

# بررسی روش‌های مختلف استخراج ویژگی به منظور طبقه‌بندی تصاویر پرتیفی

نویسندگان: مجید رحیم‌زادگان<sup>۱</sup>، محمدجواد ولدان‌زوج<sup>۲</sup>، مسعود ورشوساز<sup>۳</sup>، یاسر مقصودی مهرانی<sup>۴</sup>  
<sup>۱</sup> دانشجوی کارشناسی ارشد دانشگاه صنعتی خواجه نصیرالدین طوسی [maj\\_r2002@yahoo.com](mailto:maj_r2002@yahoo.com)  
<sup>۲</sup> دانشیار گروه سنجش از دور، دانشکده مهندسی نقشه برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی  
[valadanzouj@yahoo.com](mailto:valadanzouj@yahoo.com)  
<sup>۳</sup> استادیار گروه فتوگرامتری، دانشکده مهندسی نقشه برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی  
[varshosazm@yahoo.com](mailto:varshosazm@yahoo.com)  
<sup>۴</sup> کارشناس ارشد سنجش از دور، دانشگاه صنعتی خواجه نصیرالدین طوسی [ymaghsoudi@yahoo.com](mailto:ymaghsoudi@yahoo.com)  
 آدرس: تهران، خیابان ولیعصر، تقاطع میرداماد، دانشکده مهندسی نقشه‌برداری، گروه سنجش از دور

## چکیده

طبقه‌بندی تصاویر پرتیفی یکی از مهم‌ترین و پرکاربردترین روش‌های استخراج اطلاعات در تصاویر ماهواره ای است. استخراج ویژگی یکی از مهم‌ترین روش‌های کاهش تعداد باندها در تصاویر ماهواره ای پرتیفی به منظور انجام یک طبقه‌بندی مناسب است. در تصاویر ماهواره‌ای پرتیفی، به علت وجود تعداد زیاد باند و همچنین محدود بودن نمونه‌های آموزشی، طبقه‌بندی این تصاویر با مشکل مواجه خواهد شد. این مشکل به علت پدیده Hughes اتفاق می‌افتد. روش‌های مختلف استخراج ویژگی با در نظر گرفتن تعداد ابعاد بهینه برای طبقه‌بندی تصاویر پرتیفی، مشکل به وجود آمده به علت پدیده Hughes را حل می‌نمایند. در این مقاله به بررسی روش‌های استخراج ویژگی در تصاویر ماهواره‌ای پرتیفی پرداخته می‌شود. نتایج به دست آمده نشان می‌دهد که روش NWFN مناسب‌ترین روش برای استخراج ویژگی در تصاویر ماهواره‌ای پرتیفی می‌باشد.

## ۱- مقدمه

تصاویر پرتیفی<sup>۱</sup> به علت جمع آوری داده در تعداد ابعاد بسیار بالا نگاهت کاملی از فضای طیفی، در طول موج‌های مورد نظر، در اختیار ما قرار می‌دهند. در واقع به علت تراکم بسیار بالای داده در این تصاویر می‌توان به یک منحنی پیوسته در فضای طیفی، برای هر پیکسل تصویری، دست یافت [۱] و [۲]. در نتیجه در این تصاویر به

<sup>۱</sup>Hyperspectral images

علت اختلافات کوچک باند های طیفی مجاور، می توان کلاس هایی را که شباهت طیفی بالایی به هم دارند، از هم تفکیک نمود.

استخراج ویژگی یکی از مهمترین روش های کم کردن ابعاد در تصاویر ماهواره ای پرتیفی به منظور طبقه بندی این تصاویر است [۱] و طبقه بندی یکی از مهمترین و در عین حال قوی ترین روش های استخراج اطلاعات از تصاویر ماهواره ای است. در واقع طبقه بندی یک فرآیند تصمیم گیری است که مقادیر پیکسل ها در تصاویر اولیه را برچسب گذاری نموده و با کلاس های نهایی جایگزین می کند.

در طبقه بندی تصاویر پرتیفی بایستی پارامترهای آماری مورد نیاز برای کلاس ها برآورد شود. برای برآورد این پارامترهای آماری یک سری نمونه های آموزشی نیاز است. در سنجش از دور این نمونه های آموزشی معمولاً اندازه محدودی دارند و چون در تصاویر پرتیفی با ابعاد بالا مواجه هستیم، بایستی به طریقی ابعاد این تصاویر کاهش یابد. برای کاهش ویژگی در تصاویر پرتیفی دو روش وجود دارد [۱]: (۱) انتخاب ویژگی<sup>۱</sup> (۲) استخراج ویژگی<sup>۲</sup>

در انتخاب ویژگی تعدادی از ویژگی ها که دارای بیشترین اطلاعات و کمترین نویز هستند، انتخاب می شود، در حالی که در استخراج ویژگی، از تمام ویژگی های موجود، استفاده شده و با استفاده از مینیمم کردن ماتریس پراکندگی داخل کلاسی و ماکزیمم کردن ماتریس پراکندگی بین کلاسی نمونه های موجود، تعداد ویژگی ها کاهش می یابد. مسلماً روش های استخراج ویژگی به علت استفاده از اطلاعات تمام باندها، اطلاعاتی در مورد جدایی کلاس ها از دست نمی دهند، زیرا حتی باندهای نویزی هم، فاقد اطلاعات نمی باشند.

یکی از روش های کاهش ابعاد در تصاویر پرتیفی، استخراج ویژگی است که در آن بایستی پارامترهای آماری به روشی تخمین زده شوند. در واقع در این تصاویر به علت کمبود نمونه های آموزشی، بایستی از روش های برآورد کووریانس با استفاده از نمونه های آموزشی کوچک پرداخته شود. برای انجام این برآورد ها، از روش هایی مانند RDA<sup>۳</sup> و LOOC<sup>۴</sup> استفاده می شود [۳] و [۱۳].

در بخش اول این مقاله در مقدمه توضیحاتی راجع به پدیده Hughes بیان شده، زیرا پدیده Hughes علت اصلی پرداختن به روش های استخراج ویژگی است. در بخش دوم به بیان توضیحاتی راجع به طبقه بندی کننده پرداخته شده و روش توابع تشخیص برای طبقه بندی توضیح داده خواهد شد. بخش سوم به روش های برآورد کووریانس با استفاده از نمونه آموزشی کوچک پرداخته است، چون همانطور که ذکر شد، در تصاویر پرتیفی با کمبود نمونه های آموزشی مواجه هستیم. بخش چهارم به بیان روش های مختلف استخراج ویژگی پرداخته و نهایتاً بخش پنجم به بیان نتیجه گیری می پردازد.

---

Feature selection<sup>1</sup>

Feature extraction<sup>2</sup>

Regularized Discriminant Analysis<sup>3</sup>

Leave One Out Covariance<sup>4</sup>


## ۲-۱- پدیده Hughes

پدیده Hughes بیان می کند که در تصاویر پرتیفی، با افزایش تعداد باندها، به علت افزایش جدایی بین باندها، تا حد مشخصی افزایش دقت طبقه بندی اتفاق می افتد، ولی بعد از این حد به دلیل کاهش دقت برآورد پارامترهای آماری، کاهش دقت خواهیم داشت. در واقع این پدیده بیان می کند که در تصاویر ماهواره ای پرتیفی، همیشه یک حد بهینه تعداد باندها برای انجام طبقه بندی وجود دارد و افزایش تعداد باندها لزوماً به دقت طبقه بندی بالاتر منجر نمی شود.

پیچیدگی اندازه گیری ها به این معنی است که یک اندازه گیری تا چه حد جزئی انجام شده است. اگر تعداد باندهای طیفی برابر  $n$  باشد و تعداد درجات روشنایی گسسته در هر باند طیفی  $k$  باشد، تعداد مکان های گسسته در فضای ویژگی  $n$  بعدی،  $k^n$  خواهد بود [۱].

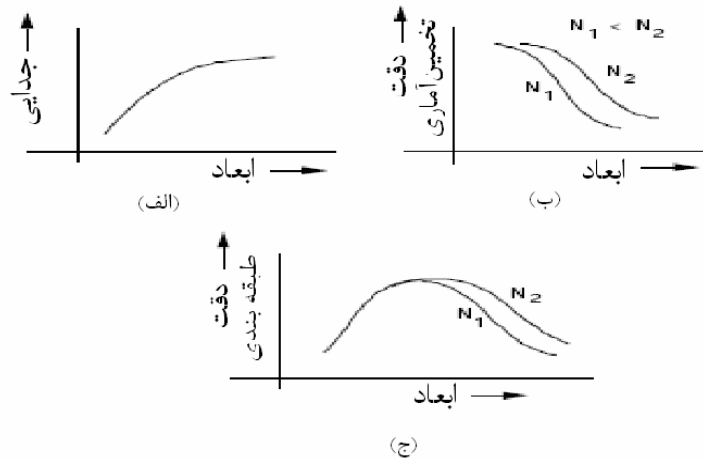
در تعداد نمونه های آموزشی محدود، هنگامی که پیچیدگی اندازه گیری ها افزایش یابد، می توان انتظار داشت دقت افزایش یابد. البته با افزایش پیوسته تعداد باندها، ممکن است یک اثر اشباع اتفاق بیفتد، یعنی با افزایش پیچیدگی اندازه گیری، دقت اندازه گیری به میزان بسیار کمی افزایش یابد.

موردی که ذکر شد، در حالتی است که تعداد نمونه های آموزشی نامحدود باشد. برای تعداد نمونه های آموزشی محدود یک حد پیچیدگی اندازه گیری بهینه وجود دارد. در واقع تعداد بسیار زیاد باندهای طیفی یا تعداد بسیار زیاد درجات روشنایی در هر باند طیفی، لزوماً به دقت بهتر منجر نمی شود. دکتر Hughes [۲] و [۱]، تحقیقاتی راجع به این موضوع انجام داده که نتایج آن در شکل ۱ نشان داده شده است.



شکل ۱ نمایش اثر Hughes [۱]

در شکل ۱، افت دقت به وجود آمده به علت عدم وجود نمونه های آموزشی کافی می باشد، به طوریکه اگر نمونه های آموزشی به حد کافی موجود می بود، این مشکل به وجود نمی آمد.

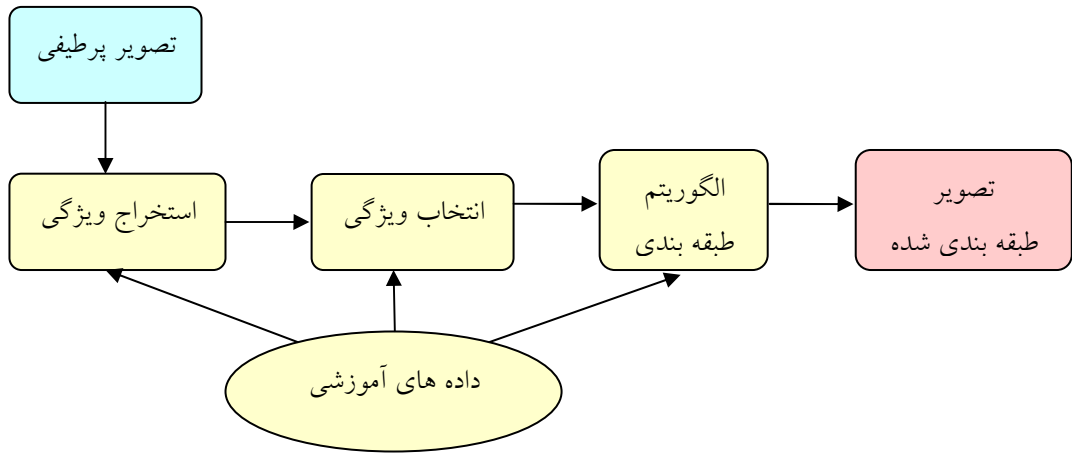


شکل ۲ اثراتی که به علت پدیده Hughes اتفاق می افتد [۱]

همانطور که در شکل ۳ (الف) دیده می شود، با افزایش ابعاد، جدایی بین کلاس ها افزایش می یابد. یعنی در تعداد نمونه های آموزشی نامحدود، با افزایش میزان جزئیات، میزان جدایی بین کلاس ها کاهش می یابد. شکل ۳ (ب) نشان می دهد که با افزایش تعداد باندهای طیفی و افزایش پیچیدگی اندازه گیری، با یک تعداد محدود داده آموزشی، بعد از یک تعداد ثابت باند، دقت شروع به کاهش می کند، که این تعداد ثابت باند به تعداد نمونه های آموزشی بستگی دارد. در این شکل،  $N$ ها نشان دهنده تعداد نمونه های آموزشی بوده و نشان می دهد، هرچه تعداد نمونه های آموزشی بیشتر باشد، دقت در تعداد ابعاد بیشتری شروع به کاهش می کند. همانطور که در شکل ۳ (ج) نشان داده شده، در هر محدوده کاربردی یک مقدار بهینه پیچیدگی داده وجود دارد و ویژگی های بیشتر لزوماً به نتایج بهتر منجر نمی شود. این موضوع، همان نتیجه ای است که دکتر Hughes بدان رسیده است.

## ۲- طبقه بندی تصاویر پرتیفی

طبقه بندی، تقسیم بندی فضای ویژگی به یک دسته از نواحی بدون پوشش می باشد، که مجموع آن ها فضای اولیه را تشکیل دهد. به نحوی که هر نقطه در فضا به صورت یک به یک با یکی از کلاس های برچسب گذاری شده مرتبط باشد که در آن لازم است محدوده تصمیم گیری تشکیل شود. برای این منظور به یک دسته از نقاط که از قبل برچسب گذاری شده و کلاس هر کدام مشخص است، احتیاج است. این نمونه ها، نمونه های طراحی یا نمونه های آموزشی نامیده می شود. مثلاً در مورد طبقه بندی کننده حداقل فاصله، تعریف محدوده تصمیم گیری با مشخص کردن مکان هندسی نقاطی که از میانگین کلاس ها فاصله یکسانی دارند، انجام می شود، یا در مورد طبقه بندی کننده نزدیکترین همسایگی، این کار با مشخص نمودن مکان هندسی نقاطی که از نزدیکترین اعضاء دو کلاس هم فاصله هستند، انجام می شود. روند انجام طبقه بندی در تصاویر پرتیفی در شکل ۳ نمایش داده شده است.

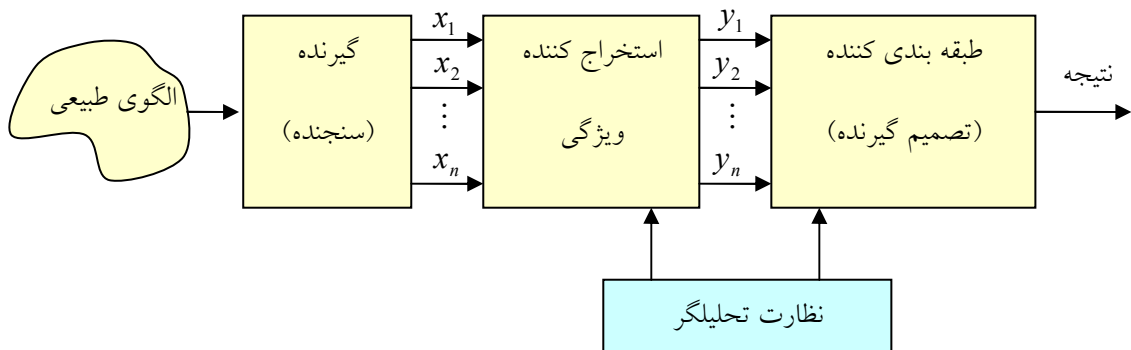


شکل ۳ روند طبقه بندی تصاویر پرتیفی

همانطور که در شکل ۳ دیده می شود، برای طبقه بندی تصاویر پرتیفی، ابتدا بایستی روی آن ها یک مرحله استخراج ویژگی انجام داد، سپس بایستی از میان ویژگی های استخراج شده، یک سری ویژگی را برای انجام الگوریتم طبقه بندی انتخاب نمود و سپس الگوریتم طبقه بندی را پیاده سازی نمود. سه مرحله اخیر بایستی تحت نظارت داده های آموزشی انجام شوند و نهایتاً یک تصویر طبقه بندی شده نهایی خواهیم داشت.

### ۳- روش های استخراج ویژگی

سیستم های سنجنده اغلب برای جمع آوری داده در تعداد باندهای طیفی بیش از میزان مورد نیاز، برای یک کاربرد خاص طراحی می شوند. یکی از علل این موضوع آن است که در محدوده کاربردی، هر کاربرد ممکن است با یک سری ویژگی متفاوت، به بهترین نحو انجام شود. هرچند همان طور که قبلاً نشان داده شد استفاده از ویژگی های طیفی بسیار زیاد، در عمل می تواند برای انجام یک تحلیل زیان آور باشد.



شکل ۵ استخراج ویژگی به عنوان یک بخش از یک سیستم اطلاعات کلی

ممکن است در تعیین سری ویژگی برای استفاده در یک مورد خاص، اهداف متفاوتی وجود داشته باشد. بعضی از آن ها برای کارهای بارزسازی تصویر، به منظور واضح تر ساختن یک ویژگی خاص برای مشاهده کننده مفید هستند. بقیه به خاطر استفاده از محاسبه ویژگی های بهینه در فضای ویژگی برای استفاده در یک الگوریتم تشخیص الگو مدنظر می باشند.

همانطور که قبلاً ذکر شد، کلاً برای کاستن ابعاد تصاویر پرتیفی دو روش وجود دارد (شکل ۵) که عبارتند از: انتخاب ویژگی و استخراج ویژگی. روش اول از میان تمام ویژگی‌ها، ویژگی‌هایی را انتخاب می‌کند که بیشترین اطلاعات و کمترین نویز را داشته باشند، ولی روش دوم از اطلاعات تمامی باندها استفاده می‌کند. در این مقاله بیشتر روی روش‌های استخراج ویژگی بحث خواهد شد.

## ۲-۳- استخراج ویژگی آنالیز تشخیص (DAFE) Discriminant Analysis Feature Extraction

تبدیل مؤلفه‌های اصلی بر مبنای ماتریس کوواریانس کلی همه سری داده قرار دارد و بنابراین به صراحت به ساختار داخل کلاسی حساس نیست. اغلب این روش به عنوان یک وسیله کاهش ویژگی عمل می‌کند. چون در داده‌های سنسجش از دور، کلاس‌ها به کرات در جهت بیشترین پراکندگی داده توزیع شده‌اند. استخراج ویژگی آنالیز تشخیص یک روش برای بارزسازی جدایی است.

در حالت ماتریسی، ماتریس پراکندگی داخل کلاسی  $\Sigma_w$  و ماتریس پراکندگی بین کلاسی  $\Sigma_B$  می‌تواند به صورت زیر تعریف شود [۳]، [۹] و [۱۰]:

$$\Sigma_w = \sum p_i(w_i) \Sigma_i \quad (\text{ماتریس پراکندگی داخل کلاسی}) \quad (\text{رابطه ۱})$$

$$\Sigma_B = \sum p(w_i) (\mu_i - \mu_0) (\mu_i - \mu_0)^T \quad (\text{ماتریس پراکندگی بین کلاسی}) \quad (\text{رابطه ۲})$$

$$\mu_0 = \sum p(w_i) \mu_i \quad (\text{رابطه ۳})$$

در این جا  $\mu_i$ ،  $\Sigma_i$  و  $p(w_i)$  به ترتیب بردار میانگین، ماتریس کوواریانس و احتمال کلاس  $w_i$  است. معیار بهینه‌سازی می‌تواند با بهینه‌سازی معیار Fisher، به صورت زیر تعریف شود:

$$J_{DAFE} = tr(\Sigma_w^{-1} \Sigma_B) \quad (\text{رابطه ۴})$$

بردارهای ویژگی جدید برای ماکزیمم کردن معیار انتخاب می‌شوند. این پایه‌ای برای آنالیز تشخیص استخراج ویژگی (DAFE) است.

این روش همچنین نقایصی دارد، که عبارتند از [۱۰]:

- از آن جایکه آنالیز تشخیص به طور اصلی اختلاف میانگین کلاس را در نظر می‌گیرد، اگر بردارهای میانگین نزدیک به یکدیگر باشند، بردار ویژگی انتخاب شده با آنالیز تشخیص، قابل اعتماد نخواهد بود و با استفاده از جایگذاری کوواریانس در معیار، آنالیز تشخیص ممکن است اطلاعات داخل کوواریانس کلاسی را از دست بدهد.
- یک مشکل دیگر با تابع معیاری که از ماتریس‌های پراکندگی استفاده می‌کند، آن است که معیار عموماً "یک رابطه مستقیم با احتمال خطا ندارد.
- شاید بزرگترین اشکال آن، این باشد که این روش فقط ویژگی‌های بهینه را تا حدی انتخاب می‌کند که یکی کمتر از تعداد کلاس‌ها باشد.

### ۳-۳- aPAC Linear Dimension Reduction (aPAC-LDR)

معیار aPAC-LDR<sup>۱</sup> به معنی معیار کاهش ابعاد خطی دقت دوتایی برآورد شده می باشد [۱۱]. این روش مانند روش DAFE عمل می کند، با این تفاوت که میزان شرکت وزن دار هر جفت کلاس در نظر گرفته شده در آن، بر اساس فاصله اقلیدسی کلاس های مورد نظر خواهد بود. این وزن به صورت زیر تعریف می شود [۱۲]:

$$w(MD_{ij}) = \frac{1}{2MD_{ij}^2} \operatorname{erf}\left(\frac{MD_{ij}}{2\sqrt{2}}\right) \quad (\text{رابطه ۵})$$

که در آن  $MD_{ij}$  فاصله Mahalanobis میانگین کلاس های  $i$  و  $j$  می باشد و  $\operatorname{erf}$  تابع خطا می باشد، که به صورت زیر تعریف می شود:

$$\operatorname{erf}(z) = \frac{2}{\sqrt{\pi}} \int_0^z e^{-t^2} dt \quad (\text{رابطه ۶})$$

در این معیار ماتریس پراکندگی داخل کلاسی مانند روش DAFE است، ولی ماتریس پراکندگی بین کلاسی مجدداً تعریف می شود. یعنی خواهیم داشت [۱۲] و [۳] و [۱۰]:

$$S_w^{LDR} = \sum_{i=1}^L P_i \Sigma_i = S_w^{DA} \quad (\text{رابطه ۷})$$

$$S_b^{LDR} = \sum_{i=1}^{L-1} \sum_{j=i+1}^L P_i P_j w(MD_{ij})(m_i - m_j)(m_i - m_j)^T \quad (\text{رابطه ۸})$$

یک آزمایش با داده واقعی و نمونه شبیه سازی شده در [۱۱] انجام شده است. این آزمایشات نشان می دهد که مزایای این روش عبارتند از:

- این روش می تواند تأثیر پرتی های<sup>۲</sup> کلاس ها را در تبدیل LDR نهایی کاهش دهد.
- روش aPAC-LDR برای رسیدن به دقت بهینه ای که روش DAFE بدان می رسد، نیاز به ویژگی های کمتری دارد، ولی بهترین دقت aPAC-LDR تقریباً با DAFE یکسان است.

همچنین به علت این که این روش همچنان به صورت پارامتریک عمل می کند، مشکل بهینه کردن مشابه با DAFE خواهد بود.

### ۳-۴- استخراج ویژگی محدوده تصمیم گیری Decision Boundary Feature Extraction (DBFE)

در سنجش از دور، به ویژه برای حداقل کردن اثر متغیرهای مشاهداتی غیر قابل کنترل، باید طبقه بندی کننده برای هر سری داده که قرار است تحلیل شود، آموزش داده شود. این موضوع اهمیت استفاده از یک پردازش آموزش

<sup>۱</sup> The approximated pairwise Accuracy Criterion Linear Dimension Reduction  
<sup>۲</sup> outlier

صحیح و انتخاب ویژگی را بارزتر می سازد. این مشخصه ما را ملزم می کند که بهترین ویژگی های ابعاد داده شده را انتخاب نموده و بهترین ابعاد مورد استفاده قرار گیرد.

این روش به طور مستقیم از نمونه های آموزشی به جای استفاده از آماره هایی که از آن ها استخراج می شود، استفاده می کند. نمونه های آموزشی برای مشخص کردن موقعیت محدوده تصمیم گیری که با آن ها به وجود می آید، استفاده می شود. سپس با کمک این محدوده تصمیم گیری و یافتن بردارهای نرمال بر آن ها می توان ماتریس ویژگی مرز تصمیم گیری را ایجاد نمود و با کمک این ماتریس ویژگی مرز تصمیم گیری و یافتن بردارهای ویژه این مرز تصمیم گیری به ویژگی های استخراجی رسید. در واقع ویژگی های استخراج شده در امتداد این بردارهای ویژه می باشند.

قانون Bayes می تواند به صورت زیر بیان شود [۱]:

$$p(w_1)p(x|w_1) > p(w_2)p(x|w_2) \sim x \in w_1 \quad (\text{رابطه ۹})$$

$$p(w_1)p(x|w_1) < p(w_2)p(x|w_2) \sim x \in w_2 \quad (\text{رابطه ۱۰})$$

$$h(x) = -\ln\{p(x|w_1)\} + \ln\{p(x|w_2)\} \quad (\text{رابطه ۱۱})$$

$$t = \ln\left\{\frac{p(w_1)}{p(w_2)}\right\} \quad (\text{رابطه ۱۲})$$

سپس قانون تصمیم گیری Bayes به شکل زیر بیان می شود:

$$h(x) < t \sim x \in w_1 \quad (\text{رابطه ۱۳})$$

$$h(x) > t \sim x \in w_2 \quad (\text{رابطه ۱۴})$$

در این جا بیان بعضی تعاریف لازم به نظر می رسد، که این تعاریف به شرح زیر می باشند:

- ویژگی هایی که از لحاظ تشخیص افزونگی هستند:

اگر  $\{\beta_1, \beta_2, \dots, \beta_n\}$  پایه های یک نمایش فضای ویژگی جدید ممکن باشد، برای اندازه گیری  $N$  باند پاسخ پیکسل ها داریم:

$$x = \sum_{i=1}^N a_i \beta_i \quad \hat{x} = \sum_{i=1, i \neq k}^N a_i \beta_i \quad (\text{رابطه ۱۵ و ۱۶})$$

که در این جا  $\hat{x}$ ،  $x$  را در فضای اصلی بدون  $\beta_k$  تخمین می زند.

تعریف:  $\beta_k$  را از لحاظ تشخیص افزونگی می نامیم، اگر برای تمام مشاهدات  $x$  داشته باشیم:

$$\{h(x) - t\} \{h(\hat{x}) - t\} > 0 \quad (\text{رابطه ۱۷})$$

یعنی بدون حضور و با حضور  $\beta_k$ ، کلاس تغییری نکند.

- ویژگی هایی که از لحاظ تشخیص دارای اطلاعات هستند:  $\beta_k$  را از لحاظ تشخیص دارای اطلاعات می - گوئیم، اگر حداقل یک مشاهده  $x$  وجود داشته باشد، به نحوی که:

$$\{h(x) - t\} \{h(\hat{x}) - t\} < 0 \quad (\text{رابطه ۱۸})$$

یعنی بدون  $\beta_k$ ، طبقه بندی تغییر می کند.



- محدوده تصمیم گیری مؤثر: محدوده تصمیم گیری به صورت  $\{x | h(x) = t\}$  است. این محدوده می تواند یک نقطه، خط، سطح، یا یک رویه فضایی باشد. این محدوده در بسیاری از موارد که در بخشی از آن جدایی بین کلاس ها زیاد نیست، می تواند به سمت بی نهایت برود. ولی برای اهداف عملی ما محدوده تصمیم گیری مؤثر را به صورت زیر تعریف می کنیم:

$$\{x | h(x) = t, x \in R_1 \vee x \in R_2\} \quad (\text{رابطه ۲۳})$$

در حالی که  $R_1$  کوچکترین محدوده ای است که یک سهم خاص  $P_{threshold}$ ، از کلاس  $w_1$  را شامل می شود و  $R_2$  کوچکترین محدوده ای است که یک سهم خاص  $P_{threshold}$ ، از کلاس  $w_2$  را شامل می شود. بنابراین محدوده تصمیم گیری مؤثر ممکن است یک قطعه از محدوده تصمیم گیری باشد.

- ابعاد تشخیص ذاتی: ابعاد تشخیص ذاتی کوچکترین ابعاد  $M$  از یک زیر فضای  $w$  است که برای هر مشاهده  $x$  داشته باشیم:

$$\{h(x) - t\} \{h(\hat{x}) - t\} > 0 \quad (\text{رابطه ۱۹})$$

در این جا  $\hat{x} = \sum_{h=1}^M a_h \phi_h$  یک تقریب از  $x$  در یک فضای تبدیل شده با پایه های زیر است:

$$\{\phi_1, \phi_2, \dots, \phi_M\}, M \leq N \quad (\text{رابطه ۲۰})$$

پس ابعاد تشخیص ذاتی کوچکترین ابعاد زیرفضا است، به نحوی که یک دقت طبقه بندی یکسان با فضای اصلی را ایجاد کند.

- تست افزونگی: اگر بردار  $V$  عمود بر نرمال بر محدوده تصمیم گیری در هر نقطه روی محدوده تصمیم گیری باشد، بردار  $V$  هیچ اطلاعاتی را که در تشخیص بین کلاس ها قابل استفاده باشد، ندارد. به این بردار  $V$ ، بردار افزونه می گویند.

بردارهای آموزنده: اگر بردار  $V$  نرمال بر محدوده تصمیم گیری در حداقل یک نقطه از محدوده تصمیم گیری باشد، بردار  $V$  حاوی اطلاعات مفیدی در تشخیص بین کلاس ها خواهد بود. به این بردار  $V$ ، بردار آموزنده می گویند.

- ماتریس ویژگی محدوده تصمیم گیری: یک بردار نرمال بر محدوده تصمیم گیری در یک نقطه، بردار آموزنده است و تأثیر بردار تقریباً متناسب با مساحتی از محدوده تصمیم گیری است که بردار نرمال به این شکل دارند. حال می توان ماتریس ویژگی محدوده تصمیم گیری را تعریف کرد، که می توان از آن برای پیش بینی ابعاد محدوده تصمیم گیری و پیدا کردن بردارهای ویژگی مؤثر استفاده کرد.
- اگر  $N(x)$  بردار نرمال واحد بر محدوده تصمیم گیری در یک نقطه  $x$  در محدوده تصمیم گیری باشد، ماتریس ویژگی محدوده تصمیم گیری به صورت زیر تعریف می شود:

$$\Sigma_{DBFM} = \frac{1}{k} \int_s N(x) N'(x) p(x) dx \quad (\text{رابطه ۲۱})$$

در حالی که  $p(x)$  یک تابع چگالی احتمال است،  $k = \int_s p(x) dx$ ،  $s$  محدوده تصمیم گیری است و انتگرال در محدوده تصمیم گیری ایجاد شده است. ماتریس ویژگی محدوده تصمیم گیری مؤثر (EDBFM) به عنوان یک حالت خاص که ماتریس ویژگی محدوده تصمیم گیری را از محدوده تصمیم گیری مؤثر ایجاد می کند، در نظر گرفته می شود. قابل توجه است که اگر قطعات متقابلاً جدا و جامع باشند، DBFM همه محدوده می تواند به صورت مجموع DBFM های محاسبه شده از قطعات محدوده تصمیم گیری در نظر گرفته شود.

- تئوری ابعاد تشخیص ذاتی: مرتبه ماتریس ویژگی محدوده تصمیم گیری (DBFM) از یک مسأله تشخیص الگو مساوی ابعاد تشخیص ذاتی است. بردارهای ویژه DBFM منطبق بر مقادیر ویژه غیر صفری است که بردارهای ویژگی لازم را برای به دست آوردن دقت یکسان با فضای اصلی ایجاد می کند.

روش DBFE [۱۳] نه تنها برای پیدا کردن بهترین ویژگی ها خوب عمل می کند، بلکه می تواند به خوبی میزان دقتی را که برای ابعاد مورد نظر به دست می آید، پیش بینی کند

آنالیز استخراج ویژگی محدوده تصمیم گیری محاسبات طولانی دارد، ولی محدودیت اصلی آن، این است که چون تکیه اصلی آن روی نمونه های آموزشی است، وقتی که سری آموزشی کوچک باشد، خوب عمل نمی کند.

### ۵-۳- استخراج ویژگی غیرپارامتریک وزن دار Nonparametric Weighted Feature Extraction (NWFE)

آزمایش DAFE و DBFE ما را به تعریف یک روش استخراج ویژگی جدید به نام استخراج ویژگی غیر پارامتریک وزن دار (NWFE) راهنمایی کرد. این روش مزایای هر دو DAFE و BDFE را در نظر گرفته و محدودیت های آن ها را کاهش می دهد. از DBFE داریم که تأکید روی نمونه های نزدیک موقعیت محدوده تصمیم گیری نهایی، برای بهبود DAFE می تواند مؤثر باشد. ایده اصلی NWFE قرار دادن وزن های متفاوت برای هر نمونه جهت محاسبه "میانگین محلی" و تعریف ماتریس پراکندگی بین کلاسی و داخل کلاسی غیرپارامتریک جدید برای به دست آوردن ویژگی های بیشتر می باشد. در NWFE، ماتریس پراکندگی بین کلاسی به صورت زیر تعریف می شود:

$$\lambda_k^{(i,j)} = \frac{\text{dist}(x_k^{(i)}, M_j(x_k^{(i)}))^{-1}}{\sum_{l=1}^{n_i} \text{dist}(x_l^{(i)}, M_j(x_l^{(i)}))^{-1}} \quad (\text{رابطه } 22)$$

در حالی که  $x_k^{(i)}$  نمونه  $k$  ام کلاس  $i$  می باشد.  $\lambda_k^{(i,j)}$  وزن ماتریس پراکندگی است و به صورت زیر می باشد:

$$S_b = \sum_{i=1}^{nc} \frac{P_i}{nc-1} \sum_{j=1, j \neq i}^{nc} \sum_{k=1}^{n_i} \lambda_k^{(i,j)} (x_k^{(i)} - M_j(x_k^{(i)}))(x_k^{(i)} - M_j(x_k^{(i)}))^T \quad (\text{رابطه } 23)$$

$$M_j(x_k^{(i)}) = \sum_{l=1}^{n_i} W_l^{(i,j)} x_l^{(i)} x_l^{(j)} \quad (\text{رابطه } 24)$$

در حالی که  $\text{dist}(a,b)$  به معنی فاصله از  $a$  تا  $b$  است و  $M_j(x_k^{(i)})$  میانگین محلی  $x_k^{(i)}$  در کلاس  $j$  است که به صورت زیر تعریف می شود:

$$W_l^{(i,j)} = \frac{\text{dist}(x_k^{(i)}, x_l^{(j)})^{-1}}{\sum_{l=1}^{n_j} \text{dist}(x_k^{(i)}, x_l^{(j)})^{-1}} \quad (\text{رابطه ۲۵})$$

ماتریس پراکندگی داخل کلاسی غیر پارامتریک وزن دار به صورت زیر تعریف می شود:

$$S_w = \sum_{i=1}^{nc} p_i \sum_{k=1}^{n_i} \lambda_k^{(i,j)} (x_k^{(i)} - M_i(x_k^{(i)}))(x_k^{(i)} - M_i(x_k^{(i)}))^T \quad (\text{رابطه ۲۶})$$

ویژگی های بهینه با بهینه کردن معیار Fisher تعیین می شوند.

برای کاهش اثر ضرب خارجی فاصله های بین کلاسی و جلوگیری از یکتا شدن، می توان  $S_w$  را با مورد زیر جایگزین نمود:

$$S_w = 0.5S_w + 0.5\text{diag}(S_w) \quad (\text{رابطه ۲۷})$$

#### ۴- نتیجه گیری

با توجه به مطالب ذکر شده می توان نتیجه گرفت، که در کار با داده های با ابعاد بالا ناگزیر به استفاده از روش های کاهش ویژگی هستیم و روش های استخراج ویژگی چون اطلاعاتی در مورد جدایی کلاس ها از دست نمی دهد، مناسب ترین روش برای استخراج ویژگی است. همچنین می توان به این نتیجه رسید که مناسب ترین روش برای استخراج ویژگی جهت دستیابی به یک دقت مناسب، روش NWFه است. چون این روش مزایای روش های دیگر را دارد و همزمان معایب آن ها را می کاهد.

با توجه به مطالبی که ذکر شد، در ادامه کار قصد داریم با توجه به معیارهای مورد نظر، استخراج ویژگی، جهت ایجاد طبقه بندی های مؤثرتر انجام دهیم. در واقع معیارهای مورد نظر ما معیارهایی است که به جای استفاده از ماتریس های پراکندگی بین کلاسی و داخل کلاسی تمام کلاس ها، از معیارهای به دست آمده از تک کلاس استفاده کنیم و بدین ترتیب دقت را بالاتر ببریم. اما روش هایی که برای طبقه بندی مدنظر ما می باشند، به صورت زیر عمل می کنند:

#### منابع و مأخذ

[1] David Landgrebe, *Signal Theory Methods In Multispectral Remote Sensing*, 508 pages plus a CD containing exercises and data. John Wiley & Sons, January 2003, ISBN 0-471-42028-X.

[2] G. F. Hughes, "On the mean accuracy of statistical pattern recognition", *IEEE Trans. Information Theory*, 1968, vol. IT-14, no. 1, pp. 55-63.

[3] B-C. Kuo and D. A. Landgrebe, "Improved Statistics Estimation And Feature

Extraction For Hyperspectral Data Classification”, *PhD Thesis and School of Electrical & Computer Engineering Technical Report*. TR-ECE 01-6, December 2001.

[4] J. P. Hoffbeck and D.A. Landgrebe, “Classification of High Dimensional Multispectral Data”, *Purdue University, West Lafayette, IN.*, TR-EE 95-14, May, 1995, pp.43-71.

[5] S. Tadjudin and D. A. Landgrebe, “Covariance Estimation With Limited Training Samples” *IEEE Transactions on Geoscience and Remote Sensing* Vol. 37, No. 4, pp. 2113-2118, July 1999.

[6] Saldju Tadjudin and David Landgrebe, “Classification of High Dimensional Data with Limited Training Samples”, *PhD Thesis and School of Electrical & Computer Engineering Technical Report* TR-ECE 98-8, May 1998.

[7] J. P. Hoffbeck and D.A. Landgrebe, “Covariance matrix estimation and classification with limited training data” *IEEE Transactions on Pattern Analysis & Machine Intelligence*, vol.18, No. 7, 1996, pp. 763-767.

[8] J.H. Friedman, “Regularized Discriminant Analysis”, *Journal of the American Statistical Association*, vol. 84, pp. 165-175, March 1989.

[9] K. Fukunaga, *Introduction to Statistical Pattern Recognition*, Second Ed., Boston, Academic Press, 1990, pp. 445-479.

[10] B-C. Kuo and D. A. Landgrebe, “Nonparametric Weighted Feature Extraction for Classification”, *IEEE Transactions on Geoscience and Remote Sensing*, Volume 42 No. 5, pp 1096-1105, May, 2004.

[11] R. P. W. Duin and R. Haeb-Umbach, “Multiclass Linear Dimension Reduction by Weighted Pairwise Fisher Criteria,” *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol. 23, pp. 762-766, 2001.

[12] Marco Loog, R.P.W. Duin, “Multiclass Linear Dimension Reduction by Weighted Pairwise Fisher Criteria”, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 23, NO. 7, July 2001.

[13] Chulhee Lee and David Landgrebe, “Feature Extraction And Classification Algorithms For High Dimensional Data”, *PhD Thesis and School of Electrical Engineering Purdue University West Lafayette, Indiana 47907-1285*. TR-EE 93-1, January, 1993.