

برآورد بعد ذاتی در تصاویر ماهواره‌ای ابرطیفی

مهدی حسنلو^{۱*}، فرهاد صمدزادگان^۲

^۱ استادیار گروه مهندسی نقشه‌برداری - پردیس دانشکده‌های فنی - دانشگاه تهران

hasanlou@ut.ac.ir

^۲ استاد گروه مهندسی نقشه‌برداری - پردیس دانشکده‌های فنی - دانشگاه تهران

samadz@ut.ac.ir

(تاریخ دریافت اردیبهشت ۱۳۹۲، تاریخ تصویب آذر ۱۳۹۲)

چکیده

با پیشرفت سنجنده‌های سنجش از دور طیفی با توان تفکیک طیفی بالا، تصاویر ابرطیفی ماهواره‌ای بطور وسیع به منظور نظارت بر سطح زمین به خدمت گرفته شده‌اند. بزرگی ابعاد این تصاویر نه تنها باعث افزایش پیچیدگی محاسبات گردیده بلکه باعث کاهش دقت طبقه‌بندی تصویر نیز شده است. کاهش ابعاد یکی از اصلی‌ترین روش‌ها در تصاویر ابرطیفی برای بهبود دقت طبقه‌بندی است. معمول‌ترین روش در کاهش ابعاد انتخاب عارضه می‌باشد. بطور ایده‌آل کاهش نمایندگان یک مجموعه به کاهش ابعاد ذاتی آن مرتبط می‌شود. روش‌های مختلفی برای برآورد بعد ذاتی و نیز کاهش ابعاد در تصاویر ابرطیفی در منابع وجود دارد. در این مقاله به شرح و مقایسه پنج تکنیک برآورد بعد ذاتی پرداخته و کارایی این تکنیک‌ها را به منظور طبقه‌بندی بانظارت تصاویر ابرطیفی بررسی و بحث کرده است. این تکنیک‌ها شامل برآوردکننده مقدار ویژه (EV)، برآوردکننده بیشترین شباهت (ML)، برآوردکننده بعد همبسته (CD)، برآوردکننده عدد بسته‌بندی (PN) و کمترین گسترش درخت ژئودزیک (GMST) می‌باشد. روش طبقه‌بندی کننده نزدیکترین همسایگی (K-NN) به منظور طبقه‌بندی بانظارت مورد استفاده قرار گرفته است. تعداد زیادی از فواصل متریک در این طبقه‌بندی کننده مورد استفاده و مقایسه قرار گرفته است. پرکاربردترین روش‌های کاهش ابعاد مانند تحلیل مولفه اصلی (PCA) و تحلیل مولفه مستقل (ICA) در خروجی روش‌های برآورده‌گر بکارگرفته شده است. این تحقیق نگاهی مقایسه‌ای و مروری بر روش‌های برآورده‌گر داشته و نیز عارضه‌های باندی استخراج شده را به منظور طبقه‌بندی مورد استفاده قرار داده است.

واژگان کلیدی: تصاویر ابرطیفی، کاهش ابعاد، برآوردکننده بعد ذاتی، استخراج عوارض، طبقه‌بندی بانظارت.

* نویسنده رابط

۱- مقدمه

همسایگی (K-NN) به منظور طبقه‌بندی بانظارت مورد استفاده قرار گرفته است. تعداد زیادی از فواصل متریک شامل فاصله اقلیدسی، نرم ال یک، فاصله کوسینوسی و فاصله همبستگی در این طبقه‌بندی کننده مورد استفاده و مقایسه قرار گرفته است. پرکاربردترین روش‌های کاهش ابعاد مانند تحلیل مولفه اصلی (PCA) و تحلیل مولفه مستقل (ICA) در خروجی روش‌های برآورده گر بعد ذاتی بکار گرفته شده است.

۲- برآورد بعد ذاتی

روش‌های مختلفی برای برآورد بعد ذاتی در تصاویر ابرطیفی وجود دارد که به بررسی روش‌های مختلف تخمین بعد ذاتی می‌پردازد. به منظور سهولت کار، فرض می‌نماییم که بعد ذاتی تصاویر ابرطیفی d بوده و تخمین آن \hat{d} می‌باشد. روش‌های تخمین بعد ذاتی به دو دسته تقسیم‌بندی می‌شوند. (۱) برآوردکننده بر مبنای تحلیل خصوصیات محلی داده و (۲) برآوردکننده بر مبنای تحلیل خصوصیات کلی داده. برآوردکننده‌های محلی بر مبنای مشاهدات تعداد داده‌ها پوشش داده شده با ابرکره حول نقطه با شعاع r که به r^d نسبت دارد، گسترش می‌یابد، که در آن d بعد ذاتی حول نقطه اصلی می‌باشد. در نتیجه، بعد ذاتی با اندازه‌گیری تعداد نقاط محصور شده در ابرکره تخمین زده می‌شود. برخلاف برآوردکننده‌های محلی که با میانگین حول عدد بعد ذاتی این عمل را انجام می‌دهند، برآوردکننده‌های کلی با در نظر گرفتن کلیه داده‌ها به تخمین بعد ذاتی می‌پردازند. در این تحقیق پنج روش برآورد کننده بعد ذاتی شامل دو محلی (CD, ML) و سه کلی (EV, PN, GMST) مورد تحقیق قرار گرفته است.

۲-۱- برآورد کننده بعد همبسته

این روش [۴] با بیان این مفهوم که، تعداد نقاط در ابرکره با شعاع r ، نسبت مستقیم با r^d دارد، به محاسبه مقدار نسبی نقاط محدود به کره با شعاع r می‌نماید. این مقدار نسبی با رابطه زیر محاسبه می‌گردد.

$$C(r) = \frac{2}{n(n-1)} \sum_{i=1}^n \sum_{j=i+1}^n c, c = \begin{cases} 1, & \text{if } \|x_i - x_j\| \leq r \\ 0, & \text{if } \|x_i - x_j\| > r \end{cases} \quad (1)$$

با پیشرفت سنجنده‌ها در سنجش از دور، تصاویر ابرطیفی^۱ بطور وسیعی در دسترس بوده و جزء ابزارهای نظارت بر سطح زمین به شمار می‌روند [۱]. سنجنده‌های ابرطیفی با تهیه اطلاعات با توان تفکیک زیاد در طیف الکترومغناطیس، باعث شناسایی و جداسازی سطوح زمینی شبیه به هم می‌شود. این تصاویر با برداشت اطلاعات در باندهای بسیار ریز و وابسته به هم، باعث برداشت اطلاعات اضافی می‌شود. این ابعاد بسیار بزرگ نه تنها باعث افزایش پیچیدگی محاسباتی می‌شود، بلکه باعث کاهش دقت طبقه‌بندی این تصاویر نیز خواهد شد [۲]. با افزایش ابعاد تصاویر سنجش از دوری، دقت طبقه‌بندی ابتدا افزایش و سپس با افزایش باندها، کم و ثابت بودن مکان‌های آموزشی کاهش می‌یابد. این مشکل به پدیده هیوز یا مشکل ابعاد معرف است [۳]. بنابراین کاهش ابعاد در تصاویر ابرطیفی بدون از دست دادن اطلاعات مهم در مورد اشیاء با هدف طبقه‌بندی تصویر موضوع تحقیقات بسیاری در دهه‌های اخیر بوده است. کاهش ابعاد در تصاویر ابرطیفی تبدیلی است که تصاویر ابرطیفی را در نمایشی جدید به فضای دیگر تبدیل نموده که ابعاد آن کاهش یافته باشد. بطور ایده‌آل تصویر کاهش یافته دارای ابعادی است که به بعد ذاتی^۲ معرف است. تکنیک‌های کاهش ابعاد تصاویر سعی در تبدیل تصاویر ابرطیفی به تصویر ابرطیفی جدید با بعد جدید d دارند، به شرطی که هندسه تصاویر ابرطیفی تا حد ممکن ثابت بماند. در حالت کلی، هم هندسه و هم عدد بعد ذاتی تصاویر ابرطیفی نامعلوم است. بنابراین، کاهش ابعاد تصاویر یک مساله وخیم^۳ بوده و تنها در صورت فرض بعضی از خصوصیات داده قابل حل می‌باشد. این مقاله توانایی پنج تکنیک برآورد بعد ذاتی در تصاویر ابرطیفی ماهواره‌ای را بررسی می‌نماید. این تکنیک‌ها شامل برآورد کننده مقدار ویژه (EV)، برآورد کننده بیشترین شباهت (ML)، برآورد کننده بعد همبسته (CD)، برآورد کننده عدد بسته‌بندی (PN) و کمترین گسترش درخت ژئودزیک (GMST) می‌باشد. روش طبقه‌بندی کننده نزدیکترین

^۱ Hyperspectral

^۲ Intrinsic Dimension

^۳ ill-posed

ویژه با فراوانی زیاد بوده (که در اینجا d همان بعد ذاتی می‌باشد) و باقیمانده‌ی مقادیر ویژه کوچک بوده و بصورت نویز در مدل داده نشان داده می‌شود.

۲-۴- برآورد کننده عدد بسته‌بندی

این روش [۷]، بر مبنای نسبت مستقیم پوشش r تایی $N(r)$ با r^d می‌باشد. پوشش r تایی $N(r)$ عددی است از ابرکره با شعاع r که می‌بایست تمامی نقاط x_i از تمامی داده X می‌باشد. با توجه به نسبت $N(r)$ با r^d عدد بعد ذاتی داده‌های X ، بصورت زیر محاسبه می‌شود.

$$d = - \lim_{r \rightarrow 0} \frac{\log N(r)}{\log r} \quad (۶)$$

در حالت کلی پیدا نمودن $N(r)$ از داده‌های X از لحاظ محاسباتی غیرممکن می‌باشد. روش بسته‌بندی عدد با بکارگیری r عدد بسته‌بندی $M(r)$ که همان حداکثر اندازه r زیرمجموعه از داده‌های X می‌باشد، به محاسبه عدد بعد ذاتی می‌پردازد. به بیان دیگر $M(r)$ حداکثر تعداد نقاط از داده X می‌باشد که در یک ابرکره با شعاع r محصور شده است. برای داده‌های با اندازه معقول پیدانمودن $M(r)$ از لحاظ محاسباتی قابل انجام می‌باشد. در این صورت بعد ذاتی d بصورت زیر محاسبه می‌گردد.

$$d = - \lim_{r \rightarrow 0} \frac{\log M(r)}{\log r} \quad (۷)$$

بعلت اینکه حدگیری بطور صریح قابل انجام نیست، بعد ذاتی با روش زیر محاسبه می‌گردد.

$$\hat{d} = \frac{-\log(M(r_2)-M(r_1))}{\log(r_2-r_1)} \quad (۸)$$

۲-۵- برآورد کننده کمترین گسترش درخت ژئودزیک

این روش [۸]، بر مبنای نسبت تابع طول خم ژئودزیک با عدد بعد ذاتی d می‌باشد. این روش بر مبنای کمترین گسترش درخت ژئودزیک از گراف همسایگی تعریف شده از داده‌های X می‌باشد. طول تابع بعد ذاتی برابر جمع فواصل اقلیدسی برای هر گوشه در کمترین گسترش درخت ژئودزیک می‌باشد. این روش گراف همسایگی G در داده X را طوری تهیه می‌نماید که هر نقطه x_i با k تا

بعلت نسبت مقادیر $C(r)$ به r^d ، ما می‌توانیم به تخمین بعد ذاتی d در داده بپردازیم، این تخمین با رابطه زیر انجام می‌شود.

$$d = \lim_{r \rightarrow 0} \frac{\log C(r)}{\log r} \quad (۲)$$

این حد بطور صریح قابل حل نمی‌باشد، برای حل دو مقدار تخمین زده شده بوسیله $C(r)$ برای دو مقدار r محاسبه می‌گردد. تخمین عدد بعد ذاتی داده بوسیله نسبت زیر محاسبه می‌گردد.

$$\hat{d} = \frac{\log(C(r_2)-C(r_1))}{\log(r_2-r_1)} \quad (۳)$$

۲-۲- برآورد کننده بیشترین شباهت

همانند برآورد کننده بعد همبسته، این روش [۵] نیز به تخمین تعداد نقاط در ابرکره با شعاع r می‌پردازد. در مقایسه با روش قبلی این روش به مدل کردن نقاط داخل ابرکره بوسیله عملیات Poisson می‌پردازد. در پردازش Poisson، نسبت پردازش $\lambda(t)$ در بعد ذاتی d با رابطه زیر نمایش داده می‌شود.

$$\lambda(t) = \frac{f(x)\pi^{d/2} dt^{d-1}}{\Gamma(d/2+1)} \quad (۴)$$

که $f(x)$ مقدار نمونه برداری و $\Gamma(\cdot)$ تابع گاما می‌باشد. بر مبنای پردازش Poisson، می‌توان نشان داد که بیشینه مقدار شباهت در تخمین بعد ذاتی d ، حول نقاط x_i با k نزدیکترین همسایگی با رابطه زیر نمایش داده می‌شود.

$$\hat{d}_k(x_i) = \left(\frac{1}{k-1} \sum_{j=1}^{k-1} \log \frac{T_k(x_i)}{T_j(x_i)} \right)^{-1} \quad (۵)$$

که $T_k(x_i)$ نماینده کوچکترین ابرکره با مرکز x_i با پوشش k همسایه نقاط می‌باشد.

۲-۳- برآورد کننده مقدار ویژه

این روش با اعمال PCA بر روی داده‌ها با ابعاد زیاد و محاسبه مقادیر ویژه آنها به محاسبه عدد بعد ذاتی می‌پردازد [۶]. مقادیر ویژه به محاسبه وریانس بوسیله بردار ویژه می‌پردازد. بعد از نرمالیزه نمودن، مقادیر ویژه و نمایش مرتب آنها عدد بعد ذاتی با یک حد آستانه استخراج می‌گردد. در این نمایش، مقدار d اولین، مقدار

۳-۱- تحلیل مولفه اصلی

یکی از معرفت‌ترین روش‌های استخراج عوارض در سنجش از دور تبدیل مولفه اصلی می‌باشد [۱۰]. این تبدیل، داده‌های اصلی را به داده‌های کوچکتر که کمتر از داده‌های قبلی به یکدیگر وابسته هستند، تبدیل می‌نماید. بنابراین کاهش تعداد متغیرهای جدید در داده‌های اصلی نهفته می‌باشد. در هر حال استفاده از مولفه اصلی در استخراج عارضه در طبقه‌بندی تصویر مناسب نیست و این به دلیل لحاظ نکردن کلاس مورد نظر می‌باشد. بنابراین زیر فضای مناسب برای طبقه‌بندی را تشکیل نمی‌دهد. روش‌های دیگر کاهش ابعاد در [۱۱] نشان داده شده است. در حالت کلی PCA به دنبال کاهش بعد داده به منظور پیدا نمودن تعداد محدودتری از ترکیب‌های خطی متعامد از داده اصلی با وریانس زیاد می‌باشد. همیشه به تعداد داده‌های موجود، مولفه اصلی وجود دارد. معمولاً اولین مولفه‌ها دارای وریانس بیشتری هستند و با حذف بقیه داده‌های با وریانس کمتر، از اطلاعات داده کم نخواهد شد. از آنجایی که وریانس وابسته به مقیاس متغیرهاست، بطور معمول ابتدا متغیرها را با میانگین صفر و انحراف معیار یک استاندارد می‌نماییم. فرض استاندارد سازی با ماتریس به صورت زیر می‌باشد.

$$\sum_{p \times p} = \frac{1}{n} X X^T \quad (10)$$

ما با بکارگیری تئوری تجزیه طیفی بصورت زیر

$$\sum = U \Lambda U^T \quad (11)$$

که در آن $\Lambda = \text{diag}(\lambda_1, \dots, \lambda_p)$ یک ماتریس قطری با ترتیب مقادیر ویژه $\lambda_1 \leq \dots \leq \lambda_p$ و U یک ماتریس $p \times p$ متعامد است، که شامل مقادیر ویژه می‌باشد. می‌توان نشان داد که مولفه‌های اصلی از رابطه زیر قابل محاسبه می‌باشد.

$$S = U^T X \quad (12)$$

با مقایسه معادلات، می‌توان ماتریس وزن W با U^T نشان داد. می‌توان نشان داد که زیرفضا با اولین k بردار ویژه دارای کمترین انحراف معیار از میان X زیر فضا با بعد k می‌باشد و معادل بعد ذاتی داده‌ها می‌باشد.

نزدیکترین نقطه همسایگی x_{jij} متصل است. در این حالت کمترین گسترش درخت ژئودزیک T بصورت کمترین گراف حول داده‌های X تعریف می‌شود، با طول

$$L(X) = \min_{T \in \mathcal{T}} \sum_{e \in T} g_e \quad (9)$$

که T تعدادی از زیر درخت‌های گراف G بوده و e گوشه در درخت T است و g_e فاصله اقلیدسی وابسته به گوشه e می‌باشد. در این برآوردکننده، تعداد زیر داده‌های $A \subset X$ از مجموعه X که با اندازه‌های مختلف m ساخته شده و طول $L(A)$ از این برآورد کننده، از زیر داده A محاسبه می‌گردد. بطور تئوری نسبت $\log L(A) / \log m$ خطی بوده و بوسیله تابع $y = ax + b$ قابل تخمین می‌باشد. مقادیر a, b بوسیله محاسبات کمترین مربعات قابل برآورد می‌باشند. می‌توان نشان داد که مقدار تخمین زده شده a با مقدار بعد ذاتی بصورت $\hat{d} = 1 / (1 - a)$ رابطه دارد.

۳- تکنیک‌های کاهش ابعاد

در عمل و تئوری استفاده از تصاویر ابرطیفی می‌بایست باعث افزایش توانایی‌های ما برای طبقه‌بندی و تهیه نقشه پوشش/کاربری اراضی گردد. روند معمول طبقه‌بندی تصاویر چند طیفی در تصاویر ابرطیفی ناکارآمد خواهد بود [۹]. با افزایش ابعاد در فضای عارضه که همان تعداد باندها باشد، تعداد مکان‌های آموزشی نیز می‌بایست افزایش یابد. تحقیقات نشان داده است که تعداد مکان‌های آموزشی نسبت خطی با ابعاد طبقه‌بندی کننده‌های خطی و با مربع ابعاد آنها در طبقه‌بندی کننده‌های مربعی دارد [۶]. با افزایش تعداد ابعاد باندها، مکان‌های آموزشی می‌بایست بسیار افزایش یافته تا در تخمین پارامترهای طبقه‌بندی موثر باشد. اگر مکان‌های آموزشی ناکافی باشد (که در تصاویر ابرطیفی بسیار معمول است) پارامترهای تخمین زده شده بی‌دقت می‌باشد. در این حال دقت طبقه‌بندی کننده ابتدا افزایش یافته و بعد با افزایش تعداد باندهای کاهش می‌یابد (پدیده هیوز). همانطور که گفته شده یکی از راه‌های بهبود کارایی طبقه‌بندی تصویر کاهش ابعاد می‌باشد. روش کاهش بعد، باعث تبدیل بعد از بعد بالاتر به بعد پایین‌تر می‌شود. دو روش پرکاربرد در کاهش ابعاد در این تحقیق مورد استفاده قرار گرفته است.

۳-۲- تحلیل مولفه مستقل

مدل بکارگیری شده [۱۲] در ICA بصورت

$$x = As \quad (13)$$

که در آن x بردار سیگنال مشاهدات و A ماتریس عدد از ضرایب مختلط و s سیگنال منبع است. در ICA دو فرضیه را می‌بایست در نظر گرفت H_1 : مولفه‌های s_i از s بطور آماری مستقل هستند. H_2 : مولفه‌های s_i از s می‌بایست دارای توزیع غیر گوسی باشند. در رابطه ۱۳، دو مشخصه قابل فهم می‌باشد. (۱) عدم امکان استخراج وریانس منبع و (۲) عدم امکان استخراج ترتیب مولفه منابع. هدف ICA، پیدا نمودن ماتریس $W=A^{-1}$ بطوریکه $S_{est}=Wx$ که در آن سیگنال مشاهده شده با بهینه‌سازی معیارهای مستقل آماری بدست می‌آید. یک سیگنال S_i وقتی مستقل است که هیچ اطلاعاتی در در سیگنال S_j نداشته باشد. تابع چگالی احتمال با حاصلضرب توابع چگالی مرزی است.

$$P(s_1 \dots s_i) = \prod P_{s_i}(u_i) \quad (14)$$

بدیهی است که مستقل بودن نشان دهنده عدم وابستگی است و برعکس آن درست نیست. این مشاهدات ما را قادر به تخمین رویه استخراج سیگنال‌های مستقل و محدودکردن سیگنال‌های ناهمبسته می‌نماید. اولین مرحله محاسبه ICA، غیر همبسته‌کردن مشاهدات سیگنال می‌باشد، این کار با یک PCA معمول قابل انجام می‌باشد. رابطه محکمی بین مستقل بودن و غیر گوسی بودن وجود دارد. تئوری حد مرکزی^۱ می‌گوید که مجموع N متغییر تصادفی مستقل، وقتی N به سمت بی نهایت می‌رود بسمت توزیع گوسی خواهند رفت.

این تئوری بدان مفهوم است که، مجموع دو متغییر تصادفی مستقل دارای توزیع گوسی بیشتری نسبت به یک متغییر تصادفی اولیه می‌باشد. در این حالت تخمین مولفه‌های مستقل شامل پیدا کردن ماتریس وزن W می‌باشد که بردار $S_{est}=Wx$ دارای کمترین مقدار گوسین باشد. سپس محاسبه غیرگوسی بودن مورد نیاز می‌باشد.

مقدار آنتروپی بردار تصادفی x از تابع چگالی $P_x(u)$ بصورت زیر تعریف می‌گردد.

$$H(P_x) = - \int P_x(u) \log P_x(u) du \quad (15)$$

در $H(p_x)$ در این رابطه بیشینه مقدار گوسی از بردار تصادفی x می‌باشد. پارامتر آنتروپی منفی^۲ با تفاضل آنتروپی بین x و بردار تصادفی گوسی x_g با ماتریس کوواریانس یکسان بصورت زیر است.

$$J(x) = H(P_{xg}) - H(P_x) \quad (16)$$

با محاسبه فاصله دیورژانس Kullback-Leibler بین دو توزیع P_v, P_w خواهیم داشت:

$$H(P_v, P_w) = - \int P_v(u) \log [P_v(u)/P_w(u)] du \quad (17)$$

می‌توان نشان داد که آنتروپی منفی $J(x)$ برابر با دیورژانس Kullback-Leibler می‌باشد.

$$J(x) = H(P_x, P_{xg}) \quad (18)$$

این عبارت نیاز به محاسبه تابع چگالی دارد، که بسیار مشکل می‌باشد. Hyvärinen روشی را برای تخمین آنتروپی منفی پیشنهاد داده است [۱۱].

$$J(x) = \{E[G(x)] - E[G(x_g)]\}^2 \quad (19)$$

که در آن G ، یک تابع غیر درجه دوم می‌باشد. بیشینه سازی غیرگوسی $J(x)$ نیاز به الگوریتم‌های بهینه‌سازی دارد. یکی از این الگوریتم‌ها Fast-ICA می‌باشد [۱۳]. که بر مبنای شیوه‌های تکراری اعداد صحیح و برای هر مولفه استفاده می‌شود. مراحل آن بدین صورت است:

(۱) انتخاب تصادفی ماتریس وزن W .

(۲) $w = E \{x g(w^T x)\} - E \{g'(w^T x)\} w$ در حالیکه $g(u) = \tanh(u)$

(۳) $w = w^+ / \|w^+\|$.

^۲ negentropy

^۱ Central Limit Theorem


بعد از هر تکرار بردار Wx بوسیله ماتریس W غیرهمبسته می‌شود.

$$W = (W W^T)^{1/2} W \quad (20)$$

W ماتریس $(w_1, \dots, w_n)^T$ و $(W W^T)^{-1/2}$ با استفاده از تجزیه مقادیر ویژه بدست می‌آید. در حالت خاص (کاهش ابعاد در تصاویر ابرطیفی است) منبع فیزیکی وجود ندارد و مدل $x=As$ هم بر فرض H_1 استوار نیست و از آن صرف‌نظر می‌شود. در این حالت ICA برای پیدانمودن مولفه‌های تصویر شده بصورتی که تمامی آن مستقل باشند، بکارگرفته می‌شود.

۴- نتایج و آزمایشات

به منظور ارزیابی توانایی روش‌های برآورد بعد ذاتی، یک تصویر ابرطیفی از سنجنده AVIRIS با ابعاد 145×145 پیکسل مورد استفاده قرار گرفته است (شکل ۱-الف). این تصویر دارای شانزده کلاسی می‌باشد (شکل ۱-ب). ما در این تحقیق سی درصد از واقعیت زمینی را بعنوان مکان‌های آموزشی برای طبقه‌بندی مورد استفاده قرار دادیم. این تصویر دارای ۲۲۰ باند طیفی با توان تفکیک طیفی ۱۰ نانومتر بین ۰/۴ تا ۲/۴۵ میکرومتر و نیز توان تفکیک مکانی ۲۰ متر می‌باشد. قبل از پردازش ۲۰ باند جذبی آب بعلاوه ۱۵ باند نویزی از مجموع تعداد باندها حذف گردید [۱۴].



شکل ۱- الف) تصویر ابرطیفی. ب) واقعیت زمینی

پنج روش تخمین بعد ذاتی بر روی تصویر AVIRIS با ۱۸۶ باند پیاده سازی شد و خروجی‌های جدول ۱ که حاوی عدد بعد ذاتی برآورد شده می‌باشد، حاصل گردید. با تخمین بعد ذاتی و بکارگیری روش‌های گفته شده برای کاهش بعد تصاویر به ارزیابی دو روش استخراج عارضه می‌پردازیم. قبل از استخراج عوارض، با روش مستقیم کسر

نویز حداقلی^۳ و معکوس آن نویز موجود در باندها ناشی از سنجنده را کاهش دادیم [۱۵]. شکل ۲ نشان دهنده اولین عارضه از ابعاد استخراج شده و کاهش داده شده با دو روش گفته شده می‌باشد.

جدول ۱- جزئیات تخمین عدد بعد ذاتی

روش تخمین بعد ذاتی	\hat{d}
Eigen value (EV)	14
Maximum likelihood (ML)	9
Correlation dimension (CD)	4
Packing number (PN)	3
Geodesic minimum spanning tree (GMST)	8

۴-۱- طبقه‌بندی بانظارت

به منظور ارزیابی توانایی روش‌های برآورد بعد ذاتی و نیز کاهش ابعاد، می‌بایست عارضه‌های استخراج شده در یک رویه طبقه‌بندی بانظارت وارد نمود. بر این مبنا از طبقه‌بندی کننده K-NN استفاده گردید. در بکارگیری این طبقه‌بندی کننده، فواصل متریک مختلفی مورد استفاده و مقایسه قرار گرفت (جدول ۲).

جدول ۲- فواصل متریک مختلف برای طبقه‌بندی تصویر


Distance	Formulation
Euclidean	$d_{rs}^2 = (x_r - x_s)(x_r - x_s)^T$
Norm L1	$d_{rs} = \sum_{j=1}^n x_{rj} - x_{sj} $
Cosine	$d_{rs} = (1 - x_r^T x_s / ((x_r^T x_r)^{1/2} (x_s^T x_s)^{1/2}))^{1/2}$
Correlation	$d_{rs} = 1 - \frac{(x_r - \bar{x}_r)(x_s - \bar{x}_s)^T}{((x_r - \bar{x}_r)(x_r - \bar{x}_r)^T)^{1/2} ((x_s - \bar{x}_s)(x_s - \bar{x}_s)^T)^{1/2}}$

معیار کیفیت طبقه‌بندی کننده، با اندکس کاپا^۴ و دقت کلی^۵ تعیین می‌گردد [۱۶]. خروجی‌های استخراج شده با متریک‌های مختلف در جدول ۳ نشان داده شده‌است. با نگاهی به جدول ۳، واضح است که بهترین کارایی از طبقه‌بندی تصویر از روش ICA بدست آمده است. با مقایسه دقت کلی طبقه‌بندی با متریک‌های مختلف شامل: نرم L1، اقلیدسی، کوسینوسی و همبستگی در شکل ۳ بتفکیک روش‌های کاهش بعد نشان داده شده است. در دو روش کاهش بعد، گزینه برآورده‌کننده مقدار ویژه (EV) دارای بیشترین مقدار دقت کلی مخصوصاً در

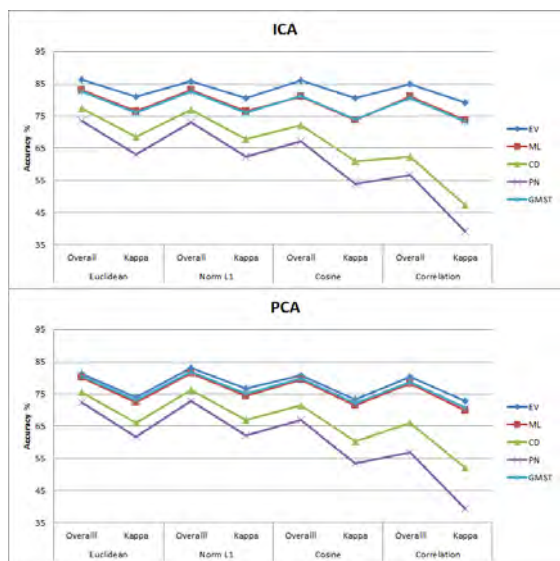
۱ Minimum Noise Fraction

۲ Kappa Index

۳ Overall Accuracy




شکل ۳- دقت کلی طبقه‌بندی به تفکیک متریک‌های مختلف در تکنیک‌های کاهش ابعاد



شکل ۴- مقایسه تمامی روش‌های کاهش بعد و متریک‌های مختلف بکارگرفته شده

روش ICA می‌باشد (شکل ۴). در فواصل متریک فضا که در روش K-NN استفاده شد است، نرم L1 بیشترین کارایی را در طبقه‌بندی تصاویر ابرطیفی دارد. بطور خلاصه روش ICA بهترین کاهش دهنده بعد، روش EV بهترین روش برآورد بعد ذاتی و نرم L1 مناسبترین فاصله و متریک در طبقه‌بندی بانظارت تصاویر ابرطیفی می‌باشد.



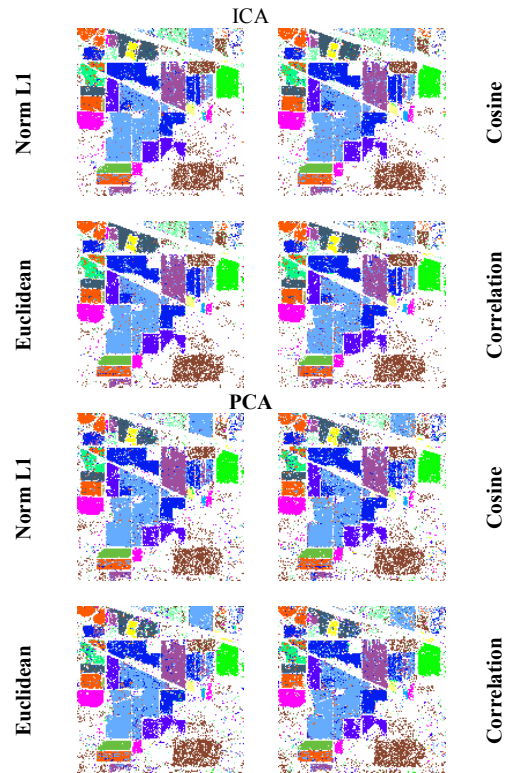
شکل ۲- اولین عارضه استخراج شده در تکنیک‌های ICA و PCA

شکل ۵ نشان دهنده خروجی طبقه‌بندی تصاویر با بکارگیری روش EV بعنوان برآورد کننده بعد ذاتی با متریک‌های مختلف فضا می‌باشد. با نگاهی به نتایج بدست آمده می‌توان فهمید که بهترین برآورده کننده بعد ذاتی EV و بدترین آنها PN می‌باشد بعلاوه بهترین روش استخراج عارضه از تصاویر ابرطیفی روش ICA با دقت کلی ۸۸/۳۳٪ می‌باشد. در این تحقیق بهترین متریک فضا برای طبقه‌بندی کننده تصاویر ابرطیفی نرم L1 و بدترین آنها فاصله همبستگی می‌باشد. در انتها باید خاطر نشان کرد در تحقیق‌های آتی می‌بایست در مورد تعیین و تخمین بعد ذاتی بطور اتوماتیک به‌همراه استخراج عوارض تاکید کرد.

جدول ۳- کارایی طبقه بندی بانظارت تصویر ابرطیفی

Reduction	PCA							
	Euclidean		Norm L1		Cosine		Correlation	
Metric	Overall	Kappa	Overall	Kappa	Overall	Kappa	Overall	Kappa
Accuracy	81.17	73.90	83.19	76.61	80.75	73.37	80.28	72.77
EV	81.17	73.90	83.19	76.61	80.75	73.37	80.28	72.77
ML	80.12	72.45	81.56	74.43	79.36	71.44	78.24	69.78
CD	75.59	66.03	76.23	66.87	71.54	60.33	66.04	52.22
PN	72.46	61.71	72.91	62.23	66.84	53.58	56.89	39.35
GMST	80.63	73.07	81.97	75.10	79.81	72.05	78.75	70.68
Reduction	ICA							
	Euclidean		Norm L1		Cosine		Correlation	
Metric	Overall	Kappa	Overall	Kappa	Overall	Kappa	Overall	Kappa
Accuracy	86.33	81.05	85.92	80.53	85.95	80.50	84.91	79.12
EV	86.33	81.05	85.92	80.53	85.95	80.50	84.91	79.12
ML	83.01	76.47	83.10	76.53	81.14	73.73	80.98	73.64
CD	77.31	68.47	76.88	67.78	72.26	61.12	62.44	47.45
PN	73.50	62.98	72.98	62.46	67.26	53.88	56.63	39.12
GMST	82.63	75.93	82.67	75.99	81.31	74.05	80.67	73.24

مقایسه شد. باتوجه به گستردگی روش‌های تخمین بعد ذاتی و تاثیر آن در کاهش ابعاد تصاویر و همچنین کارایی این تکنیک‌ها به منظور طبقه‌بندی بانظارت تصاویر ابرطیفی، مطالعه و تحقیق در این زمینه امری اجتناب ناپذیراست. این تکنیک‌ها شامل برآوردکننده مقدار ویژه، برآوردکننده بیشترین شباهت، برآوردکننده بعد همبسته، برآوردکننده عدد بسته‌بندی و کمترین گسترش درخت ژئودزیک می‌باشد. روش طبقه‌بندی کننده K-NN به منظور طبقه‌بندی بانظارت مورد استفاده قرار گرفت. چهار فاصله متریک در این طبقه‌بندی کننده مورد بررسی و مقایسه شد و همچنین پرکاربردترین روش‌های کاهش ابعاد بعنوان کاهش دهنده ابعاد بررسی شدند. همانطور که از جدول ۳ و شکل ۴ مشخص است، روش ICA بعنوان بهترین کاهش دهنده ابعاد، روش EV بهترین روش برآورد بعد ذاتی و نرم L1 مناسبترین فاصله و متریک در طبقه‌بندی بانظارت تصاویر ابرطیفی می‌باشد. این تحقیق نیاز به بررسی دقیقتر روش‌های مختلف کاهش ابعاد و نیز استفاده از روش‌های پارامتریک طبقه‌بندی کننده تصاویر ابرطیفی مانند ماشین بردار پشتیبان دارد.



شکل ۵- خروجی تخمین برآورد گر EV.

۵- نتیجه‌گیری

این تحقیق روش‌های مختلف برآورد بعد ذاتی و نیز تکنیک‌های کاهش ابعاد در تصاویر ابرطیفی بررسی و

مراجع

- [1] Dai C-guang, H X-bo, Dong, G-jun, (2007). Support Vector Machine for Classification of Hyperspectral Remote Sensing Imagery, Fourth International Conference on Fuzzy Systems and Knowledge Discovery.
- [2] K. Fukunaga and D.R. Olsen (1971). An algorithm for finding intrinsic dimensionality of data, IEEE Transactions on Computers, C-20, pp176–183.
- [3] D. W. Scott, (1992). The curse of dimensionality and dimension reduction in Multivariate Density Estimation: Theory, Practice, and Visualization. New York: Wiley, ch. 7, pp 195–217.
- [4] P. Grassberger and I. Procaccia (1983). Measuring the strangeness of strange attractors, Physica, D9, pp 189-208.
- [5] E. Levina and P.J. Bickel (2004). Maximum likelihood estimation of intrinsic dimension, In Advances in Neural Information Processing Systems, volume 17, Cambridge, MA, USA, The MIT Press.
- [6] K. Fukunaga (1989). Intrinsic dimensionality extraction, in Classification, Pattern Recognition and Reduction of Dimensionality, P. R. Krishnaiah and L. N. Kanal, Eds. Amsterdam, The Netherlands: North-Holland, vol. 2, Handbook of Statistics, pp 347–360.
- [7] B. Kegl (2002). Intrinsic dimension estimation based on packing numbers, In Advances in Neural Information Processing Systems, volume 15, pages 833–840, Cambridge, MA, USA, The MIT Press.

- [8] Van der Maaten L, (2007). An introduction to dimensionality reduction using matlab, Technical Report MICC 07-07, Maastricht University, Maastricht, The Netherlands.
- [9] Hsieh, P.F and Landgrebe, D.A (1998). Classification of High Dimensional Data, School of Electrical and Computer Engineering, Purdue University, West Lafayette, Indiana, USA.
- [10] Du H, Qi H, (2004). An FPGA Implementation of Parallel ICA for Dimensionality Reduction in Hyperspectral Images, Geoscience and Remote Sensing Symposium (IGARSS), Proceedings IEEE International. v.5, pp 3257-3260.
- [11] Bruske J, Merényi E (1999). Estimating the Intrinsic Dimensionality of Hyperspectral Images, ESANN'1999 proceedings European Symposium on Artificial Neural Networks Bruges, ISBN 2-600049-9-X. Belgium, pp 105-110.
- [12] Hyvärinen and E. Oja (2000). Independent component analysis: Algorithms and applications, Neural Network., vol. 13, no. 4/5, pp 411-430.
- [13] Hyvärinen (1999). Fast and Robust Fixed-Point Algorithms for Independent Component Analysis, IEEE Transactions, on Neural Networks, vol. 10(3), pp 626-634.
- [14] P. K. Varshney and M. K. Arora (2004). Advanced Image Processing Techniques for Remotely Sensed Hyperspectral Data. Berlin, Germany: Springer-Verlag.
- [15] C-I Change and Q Du (1999). Interference and Noise-Adjusted Principal Components Analysis, IEEE Transactions, Geoscience. Remote Sensing, Vol 36, No 5.
- [16] Canran Liu, Paul Frazier, Lalit Kumar, "Comparative assessment of the measures of thematic classification accuracy," Remote Sensing of Environment, 107, pp 606-616, 2007.

