ورودی و روش‌های پیش پردازش و پردازش تصاویر ممکن است منجر به تولید نتایج متفاوتی گردد. علیرغم پتانسیل بالای داده‌های ابرطیفی در تولید نقشه‌های طبقه‌بندی، مسائلی مانند: ۱- وجود باندهای طیفی نوین آلود[۱۳]، ۲- بعد بالای فضای ویژگی و افزونگی بالا در داده[۱۴]، ۳- تمایز بعد ذاتی داده‌ها با بعد فضای ویژگی[۱۵]، ۴- وجود باندهای طیفی که توان تفکیک مناسب برای کلاس‌های طبقه‌بندی ندارند[۱۶]، ۵- ناهماهنگی بین ابعاد بالای تصویر و تعداد محدود داده‌های آموزشی در طبقه‌بندی [۹] و ۶- تنوع بالا در روش‌های طبقه‌بندی، از جمله چالش‌های موجود در پردازش داده‌های ابرطیفی محسوب می‌شود.

با توجه به مشکلات مطرح شده، طبقه‌بندی تصاویر ابرطیفی با استفاده مستقیم از طبقه‌بندی کننده‌ها از دقت مطلوبی برخوردار نمی‌باشد؛ بنابراین در طبقه‌بندی تصاویر ابرطیفی نیاز به روش‌هایی می‌باشد

---

<sup>۱</sup>Supervised  
<sup>۲</sup>Unsupervised

که به راحتی با ابعاد بالای داده‌های ورودی کار کرده و همچنین با استفاده از نمونه‌های آموزشی کم، کاهش دقت چندانی حاصل نکند.

بررسی‌های انجام شده نشان داده است که در حالت کلی روش‌های استخراج و انتخاب ویژگی روش‌هایی هستند که می‌توانند تا حدود زیادی بر این مشکلات فائق آمده و منجر به بهبود دقت طبقه‌بندی شوند. علاوه بر این، به منظور استفاده بهینه از اطلاعات تصاویر نه تنها اطلاعات طیفی بلکه اطلاعات مکانی نیز در فرآیندهای طبقه‌بندی مورد استفاده قرار گرفته که منجر به بهبود دقت نتایج طبقه‌بندی شده است. روش‌های استخراج ویژگی خود به دو دسته روش‌های خطی و غیرخطی تقسیم می‌شوند. در این پژوهش سعی شده است با به کارگیری روش‌های استخراج ویژگی خطی LDA<sup>۱</sup>، غیرخطی NLPCA<sup>۲</sup> و تخمین تنک، سپس تلفیق روش‌های مذکور به منظور تولید ویژگی‌هایی با تفکیک‌پذیری بالا در طبقه‌بندی و نهایتاً استفاده از الگوریتم طبقه‌بندی کننده KNN، دقت طبقه‌بندی را تا حدودی بهبود دهیم.

بر این اساس سئوالات اصلی تحقیق به شرح زیر است:

- آیا استخراج ویژگی به طریق نظارت شده با استفاده از تبدیل NLPCA می‌تواند در تولید ویژگی‌هایی با تفکیک‌پذیری بالاتر به منظور بهبود دقت طبقه‌بندی مؤثر باشد؟ چه پارامترهایی در این مورد تأثیر گذار می‌باشد؟
- مناسب‌ترین ترکیب روش‌های استخراج ویژگی LDA ، NLPCA و تخمین تنک به منظور تولید ویژگی‌هایی با تفکیک‌پذیری بالا جهت ورود به الگوریتم طبقه‌بندی کننده، چه ترکیبی می‌باشد؟
- آیا افزودن اطلاعات مکانی منجر به بهبود دقت طبقه‌بندی می‌گردد؟

---

<sup>۱</sup>Linear Discriminant Analysis (LDA)

<sup>۲</sup>Nonlinear Principal Component Analysis (NLPCA)

### ۱-۳- اهداف تحقیق

آنچه یک روش طبقه‌بندی را بر دیگری برتری می‌دهد استفاده بهینه از داده‌های ورودی به الگوریتم است. تولید نتایج متفاوت با داده‌های ورودی مشابه توسط طبقه‌بندی کننده‌های گوناگون یک امر بدیهی است. انتخاب یا تولید ویژگی‌های تفکیک‌پذیر و انتخاب الگوریتم طبقه‌بندی کننده دو رکن اصلی در یک طبقه‌بندی موفق است.

تاکنون راهکارهای توسعه یافته در مورد طبقه‌بندی دو رویکرد اصلی: ۱- افزایش تفکیک‌پذیری فضای ویژگی از طریق انتخاب یا تولید ویژگی و ۲- توسعه و به‌کارگیری تکنیک‌های مؤثر طبقه‌بندی را در دستورکار خود داشته‌اند. در این راستا این پژوهش به‌منظور بهبود دقت طبقه‌بندی اهداف زیر را دنبال می‌کند:

- تولید و تلفیق ویژگی‌های تفکیک‌پذیر توسط تخمین تنک، تبدیلات خطی و تبدیلات غیرخطی
- به‌کارگیری اطلاعات مکانی در کنار اطلاعات طیفی به‌منظور بهبود دقت نتایج طبقه‌بندی
- کسب دقت مطلوب در مورد کلاس‌هایی که تعداد داده‌های آموزشی اندکی از آن‌ها در روند تولید ویژگی حضور دارند.

### ۱-۴- ساختار پایان‌نامه

ساختار پایان‌نامه پیش رو مشتمل بر پنج فصل می‌باشد. در فصل اول به بررسی تاریخچه تصاویر ابرطیفی و اهمیت طبقه‌بندی پرداخته شده است. در فصل دوم مبانی نظری روش‌های استخراج ویژگی ارائه شده، همچنین به بیان پیشینه‌ی تحقیقی از مبانی نظری ذکر شده پرداخته است. در فصل سوم به تشریح روش پیشنهادی پرداخته شده است. در فصل چهارم نتایج کسب شده از روش پیشنهادی ارائه شده و مورد بحث

قرار گرفته و آخرین فصل از پایان نامه نیز به نتیجه گیری و ارائه پیشنهادات برای کارهای آتی اختصاص دارد.

## فصل دوم

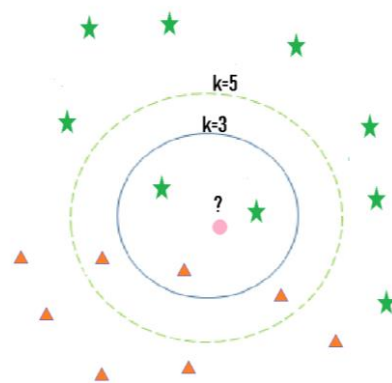
### مبانی نظری و پیشینه‌ی تحقیق

در پژوهش‌های پیشین به منظور استخراج بهینه اطلاعات از تصاویر ابرطیفی تحقیقاتی در زمینه‌ی روش‌ها و تکنیک‌های مختلف طبقه‌بندی داده‌های ابرطیفی انجام شده است. پژوهشگران به دنبال ارائه راهکارهایی به منظور ارتقا دقت طبقه‌بندی در تصاویر ابرطیفی بوده و بر این اساس محور عملکرد پژوهش‌های پیشین بر پایه‌ی دو محور استوار است: ۱- انتخاب طبقه‌بندی کننده‌ی مناسب ۲- تنظیم ورودی طبقه‌بندی کننده، که در بسیاری از پژوهش‌ها تلفیقی از دو عملکرد ذکر شده بکار رفته است.

در رویکرد انتخاب طبقه‌بندی کننده‌ی مناسب، الگوریتم‌های طبقه‌بندی در دو دسته جای گرفته‌اند: ۱- روش‌های طبقه‌بندی آماری (پارامتریک) ۲- روش‌های طبقه‌بندی غیر آماری (غیر پارامتریک). در دسته اول با استفاده از مقادیر پارامترهای آماری مختلفی نظیر میانگین و واریانس و در دسته‌ی دوم اغلب بر اساس مقادیر خود پیکسل‌ها و تعداد پیکسلی از یک کلاس خاص در اطراف پیکسل مجهول، الگوریتم طبقه‌بندی طراحی می‌شود. در ادامه به نمونه‌هایی از تحقیقات در این زمینه اشاره می‌شود.

به عنوان نمونه در پژوهشی در سال ۲۰۱۴ محققان روش آماری جدیدی مبتنی بر روش بیشترین شباهت ارائه کردند که از این روش برای تعیین عمق و کیفیت آب در مناطق بزرگ استفاده شده است. در روش پیشنهادی ابتدا تصویر شبکه‌بندی شده و با فرض همگن بودن کیفیت آب در کل شبکه، در هر قسمت شبکه ویژگی‌های ستون آب با یک مدل عمق خطی و ثابت به کمک تکنیک ML تخمین زده می‌شود. سپس نقشه نهایی از ترکیب این تخمین‌ها به دست می‌آید. کارایی روش با استفاده از تصاویر ابرطیفی واقعی ارزیابی شد. نتایج نشان داد که روش پیشنهادی، مدل‌سازی عمق، تخمین عمق و کیفیت آب را به‌ویژه در آب‌های کم‌عمق بهبود می‌بخشد [۱۷].

الگوریتم  $k$ -نزدیک‌ترین همسایگی (KNN)<sup>۱</sup> یک روش غیر پارامتری است که با هدف طبقه‌بندی در پژوهش‌های پیشین مورد استفاده قرار گرفته است [۱۸، ۱۹]. در این روش ورودی شامل  $K$  عدد از نزدیک‌ترین نمونه‌های آموزشی در فضای ویژگی است و خروجی برچسب یک کلاس می‌باشد. یک نمونه با رأی اکثریت  $K$  همسایه‌ی خود طبقه‌بندی شده و به یکی از آن‌ها اختصاص می‌یابد.  $K$  یک عدد صحیح مثبت و به‌طور معمول کوچک است. اگر  $K = 1$  باشد، نمونه موردنظر به سادگی به تک همسایه نزدیک خود تخصیص داده می‌شود (طبقه‌بند نزدیکترین همسایه (NN)). به عبارتی دیگر در این الگوریتم نمونه‌های آموزشی شامل بردارهایی در یک فضای ویژگی چندبعدی می‌باشند که هر یک دارای یک برچسب کلاس است. مرحله‌ی آموزش الگوریتم تنها شامل ذخیره‌سازی بردارهای ویژگی و برچسب‌های کلاس نمونه‌های آموزشی است. در هر مرحله طبقه‌بندی، برچسب کلاس نمونه‌ی آزمون برابر برچسبی انتخاب شده که بیشترین تکرار را بین  $K$  نمونه‌ی نزدیکش داشته باشد ( $K$  یک عدد است که توسط کاربر مشخص می‌شود). یک متریک فاصله‌ی رایج و مورد استفاده در این روش، فاصله‌ی اقلیدسی است [۲۰]. شکل (۱-۲) یک نمونه داده آزمون را نشان می‌دهد که به روش KNN طبقه‌بندی شده است. اگر مقدار  $K$  برابر ۳ انتخاب شود، نمونه‌ی جدید در کلاس ستاره قرار می‌گیرد. در حالیکه اگر  $K = 5$  باشد، این نمونه جزء کلاس مثلث خواهد بود.



شکل ۱-۲- الگوریتم  $k$ -نزدیکترین همسایگی

<sup>۱</sup>K Nearest Neighborhood

<sup>۲</sup>Euclidean distance

در پژوهشی در سال ۲۰۱۸ با به کارگیری الگوریتم KNN و ترکیب اطلاعات طیفی و مکانی، دقت بالایی در طبقه‌بندی حاصل شد. در این پژوهش ابتدا یکسری اطلاعات مکانی نزدیک از پیکسل‌ها توسط یک فیلتر هدایت شده استخراج می‌شود، سپس از الگوریتم KNN پیشنهاد شده برای طبقه‌بندی پیکسل‌ها استفاده می‌شود. در روش فوق از این ایده استفاده می‌کنند که نقطه مرکزی می‌تواند توسط همسایگان مجاور با استفاده از فیلتر هدایت شده نمایش داده شود [۲۱].


برخی از طبقه‌بندی‌کننده‌های غیر پارامتریک حساسیت کمتری به تعداد نمونه‌های آموزشی دارند و راه‌حلی برای حل مشکل محدودیت تعداد نمونه‌های آموزشی می‌باشند [۲۲، ۲۳]. روش ماشین بردار پشتیبان (SVM) از دیگر روش‌های غیر آماری است که به‌طور گسترده در پژوهش‌های پیشین مورد استفاده قرار گرفته و قابلیت کنترل فضای ویژگی با ابعاد بالا را برای آموزش دارد و آن را برای طبقه‌بندی داده‌های ابرطیفی مناسب می‌سازد [۲۴].

با توجه به دقت بالای سنجنده‌های سنجش از دوری و اندازه‌گیری دقیق طیف مواد در تصاویر ابرطیفی، انتظار می‌رود که بتوان با انتخاب طبقه‌بندی‌کننده‌ی مناسب، طبقه‌بندی با دقت بالایی روی این تصاویر انجام داده و کلاس‌ها را با دقت مطلوبی از هم تفکیک کرد؛ اما استفاده از همه‌ی باندها در تصاویر ابرطیفی علاوه بر بار محاسباتی بالا، منجر به مشکلاتی در زمینه‌ی یادگیری ماشینی می‌شود. علاوه بر این همه ویژگی‌های به دست آمده در تصاویر ابرطیفی به دلیل وجود نویز با اهمیت نیستند؛ بنابراین این تصاویر شامل ویژگی‌هایی هستند که در طبقه‌بندی نامناسب، ممکن است گمراه‌کننده و زائد باشند. علاوه بر این، فضای با ابعاد بالا ویژگی‌های هندسی‌ای دارد که به‌صورت مستقیم قابل درک نمی‌باشد و فراتر از ویژگی‌هایی است که در فضاهای با ابعاد پایین (فضاهای دوبعدی یا سه‌بعدی) مشاهده می‌شود. هم‌چنین ابزارهای تحلیل داده موجود اغلب با فضاهای با ابعاد پایین سازگار بوده و در صورت استفاده از این ابزارها برای داده‌های با بعد بالا و پیچیده‌تر ممکن است نتایج نادرستی در تحلیل‌ها حاصل شود. به عبارتی با وجود آنکه افزایش تعداد باندهای طیفی اطلاعات بیشتری در مورد جداپذیری کلاس‌ها در اختیار ما قرار می‌دهد اما با توجه به ضعفی که طبقه‌بندی‌کننده‌ها در برخورد با داده بعد بالا دارند، اثر مثبت و مکمل باندهای طیفی



کاهش می‌یابد. برای برطرف کردن این مشکلات پژوهشگران در رویکرد تنظیم ورودی طبقه‌بندی کننده به دنبال ارائه راهکاری به منظور استخراج، شناسایی یا انتخاب ویژگی‌های ورودی به الگوریتم طبقه‌بندی کننده بوده، به نحوی که ویژگی‌هایی با تفکیک‌پذیری بالاتر، به منظور افزایش دقت طبقه‌بندی حاصل شود. در ادامه برخی از روش‌های طبقه‌بندی متکی به استخراج ویژگی مرور شده‌اند.

روش‌های کاهش ویژگی (کاهش بعد) از جمله راهکارهایی هستند که انجام موفقیت‌آمیز آن تأثیر قابل توجهی در افزایش دقت یک طبقه‌بندی کننده دارد. کاهش ویژگی به معنای انتقال داده‌ی بعد بالا به فضایی با بعد پایین‌تر است که در حالت ایده‌آل، بعد پایین باید بعدی متناظر با ابعاد حقیقی داده داشته باشد. ابعاد حقیقی داده، عبارت است از فضایی با کمترین تعداد ویژگی مورد نیاز که خواص مشاهده شده در داده را حفظ کند. به عنوان مثال با مشاهده‌ی مجموعه داده‌ی شکل (۲-۲-الف) تصور می‌شود این داده در دو بعد گسترش یافته است. با اعمال روش کاهش بعد PCA (که در آینده به تفصیل شرح داده می‌شود) بر روی این داده در شکل (۲-۲-ب) مشاهده می‌شود که در فضای جدید حاصل از این تبدیل ویژگی‌های داده موردنظر در راستای یک خط گسترش یافته است؛ بنابراین این تبدیل علاوه بر کاهش بعد، نمایانگر بعد حقیقی داده می‌باشد که در این فضای کاهش یافته معادل یک است.



شکل ۲-۲- نمایش بعد حقیقی داده با روش کاهش بعد

روش‌های کاهش ویژگی به دو دسته انتخاب ویژگی و استخراج ویژگی، تقسیم می‌شوند [۲۵، ۲۶، ۲۷]. در حالت نخست، طی فرآیندی زیرمجموعه‌ی مناسبی از ویژگی‌های اولیه (عمدتاً باندهای طیفی) بر اساس معیار مشخصی انتخاب و مابقی ویژگی‌ها کنار گذاشته می‌شوند. بطوریکه ویژگی‌های جدید شامل بسیاری از اطلاعات داده اصلی باشد. مزیت این روش حفظ تعبیر فیزیکی ویژگی انتخاب شده می‌باشد. هدف فرآیند انتخاب ویژگی، انتخاب مؤثرترین زیرمجموعه از ویژگی‌های موجود به منظور استفاده در طبقه‌بندی بر طبق یک تابع معیار و الگوریتم جستجو است [۲۸]. از مشکلات این روش‌ها زمان‌بر بودن و بار محاسباتی بالای بهینه‌سازی روی یک فضای گسسته برای پیدا کردن باندهای منتخب می‌باشد. این درحالی است که تعیین نگاهت بهینه در روش‌های استخراج ویژگی، بار محاسباتی کمتری دارند.

استخراج ویژگی به مفهوم تولید تعدادی ویژگی جدید بر اساس تبدیلات معین یا یک نگاهت از باندهای اولیه است [۲۹]. در واقع این تکنیک ویژگی‌های جدیدی متأثر از ویژگی‌های اولیه تولید می‌کند که متفاوت از آن‌هاست. این نگاهت به طریقی محاسبه می‌شود که ویژگی‌های استخراج شده دارای تمام (یا بخش اعظمی از) اطلاعات موجود در ویژگی‌های اولیه باشند. در رویکرد استخراج ویژگی، مجموعه‌ای از تبدیلات خطی و غیرخطی برای محاسبه‌ی ویژگی‌های جدید استفاده می‌شود. تبدیلات خطی همچون LDA و PCA [۳۰] و یا غیرخطی مانند NLPCA و KPCA [۳۱] نمونه‌هایی از این روش‌های استخراج ویژگی بشمار می‌روند. در این روش‌ها عمدتاً تولید ویژگی با هدف کاهش بعد دنبال می‌شود. هرچند که در مواردی مانند روش‌های SVM<sup>۳</sup> و KPCA با انتقال داده‌ها به فضایی با ابعاد بالاتر، افزایش تفکیک‌پذیری دنبال می‌گردد [۳۲].

در پژوهشی در سال ۲۰۱۱ با استفاده از ویژگی‌های تولید شده توسط تبدیلات PCA، NLPCA و KPCA بر روی دو داده ابرطیفی به دست آمده از سنجنده‌های Chris و HyMap و به کارگیری روش‌های طبقه‌بندی ANN<sup>۴</sup> و SVM به این نتیجه دست یافتند که ویژگی‌های استخراج‌شده از روش NLPCA

---

<sup>۱</sup>Principal Component Analysis (PCA)

<sup>۲</sup>Kernel Principal Component Analysis (KPCA)

<sup>۳</sup>Support Vector Machine (SVM)

<sup>۴</sup>Artificial Neural Network(ANN)

به طریق نظارت نشده منجر به دقت بالاتر طبقه‌بندی در مقایسه با ویژگی‌های استخراج شده از تبدیل‌های PCA، KPCA و همچنین داده خام اولیه شده است [۳۱]. مزیت روش NLPCA نسبت به PCA و KPCA در این پژوهش حفظ محتوای اطلاعاتی بیشتر و همچنین توزیع یکنواخت اطلاعات بین ویژگی‌های مستخرج، گزارش شده است [۳۳].

در این پژوهش تمرکز بر روی بهبود نتایج طبقه‌بندی تصاویر ابرطیفی از طریق روش‌های استخراج ویژگی می‌باشد. در این فصل ابتدا رویکردهای خطی و غیرخطی استخراج ویژگی بیان شده است. سپس روش‌ها و الگوریتم‌های پایه استخراج ویژگی که به منظور تولید ویژگی با افزایش تفکیک‌پذیری فضای ویژگی، در روند پیاده سازی این پژوهش مورد استفاده قرار گرفته‌اند، معرفی و تشریح می‌گردند، سپس مزایا و معایب این روش‌ها مرور می‌شود. در انتها مفاهیم پایه‌ای روش‌های تولید ویژگی مبتنی بر نمایش تنک به همراه تعدادی الگوریتم طبقه‌بندی موجود در این زمینه بیان می‌شود.

## ۲-۲- تبدیلات خطی

در این بخش مسأله‌ی کاهش ابعاد داده به صورت خطی به بیان ریاضی شرح داده شده است. در مسأله کاهش ابعاد به صورت خطی از یک متغیر تصادفی  $p$ -بعدی به صورت  $x = [x_1, x_2, \dots, x_p]^T$ ، متغیر  $k$ -بعدی  $s = [s_1, s_2, \dots, s_k]^T$  به طریقی استخراج می‌شود که اولاً  $k < p$  بوده و ثانیاً  $s$  محتوای را که در  $x$  وجود را بر اساس معیاری خاص دارا باشد.

همان‌طور که در رابطه‌ی (۱-۲) مشاهده می‌شود، روش‌های خطی سعی می‌کنند هر یک از  $k$  مؤلفه را از ترکیب خطی  $p$  مؤلفه‌ی اولیه به دست آورند.

$$s_i = w_{i,1}x_1 + \dots + w_{i,p}x_p \quad , \quad i = 1, \dots, k \quad (1-2)$$

به عبارتی برای هر متغیر برداری  $s$  ماتریس نگاشت خطی  $w$  بر روی متغیر  $x$  مطابق با رابطه‌ی (۲)-

(۲) اعمال می‌شود.

$$S_{k \times 1} = W_{k \times p} * x_{p \times 1} \quad (2-2)$$

$$\begin{bmatrix} S_1 \\ \vdots \\ S_k \end{bmatrix}_{k \times 1} = \begin{bmatrix} W_{1,1} & \cdots & W_{1,p} \\ W_{2,1} & \cdots & W_{2,p} \\ \vdots & \ddots & \vdots \\ W_{k,p} & \cdots & W_{p,p} \end{bmatrix}_{k \times p} * \begin{bmatrix} x_1 \\ \vdots \\ x_p \end{bmatrix}_{p \times 1} \quad (3-2)$$


هدف از تبدیلات خطی به دست آوردن ماتریس نگاشت  $W$  بوده به نحوی که با ضرب این ماتریس نگاشت به داده اولیه، این داده به فضایی با ابعاد کمتر از داده‌ی اولیه انتقال پیدا کند. در ادامه‌ی این بخش به تشریح روش‌های خطی استخراج ویژگی تحت عنوان، تبدیل تحلیل مؤلفه اصلی به صورت نظارت نشده و تبدیل تحلیل تفکیک‌پذیری خطی به صورت نظارت شده پرداخته شده است.

### ۲-۲-۱- تبدیل تحلیل مؤلفه اصلی (PCA)

یکی از روش‌های خطی تولید ویژگی نظارت نشده روش تحلیل مؤلفه‌های اصلی است. این تبدیل به‌طور گسترده‌ای برای کاربردهایی مانند کاهش بعد و استخراج ویژگی تصویرهای ابرطیفی استفاده می‌شود. روش تبدیل خطی PCA تلاش می‌کند که همبستگی موجود در داده را با تصویر کردن داده به یک فضای جدید حذف کند. مراحل الگوریتم PCA به شرح زیر است:

مرحله اول: انتقال مبدأ سیستم مختصات به مرکز ثقل داده‌ها

در این مرحله میانگین مقادیر نمونه‌های هر باند را از مقادیر آن باند کم کرده تا میانگین داده‌ها در هر باند صفر شود. هنگام اعمال تبدیل PCA در فضای دوبعدی مطابق شکل (۳-۲) مشاهده می‌شود داده‌ها از سیستم مختصات اولیه با محورهای  $x_1$  و  $x_2$  به سیستم مختصاتی با مبدأ متفاوت از سیستم مختصات اولیه منتقل شده که میانگین داده‌ها در این سیستم مختصات صفر می‌باشد.



شکل ۲-۳- انتقال داده به سیستم مختصات جدید در تبدیل PCA

به بیان ریاضی اگر تصویر ابرطیفی شامل  $n$  نمونه و در ابعاد  $b$  به شکل متغیر برداری بوده است. داده‌ها در سیستم مختصات جدید با متغیر برداری  $Y_i$  حاصل از رابطه‌ی زیر نمایش داده می‌شوند.

$$Y_i = X_i - \left( \frac{1}{n} \sum_{k=1}^n x_{i,k} \right) [1]_{n,1} \quad , \quad i = 1, 2, \dots, b \quad (۴-۲)$$

مرحله دوم: محاسبه ماتریس کوواریانس

در این مرحله ماتریس کوواریانس داده‌های حاصل از مرحله‌ی قبل از رابطه‌ی (۴-۲) محاسبه می‌شود.

$$C(i,j) = \frac{1}{n} (Y_i Y_j^T) \quad i = 1, 2, \dots, b \quad , \quad j = 1, 2, \dots, b \quad (۵-۲)$$

مرحله سوم: محاسبه‌ی بردارهای ویژه و مقادیر ویژه

در این مرحله بردارهای ویژه و مقادیر ویژه‌ی ماتریس کوواریانس حاصل از مرحله‌ی قبل محاسبه

می‌شود. مقادیر ویژه میزان پراکندگی داده‌ها را در راستای بردار ویژه‌ی مربوطه نشان می‌دهد.

مرحله چهارم: مرحله کاهش بعد

در این مرحله بردارهای ویژه حاصل از مرحله‌ی قبل را بر اساس مقادیر ویژه‌ی آن‌ها از بزرگ به کوچک مرتب کرده، سپس از بردارهای ویژه متناظر با مقادیر ویژه خیلی کوچک و نزدیک به صفر چشم‌پوشی کرده و بردارهای ویژه متناظر با سایر مقدار ویژه را به عنوان محورهای فضای جدید انتخاب می‌کنند. به عبارتی دیگر، محورهای مختصات جدیدی برای داده‌ها تعریف شده و داده‌ها بر اساس این محورهای مختصات جدید تصویر می‌شود. اولین محور در جهت بردار ویژه متناظر با بیشترین مقدار ویژه ( $\lambda_1$ ) قرار می‌گیرد که پراکندگی داده در این راستا بیشتر است. دومین محور عمود بر محور اول در جهت بردار ویژه متناظر با دومین مقدار ویژه ( $\lambda_2$ ) در جهتی با پراکندگی کمتر از پراکندگی محور اول قرار می‌گیرد و به همین ترتیب محورهای بعدی عمود بر محور قبلی و در جهت بردار ویژه با پراکندگی کمتر قرار می‌گیرند. شکل (۲-۳) جهت‌گیری این محورها را در فضای ویژگی دوبعدی نمایش می‌دهد.

همان‌طور که مشاهده می‌شود، در این تکنیک بردارهای ویژه‌ی ماتریس کوواریانس داده‌ها در سیستم مختصات منتقل شده به مرکز ثقل داده‌ها به عنوان مبنای تبدیل استفاده شده است. مشاهده می‌شود مؤلفه‌های اصلی متناظر با مقادیر ویژه بزرگ‌تر، پراکندگی بیشتری را در خود جای می‌دهند؛ اما لزوماً این راستاها تضمین‌کننده‌ی این موضوع نیستند که قادر باشند تفکیک‌پذیری بهتری را تأمین سازند؛ بنابراین وقتی که هدف طبقه‌بندی اشیا است PCA نمی‌تواند روش کارایی برای کاهش بعد باشد.

از دیگر کاربردهای PCA در تصاویر ابرطیفی حذف نویز و هم‌چنین فشردن‌سازی تصاویر می‌باشد. کاهش تدریجی محتوای اطلاعاتی در ویژگی‌های تولید شده توسط تبدیل PCA، حذف همبستگی میان داده‌ها با فرضیات خطی، نظارت نشده بودن و عدم لحاظ شدن رفتارهای پیچیده و غیرخطی در توزیع داده‌ها را می‌توان از محدودیت‌های روش PCA قلمداد نمود [۳۴]. این تبدیل به طور گسترده در زمینه‌های دیگری مانند شناسایی الگو و تشخیص چهره مورد استفاده قرار می‌گیرد [۳۵، ۳۶، ۳۷].

از آنجا که به دلایل مختلف وابستگی بین مؤلفه‌های داده‌های ابرطیفی غیرخطی هستند؛ بنابراین استفاده از یک تبدیل غیرخطی می‌تواند کارآمدتر باشد و با حذف وابستگی‌های غیرخطی فشردن‌سازی

بیشتری را تامین سازد. بدین منظور با استفاده از روش هسته‌ها یک نسخه غیرخطی برای روش PCA پیشنهاد شده و به KPCA معروف است که در بخش‌های آتی بحث خواهد شد.

## ۲-۲-۲- تبدیل تحلیل تفکیک‌پذیری خطی (LDA)

یکی از روش‌های خطی تولید ویژگی نظارت شده که از معیار جدایی‌پذیری کلاس‌ها برای استخراج ویژگی استفاده می‌کند تبدیل LDA می‌باشد. در این تبدیل داده‌ها به فضایی نگاشت شده که علاوه بر کاهش ویژگی از تفکیک‌پذیری بهتری برخوردار می‌شوند. به عبارت بهتر، این تبدیل داده‌ها را از فضای اولیه به فضایی نگاشت می‌دهد که در آن مقدار پراکندگی بین کلاس‌ها افزایش و از پراکندگی داخل کلاس‌ها کاسته می‌شود. در LDA ماتریس‌های پراکندگی درون کلاسی ( $S_w$ ) و بین کلاسی ( $S_b$ ) به شکل زیر تعریف می‌شوند.

$$S_b = \sum_{k=1}^{n_c} n_k (\mu_k - \mu)(\mu_k - \mu)^T \quad (6-2)$$

$$S_w = \sum_{k=1}^{n_c} \sum_{i=1}^{n_k} (x_{i,k} - \mu_k)(x_{i,k} - \mu_k)^T \quad (7-2)$$


در روابط فوق  $\mu_k$ ،  $n_k$ ،  $\mu$  و  $x_{i,k}$  به ترتیب بردار میانگین کلاس  $k$ ام، تعداد نمونه‌های کلاس  $k$ ام، میانگین کل نمونه‌های آموزشی و نمونه  $i$ ام در کلاس  $k$ ام بوده و همچنین تعداد کلاس‌ها برابر  $n_c$  می‌باشد.

هدف از تبدیل LDA یافتن راستاهایی است که با تصویر کردن نمونه‌های فضای ویژگی به آن‌ها تابع هدف ارائه شده در رابطه‌ی (۸-۲) بیشینه گردد.

$$J(w) = \frac{W^T S_b W}{W^T S_w W} \quad (8-2)$$

در این رابطه  $W$  راستای مورد نظر به منظور بیشینه‌سازی تابع هدف ( $J$ ) است. اثبات می‌شود که راستای مورد نظر معادل با بردار ویژه متنظر با بزرگ‌ترین مقدار ویژه ماتریس  $S_W^{-1}S_B$  می‌باشد. سایر بردارهای ویژه این ماتریس از نظر تفکیک‌پذیری در رده‌های بعدی قرار خواهند داشت [۳۸].

برای درک بهتر این تبدیل در شکل (۲-۴) داده‌های سه کلاس که در یک فضای ویژگی واقع شده‌اند مشاهده می‌شود. تبدیل LDA در واقع راستایی در فضای ویژگی ایجاد می‌کند که داده‌ها پس از نگاشت به این راستا بیشترین تفکیک‌پذیری را ایجاد کنند. در این راستا پراکندگی درون کلاسی کاهش یافته و پراکندگی بین کلاسی افزایش می‌یابد.




شکل ۲-۴- تبدیل تحلیل تفکیک‌پذیری خطی

به بیانی دیگر، هدف تبدیل LDA بیشینه کردن معیار زیر بین کلاس‌ها در راستای جدید است. این شاخص به نام نسبت فیشر، یکی از ساده‌ترین شاخص‌های جدایی‌پذیری بین کلاسی می‌باشد که تلاش می‌کند هم‌زمان پراکندگی داده‌های هر کلاس را کمینه و فاصله‌ی کلاس‌ها را از یکدیگر بیشینه کند. نمونه‌ای از این تابع هدف به ازای ۲ کلاس را می‌توان در رابطه‌ی (۲-۹) مشاهده نمود.



$$J(w) = \frac{|\tilde{\mu}_1 - \tilde{\mu}_2|^2}{\tilde{s}_1^2 + \tilde{s}_2^2} \quad (9-2)$$

همان‌طور که در شکل (۵-۲) مشاهده می‌شود، مقادیر  $\tilde{\mu}_1$  و  $\tilde{\mu}_2$  مراکز کلاس‌ها در راستای حاصل از LDA و مقادیر  $\tilde{s}_1$  و  $\tilde{s}_2$  پراکندگی داخل کلاس‌ها می‌باشد.



شکل ۵-۲- نمایش شاخص فیشر بین دو کلاس

تفاوت LDA با PCA در آن است که LDA ماتریس پراکندگی (کوواریانس) بین کلاس‌ها را نیز در نظر می‌گیرد که سبب می‌شود عملکرد بهتری در مقایسه با PCA داشته باشد.

تبدیل LDA علاوه بر مزایایی که دارد در مواردی با چالش‌هایی مواجه می‌باشد که از آن جمله می‌توان به موارد زیر اشاره کرد:

۱. برای داده‌هایی که فاصله‌ی بین میانگین کلاس‌ها در آن کم یا زیاد است LDA دارای عملکرد ضعیفی می‌باشد؛ زیرا در صورتیکه فاصله‌ی بین میانگین کلاس‌ها کم باشد آنگاه ماتریس پراکندگی بین کلاسی به صفر نزدیک شده و اثر پراکندگی درون کلاسی نیز از

بین می‌رود و ویژگی‌های استخراج شده قابل اعتماد نمی‌باشند. از طرفی اگر فاصله میانگین یکی از کلاس‌ها با میانگین دیگر کلاس‌ها تفاوت زیادی داشته باشد، محاسبه‌ی ماتریس پراکندگی بین کلاسی را تحت شعاع قرار می‌دهد و الگوریتم تمام توجه خود را به جدایی پذیری این کلاس با بقیه کلاس‌ها معطوف می‌کند، در نتیجه استخراج ویژگی به صورت مؤثر انجام نمی‌شود.

۲. در صورتی که تعداد نمونه‌های آموزشی کمی در دسترس باشد، ماتریس پراکندگی درون کلاسی سینگولار شده و در این حالت LDA کارایی ضعیفی خواهد داشت.

۳. تبدیل LDA زمانی خوب عمل می‌کند که نمونه‌های هر کلاس دارای توزیع نرمال یا توزیع احتمال گوسی باشند. در صورتیکه توزیع کلاس‌ها غیرنرمال باشد این روش عملکرد خوبی در استخراج ویژگی نخواهد داشت.

## ۲-۳- تبدیلات غیرخطی

وابستگی‌های غیرخطی بین داده‌های ابرطیفی یکی از عوامل خطا در پردازش آن‌ها می‌باشد. رفتار غیرخطی در تصاویر ابرطیفی ناشی از عواملی مانند تغییرات نور خورشید، میزان متغیر آب در سطح و ترکیب غیرخطی طیف مواد داخل یک پیکسل مخلوط می‌باشد. در بخش قبل روش‌های نظارت شده و نظارت نشده کاهش ویژگی که بر اساس تبدیل‌های خطی بنا شده بود مورد بررسی قرار گرفت. روش‌های خطی محدود به انتقال ویژگی به یک فضای خطی بوده که در آن هر ویژگی جدید، توسط ترکیب خطی ویژگی‌های قبلی حاصل می‌شود. در سال‌های اخیر تعمیم روش‌های خطی به نوع غیرخطی برای پردازش تصاویر ابرطیفی بسیار مورد توجه بوده است. روش‌های مبتنی بر هسته‌های غیرخطی از این نمونه می‌باشند. یکی از راه‌های تعمیم روش‌های خطی مانند PCA و LDA به غیرخطی استفاده از تکنیک‌های مبتنی بر کرنل یا هسته‌ها می‌باشد [۳۹]. در این بخش به شرح دو نمونه از تبدیلات غیرخطی می‌پردازیم.

## ۲-۳-۱- تبدیل تحلیل مؤلفه اصلی هسته (KPCA)

روش‌های استخراج ویژگی خطی، توانایی تفکیک‌پذیری غیرخطی مناسب برای طبقه‌بندی کلاس‌هایی که به صورت خطی قابل جداسازی نیستند را ندارند (شکل ۲-۶-الف). بدین منظور روش‌های خطی استخراج ویژگی را می‌توان با هسته‌دار کردن به روش‌های غیرخطی تبدیل نمود. الگوریتم KPCA نمونه‌ای از این روش‌ها می‌باشد. تکنیک اصلی KPCA محاسبه تبدیل PCA در فضای نگاشت یافته توسط یک تابع نگاشت غیرخطی می‌باشد که از ایده‌ی کرنل (هسته) برای تخمین این نگاشت استفاده می‌کند. در واقع تبدیل KPCA همان مراحل و ویژگی‌های PCA را در فضایی متفاوت اعمال می‌کند.

ایده اولیه‌ی این روش‌ها به این صورت است که ابتدا داده‌ها با استفاده از یک نگاشت غیرخطی، به فضایی با بعد بالاتر نگاشت می‌شوند، به عبارتی ابتدا روی  $n$  داده‌ی اولیه نگاشت غیرخطی  $\phi$  به صورت  $\phi: x \rightarrow \phi(x)$  اعمال شده و داده‌ها در فضای جدید به صورت  $(\phi(x_1), \phi(x_2), \dots, \phi(x_n))$  در نظر گرفته می‌شوند. سپس روش‌های خطی تفکیک‌پذیری داده‌ها در این فضا اعمال می‌شوند. اما در عمل نگاشت نمونه‌های داده به یک فضای بعد بالاتر به صورت صریح عملی نیست و بنابراین از توابع مبتنی بر هسته برای رفع این محدودیت استفاده می‌کنیم. یعنی در این روش تابع بجای وابستگی به  $\phi(x_1)$  و  $\phi(x_2)$  به ضرب داخلی آن‌ها یعنی  $(\phi(x_1) \cdot \phi(x_2))$  وابسته باشد. به عبارتی توابع مبتنی بر هسته به صورت رابطه زیر در نظر گرفته می‌شوند:

$$K(x,y) = (\phi(x) \cdot \phi(y)) \quad (۱۰-۲)$$

در این رابطه  $(\cdot)$  بیانگر ضرب داخلی می‌باشد. در این حالت نیازی به محاسبه  $\phi(x)$  یا  $\phi(y)$  به صورت صریح نمی‌باشد و تنها نیاز به تعیین تابع هسته  $K$  می‌باشد. یک هسته مانند  $K$  که معرف ضرب داخلی می‌باشد باید دارای خصوصیات زیر باشد:

$$K(x,y) = K(y,x) \quad ۱.$$

$$K(x,x) \gg 0, K(x,x)=0 \Leftrightarrow x = 0 \quad ۲.$$

$$3. (K(x,y))^2 \ll K(x,x) \times K(y,y)$$

این کرنل‌ها خواص غیرخطی دارند و معادل یک نگاشت ویژگی غیرخطی می‌باشند. اثبات شده است، توابع گاوسی و چندجمله‌ای از جمله توابع مبتنی بر هسته می‌باشند که می‌توان آن‌ها را به فرم ضرب داخلی نوشت. در روابط (۱۱-۲) و (۱۲-۲) این توابع مبتنی بر هسته مشاهده می‌شوند.

$$K(x,y) = \exp\left(-\frac{\|x-y\|^2}{2\sigma^2}\right) \quad (11-2)$$


$$K(x,y) = (1 + x \cdot y)^2 \quad (12-2)$$

با استفاده از این خاصیت که جمع دو هسته‌ی معتبر نیز خود یک هسته معتبر است، می‌توان هسته‌های متنوع زیادی را به دست آورد. یکی از مهم‌ترین عیوب روش‌های مبتنی بر هسته وابستگی بیش از حد نتایج به هسته‌ی انتخابی می‌باشد در صورتیکه هسته مناسب برای یک مجموعه داده‌ها انتخاب نشود نتایج چندان رضایت بخش نیست. یکی از زمینه‌های تحقیقاتی در استفاده از روش‌های مبتنی بر هسته، پیدا کردن هسته مناسب برای یک مجموعه داده‌ی خاص می‌باشد.

درنهایت تبدیل PCA بر روی این فضای غیرخطی اعمال شده و به طریقی مشابه با مراحل ذکر شده در الگوریتم PCA در این فضا عمل می‌کند. تبدیل KPCA به دنبال یافتن جهت‌هایی می‌باشد که متغیرهای تصویر شده به این فضا، بیشترین میزان پراکندگی را در آن جهات داشته باشند.

KPCA در مقایسه با روش PCA نتایج بهتری در طبقه‌بندی ایجاد می‌کند، زیرا مقادیر ویژه متمایزتری در مقایسه با روش‌های خطی ایجاد می‌کند. همچنین پیچیدگی محاسباتی KPCA از PCA بیشتر است [۴۰].


شکل (۶-۲) نمایش دهنده مقایسه روش‌های استخراج ویژگی به طریق خطی و غیرخطی می‌باشد.




شکل ۲-۶- مقایسه روش‌های خطی (الف) و غیرخطی (ب) استخراج ویژگی

## ۲-۳-۲- تحلیل مؤلفه اصلی غیرخطی (NLPCA)

تاکنون راهکارهای مختلفی به‌منظور یافتن مؤلفه‌های اصلی در شرایط توزیع پیچیده‌ی داده‌ها در فضای ویژگی توسعه یافته است. یکی از این نسخه‌ها، تبدیل غیرخطی تحلیل مؤلفه‌ی اصلی (NLPCA) است. این تبدیل با تصویر کردن داده‌های ورودی به سطوح پیچیده و چندبعدی، تلاش می‌کند تا مؤلفه‌های غیرخطی در توزیع داده‌ها را شناسایی کند. شکل (۲-۷) نحوه‌ی انطباق یافتن مؤلفه‌های اصلی در این تبدیل را نشان می‌دهد. مطابق با این شکل، تبدیل NLPCA یک تعمیم غیرخطی از تحلیل مؤلفه‌های اصلی (PCA) می‌باشد. هرچند که تفاوت‌های ذاتی زیادی بین آنها وجود دارد. این تکنیک همبستگی خطی و غیرخطی بین ویژگی‌ها را بدون توجه به ماهیت غیرخطی داده برآورد کرده و داده‌ها را توسط مؤلفه‌های غیرخطی از فضای اولیه به فضایی با ابعاد پایین‌تر نگاشت می‌کند.



(ب)



(الف)

شکل ۲-۷- تحلیل مؤلفه‌های اصلی غیرخطی

تبدیل NLPCA توسط کرامر معرفی شده است. در این روش یک شبکه عصبی مصنوعی چند لایه به منظور تعیین نگاشت غیرخطی داده‌ها آموزش داده می‌شود. ورودی و خروجی این شبکه‌ی عصبی در روند آموزش یکسان است. به عبارت بهتر، این شبکه‌ی عصبی مصنوعی، داده‌های ورودی را به خود آن‌ها نگاشت می‌کند. معماری این شبکه از سه لایه ورودی، خروجی و میانی تشکیل شده، که در لایه‌ی میانی از نرون‌های کمتری نسبت به لایه‌های ورودی و خروجی استفاده می‌شود [۴۱].

به طور کلی این شبکه‌ی عصبی از دو نیمه تشکیل شده است. نیمه اول با استفاده از لایه‌های نگاشت (Mapping) ویژگی‌هایی با ابعاد کمتر استخراج می‌کند (شکل ۲-۸).

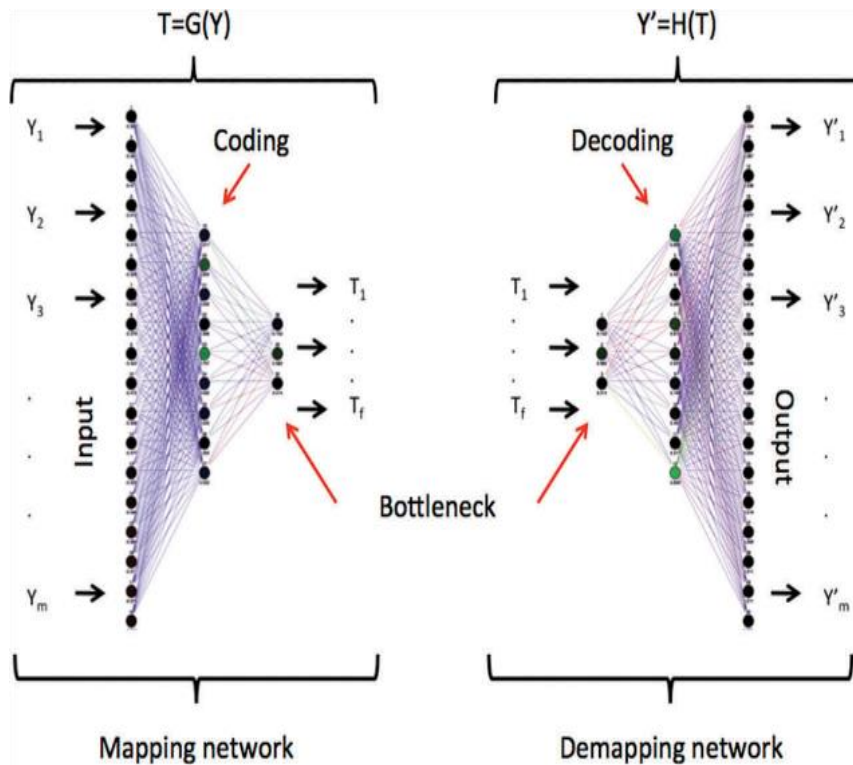
$$T = G(Y) \quad (۲-۱۳)$$

به طریقی مشابه، نیمه دوم شبکه‌ی عصبی با استفاده از لایه‌های بازبازی (Demapping) داده‌ها را از فضای ویژگی با ابعاد کمتر در لایه‌ی میانی بازسازی کرده و به ابعاد اولیه بازمی‌گرداند (شکل ۲-۸).

$$Y' = H(T)$$

(۱۴-۲)

در روابط (۱۳-۲) و (۱۴-۲)،  $Y$  و  $Y'$  به ترتیب داده‌های ورودی به شبکه عصبی و داده‌ی تخمین‌زده شده توسط آن می‌باشند.  $T$  بردار مؤلفه‌های اصلی متناظر با هر مشاهده در فضای  $Y$  است. توابع  $H$  و  $G$  نیز به ترتیب تبدیلات غیرخطی نگاشت و بازسازی می‌باشند.



شکل ۲-۸- تابع نگاشت (چپ) و تابع بازسازی (راست)

توپولوژی شبکه‌ی عصبی در NLPCA به نحوی انتخاب شده که در لایه‌ی خروجی، کمترین خطا در بازسازی داده‌ی اولیه تولید گردد. از مزایای روش NLPCA علاوه بر کاهش بعد، فشردگی اطلاعات و همچنین توزیع اطلاعات در مؤلفه‌های غیرخطی استخراج شده است. در این روش، تعداد مؤلفه‌های تولیدی برابر با بعد فضای ورودی نیست. به همین دلیل در مقایسه با تبدیل PCA میزان از دست رفتن اطلاعات متناسب با کیفیت برآزش شبکه عصبی اندازه‌گیری می‌شود. از مشکلات این روش، مسائل مربوط به آموزش شبکه‌های عصبی و همچنین جستجو به منظور شناسایی توپولوژی بهینه برای آن می‌باشد [۴۲].

## ۲-۴- استخراج ویژگی مبتنی بر تخمین تنک

یکی دیگر از روش‌های تولید ویژگی، روش‌های مبتنی بر نمایش تنک (SR) است. این تکنیک بر این فرض استوار بوده که می‌توان پیکسل‌های مورد آزمون را با تعداد معدودی اتم (عضو خالص) از یک دیکشنری از اتم‌ها بازنمایی نمود. این تکنیک طی سال‌های اخیر جایگاه ویژه‌ای در پردازش تصاویر ابرطیفی به خود اختصاص داده است. در این بخش مباحث پایه‌ای نمایش تنک به همراه تعدادی از الگوریتم‌های رایج در تعیین این نمایش تشریح شده است. سپس به اهمیت استفاده از نمایش تنک اشاره شده است. در انتها کاربرد نمایش تنک در طبقه‌بندی تشریح شده و به تعدادی از الگوریتم‌های رایج در طبقه‌بندی مبتنی بر نمایش تنک اشاره شده است.

### ۲-۴-۱- نمایش تنک

در سال‌های اخیر، استفاده از نمایش تنک سیگنال در کاربردهایی مانند نمونه‌برداری، فشرده‌سازی، نويز زدایی و طبقه‌بندی مورد توجه بسیار قرار گرفته است [۴۳، ۴۴، ۴۵، ۴۶]. موفقیت نمایش تنک در این کاربردها، از آن‌جا ناشی می‌شود که اکثر سیگنال‌های طبیعی مانند تصویر و یا گفتار، با در نظر گرفتن پایه‌های مشخصی دارای نمایشی تنک هستند. نمایش سیگنال‌ها در پایه‌ی مناسب همواره به عنوان یک گام اساسی در شناخت ویژگی‌ها و نیز استخراج و تفسیر اطلاعات سیگنال‌ها مورد توجه بوده است [۴۷].

به عبارتی دیگر کدگذاری تنک شاخه‌ای از علوم مرتبط با حسگری فشرده بوده که در آن تلاش می‌شود یک سیگنال به کمک ترکیب خطی تعداد معدودی عنصر خالص از یک کتابخانه از عناصر پایه بازنمایی گردد. مصطلح است که بردار عناصر کتابخانه، اتم و کتابخانه، دیکشنری نامیده شوند. دیکشنری متشکل از تعداد زیادی اتم با طول واحد می‌باشد [۴۸] (رابطه ۲-۱۵).

$$[D]_{n \times m} = [d_1, d_2, \dots, d_m] \quad (2-15)$$



در رابطه‌ی (۲-۱۵) که نحوه‌ی تشکیل ماتریس دیکشنری  $D \in R^{n \times m}$  نمایش داده می‌شود،  
 اتم‌های دیکشنری،  $n$  تعداد باندهای طیفی و  $m$  تعداد اتم‌های دیکشنری  $[\vec{d}_i]_{n \times 1}$   $i = 1, 2, \dots, m$   
 می‌باشند.

از آنجا که اتم‌های مورد استفاده در نمایش یک سیگنال باید ویژگی‌های مهم و به طور کلی اطلاعات مفید آن را استخراج کنند، لذا انتخاب دیکشنری مناسب در این مرحله از اهمیت زیادی برخوردار است. دیکشنری‌های مورد استفاده بدین منظور را می‌توان به دو دسته کلی دیکشنری‌های ثابت (غیروفتی) و وفقی تقسیم کرد. در دیکشنری‌های ثابت، اتم‌های دیکشنری از پیش مشخص بوده و به عبارتی وابسته به سیگنال نیستند. اگرچه این دیکشنری‌ها از نظر محاسباتی سریع هستند، اما ضعف عمده آن‌ها در این است که تنها برای توصیف برخی از ویژگی‌های سیگنال تحت بررسی مناسب هستند و نمی‌توانند نمایشی به اندازه کافی تنک از آن ارائه کنند. در دیکشنری‌های وفقی، با استفاده از داده‌های آموزشی و طی یک الگوریتم آموزشی، اتم‌های دیکشنری به گونه‌ای بهینه می‌شوند که تا حد امکان نمایان‌گر برجسته‌ترین ویژگی‌های مجموعه آموزشی بوده و در نتیجه نمایشی به اندازه کافی تنک برای آن‌ها ارائه دهند. روش‌های به دست آوردن دیکشنری با استفاده از داده‌های آموزشی را آموزش دیکشنری گویند. تاکنون روش‌های متنوعی برای آموزش دیکشنری‌هایی که نمایشی به اندازه کافی تنک از سیگنال مورد نظر فراهم کنند، ارائه شده است.

سیگنالی به صورت بردار  $s \in R^n$  در نظر گرفته شده است. به منظور نمایش این بردار برحسب اتم‌های دیکشنری باید بردار ضرایب تخمین تنک  $\alpha \in R^n$  از دستگاه معادلات خطی زیر تعیین گردد:

$$s = \sum_{i=1}^m \alpha_i d_i = D\alpha \quad (2-16)$$

در رابطه‌ی فوق، اگر  $m=n$  و ماتریس  $D$  متعامد یک‌به‌یک باشد، جواب دستگاه فوق یکتا بوده و از رابطه‌ی زیر به دست می‌آید:

$$\alpha = D^{-1}s = D^T s \quad (17-2)$$

رابطه‌ی (۱۷-۲) اگرچه جواب یکتایی برای نمایش سیگنال به دست می‌آید، اما در بسیاری موارد این جواب تنک نیست.

در پردازش تنک سیگنال در صورتی که  $m > n$  باشد ماتریس دیکشنری را فرا کامل در نظر می‌گیرند [۴۹]. در چنین شرایطی دستگاه معادلات خطی رابطه‌ی (۱۶-۲) فرومعیین خواهد بود، چرا که تعداد معادلات از تعداد مجهولات کمتر است.

از آنجا که همواره توصیف سیگنال‌ها به ساده‌ترین صورت ممکن و با استفاده از کم‌ترین تعداد سیگنال‌های پایه مورد توجه بوده است؛ بنابراین تبدیل و یا نمایشی مطلوب تلقی می‌شود که برای ساختن یا بسط سیگنال با یک خطای مشخص تنها از تعداد کمی سیگنال پایه استفاده کند. به عبارتی به منظور دستیابی به ساده‌ترین توصیف از سیگنال مورد بررسی، نمایشی از سیگنال مطلوب است که از کم‌ترین تعداد اتم‌ها استفاده کند. بنابراین از میان پاسخ‌های بی‌شمار دستگاه معادلات خطی فرومعیین، به دنبال جوابی هستیم که تا حد ممکن درایه‌ی صفر (یا خیلی نزدیک صفر) داشته باشد. بدین ترتیب، با اعمال شرط تنکی بر روی جواب حاصل از دستگاه فوق می‌توان به پاسخی یکتا دست یافت.

بدین منظور قیدی به مسئله‌ی فرومعیین مذکور اضافه می‌شود که تعداد مؤلفه‌های غیر صفر نمایش حاصل را محدود کند. از آنجا که نرم صفر یک بردار معرف تعداد مؤلفه‌های غیر صفر آن می‌باشد لذا کمینه سازی نرم صفر منجر به تحمیل شرط تنکی به بردار خواهد شد. برای به دست آوردن تنک‌ترین جواب باید مسئله‌ی زیر حل شود:


$$\min_{\alpha} \|\alpha\|, \quad \text{subject to } s = D\alpha \quad (18-2)$$

---

<sup>۱</sup>Underdetermined

در رابطه‌ی فوق  $\|\alpha\|$  نشان دهنده‌ی تعداد مؤلفه‌های غیرصفر بردار  $\alpha$  است. از آنجا که نرم صفر محدب نیست ( $\|\cdot\|_p$  برای  $0 \leq p < 1$  محدب نیست) و از آن مهم‌تر، مشتق‌پذیر نیست، مسئله‌ی فوق NP-Hard تلقی می‌شود و حل آن منوط به جستجوی کامل است که به وضوح در ابعاد بالا غیرعملی است. به عبارت دیگر، برای پیدا کردن جوابی با  $k$  درایه‌ی غیرصفر، لازم است در بدترین حالت تعداد  $N = \binom{m}{k}$  زیر ماتریس از  $D$  که هر کدام نماینده‌ی یک زیرفضا است، مورد بررسی قرار گیرد.

یکی از راهکارهای مهم در حل سیستم‌های خطی با فرض تنگ بودن جواب (مشابه مسئله مطرح شده در رابطه‌ی (۲-۱۸))، تقریب زدن نرم صفر با نرمی از مرتبه بالاتر است که کمینه کردن آن ساده‌تر باشد [۵۰]. طبیعی است که هر چه نرم مرتبه‌ی پایین‌تری استفاده شود، جواب حاصل از کمینه سازی به جواب حاصل از کمینه سازی نرم صفر نزدیک‌تر خواهد بود. همان‌طور که در شکل (۲-۹) مشاهده می‌شود، تابع نرم به ازای  $0 \leq p < 1$  محدب نیست و هر چه به سمت یک نزدیک می‌شود، تابع هموارتر شده و به ازای  $p = 1$  تابع محدب خواهد بود.



شکل ۲-۹- نمایش نرم‌های مختلف

از آنجا که نرم یک نزدیک‌ترین نرم محدب به نرم صفر است، جایگزینی نرم صفر با نرم یک منطقی -ترین تقریب به نظر می‌رسد [۵۱]. اگرچه با افزایش مرتبه نرم، پیچیدگی محاسباتی کاهش می‌یابد، اما به احتمال زیاد جواب حاصل تا حدی با جواب اصلی متفاوت است. در صورتی که نرم صفر با نرم دو تقریب

زده شود این روند مشهودتر خواهد بود. نشان داده شده است که تقریب حاصل از نرم یک، هنگامی که تعداد نمونه‌ها به اندازه کافی باشد، به سیگنال اصلی بسیار نزدیک است [۵۲].

مشکل دیگری که در نمایش تنک سیگنال‌ها مطرح می‌باشد آن است که تساوی  $s = D\alpha$  عموماً در عمل برقرار نیست، و اگر هم بخواهد دقیقاً برقرار باشد لزوماً به پاسخ تنکی برای  $\alpha$  منجر نخواهد شد. به‌طور کلی در بسیاری از کاربردها، با تساوی زیر مواجه هستیم.

$$s = D\alpha + N \quad (19-2)$$

در رابطه‌ی فوق  $N$  بردار نویز (نویز سفید گوسی) می‌باشد که سیگنال را آلوده کرده است. در چنین حالتی، به منظور پایداری جواب در تقریب تنک سیگنال، به جای استفاده از رابطه‌ی (۱۸-۲) باید از نسخه‌های پایدار نسبت به نویز آن‌ها استفاده کرد [۵۳]. در این حالت هر سیگنال می‌تواند به وسیله‌ی ترکیبات مختلفی از اتم‌های متفاوت نمایش داده شود. هنگامی که اختلاف بازسازی شده‌ی سیگنال به کمک یک نمایش تنک با سیگنال اصلی از یک مقدار آستانه کمتر باشد، به عبارتی خطای بازسازی توسط نمایش تنکی که برای سیگنال به دست آورده‌ایم قابل چشم پوشی باشد، می‌توان گفت سیگنال دارای نمایش تنک با توجه به یک دیکشنری خاص است.

با در نظر گرفتن مفاهیم ذکر شده، هدف از فرآیند تخمین تنک یک سیگنال، یافتن بردار تنک  $\alpha_{m \times 1}$  از طریق حل دستگاه معادلات فرو معین ارائه شده در رابطه (۲۰-۲) می‌باشد [۵۴].

$$s = D \times \alpha$$

$$\min_{\alpha} \|\alpha\|, \text{ or } \|\alpha\| \leq k \quad \text{subject to} \quad \|s - D\alpha\| \leq \varepsilon \quad (20-2)$$

در رابطه‌ی (۲۰-۲)،  $s$  سیگنال مشاهداتی،  $\|\cdot\|$  نرم دوم بردار و  $\|\cdot\|$  نرم صفر یک بردار (شمارنده‌ی تعداد عناصر غیر صفر یک بردار) می‌باشند.  $k$  اصطلاحاً حداکثر میزان تنکی یک بردار (یک سیگنال « $k$  - تنک» نامیده می‌شود اگر نمایش آن در یک حوزه متعامد یکه، حداکثر  $k$  مؤلفه‌ی غیر صفر داشته باشد) و

$\varepsilon$  حد مجاز خطا در بازسازی یک سیگنال در روش تخمین تنک است. مسئله فوق نسبت به نویز پایدار است.

فرو معین بودن دستگاه معادلات مربوط به تخمین تنک و عدم مشارکت بخش بسیار زیادی از عناصر کتابخانه در روند کدگذاری یک سیگنال از ویژگی‌های این تکنیک محسوب می‌شود [۵۵، ۵۶].


به این ترتیب با حل مسئله رابطه‌ی (۲-۲۰) می‌توان تخمینی از سیگنال بدون نویز  $y$  به صورت رابطه‌ی زیر به دست آورد.

$$\hat{y} = D\hat{\alpha} \quad (2-21)$$

در رابطه‌ی فوق  $\hat{\alpha}$  جواب مسئله‌ی (۲-۲۰) می‌باشد. در این مسئله  $(\|s - D\alpha\| \leq \varepsilon)$  به شرط LASSO شهرت دارد.

از نقطه نظر تئوری، راهکاری صریح به منظور حل چنین دستگاه معادلاتی (رابطه‌ی ۲-۲۰) وجود نداشته و به کارگیری الگوریتم‌های ابتکاری و مبتنی بر جستجو، یکی از راهکارهای یافتن پاسخ برای این دستگاه‌های معادلات محسوب می‌شود [۵۴].

از جمله کاربردهای نمایش تنک کاهش حجم اطلاعات می‌باشد. مشاهده می‌شود که در بسیاری از موارد سیگنال‌های با ابعاد بالا اطلاعات کمی را در مقایسه با ابعادشان دارند. برای چنین سیگنال‌هایی با در نظر گرفتن نمایش تنک می‌توان همان میزان اطلاعات مفید سیگنال را با مقدار ضرایب بسیار کمتری نمایش داد (شکل ۲-۱۰).



شکل ۲-۱۰- نمایش تنک سیگنال S به کمک دیکشنری D (http://lions.epfl.ch/research)

## ۲-۴-۲- الگوریتم‌های رایج در تعیین نمایش تنک

طی سال‌های اخیر الگوریتم‌های زیادی برای به دست آوردن نمایش تنک سیگنال ارائه شده است [۵۴]. این الگوریتم‌ها را می‌توان در دو دسته‌ی کلی الگوریتم‌های مبتنی بر حل مسئله‌ی بهینه‌سازی و الگوریتم‌های حریص دسته‌بندی کرد. هدف الگوریتم‌های دسته‌ی اول، حل یک مسئله‌ی بهینه‌سازی می‌باشد. اما دسته‌ی الگوریتم‌های حریص<sup>۱</sup> به صورت قدم به قدم یک یا چند اتم را که بیشترین همبستگی با باقی‌مانده‌ی مربوط به نمایش سیگنال دارند را انتخاب کرده و با استفاده از آن‌ها، این باقی‌مانده را به روز می‌کنند. اساس این روش‌ها مبتنی بر تخمین مرحله به مرحله‌ی سیگنال با استفاده از اتم‌های دیکشنری است. به طور کلی الگوریتم‌های حریص نسبت به دسته‌ی دیگر سریع‌تر بوده؛ اما اغلب، هزینه‌ی این سرعت بالا دقت کم‌تر این الگوریتم‌ها است. در ادامه به بررسی دو نمونه از این الگوریتم‌های حریص می‌پردازیم.

### • الگوریتم MP<sup>۲</sup>

الگوریتم MP ساده‌ترین نوع الگوریتم‌های حریص می‌باشد [۵۷]. اگر برداری  $k$ -تنک باشد، سیگنال  $s$  می‌تواند به صورت یک ترکیب خطی از  $k$  اتم دیکشنری نوشته شود. در الگوریتم مذکور ابتدا ستون‌های مورد استفاده از ماتریس دیکشنری در ترکیب خطی آشکار شده و سپس ضرایب این ستون‌ها که همان

<sup>۱</sup>Greedy

<sup>۲</sup>Matching Pursuit

مقادیر غیرصفر بردار  $\alpha$  هستند، با حل یک مسئله کمترین مربعات محاسبه می‌گردند. در این روش، در هر مرحله، یک اتم از دیکشنری که بیشترین شباهت را به داده آزمون دارد، به عنوان عضو فعال در ترکیب خطی در نظر گرفته شده و ضریب مربوط به آن محاسبه می‌گردد. تفاضل حاصل ضرب این تقریب ۱-تنک در دیکشنری، از داده‌ی آزمون به عنوان باقی‌مانده در نظر گرفته شده و مراحل فوق تکرار می‌شوند. در هر مرحله، جمع تقریب‌های ۱-تنک به دست آمده با تقریب‌های قبلی، به عنوان تقریب جدید در نظر گرفته می‌شود و این روند تا جایی ادامه می‌یابد که یا تعداد مراحل مشخصی طی شود و یا خطا از مقدار معینی کمتر شود. [۵۸، ۵۹]

به بیانی دیگر، در این رویکرد، با روندی تکراری، اتم‌های سازنده‌ی یک سیگنال هم‌زمان با تأمین قیود رابطه‌ی (۲-۲۰) شناسایی و ضریب (فراوانی) هر اتم برآورد می‌گردد [۶۰] به عبارت بهتر، در تکنیک MP، در روندی تکراری و در هر مرحله، اتمی از دیکشنری که دارای کم‌ترین زاویه‌ی طیفی با بردار خطای تخمین سیگنال (برآورد شده توسط اتم‌های یافته شده در تکرارهای قبلی) داشته باشد، به عنوان اتم جدید به مجموعه اتم‌های انتخاب شده‌ی قبلی افزوده می‌شود. به عبارت دیگر، با در نظر گرفتن  $r$  به عنوان بردار خطای تخمین توسط اتم‌های انتخاب شده‌ی قبلی برای سیگنال  $s$  (رابطه‌ی ۲-۲۰)، در هر تکرار، اتمی که  $\| [d_i]^T \times [r] \|_2$  را بیشینه سازد، به عنوان اتم جدید به مجموعه اتم‌های انتخاب شده‌ی قبلی افزوده می‌شود.

$$[r] = [s] - D \times [A] \quad (۲-۲۲)$$

شایان ذکر است در تکرار اول و به منظور انتخاب اولین اتم در این تکنیک،  $r = s$  در نظر گرفته می‌شود [۶۱]. از جمله مهم‌ترین مزایای این روش‌ها می‌توان به سرعت بالای آن‌ها اشاره کرد [۶۲].

## • الگوریتم OMP<sup>۱</sup>

<sup>۱</sup>Orthogonal Matching Pursuit

یکی از راهکارهای توسعه یافته به منظور تخمین تنک یک سیگنال الگوریتم OMP است. در روش OMP که تعمیم یافته روش MP است، در هر مرحله ضرایب ستون‌های فعال از ماتریس دیکشنری به صورت مستقل از نتایج مراحل قبل انتخاب می‌شوند و از نتایج قبلی تنها در یافتن مکان مؤلفه‌های غیر صفر استفاده می‌شود. در این روش‌ها هر بار به جای انتخاب یک ستون از ماتریس D، تعداد بیشتری اتم انتخاب می‌شود، سپس طی پیشروی الگوریتم، تعدادی از این اتم‌ها حذف شده و یا اتم‌های جدیدی به مجموعه اضافه می‌شود. تفاوت بین الگوریتم‌های OMP و MP در چگونگی تخمین پارامترها است. در روش MP در هر تکرار یک اتم شناسایی شده سپس ضریب آن برآورد می‌شود. این ضرایب با افزوده شدن اتم‌های جدید به روز نمی‌شوند. اما در روش OMP بعد از افزوده شدن هر اتم جدید فرآیند تخمین ضرایب مرتبط با تمامی اتم‌ها تکرار می‌شود.

## ۲-۴-۳- طبقه‌بندی با استفاده از نمایش تنک

طی سال‌های اخیر پردازش تنک سیگنال به عنوان ابزاری قدرتمند و کارا توجه بسیاری از محققین را به خود جلب کرده است. علاوه بر این استفاده از نمایش تنک سیگنال‌ها در مسائل طبقه‌بندی نیز نتایج موفقیت‌آمیزی به همراه داشته است. همان‌طور که قبلاً ذکر شد ایده اصلی در نمایش تنک این است که هر داده ورودی می‌تواند به صورت یک ترکیب خطی تنک از اتم‌های دیکشنری نوشته شود؛ بنابراین ایده، دو دلیل عمده استفاده از نمایش تنک در طبقه‌بندی عبارت است از: (۱) نمایش فشرده و تفسیر بهتری از داده‌ها فراهم می‌کند. (۲) مزایایی از جمله حذف نویز و جلوگیری از فرا انطباق<sup>۱</sup> دارد. با این حال، کیفیت عملکرد این طبقه‌بندی کننده‌ها در شرایط سخت، از جمله در مواردی که ابعاد داده‌ها در مقایسه با تعداد داده‌های آموزشی زیاد باشد، به شدت افت پیدا می‌کند. علاوه بر این، پیچیدگی محاسباتی بالای برخی از این روش‌ها، استفاده از آن‌ها را در بسیاری از کاربردهای عملی با مشکل مواجه می‌کند. برای کاهش این مشکلات روش‌های مختلفی ارائه شده است.

---

<sup>۱</sup>Overfitting



این بخش کاربرد نمایش تنک در طبقه‌بندی داده‌ها را مورد بررسی قرار داده است. ابتدا نمونه‌هایی از روش‌های مختلف استفاده از نمایش تنک در طبقه‌بندی معرفی شده است. سپس چالش‌های اساسی پیش‌رو در این روش‌ها ذکر شده است. روش SRC به عنوان روش پایه ویکی از موفق‌ترین روش‌ها در استفاده از نمایش تنک به‌منظور طبقه‌بندی معرفی شده است. سپس الگوریتم‌های دیگری که به‌منظور بهبود عملکرد این روش ارائه شده‌اند، مورد بررسی قرار گرفته است.

## ۲-۴-۳-۱- الگوریتم SRC<sup>۱</sup>

طبقه‌بندی کننده مبتنی بر نمایش تنک (SRC) در سال ۲۰۰۸ به‌منظور تشخیص چهره ارائه شد [۶۳]. روش SRC را می‌توان به عنوان یکی از موفق‌ترین روش‌های طبقه‌بندی با استفاده از نمایش تنک در نظر گرفت [۶۴]. در این روش از تمامی نمونه‌های آموزشی متعلق به کلاس‌های مختلف به عنوان اتم‌های دیکشنری استفاده کرده و یک دیکشنری کلی به‌صورت ترکیبی از داده‌های آموزشی تمام کلاس‌ها تشکیل می‌شود. بنابراین مرحله آموزش دیکشنری در این روش وجود ندارد. اگرچه در این روش دیکشنری آموزش داده نمی‌شود، ولی این روش اساس روش‌های طبقه‌بندی مبتنی بر نمایش تنک است. ایده اصلی در این روش، نمایش داده آزمون به‌صورت یک ترکیب خطی تنک از تمامی نمونه‌های آموزشی است. در چنین حالتی بردار ضرایب نمایش تنک تنها دارای تعداد کمی مؤلفه است که بر روی نمونه‌های آموزشی دارای برجسب یکسان با داده آزمون متمرکز هستند.

طبقه‌بندی با روش SRC شامل دو مرحله است: ابتدا داده ورودی با استفاده از ماتریس دیکشنری که از کنار هم قرار گرفتن تمامی داده‌های آموزشی تشکیل شده است به‌صورت تنک کد می‌شود. سپس با استفاده از این ضرایب تنک و با بازسازی داده آزمون طبقه‌بندی انجام می‌گیرد [۶۳].

اغلب داده‌های متعلق به یک کلاس روی یک زیر فضا قرار می‌گیرند. بنابراین، چنانچه  $s \in R^n$  داده ورودی مربوط به کلاس  $i$  ام باشد، می‌توان آن را به‌صورت ترکیب خطی از ستون‌های ماتریس

---

<sup>۱</sup>Sparse Representation Classification (SRC)

$D_i = [d_{i,1}, d_{i,2}, \dots, d_{i,N_i}] \in R^{n \times N_i}$  که از کنار هم قرار گرفتن  $N_i$  داده آموزشی متعلق به همین کلاس تشکیل شده است به صورت زیر نمایش داد:

$$s = x_{i,1}d_{i,1} + x_{i,2}d_{i,2} + \dots + x_{i,N_i}d_{i,N_i} = \sum_{j=1}^{N_i} x_{i,j} d_{i,j} \quad (23-2)$$

که در آن،  $x_{i,j}$  ها ضرایبی اسکالر هستند. از آنجا که برچسب داده‌ی ورودی برای سیستم مجهول است، ماتریس  $D$  به صورت ترکیبی از تمام داده‌های آموزشی از همه  $n_c$  کلاس در نظر گرفته می‌شود:

$$D = [D_1, \dots, D_{n_c}] \quad (24-2)$$

در این رابطه، هر کدام از  $D_i$  ها زیرماتریس‌هایی هستند که داده‌های آموزشی کلاس  $i$  ام را در خود جای داده‌اند و  $m = N_1 + \dots + N_{n_c}$  تعداد کل داده‌های آموزشی است. بنابر توضیحات داده شده نمایش داده‌ی آزمون  $s$  بر حسب ستون‌های ماتریس  $D$ ، در حالت ایده‌آل به صورت زیر خواهد بود:

$$s = D\alpha, \quad \alpha = [0, \dots, 0, \alpha_{i,1}, \dots, \alpha_{i,N_i}, 0, \dots, 0]^T \in R^m \quad (25-2)$$

در رابطه فوق مشاهده می‌شود که مؤلفه‌های غیر صفر در بردار نمایش تنک، متناظر با ستون‌هایی از ماتریس  $D$  است که مربوط به کلاس  $i$  ام باشند. با توجه به تنک بودن ضرایب نمایش داده آزمون بر روی ماتریس حاوی داده‌های آموزشی و در نظر گرفتن نویز موجود در داده‌ها، بردار  $\alpha$  از رابطه‌ی زیر محاسبه می‌شود.

$$\hat{\alpha} = \arg \min \|\alpha\|, \quad s.t. \quad \|s - D\alpha\| \leq \varepsilon \quad (26-2)$$

در حالت ایده‌آل، انتظار می‌رود تمامی مؤلفه‌های غیر صفر در بردار نمایش تنک، متناظر با ستون‌هایی از  $D$  باشند که مربوط به یک کلاس هستند. در این صورت می‌توان برچسب آن کلاس را به داده آزمون ورودی اختصاص داد. اما نویز و خطای مدل‌سازی غیر قابل اجتناب بوده و منجر به تولید مؤلفه‌های غیر صفر کوچکی در محل ضرایب متناظر با کلاس‌های مختلف، می‌شوند. برای حل این مشکل و به منظور

دستیابی به یک طبقه‌بندی مقاوم، قابلیت بازسازی داده آزمون  $s$  توسط ضرایب متناظر با هر یک از کلاس‌ها، به عنوان معیار طبقه‌بندی در نظر گرفته می‌شود. به عبارتی، در SRC از میزان شباهت داده ورودی به هر یک از کلاس‌ها برای طبقه‌بندی استفاده می‌شود و خطای نمایش روی هر کلاس، به عنوان یک شاخص برای طبقه‌بندی داده آزمون به کار می‌رود.

بدین منظور، تابع  $\delta_i : R^m \rightarrow R^m$  به صورت زیر تعریف می‌شود که با اعمال آن بر روی بردار  $\alpha$ ،  $N_i$  مؤلفه بردار  $\alpha$  متناظر با داده‌های کلاس  $i$  ام در دیکشنری حفظ شده و سایر مؤلفه‌ها صفر می‌شوند.

$$\delta_i(\alpha) = [0, \dots, 0, \alpha_{i_1}, \dots, \alpha_{i_{N_i}}, 0, \dots, 0]^T \in R^m \quad (27-2)$$

بنابراین  $\hat{s}_i = D\delta_i(\alpha)$  داده‌ی  $s$  را تنها به صورت ترکیب خطی از داده‌های کلاس  $i$  ام بیان می‌کند. با اعمال این تابع روی نمایش تنک داده‌ی  $s$  و بازسازی آن با استفاده از داده‌های متعلق به هر یک از کلاس‌ها در هر مرحله، در نهایت داده ورودی به کلاسی نسبت داده می‌شود که میزان باقی‌مانده زیر را کمینه کند:

$$\min_i r_i(y) = \|s - D\delta_i(\hat{\alpha})\| \quad (28-2)$$

از مهم‌ترین معایب محاسبه نمایش تنک در روش SRC را می‌توان زمان بر بودن آن دانست. استفاده از تمامی نمونه‌های آموزشی در ماتریس دیکشنری، فرآیند محاسبه نمایش تنک را طولانی ساخته و در نتیجه زمان پاسخگویی سیستم را افزایش می‌دهد. علاوه بر این در صورتی که تعداد داده‌های آموزشی زیاد باشد، این مرحله از نظر محاسباتی دچار چالش خواهد شد. از دیگر مشکلات این روش آن است که وجود یک دیکشنری از پیش تعیین شده، حاوی افزونگی‌های بسیاری از جمله نویز و اطلاعات اضافی است که می‌توانند اثر منفی بر کارایی سیستم داشته باشند.

بر این اساس، پژوهشگران با مطالعه‌ی جامع در مورد روش طبقه‌بندی به کمک بازیابی تنک سیگنال (SRC)، بهبود دقت این روش را نسبت به روش‌های سنتی مانند SVM نشان دادند. سپس برای بالابردن دقت روش SRC زمانیکه تعداد محدود نمونه‌ی آموزشی موجود است؛ روش KSR<sup>۱</sup> را پیشنهاد نموده‌اند. در این روش، داده‌ها با استفاده از تابع نگاشت غیرخطی به فضایی با ابعاد بالاتر با جدایی‌پذیری بیشتر نگاشت می‌شوند. سپس در این فضای جدید با استفاده از تکنیک نمایش تنک ویژگی‌های جدیدی برای ورود به طبقه‌بندی استخراج می‌گردد [۶۵]. در ادامه الگوریتم‌های دیگری نیز بمنظور بهبود دقت طبقه‌بندی SRC پیشنهاد شده که در بخش‌های بعدی تشریح شده است.

## ۲-۴-۳-۲- الگوریتم JSRC<sup>۲</sup>

در سال‌های ۲۰۱۱ و ۲۰۱۸ پژوهشگران به‌منظور بهبود دقت طبقه‌بندی مدل SRC، مدل نمایش تنک مشترک (JSRC) را با تلفیق اطلاعات مکانی در روش SRC پیشنهاد کردند. در این روش، اطلاعات مکانی به‌صورت مجموعه‌ای از پیکسل‌های همسایه برای پیکسل مرکزی در یک پنجره مربعی با اندازه ثابت تعریف می‌شود. فرض بر این است که پیکسل‌های مربوط به یک پنجره‌ی کوچک به احتمال زیاد متعلق به عناصر خالص مشابهی بوده و می‌توان با مجموعه یکسانی از اتم‌ها در یک دیکشنری، اما با مجموعه ضرایب مختلف آن‌ها را بازسازی نمود [۶۶، ۶۷]. از محدودیت‌های این روش، تصمیم‌گیری درباره اندازه‌ی پنجره بهینه برای صحنه‌های مختلف تصویربرداری است. به عنوان مثال، یک پنجره با اندازه‌ی کوچک برای پیکسل‌های نزدیک لبه مناسب بوده، درحالی‌که در نواحی یکنواخت، پنجره‌های بزرگ برای طبقه‌بندی دقیق ترجیح پذیر خواهد بود.

محققان در سال ۲۰۱۴ به‌منظور بهره‌مندی از مزایای اندازه‌های مختلف پنجره‌های مکانی برای طبقه‌بندی، مدل MASR<sup>۳</sup> را پیشنهاد کردند. در مقایسه با روش JSRC، این مدل بهبود آشکاری را از

<sup>۱</sup>Kernel Sparse Representation (KSR)

<sup>۲</sup>Joint Sparse Representation Classification (JSRC)

<sup>۳</sup>Multiscale Adaptive Sparse Representation (MASR)

لحاظ صحت طبقه‌بندی به دست آورد. با این حال، این روش به دلیل فرآیند چند مقیاسه بودن پنجره بسیار زمان‌بر بود [۶۸].

مشاهده می‌شود روش‌های مبتنی بر نمایش تنک برای طبقه‌بندی تصاویر ابرطیفی تنها نویز گوسین را در نظر می‌گیرند در صورتی که در کاربردهای واقعی تصاویر ابرطیفی به‌طور اجتناب‌ناپذیری به وسیله انواع مختلف نویز از جمله نویز گوسین و نویز پراکنده تخریب می‌شوند. این امر ناشی از شرایط تصویری ضعیف مانند بخار آب، اثرات جوی و... است [۶۹]. برای برطرف کردن این مشکل یک روش طبقه‌بندی کلی پیشنهاد شد که در آن علاوه بر نویز گوسین، اثرات نویز پراکنده نیز بر تصاویر ابرطیفی در نظر گرفته شده است. بدین منظور پژوهشگران در روشی نوین با ترکیب مدل‌های آماری مناسب برای نویز پراکنده، حضور نویز پراکنده را در مسأله طبقه‌بندی ادغام کردند. به دنبال این ایده روش‌های موجود SRC و JSRC به‌صورت نسخه‌های پایدارتر R-SRC<sup>۲</sup> و R-JSRC<sup>۳</sup> تعمیم داده شده که این مدل‌ها عملکرد بهتری نسبت به SRC و JSRC نشان می‌دهند. در این روش یک الگوریتم بهینه‌سازی برای تابع هدف متناظر با استفاده از استراتژی کمینه‌سازی متناوب پیشنهاد شده است [۴۸].

## ۲-۴-۳- الگوریتم KNN-SRC

روش دیگر برای مقابله با مسئله بار محاسباتی بالای روش‌های طبقه‌بندی مبتنی بر نمایش تنک، انتخاب تعدادی از اتم‌های دیکشنری اولیه (دیکشنری حاوی تمام داده‌های آموزشی)، به‌منظور محاسبه نمایش تنک است. هدف این روش‌ها انتخاب یک زیرمجموعه کوچک از داده‌های آموزشی است، مشروط به این که تأثیر منفی بر عملکرد طبقه‌بندی کننده نداشته باشد. در این دسته از روش‌ها اتم‌هایی از دیکشنری اولیه برحسب یک معیار از پیش تعیین شده انتخاب می‌شوند. به عبارتی با تعریف معیاری برای تنکی، اتم‌هایی از دیکشنری که قابلیت تشریح تنک‌تر سیگنال را برخوردارند انتخاب شده که منجر به بهبود دقت طبقه‌بندی

---

<sup>۱</sup>Sparse Noise

<sup>۲</sup>Robust SRC

<sup>۳</sup>Robust JSRC

شوند [۷۰]. یکی از این روش‌ها که اتم‌های انتخابی از دیکشنری اولیه را وارد فرآیند طبقه‌بندی می‌کند الگوریتم KNN-SRC می‌باشد.

مشابه با مراحل ذکر شده در الگوریتم KNN<sup>۱</sup> (در بخش مقدمه) در روش KNN-SRC با انتخاب  $K$  نزدیک‌ترین همسایه به داده آزمون ورودی و شرکت دادن تنها این داده‌های انتخابی در فرآیند طبقه‌بندی، حجم محاسبات به میزان قابل توجهی کاسته شده است [۷۱].

در این روش، ابتدا با استفاده از معیار فاصله اقلیدسی  $K$  نزدیک‌ترین همسایه به داده آزمون از میان تمامی داده‌های آموزشی انتخاب می‌شوند. سپس، داده آزمون به وسیله این  $K$  همسایه نزدیکش نمایش داده می‌شود. در نهایت، عمل طبقه‌بندی با محاسبه‌ی باقی‌مانده داده آزمون و مقادیر بازسازی شده آن به کمک نزدیک‌ترین همسایه‌های متعلق به هر کلاس، انجام می‌گیرد.

اگر  $K_i$  همسایه  $\vec{d}_{i,1}, \vec{d}_{i,2}, \dots, \vec{d}_{i,K_i}$  متعلق به کلاس  $i$  ام باشند؛ به طوری که  $K = \sum_{i=1}^{m_c} K_i$  بوده و  $n_c$  برابر تعداد کلاس‌ها باشد. چنانچه  $\vec{D}_i = [\vec{d}_{i,1}, \vec{d}_{i,2}, \dots, \vec{d}_{i,K_i}] \in R^{n \times K_i}$  ماتریس حاوی تمامی  $K$  نزدیک‌ترین همسایه باشد، از آنجا که  $K \ll m$  است، لذا ممکن است به ازای هیچ ضریب تنکی،  $s$  کاملاً با  $\vec{D}\alpha$  برابر نباشد. بنابراین از رابطه‌ی زیر برای محاسبه ضرایب نمایش تنک استفاده می‌شود:

$$\min_{\alpha} \|\alpha\|, \quad \text{subject to} \quad \|s - \vec{D}\alpha\| \leq \varepsilon \quad (2-29)$$

پس از تعیین نمایش تنک، با دنبال کردن روال معرفی شده در SRC، عمل طبقه‌بندی نهایی انجام می‌گیرد [۷۱].

در پژوهشی Song و همکاران برای استفاده کامل از اطلاعات مکانی غیرمحلی پیکسل‌های تصویر و بهبود عملکرد JSRC، روش جدید طبقه‌بندی تصاویر ابرطیفی با استفاده از JSRC مبتنی بر KNN را پیشنهاد کردند. در این روش با استفاده از تبدیل PCA ابعاد داده‌ی اولیه کاهش یافته و یک فضای ویژگی

---

<sup>۱</sup>K Nearest Neighborhood

بر اساس مؤلفه‌های اصلی تصویر و مختصات مکانی پیکسل‌ها تعریف می‌گردد. سپس در این فضای ویژگی، K نمونه از همسایه‌های هر پیکسل با روش جستجوی KNN شناسایی شده و از طریق نمایش تنک مشترک، تمامی K پیکسل برچسب‌دهی می‌شوند. از مزایای این روش عدم نیاز به تصمیم‌گیری درباره اندازه بهینه پنجره است [۷۲]. از محدودیت‌هایی این روش می‌توان به استفاده KNN از فاصله اقلیدسی به عنوان معیار شناسایی همسایگان و یکسان بودن وزن هر ویژگی اشاره داشت. چراکه ممکن است مقیاس و توزیع هر ویژگی متفاوت باشد.

## ۲-۵- جمع بندی

با توجه به محدودیت‌ها و مزایای روش‌های استخراج ویژگی مذکور در پژوهش‌های پیشین که بمنظور بهبود دقت طبقه‌بندی کننده‌ها به کار گرفته شده است. در این تحقیق رویکردی جدید به منظور تولید ویژگی‌های تفکیک‌پذیر برای ورود به الگوریتم طبقه‌بندی کننده KNN با هدف افزایش دقت طبقه‌بندی پیشنهاد شده است. به عبارت بهتر، ایده‌ی به‌کارگیری ویژگی‌های تولید شده توسط تخمین تنک، تبدیلات خطی و تبدیلات غیرخطی راهکار پیشنهاد شده در این پژوهش می‌باشد.

## فصل سوم

### روش تحقیق و پیاده سازی



### ۳-۱- مقدمه

در فصل پیش رو هدف ارائه‌ی الگوریتمی جهت تولید ویژگی‌هایی با تفکیک‌پذیری بالا از داده ابرطیفی با تلفیق روش‌های استخراج ویژگی NLPCA، LDA و تخمین تنک به‌منظور ورود به پروسه طبقه‌بندی جهت طبقه‌بندی پوشش‌های زمینی می‌باشد. در ادامه، ابتدا به معرفی داده‌ها و مناطق مورد مطالعه می‌پردازیم. سپس به مقایسه نتایج حاصل از الگوریتم پیشنهادی و پنج ترکیب ویژگی تولید شده به‌منظور طبقه‌بندی می‌پردازیم.

### ۳-۲- منطقه‌ی مورد مطالعه و داده‌های مورد استفاده


در این پژوهش از دو تصویر ابرطیفی مشهور به همراه نقشه‌ی واقعیت زمینی آن‌ها استفاده شده است. این تصاویر در تحقیقات گسترده‌ای به‌منظور ارزیابی روش‌های طبقه‌بندی استفاده شده‌اند. در ادامه هر یک از دو داده معرفی شده است.

#### • تصویر منطقه Indian Pines

تصویر Indian pines توسط سنجنده AVIRIS در سال ۱۹۹۲ از یک سایت آزمایشی در شمال غربی ایندیانا جمع‌آوری شده است (شکل ۳-۱). این تصویر از ۲۲۴ باند طیفی در محدوده‌ی طول موج ۰/۴ تا ۲/۵ میکرومتر با ابعاد ۱۴۵ × ۱۴۵ پیکسل و حد تفکیک مکانی ۲۰ متر تشکیل شده است. پوشش این منطقه شامل دو سوم محصولات کشاورزی و یک سوم جنگل یا سایر پوشش‌های گیاهی است. از آنجا که این عکس در ماه ژوئن گرفته شده، برخی از محصولات موجود مانند ذرت و سویا در مراحل اولیه‌ی رشد با پوشش کم‌تر از ۵٪ قرار داشته‌اند. با توجه به مقدار خاشاکی که از محصولات کاشته شده از سال‌های قبل بر روی زمین باقی مانده و به دلیل متفاوت بودن خاک موجود در سطح مناطقی که گیاهان یکسان دارند، نواحی منطقه مورد بررسی به سه دسته: ۱- ناحیه بدون شخم، ۲- ناحیه کم شخم و ۳- ناحیه با شخم کامل تقسیم

شده‌اند. با این شرایط، در این تصویر ۱۶ کلاس از انواع محصولات کشاورزی وجود دارد (جدول

۳-۱) [۷۳].



شکل ۳-۱- تصویر نمونه باند داده‌ی ایندیانا

جدول ۳-۱- نام و تعداد نمونه‌های آزمایشی و آزمون هر کلاس داده ایندیانا

کلاس	نام	آزمون	تست
۱	یونجه	۱۲	۳۴
۲	ذرت-بدون شخم	۳۵۷	۱۰۷۱
۳	ذرت-کم شخم	۲۰۸	۶۲۲
۴	ذرت	۵۹	۱۷۸
۵	سبزه-علفزار	۱۲۱	۳۶۲
۶	سبزه-درختان	۱۸۳	۵۴۷
۷	سبزه-علفزار-درو شده	۷	۲۱
۸	کاه و خاشاک	۱۲۰	۳۵۸
۹	جو دوسر	۵	۱۵
۱۰	سویا-بدون شخم	۲۴۳	۷۲۹
۱۱	سویا-کم شخم	۶۱۴	۱۸۴۱
۱۲	سویا-شخم کامل	۱۴۸	۴۴۵
۱۳	گندم	۵۱	۱۵۴
۱۴	جنگل	۳۱۶	۹۴۹
۱۵	ساختمان-سبزه-درخت	۹۷	۲۸۹
۱۶	سنگ-فولاد-برج	۲۳	۷۰

• تصویر دانشگاه Pavia

تصویر دانشگاه پاویا در سال ۲۰۰۱ توسط سنجنده نوری ROSIS از محوطه‌ی دانشگاه پاویا در ایتالیا اخذ شد (شکل ۳-۲). این تصویر حاوی ۱۱۵ باند طیفی در محدوده‌ی طول موج ۰/۴۳ تا ۰/۸۶ میکرومتر، ابعاد ۳۴۰ × ۶۱۰ پیکسل، توان تفکیک مکانی ۱/۳ متر و شامل ۹ کلاس است (جدول ۳-۲) [۷۴].



شکل ۳-۲- تصویر داده‌ی دانشگاه پاویا


جدول ۳-۲- نام و تعداد نمونه‌های آزمایشی و آزمون هر کلاس داده‌ی پاویا

کلاس	نام	آزمون	تست
۱	آسفالت	۶۶۳	۵۹۶۸
۲	چمن‌زار	۱۸۶۵	۱۶۷۸۴
۳	شن و سنگ‌ریزه	۲۱۰	۱۸۸۹
۴	درختان	۳۰۶	۲۷۵۸
۵	صفحات فلزی	۱۳۵	۱۲۱۰
۶	خاک ساده	۵۰۳	۴۵۲۶
۷	قیر	۱۳۳	۱۱۹۷
۸	آجر	۳۶۸	۳۳۱۴
۹	سایه	۹۵	۸۵۲

### ۳-۳- روش پیشنهادی

در این پژوهش راهکاری سه مرحله‌ای به منظور تولید ویژگی به تعداد کلاس‌های طبقه‌بندی ( $n_c$ ) پیشنهاد شده است. در ادامه، ویژگی‌های تولید شده به کمک طبقه‌بندی‌کننده‌ی KNN وزن‌دار برچسب‌دهی می‌شوند.

در این روند سه مرحله‌ای، ابتدا از تبدیل NLPCA به صورت نظارت شده به منظور انتقال باندهای طیفی به فضایی با ابعاد بالاتر استفاده شده است. این مرحله برای اولین بار در مورد این تبدیل بکارگرفته شده و تحلیل مؤلفه‌ی اصلی غیرخطی نظارت شده (SNLPCA) نام‌گذاری شده است. در مرحله‌ی دوم، ویژگی‌های تولیدی به کمک یک تبدیل ساده‌ی LDA به فضایی با بعد  $n_c - 1$  انتقال می‌یابد. در مرحله‌ی سوم، یک دیکشنری به کمک تمامی داده‌های آموزشی تولید و هر نمونه از ویژگی‌های به دست آمده از مرحله دوم به صورت تنک تخمین زده می‌شود. در ادامه، از بردار تخمین تنک هر نمونه، به تعداد کلاس‌های طبقه‌بندی ویژگی تولید می‌شود. سازوکار روش پیشنهادی در این پژوهش در فلوجارت شکل (۳-۳) ارائه شده است.




شکل ۳-۳- الگوریتم روش پیشنهادی

در ادامه، هر یک از بخش‌های مربوط به فلوچارت شکل (۳-۳) به تفصیل تشریح شده است.

### ۳-۳-۱- گام اول (پیش پردازش)

در این گام با حذف باندهای نویزی و جذب آب در داده ایندیانا باندها به ۲۰۰ و در داده پاویا به ۱۰۳ باند کاهش می‌یابد. سپس پیکسل‌های هر دو تصویر در بازه‌ی بین صفر و یک نرمال شده است. در نهایت در تصویر ایندیانا از هر کلاس ۲۵٪ نمونه‌ها به عنوان داده آموزشی و در تصویر پاویا از هر کلاس ۱۰٪ نمونه‌ها به عنوان داده‌ی آموزشی استفاده شده است.



شکل ۳-۴- روند پیش پردازش در الگوریتم پیشنهادی

### ۳-۳-۲- گام دوم (تولید ویژگی مبتنی بر NLPCA)

بعد از اعمال پیش‌پردازش‌های ذکر شده در گام اول، اولین اقدام به‌منظور تولید ویژگی، SNLPCA است. در این روند، تعداد  $n_c$  شبکه عصبی جهت آموزش یافتن به داده‌های آموزشی هر کلاس از طبقه‌بندی بکار گرفته می‌شود. برای این اقدام از جعبه ابزار NLPCA در محیط نرم‌افزار متلب استفاده شده است. معماری شبکه‌ی عصبی به نحوی طراحی شده که در مورد داده‌های آموزشی بیشترین انطباق سراسری تأمین گردد. لازم به ذکر است که آموزش شبکه‌ی عصبی از طریق روش پس‌انتشارخطا و مبتنی بر تکنیک گرادیان نزولی انجام می‌شود [۷۵]. بعد از آموزش یافتن شبکه‌های عصبی، پاسخ تمامی پیکسل‌های تصویر ابرطیفی مربوط به لایه‌ی مؤلفه‌های اصلی (T در شکل ۲-۸) از تمامی شبکه‌های عصبی آموزش یافته، به عنوان ویژگی‌های این مرحله تولید می‌گردد. در این تحقیق ابعاد مؤلفه‌های اصلی مستخرج از شبکه‌های عصبی ثابت و معادل ۲۰ مؤلفه‌ی اصلی انتخاب شده است. بر این اساس، انتظار می‌رود که ویژگی‌های تولید شده در این مرحله معادل  $20 \times n_c$  باشد. محتمل است که در این روند با افزایش تعداد کلاس‌های طبقه‌بندی بعد فضای ویژگی تولید شده بیشتر از بعد داده‌های خام ورودی باشد. هرچند که در صورت وجود کلاس‌های محدود در طبقه‌بندی و یا بکارگیری تعداد کمتری از مؤلفه‌های اصلی در معماری شبکه‌ی عصبی، ممکن

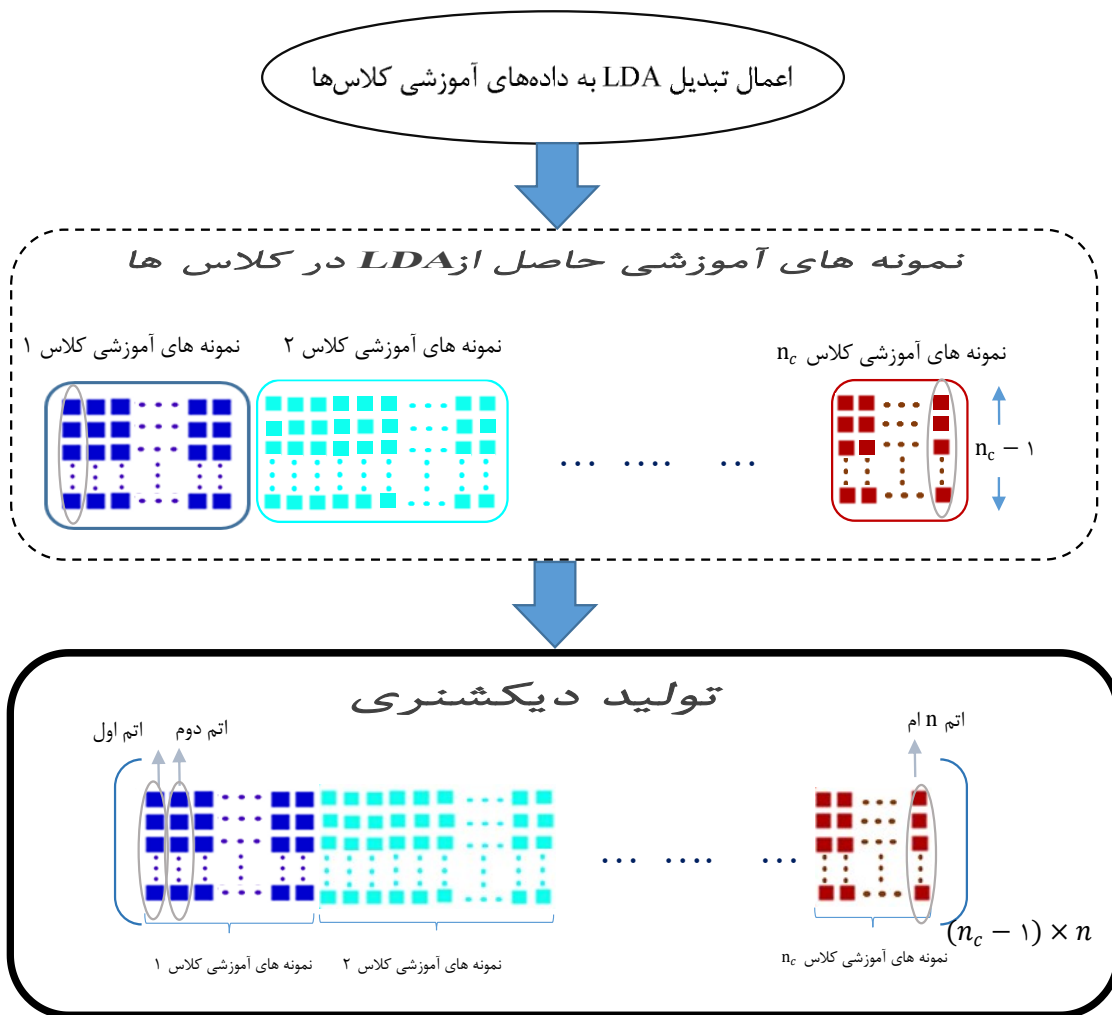
است این انتقال غیرخطی منجر به تولید فضایی با بعدی بالاتر از تعداد باندهای طیفی نگردد. ایده‌ی اصلی چنین اقدامی، احتمال پاسخ متفاوت نمونه‌های مربوط به یک کلاس در هنگام استفاده از شبکه‌ی عصبی آموزش یافته برای کلاسی دیگر می‌باشد. ضمن اینکه با چنین اقدامی، به کمک یک تبدیل غیرخطی (مشابه با کرنل‌های غیرخطی) فضای جدیدی برای بازنمایی داده‌های خام ایجاد می‌گردد.

### ۳-۳-۳- گام سوم (کاهش بعد به روش LDA)

به دلیل وجود مشکلات فضاهای ویژگی با ابعاد بالا، در این مرحله از روش پیشنهادی، کاهش بعد نظارت شده به کمک روش خطی LDA انتخاب شده است. این تبدیل تلاش می‌کند تا به کمک آماره‌هایی همچون ماتریس کوواریانس داخل کلاسی ( $S_w$ ) و بین کلاسی ( $S_b$ )، راستاهایی را به منظور تصویرکردن نمونه‌های فضای ورودی به فضایی با بیشترین تفکیک‌پذیری خطی بیابد. بدیهی است که داده‌های آموزشی مورد نیاز در تبدیل LDA نیز از خلال عبور نمونه‌های آموزشی در فضای باندهای طیفی از لایه‌ی نگاشت (Mapping) شبکه‌های عصبی مصنوعی (به ازای همه‌ی کلاس‌ها) ایجاد می‌گردند (شکل (۲-۸)). لازم به ذکر است که در شرایطی که رنک ماتریس  $S_w$  کمتر از بعد مورد انتظار باشد، از روش شبه معکوس گیری جهت تولید ماتریس معکوس استفاده شده است.

### ۳-۳-۴- گام چهارم (تولید ویژگی به کمک تخمین تنک)

در گام چهارم، به کمک موقعیت نمونه‌های آموزشی و ویژگی‌های تولید شده از تبدیل LDA، یک دیکشنری از رفتار کلاس‌های طبقه‌بندی تولید می‌گردد. اتم‌های دیکشنری شامل تمامی نمونه‌های آموزشی بوده که به صورت منظم و به تفکیک کلاس، ستون‌های ماتریس دیکشنری را تولید می‌کنند (شکل (۳-۵)).



شکل ۳-۵- تولید ماتریس دیکشنری

با در نظر گرفتن  $n$  به عنوان مجموع تمامی داده‌های آموزشی و  $b = n_c - 1$  به عنوان بعد اتم‌های دیکشنری (به دست آمده از تبدیل LDA)، ابعاد ماتریس دیکشنری  $b \times n$  خواهد بود. بدیهی است که در چنین شرایطی  $b \gg n$  است.

هر درایه از بردار  $\alpha$  متناظر با یک اتم از دیکشنری است (رابطه‌ی ۲-۱۶). متناسب با نحوه‌ی چیدمان داده‌های آموزشی در ماتریس دیکشنری (شکل ۳-۵)، می‌توان درایه‌های متناظر از بردار  $\alpha$  مربوط به داده‌های آموزشی هر کلاس را شناسایی کرد. بعد از به‌کارگیری تکنیک OMP به‌منظور تخمین تنک هر



پیکسل، در صورتیکه درایه‌های متناظر با هر کلاس از بردار  $\alpha$  مقداردهی شوند؛ ماکزیمم مقادیر درایه‌های مربوط به هر کلاس به عنوان ویژگی مربوط به آن کلاس تولید می‌گردد.

به عبارت بهتر، تعداد ویژگی‌های مستخرج از روش تخمین تنک برابر با تعداد کلاس‌های طبقه‌بندی است. هر ویژگی متناظر با یک کلاس از طبقه‌بندی بوده که مقادیر ثبت شده در آن، بیشینه درایه‌های مرتبط با آن کلاس از بردار تنک  $\alpha$  می‌باشد. بدیهی است که در صورت عدم انتخاب هیچ کدام از داده‌های آموزشی یک کلاس در روند تخمین تنک، مقدار صفر در ویژگی متناظر با آن کلاس برای آن پیکسل ثبت خواهد شد.

لحاظ کردن قرابت مکانی برچسب پیکسل‌ها در تصاویر ابرطیفی از جمله مواردی است که در تحقیقات گذشته به عنوان راهکار بهبود دقت نتایج طبقه‌بندی معرفی شده است. در مرحله سوم از روش پیشنهادی، با اعمال یک فیلتر میانگین در فضای مکان به ویژگی‌های مستخرج از مرحله دوم (تبدیل LDA) تلاش شده تا اثر پیکسل‌های همسایه در روند برچسب‌دهی هر پیکسل لحاظ شده و به نحوی نویزهای ناخواسته در داده‌ها کاهش یابد.

### ۳-۳-۵- گام پنجم (طبقه‌بندی کننده KNN وزن دار)

پس از کاهش بعد فضای تصاویر توسط تلفیق روش‌های استخراج ویژگی نوبت به انتخاب طبقه‌بندی کننده و انجام طبقه‌بندی بر روی ویژگی‌های استخراج شده می‌رسد. در حالت کلی اگر مراحل کاهش بعد به واسطه تلفیق روش‌های استخراج ویژگی با موفقیت انجام شود، کلاس‌ها در این فضای ویژگی جدید تفکیک پذیری بالایی داشته و با استفاده از یک طبقه‌بندی کننده با پیچیدگی کم دقت طبقه‌بندی خوبی حاصل می‌شود.

با توجه به تولید ویژگی‌های مبتنی بر کدگذاری تنک، انتظار می‌رود که در تصویر ویژگی‌های مرتبط با هر کلاس، یک کلاس با پاسخ بزرگ‌تری از سایر کلاس‌ها ظاهر گردد. از سوی دیگر، بردار تخمین تنک مربوط به داده‌های آموزشی هر کلاس نیز صرفاً یک درایه‌ی غیرصفر متناظر با محل قرارگیری اتم متناظرش

در دیکشنری خواهد داشت. در چنین شرایطی، مسئله‌ی برچسب‌دهی برای بخش زیادی از پیکسل‌ها محدود به یافتن نزدیک‌ترین همسایه از داده‌های آموزشی خواهد بود. با این حال بخشی از پیکسل‌ها به دلیل وجود نویز، سهم حضور اندک از کلاس‌های طبقه‌بندی و شباهت احتمالی بالا با سایر کلاس‌ها، برچسب صحیحی از طریق نزدیک‌ترین همسایه نمی‌یابند. به همین دلیل، الگوریتم طبقه‌بندی KNN وزن‌دار به عنوان طبقه‌بندی کننده انتخاب شده است. در این الگوریتم، تعداد K نزدیک‌ترین همسایه از داده‌های آموزشی با کمترین فاصله اقلیدسی ( $dist$ ) برای هر پیکسل در فضای ویژگی شناسایی می‌شوند. طبق رابطه‌ی (۱-۳) معکوس فاصله میان آن پیکسل و همسایگان یافت شده به عنوان وزن در نظر گرفته می‌شود.

$$w_i = \frac{1}{(dist)_i} \quad (i = 1, 2, \dots, K) \quad (1-3)$$

وزن کلاس‌های مشابه جمع شده و نهایتاً برچسب کلاسی که بیشترین وزن تجمعی را کسب کرده باشد به آن پیکسل اختصاص می‌یابد.

### ۳-۳-۶- گام ششم (پس پردازش)

آخرین گام همانند تمام روش‌های طبقه‌بندی، استفاده از پس‌پردازش‌های رایجی همچون فیلتر اکثریت به منظور کاهش نویز در نتایج خواهد بود. در این گام کلاس غالب در یک پنجره  $3 \times 3$  به عنوان برچسب پیکسل مرکزی در نظر گرفته می‌شود که می‌تواند بهبود جزئی بر روی دقت نهایی داشته باشد.


به منظور ارزیابی و مقایسه‌ی نتایج در این تحقیق، از پنج ترکیب مختلف (به غیر از ترکیب پیشنهاد شده در این پژوهش) از ویژگی‌های تولید شده در این پژوهش به عنوان ورودی فرایند طبقه‌بندی استفاده شده است. به عبارت بهتر، به غیر از ترکیب پیشنهاد شده، از: ۱- باندهای طیفی به‌طور مستقیم، ۲- ویژگی‌های مستخرج از اعمال تبدیل LDA به باندهای طیفی، ۳- ویژگی‌های مستخرج از روند نظارت شده‌ی NLPCA، ۴- ویژگی‌های مستخرج از اعمال تبدیل LDA به مؤلفه‌های اصلی به دست آمده از

تبدیل SNLPCA و ۵- به کارگیری مستقیم روش استخراج ویژگی به کمک کدگذاری تنک، به عنوان ورودی‌های طبقه‌بندی استفاده شده که نتایج هر یک در فصل بعد، ارائه و مورد بحث قرار گرفته است.


## فصل چهارم

### بررسی نتایج حاصل از پیاده سازی

برای ارزیابی کارایی الگوریتم پیشنهادی در این تحقیق، از دو داده‌ی واقعی ایندیانا و پاویا (معرفی شده در بخش ۳-۲) استفاده شده است. برای این هدف، طبقه‌بندی KNN وزن‌دار علاوه بر داده خام در پنج سری ویژگی استخراج شده از داده‌های مذکور پیاده‌سازی شده است. شکل ۴-۱ و ۴-۲ نقشه‌ی طبقه بندی به دست آمده از باندهای طیفی و ویژگی‌های استخراج شده از آن به همراه نقشه‌ی واقعیت زمینی را در دو مجموعه داده نشان می‌دهد.



شکل ۴-۱- نتایج طبقه‌بندی داده‌های دانشگاه Pavia؛ (الف) داده خام، (ب) LDA، (ج) SNLPCA، (د) SRC، (ه) SNLPCA+LDA، (و) نقشه واقعیت زمینی، (ز) الگوریتم پیشنهادی.



(ج)

(ب)


(الف)



(د)

(ه)

(و)



(و)

شکل ۴-۲- نتایج طبقه‌بندی داده‌های Indiana Pine. (الف) داده خام، (ب) LDA، (ج) SNLPCA، (د) SRC، (ه) SNLPCA+LDA.

(و) نقشه واقعیت زمینی. (ی) الگوریتم پیشنهادی.

مقایسه‌ی بصری نتایج در شکل ۴-۱ و ۴-۲ نشان دهنده‌ی بهبود نتیجه‌ی طبقه‌بندی روش پیشنهادی در مقایسه با روش‌های دیگر استخراج ویژگی می‌باشد. در این بین استخراج ویژگی به صورت نظارت‌شده در روش NLPCA، طبقه‌بندی ضعیف‌تری را تولید کرده است. در ادامه، به منظور ارزیابی و مقایسه کمی نتایج، از پارامترهای آماری دقت کاربر<sup>۱</sup>، دقت کلی<sup>۲</sup> و ضریب کاپا<sup>۳</sup> استفاده شده است.

بنابر تعاریف دقت کاربر بیانگر دقت طبقه‌بندی برای کلاس‌های مختلف است. دقت کلی میانگینی از دقت طبقه‌بندی بوده و نسبت پیکسل‌های صحیح طبقه‌بندی شده به جمع کل پیکسل‌های معلوم رانشان می‌دهد و ضریب کاپا مقدار دقت یک طبقه‌بندی را نسبت به حالتی که یک تصویر کاملاً به صورت تصادفی طبقه‌بندی شود را به دست می‌آورد [۷۶].

جداول ۴-۱ و ۴-۲ بیانگر این پارامترها در تصاویر ایندیانا و پابویا می‌باشند.

---

<sup>۱</sup> Producers Accuracy

<sup>۲</sup> Overall Accuracy

<sup>۳</sup> Kappa Coefficient

جدول ۴-۱- نتایج طبقه‌بندی تصویرپایا حاصل از روش‌های تولید ویژگی

روش پیشنهادی	SNLPCA +LDA	SPARSE	SNLPCA	LDA	داده خام	کلاس
۹۸/۷۶	۹۶/۹۸	۹۲/۹۴	۹۶/۷۹	۹۸/۸۱	۹۶/۵۰	۱
۹۹/۷۴	۹۹/۷۶	۹۹/۵۹	۹۹/۵۴	۹۹/۷۳	۹۹/۶۸	۲
۹۴/۹۵	۸۹/۷۶	۷۸/۴۷	۷۹/۲۸	۷۹/۷۵	۸۶/۴۷	۳
۹۶/۹۰	۹۶/۵۴	۸۹/۵۹	۸۳/۸۱	۹۲/۴۹	۸۷/۵۰	۴
۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۵
۸۹/۷۴	۷۳/۲۶	۶۳/۷۳	۴۱/۳۸	۸۳/۸۳	۵۶/۹۷	۶
۹۷/۴۴	۹۲/۶۳	۹۱/۲۰	۸۹/۶۲	۸۳/۱۶	۹۲/۹۳	۷
۹۶/۴۴	۹۰/۸۷	۹۲/۳۱	۹۰/۳۶	۹۳/۸۶	۹۲/۷۸	۸
۹۹/۸۹	۹۹/۸۹	۹۹/۸۹	۹۹/۸۹	۹۹/۵۸	۹۹/۸۹	۹
۹۷/۶۳	۹۴/۵۲	۹۱/۷۲	۸۹/۰۸	۹۵/۲۱	۹۱/۸۶	OA
۹۶/۸۴	۹۲/۶۳	۸۸/۸۱	۸۵/۰۲	۹۳/۵۷	۸۸/۹۳	Kappa

جدول ۴-۲- نتایج طبقه‌بندی تصویر ایندیانا حاصل از روش‌های تولید ویژگی

روش پیشنهادی	SNLPCA +LDA	SPARSE	SNLPCA	LDA	داده خام	کلاس
۱۰۰	۱۰۰	۸۶/۹۶	۳۰/۴۳	۸۹/۱۳	۴۷/۸۳	۱
۹۸/۴۶	۹۳/۹۱	۸۹/۳۶	۸۳/۲۶	۹۳/۹۸	۸۷/۱۱	۲
۹۹/۰۴	۹۰/۱۲	۸۷/۷۱	۸۰/۳۶	۸۷/۸۳	۸۵/۰۶	۳
۹۸/۳۱	۹۰/۳	۷۴/۲۶	۶۷/۰۹	۸۴/۸۱	۷۴/۲۶	۴
۹۹/۷۹	۹۸/۵۵	۹۴/۸۲	۹۵/۲۴	۹۸/۱۴	۹۶/۰۷	۵
۹۹/۸۶	۹۹/۷۳	۹۹/۷۳	۱۰۰	۹۹/۸۶	۱۰۰	۶
۱۰۰	۱۰۰	۱۰۰	۹۶/۴۳	۹۶/۴۳	۹۶/۴۳	۷
۱۰۰	۱۰۰	۹۹/۷۹	۱۰۰	۱۰۰	۱۰۰	۸
۱۰۰	۸۰/۰۰	۵۰/۰۰	۲۵/۰۰	۴۵/۰۰	۳۵/۰۰	۹
۹۸/۳۵	۹۰/۹۵	۹۲/۷۰	۹۱/۵۶	۹۱/۹۸	۹۲/۸۰	۱۰
۹۹/۲۳	۹۸/۱۷	۹۴/۶۲	۹۲/۷۵	۹۵/۸۹	۹۵/۰۷	۱۱
۹۹/۸۳	۹۶/۶۳	۸۱/۱۱	۶۲/۳۹	۹۶/۲۹	۷۶/۰۵	۱۲
۱۰۰	۱۰۰	۹۵/۶۱	۹۷/۰۷	۱۰۰	۹۹/۰۲	۱۳
۱۰۰	۹۹/۹۲	۹۹/۱۳	۹۹/۱۳	۹۹/۹۲	۹۹/۷۶	۱۴
۹۲/۲۳	۷۹/۰۲	۷۷/۹۸	۳۸/۶۰	۷۵/۳۹	۴۷/۶۷	۱۵
۹۸/۹۲	۹۸/۹۲	۹۸/۹۲	۱۰۰	۹۸/۹۲	۹۷/۸۵	۱۶
۹۹/۰۰	۹۵/۷	۹۲/۳۹	۸۷/۴۳	۹۴/۶۵	۹۰/۵۶	OA
۹۸/۸۵	۹۵/۰۸	۹۱/۳۰	۸۵/۵۹	۹۳/۸۹	۸۹/۱۸	Kappa




مطابق با موارد ذکر شده در بخش ۲-۳، در تصویر ایندیانا به دلیل باقی ماندن خاشاک گیاهان کاشته شده در سال‌های قبل، ناهنجاری‌های طیفی اندکی در مزارع با کشت مشابه ثبت شده است. این موضوع در برخی از زمین‌های کشاورزی باعث کاهش دقت طبقه‌بندی شده است. با این حال به‌کارگیری ویژگی‌های پیشنهاد شده در این پژوهش حتی در این موارد نیز توانسته در مقایسه با سایر ترکیبات ویژگی، دقت‌های بهتری را در نتایج طبقه‌بندی کسب نماید. از سوی دیگر، روش پیشنهادی توانسته دقت‌های حداکثری برای کلاس‌های با داده‌ی آموزشی کم (کلاس‌های ۱ و ۹ از داده‌ی ایندیانا) تولید نماید. این در حالیست که همین موارد، دقت‌های بسیار پایین‌تری را هنگام به‌کارگیری باندهای طیفی و سایر ترکیبات مربوط به ویژگی‌های تولیدی، کسب کرده‌اند.

از سوی دیگر، علیرغم به‌کارگیری فیلتر میانگین با ابعاد پنجره‌ی  $3 \times 3$  در زمان تولید ویژگی در روش تخمین تنک، کماکان دقت بالایی در برچسب دهی نمونه‌های واقع در لبه‌ی کلاس‌ها در این روش پیشنهادی مشاهده می‌شود. به عبارت بهتر، اعمال فیلتر میانگین با هدف مشارکت مکانی پیکسل‌ها در برچسب‌دهی نتوانسته در مناطق مرزی کلاس‌ها خللی ایجاد کند و ویژگی‌های تولید شده کماکان برای برچسب‌دهی در مناطق مرزی مناسب بودند.


از دیگر نتایج قابل استنباط از جدول (۴-۱) و (۴-۲)، دقت اندک استفاده از ویژگی‌های SNLPCA در نتایج طبقه‌بندی است. به نظر می‌رسد بعد بالای فضای ویژگی تولید شده توسط این تبدیل و احتمال هم‌مقیاس نبودن تمامی ویژگی‌های تولیدی دلایل عدم کفایت استفاده مستقیم از تبدیل SNLPCA باشد. این ویژگی‌ها در بیشتر موارد دقت‌های پایین‌تری را نسبت به باندهای طیفی داشتند. با اینحال زمانیکه ویژگی‌های SNLPCA به کمک تبدیلات خطی، کاهش بعد می‌یابند، تفکیک‌پذیری بهتری را نسبت به داده‌های خام (باندهای طیفی) از خود نشان می‌دهند. به‌طور متوسط دقت کلی در زمان استفاده از روش SNLPCA+LDA در مقایسه با LDA بهبود ۴ درصدی را در مورد دو داده‌ی این تحقیق نشان می‌دهد.

نتایج مشابه کسب شده از پیاده‌سازی روش پیشنهادی در داده‌های دانشگاه پاولیا نیز مؤید تعمیم‌پذیر بودن این راهکار می‌باشد. به عبارت بهتر، راهکار پیشنهادی نسبت به تمایز در محتوای تصویری، تعداد باندهای طیفی و همچنین بازه‌ی طیفی سیستم تصویربرداری، رفتار پایداری را از خود نشان داده است.

با مقایسه نتایج کمی حاصل از داده پاولیا و ایندیانا مشاهده می‌شود که در روش پیشنهادی به‌طور میانگین بهبود ۶/۰۱ درصدی نسبت به سایر روش‌های استفاده از ویژگی‌ها و باندهای طیفی حاصل شده است. شکل ۳-۴ و ۴-۴ در صفحه بعد نمودار مقایسه دقت روش‌ها را در هر یک از دو داده نشان می‌دهد. این نتایج بیانگر آن است که علاوه بر اینکه ویژگی‌های حاصل از هر یک از روش‌های استخراج ویژگی در طبقه‌بندی سودمند می‌باشد. روش پیشنهادی که ترکیبی از روش‌های ذکر شده می‌باشد دقت طبقه‌بندی را به مقدار مؤثرتری بهبود می‌بخشد.



شکل ۳-۴- مقایسه دقت طبقه‌بندی روش‌های استخراج ویژگی در داده ایندیانا



شکل ۴-۴- مقایسه دقت طبقه‌بندی روش‌های استخراج ویژگی در داده پایوا

## فصل پنجم

### نتیجه گیری و پیشنهادات

در این پژوهش، روشی تلفیقی به منظور تولید ویژگی از تصاویر ابرطیفی پیشنهاد شد. در این روش نظارت شده، از تبدیلات خطی (LDA)، غیرخطی (SNLPCA) و تخمین تنک استفاده گردید. ویژگی‌های نهایی در این روش به تعداد کلاس‌های طبقه‌بندی بود. آزمون‌های مختلفی به منظور ارزیابی کفایت این ترکیب پیشنهادی صورت گرفت. با در نظر گرفتن باندهای طیفی و همچنین سه روش LDA، SNLPCA و تخمین تنک، ۵ ترکیب از ویژگی به غیر از روش پیشنهادی به منظور طبقه‌بندی استفاده شد. نتایج ارزیابی نشان داد که روش پیشنهادی از توان تأمین دقت‌های بالاتری در نتایج طبقه‌بندی برخوردار است. از دیگر نتایج قابل توجه، کسب دقت‌های بسیار خوب در مورد کلاس‌هایی است که تعداد داده‌های آموزشی اندکی از آن‌ها در روند تولید ویژگی حضور دارند. این در حالی است که باندهای طیفی و همچنین اکثر ویژگی‌های مقایسه‌ای، توان تولید نتایج دقیق را در چنین کلاس‌هایی برخوردار نبودند. پیشنهاداتی همچون: ۱- بررسی اثر تغییر تعداد مؤلفه‌های اصلی تبدیل SNLPCA در نتایج، ۲- به کارگیری قرابت مکانی پیکسل‌های مجهول به مکان داده‌های آموزشی در روند تخمین تنک سیگنال‌ها، ۳- بهبود راستای اتم‌های موجود در ماتریس دیکشنری به کمک تکنیک‌های آموزش دیکشنری مثل KSVD، ۴- به کارگیری روش‌های پایدار مبتنی بر تولید نمونه‌های تقویتی در محاسبه‌ی ماتریس کوواریانس داخل کلاسی و بین کلاسی تبدیل LDA، در زمان وجود بعد بالای فضای ویژگی به منظور بهبود عملکرد این تبدیل و ۵- خوشه‌بندی فضای ویژگی و تولید ویژگی‌های تفکیک‌پذیر هر کلاس در هر خوشه از مواردی بشمار رفته که در ادامه‌ی این تحقیق در دستور کار نویسندگان این پژوهش قرار دارد.

- [1] Cracknell, A. P., Varotsos, C. A., & Timofeyev, Y. M. (2014). Remote sensing of atmospheric radiation and dynamics. *International Journal of Remote Sensing*, 35(15), 5563-5565.
- [2] Wilder, K. E. (2009). Photography and science.
- [3] Ryznar, R. M., & Wagner, T. W. (2001). Using remotely sensed imagery to detect urban change: Viewing Detroit from space. *Journal of the American Planning Association*, 67(3), 327-336.
- [4] Verhoeven, G. J. (2009). Providing an archaeological bird's-eye view—an overall picture of ground-based means to execute low-altitude aerial photography (LAAP) in Archaeology. *Archaeological Prospection*, 16(4), 233-249.
- [5] Williams, D. A. (2016). NASA's planetary geologic mapping program: overview. *Commission IV, ISPRS, WG IV/8 doi*, 10.
- [6] Klemas, V., Bartlett, D., Philpot, W., Rogers, R., & Reed, L. (1974). Coastal and estuarine studies with ERTS-1 and Skylab. *Remote Sensing of Environment*, 3(3), 153-174.
- [7] Simin, C., Rongqun, Z., Wenling, C., & Hui, Y. (2009). Band selection of hyperspectral images based on Bhattacharyya distance. *WSEAS Trans Inf Sci Appl*, 6(7), 1165-1175.
- [8] Sun, D.-W. (2010). *Hyperspectral imaging for food quality analysis and control*: Elsevier.
- [9] Medjahed, S. A., Saadi, T. A., Benyettou, A., & Ouali, M. (2016). Gray wolf optimizer for hyperspectral band selection. *Applied Soft Computing*, 40, 178-186.
- [10] Manolakis, D., & Shaw, G. (2002). Detection algorithms for hyperspectral imaging applications. *IEEE signal processing magazine*, 19(1), 29-43.
- [11] Stein, D. W., Beaven, S. G., Hoff, L. E., Winter, E. M., Schaum, A. P., & Stocker, A. D. (2002). Anomaly detection from hyperspectral imagery. *IEEE signal processing magazine*, 19(1), 58-69.
- [12] Eismann, M. T., Stocker, A. D., & Nasrabadi, N. M. (2009). Automated hyperspectral cueing for civilian search and rescue. *Proceedings of the IEEE*, 97(6), 1031-1055.
- [13] Mahmood, A., Robin, A., & Sears, M. (2016). Modified residual method for the estimation of noise in hyperspectral images. *IEEE transactions on geoscience and remote sensing*, 55(3), 1451-1460.
- [14] Liu, R., & Gillies, D. F. (2016). Overfitting in linear feature extraction for classification of high-dimensional image data. *Pattern Recognition*, 53, 73-86.
- [15] Ghaddar, B., & Naoum-Sawaya, J. (2018). High dimensional data classification and feature selection using support vector machines. *European Journal of Operational Research*, 265(3), 993-1004.
- [16] Li, H., Ye, Z., & Xiao, G. (2014). Hyperspectral image classification using spectral-spatial composite kernels discriminant analysis. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8(6), 2341-2350.
- [17] Jay, S., & Guillaume, M. (2014). A novel maximum likelihood based method for mapping depth and water quality from hyperspectral remote-sensing data. *Remote Sensing of Environment*, 147, 121-132.
- [18] Burba, F., Ferraty, F., & Vieu, P. (2009). k-Nearest Neighbour method in functional nonparametric regression. *Journal of Nonparametric Statistics*, 21(4), 453-469.

- [19] Altman, N. S. (1992). An introduction to kernel and nearest-neighbor nonparametric regression. *The American Statistician*, 46(3), 175-185.
- [20] Weinberger, K. Q., Blitzer, J., & Saul, L. K. (2006). *Distance metric learning for large margin nearest neighbor classification*. Paper presented at the Advances in neural information processing systems.
- [21] Guo, Y., Cao, H., Han, S., Sun, Y., & Bai, Y. (2018). Spectral-spatial hyperspectral image classification with k-nearest neighbor and guided filter. *IEEE Access*, 6, 18582-18591.
- [22] Moser, G., & Serpico, S. B. (2012). Combining support vector machines and Markov random fields in an integrated framework for contextual image classification. *IEEE transactions on geoscience and remote sensing*, 51(5), 2734-2752.
- [23] Demir, B., & Erturk, S. (2009). Clustering-based extraction of border training patterns for accurate SVM classification of hyperspectral images. *IEEE Geoscience and Remote Sensing Letters*, 6(4), 840-844.
- [24] Samadzadegan, F., Hasani, H., & Schenk, T. (2012). Simultaneous feature selection and SVM parameter determination in classification of hyperspectral imagery using ant colony optimization. *Canadian Journal of Remote Sensing*, 38(2), 139-156.
- [25] Van Der Maaten, L., Postma, E., & Van den Herik, J. (2009). Dimensionality reduction: a comparative. *J Mach Learn Res*, 10(66-71), 13.
- [26] Fodor, I. K. (2002). *A survey of dimension reduction techniques*. Retrieved from
- [27] Verleysen, M., & François, D. (2005). *The curse of dimensionality in data mining and time series prediction*. Paper presented at the International Work-Conference on Artificial Neural Networks.
- [28] Li, S., Wu, H., Wan, D., & Zhu, J. (2011). An effective feature selection method for hyperspectral image classification based on genetic algorithm and support vector machine. *Knowledge-Based Systems*, 24(1), 40-48.
- [29] Kang, X., Li, S., & Benediktsson, J. A. (2013). Feature extraction of hyperspectral images with image fusion and recursive filtering. *IEEE transactions on geoscience and remote sensing*, 52(6), 3742-3752.
- [30] Kamandar, M., & Ghassemian, H. (2012). Linear feature extraction for hyperspectral images based on information theoretic learning. *IEEE Geoscience and Remote Sensing Letters*, 10(4), 702-706.
- [31] Licciardi, G., Marpu, P. R., Chanussot, J., & Benediktsson, J. A. (2011). Linear versus nonlinear PCA for the classification of hyperspectral data based on the extended morphological profiles. *IEEE Geoscience and Remote Sensing Letters*, 9(3), 447-451.
- [32] Chen, H., Zhao, H., Shen, J., Zhou, R., & Zhou, Q. (2015). *Supervised machine learning model for high dimensional gene data in colon cancer detection*. Paper presented at the 2015 IEEE International Congress on Big Data.
- [33] Licciardi, G., Del Frate, F., & Duca, R. (2009). *Feature reduction of hyperspectral data using autoassociative neural networks algorithms*. Paper presented at the 2009 IEEE International Geoscience and Remote Sensing Symposium.
- [34] Shah, F. P., & Patel, V. (2016). *A review on feature selection and feature extraction for text classification*. Paper presented at the 2016 International Conference on Wireless Communications, Signal Processing and Networking (WiSPNET).
- [35] Timotius, I. K., Setyawan, I., & Febrianto, A. A. (2010). Face recognition between two person using kernel principal component analysis and support vector machines. *International Journal on Electrical Engineering and Informatics*, 2(1), 55-63.
- [36] Gottumukkal, R., & Asari, V. K. (2004). An improved face recognition technique based on modular PCA approach. *Pattern Recognition Letters*, 25(4), 429-436.

- [37] Bishop, C. M. (2006). *Pattern recognition and machine learning*: springer.
- [38] Wang, Q., Meng, Z., & Li, X. (2017). Locality adaptive discriminant analysis for spectral–spatial classification of hyperspectral images. *IEEE Geoscience and Remote Sensing Letters*, 14(11), 2077-2081.
- [39] Kwon, H., & Nasrabadi, N. M. (2005). Kernel RX-algorithm: A nonlinear anomaly detector for hyperspectral imagery. *IEEE transactions on geoscience and remote sensing*, 43(2), 388-397.
- [40] Vinay, A., Shekhar, V. S., Murthy, K. B., & Natarajan, S. (2015). Face recognition using gabor wavelet features with PCA and KPCA-a comparative study. *Procedia Computer Science*, 57, 650-659.
- [41] Kramer, M. A. (1991). Nonlinear principal component analysis using autoassociative neural networks. *AIChE journal*, 37(2), 233-243.
- [42] Licciardi, G., & Chanussot, J. (2018). Spectral transformation based on nonlinear principal component analysis for dimensionality reduction of hyperspectral images. *European Journal of Remote Sensing*, 51(1), 375-390.
- [43] Elad, M., Figueiredo, M. A., & Ma, Y. (2010). On the role of sparse and redundant representations in image processing. *Proceedings of the IEEE*, 98(6), 972-982.
- [44] Baraniuk, R. (2007). A lecture on compressive sensing [J]. *IEEE signal processing magazine*, 24(4), 118-121.
- [45] Mairal, J., Bach, F., Ponce, J., & Sapiro, G. (2010). Online learning for matrix factorization and sparse coding. *Journal of Machine Learning Research*, 11(Jan), 19-60.
- [46] Tomic, I., & Frossard, P. (2011). Dictionary learning: What is the right representation for my signal? *IEEE signal processing magazine*, 28(ARTICLE), 27-38.
- [47] Ramchandran, K., Vetterli, M., & Herley, C. (1996). Wavelets, subband coding, and best bases. *Proceedings of the IEEE*, 84(4), 541-560.
- [48] Huang, S., Zhang, H., & Pižurica, A. (2017). A robust sparse representation model for hyperspectral image classification. *Sensors*, 17(9), 2087.
- [49] Mallat, S. G., & Zhang, Z. (1993). Matching pursuits with time-frequency dictionaries. *IEEE Transactions on signal processing*, 41(12), 3397-3415.
- [50] Baraniuk, R., Cevher, V., & Wakin, M. B. (2010). Low-dimensional models for dimensionality reduction and signal recovery: A geometric perspective. *Proceedings of the IEEE*, 98(ARTICLE), 959-971.
- [51] Candes, E., & Romberg, J. (2007). Sparsity and incoherence in compressive sampling. *Inverse problems*, 23(3), 969.
- [52] Tsaig, Y., & Donoho, D. L. (2006). Extensions of compressed sensing. *Signal processing*, 86(3), 549-571.
- [53] Donoho, D. L., Elad, M., & Temlyakov, V. N. (2005). Stable recovery of sparse overcomplete representations in the presence of noise. *IEEE Transactions on information theory*, 52(1), 6-18.
- [54] Tropp, J. A., & Wright, S. J. (2010). Computational methods for sparse solution of linear inverse problems. *Proceedings of the IEEE*, 98(6), 948-958.
- [55] Roscher, R., & Waske, B. (2014). *Shapelet-based sparse image representation for landcover classification of hyperspectral data*. Paper presented at the 2014 8th IAPR Workshop on Pattern Recognition in Remote Sensing.
- [56] Elad, M. (2010). *Sparse and redundant representations: from theory to applications in signal and image processing*: Springer Science & Business Media.
- [57] Tropp, J., & Gilbert, A. C. (2007). Signal recovery from partial information via orthogonal matching pursuit. *IEEE Trans. Inform. Theory*, 53(12), 4655-4666.



- [58] Martin, A., Fuchs, J.-J., Guillemot, C., & Thoreau, D. (2007). *Sparse representation for image prediction*. Paper presented at the 2007 15th European Signal Processing Conference.
- [59] Miri, M., Sadeghi, M., & Abootalebi, V. (2014). Two stages sparse representation-based classifier and its application for cancer classification. *Iranian Journal of Biomedical Engineering (IJBME)*, 8, 45-56.
- [60] Aravind, N., Abhinandan, K., Acharya, V. V., & David, S. S. (2011). *Comparison of OMP and SOMP in the reconstruction of compressively sensed hyperspectral images*. Paper presented at the 2011 International Conference on Communications and Signal Processing.
- [61] Soofbaf, S., Sahebi, M., & Mojaradi, B. (2018). A sliding window-based joint sparse representation (swjsr) method for hyperspectral anomaly detection. *Remote Sensing*, 10(3), 434.
- [62] Pati, Y. C., Rezaifar, R., & Krishnaprasad, P. S. (1993). *Orthogonal matching pursuit: Recursive function approximation with applications to wavelet decomposition*. Paper presented at the Proceedings of 27th Asilomar conference on signals, systems and computers.
- [63] Wright, J., Yang, A. Y., Ganesh, A., Sastry, S. S., & Ma, Y. (2008). Robust face recognition via sparse representation. *IEEE transactions on pattern analysis and machine intelligence*, 31(2), 210-227.
- [64] Wang, J., Lu, C., Wang, M., Li, P., Yan, S., & Hu, X. (2014). Robust face recognition via adaptive sparse representation. *IEEE transactions on cybernetics*, 44(12), 2368-2378.
- [65] Bhuvaneswari, N., & Sivakumar, V. (2016). *A comprehensive review on sparse representation for image classification in remote sensing*. Paper presented at the 2016 International Conference on Communication and Electronics Systems (ICCES).
- [66] Tu, B., Zhang, X., Kang, X., Zhang, G., Wang, J., & Wu, J. (2018). Hyperspectral image classification via fusing correlation coefficient and joint sparse representation. *IEEE Geoscience and Remote Sensing Letters*, 15(3), 340-344.
- [67] Chen, Y., Nasrabadi, N. M., & Tran, T. D. (2011). Hyperspectral image classification using dictionary-based sparse representation. *IEEE transactions on geoscience and remote sensing*, 49(10), 3973-3985.
- [68] Fang, L., Li, S., Kang, X., & Benediktsson, J. A. (2014). Spectral-spatial hyperspectral image classification via multiscale adaptive sparse representation. *IEEE transactions on geoscience and remote sensing*, 52(12), 7738-7749.
- [69] Aggarwal, H. K., & Majumdar, A. (2016). Hyperspectral unmixing in the presence of mixed noise using joint-sparsity and total variation. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 9(9), 4257-4266.
- [70] Jafari, M. G., & Plumbley, M. D. (2011). Fast dictionary learning for sparse representations of speech signals. *IEEE Journal of Selected Topics in Signal Processing*, 5(5), 1025-1031.
- [71] Zhang, N., & Yang, J. (2010). *K nearest neighbor based local sparse representation classifier*. Paper presented at the 2010 Chinese conference on pattern recognition (CCPR).
- [72] Song, W., Li, S., Kang, X., & Huang, K. (2016). *Hyperspectral image classification based on KNN sparse representation*. Paper presented at the 2016 IEEE international geoscience and remote sensing symposium (IGARSS).
- [73] Zhang, W., Li, X., & Zhao, L. (2018). Band priority index: A feature selection framework for hyperspectral imagery. *Remote Sensing*, 10(7), 1095.

- [74] Chen, C., Chen, N., & Peng, J. (2016). Nearest regularized joint sparse representation for hyperspectral image classification. *IEEE Geoscience and Remote Sensing Letters*, 13(3), 424-428.
- [75] Harkat, M.-F., Tharrault, Y., Mourot, G., & Ragot, J. (2010). Multiple sensor fault detection and isolation of an air quality monitoring network using RBF-NLPCA model. *International Journal of Adaptive and Innovative Systems*, 1(3-4), 267-284.
- [76] Jog, S., & Dixit, M. (2016). *Supervised classification of satellite images*. Paper presented at the 2016 Conference on Advances in Signal Processing (CASP).

# **Hyperspectral Image Classification based on the fusion of the features generated by sparse representation methods, linear and non-linear transformations**

## **Abstract**

Classification of hyperspectral imagery is known as one of the most important ways of remotely sensed information extraction. In this paper, a novel method of feature extraction is proposed. In this method, the fusion of the extracted non-linear, linear and sparse representation based features is used to produce the effective features used in the KNN classifier. Firstly, a supervised and nonlinear transformation is done to the spectral bands through the nonlinear principal component analysis (NLPCA). In this step, usually, the spectral bands are mapped to a high dimensional feature space. In the second step, a linear discriminate analyze (LDA) transformation is used to reduce the dimension of the hypercube generated in the previous step. The last step, based on the sparse representation theory, a set of features, proportional to the number of classes, is generated. In this method, the weighted KNN is used as the classifier. The results of the classified features in the two different hyperspectral images shown in average 6 percent improvement in accuracies in comparison with spectral bands and other combinations of extracted features. Furthermore, reaching approximately 99% in the overall accuracies of the classes with the few training data can be considered as other achievements of the proposed method.

**Keywords:** hyperspectral image, classification, sparse representation, feature extraction



**Ministry of Science, Research and Technology**

**Tafresh University**

**Department of Geodesy and Surveying Engineering**

**MSc Thesis**

**Title**

**Hyperspectral Image Classification based on the  
fusion of the features generated by sparse  
representation methods, linear and non-linear  
transformations**

**By**

**Samira Allahyari bek**

**Supervisor**

**Dr.Roohollah Karimi**

**Dr.Alireza Safdarinezhad**

**winter 2020**