



سجش از دور

GIS ایران

سال اول، شماره دوم، تابستان ۱۳۸۸
Vol.1, No.2, Summer 2009

سنجش از دور و GIS ایران
Iranian Remote Sensing & GIS

۱۷-۳۰



بهبود روش استخراج ویژگی غیرپارامتریک وزن دار با استفاده از ترکیب خطی نمونه‌های آموزشی در تصاویر ابرطیفی

محسن قمری اصل^{۱*}، محمدرضا مباحثی^۲، محمدجواد ولدان زوج^۳، برات مجردی^۴

۱. دانشجوی دکترای سنجش از دور، گروه مهندسی نقشه‌برداری، دانشگاه خواجه نصیرالدین طوسی
۲. دانشیار گروه مهندسی نقشه‌برداری، دانشگاه خواجه نصیرالدین طوسی
۳. دانشیار گروه مهندسی نقشه‌برداری، دانشگاه خواجه‌نصیرالدین طوسی
۴. استادیار گروه مهندسی نقشه‌برداری، دانشگاه شهید رجایی

تاریخ پذیرش مقاله: ۱۳۸۸/۱/۳

تاریخ دریافت مقاله: ۱۳۸۸/۴/۱۰

چکیده

در این تحقیق، روشی برای بهبود استخراج ویژگی غیرپارامتریک وزن دار ارائه شده است، که در مسائل تشخیص الگو در فضاهای با ابعاد بالا استفاده می‌گردد. روش استخراج ویژگی غیرپارامتریک وزن دار براساس بسط غیرپارامتریک ماتریس‌های پراکندگی قرار گرفته است، که پارامترهای میانگین آنها به‌طور جداگانه برای هر نمونه و با استفاده از مجموع وزن دار نمونه‌های سایر کلاس‌ها محاسبه می‌شوند. وزن هر یک از این نمونه‌ها براساس فاصله اقلیدسی آنها از نمونه اصلی (نمونه تحت بررسی) محاسبه می‌گردد. اما تنها با استفاده از پارامتر فاصله نمی‌توان پراکندگی نمونه‌ها را به‌طور کامل بیان کرد، و محل قرارگیری آنها نیز در بیان پراکندگی نمونه‌ها مؤثر است. بدین معنی که ممکن است دو نمونه که فواصل یکسانی از نمونه اصلی (نمونه تحت بررسی) دارند، وابستگی‌شان به آن نمونه یکسان نباشد. به عنوان مثال، ممکن است که یکی از آنها کاملاً به نمونه اصلی وابسته باشد و دیگری کاملاً مستقل از آن باشد. از سوی دیگر، این وابستگی‌ها با ترکیب خطی آنها مرتبط است. چرا که در حالت ایده‌آل انتظار می‌رود نمونه‌های یک کلاس، کاملاً ترکیبی خطی از یکدیگر باشند و نمونه‌های کلاس‌های متفاوت کاملاً مستقل از هم باشند. از این رو، ترکیب خطی بین نمونه‌ها در تعیین پراکندگی‌ها مؤثر خواهد بود. در پژوهش حاضر، با استفاده از پارامتر مهم ترکیب خطی، نتیجه روش استخراج ویژگی غیرپارامتریک وزن دار بهبود یافته است. نتایج نشان می‌دهند که روش ارائه شده در اکثر کلاس‌ها و به‌ویژه در کلاس‌های بحرانی که تشابه طیفی بالایی نسبت به هم دارند، بهتر از روش استخراج ویژگی غیرپارامتریک وزن دار عمل کرده است. بهترین نتیجه به‌دست آمده دارای دقت کلی بیش از ۸۲ درصد با ضریب کاپایی بهتر از ۸۰ درصد بوده است.

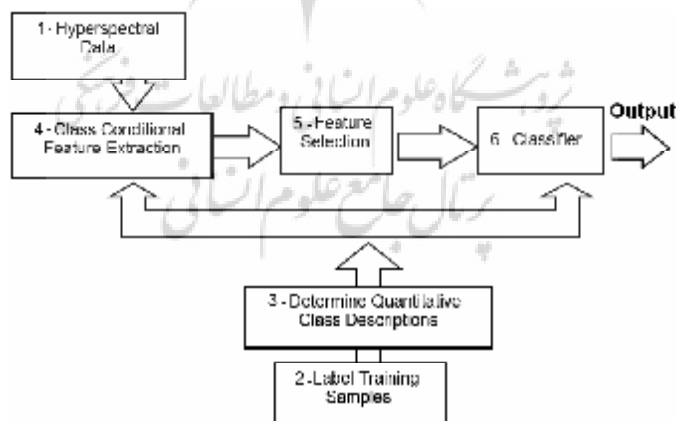
کلیدواژه‌ها: استخراج ویژگی غیرپارامتریک وزن دار (NWFE)، ترکیب خطی، کاهش ابعاد، طبقه‌بندی.

* نویسنده مکاتبه کننده: تهران، خیابان ولی‌عصر، تقاطع میرداماد، دانشگاه صنعتی خواجه نصیرالدین طوسی، دانشکده نقشه‌برداری، پ ۱۳۶۴.

۱- مقدمه

از میان مدل‌هایی که برای طبقه‌بندی داده‌ها در فضاهای با ابعاد بالا استفاده می‌شوند، مدلی که در سال‌های اخیر بیشتر استفاده می‌شود در شکل ۱ نشان داده شده است. بعد از ورود داده ابرطیفی (باکس ۱)، از طریق تعیین نمونه‌های آموزشی برای هر کلاس (باکس ۲) کلاس‌های مطلوب و مورد نظر مشخص می‌شوند. مراحل مهم بعدی در باکس‌های ۳ و ۴ مشخص شده‌اند که در مقاله حاضر روی این دو مرحله تمرکز بیشتری شده است. در روش‌های طبقه‌بندی فرض بر این است که برای دستیابی به تعریف و توصیفی کمی از کلاس‌ها (باکس ۳)، به تعداد کافی نمونه آموزشی وجود دارد. اما معمولاً در تصاویر ابرطیفی، تعداد نمونه‌های آموزشی مورد استفاده برای هر کلاس کمتر از تعداد ابعاد فضاست و قادر به آموزش کامل یک طبقه‌بندی‌کننده برای این تصاویر نیستند. این امر باعث بروز مشکلاتی مانند پدیده Hughes (Hughes, 1968) و یکتایی ماتریس‌های کوواریانس کلاس‌ها می‌گردد. یکی از مجموعه روش‌هایی که برای حل این مشکلات به کار گرفته می‌شود، روش‌های استخراج ویژگی است (باکس ۴).

داده‌های تصاویر چندطیفی و ابرطیفی، حاوی اطلاعات بسیار مفید و کاربردی از عوارض موجود در زمین هستند. مهمترین کاری که پس از دریافت این داده‌ها صورت می‌پذیرد، استخراج اطلاعات از آنهاست. روش‌های گوناگونی در سطوح مختلف برای دستیابی به هدف استخراج اطلاعات ارائه شده‌اند. از مهمترین راه‌های استخراج اطلاعات می‌توان به روش‌های طبقه‌بندی اشاره کرد. از این روش‌ها عموماً برای تهیه نقشه‌های موضوعی، و تفاسیر گوناگون (برحسب هدف و نیاز کاربر) استفاده می‌شود. در واقع روش‌های طبقه‌بندی توابعی هستند، که با استفاده از ویژگی‌های طیفی ثبت شده در پیکسل‌ها و همچنین نمونه‌های آموزشی جمع‌آوری شده، برجسب‌هایی را به هر یک از این پیکسل‌ها نسبت می‌دهند که کلاس هر کدام را نشان می‌دهد. یکی از مهمترین و پرکاربردترین روش‌های طبقه‌بندی، روش بیشترین احتمال است. این تابع برای انجام عملیات طبقه‌بندی، نیازمند محاسبه پارامترهای آماری هر کلاس است، که برای برآورد صحیح آنها بایستی مراحل ویژه‌ای طی گردند.



شکل ۱. نمودار اجمالی برای یک روش تجزیه و تحلیل داده‌های ابرطیفی

منبع: Kuo and Landgrebe, 2001, 2004

مورد بحث، در این مقاله از داده‌ی تصویری Indiana Pine استفاده شده است. این داده به‌وسیله‌ی سنجنده‌ی AVIRIS در ماه ژوئن ۱۹۹۲، به صورت Airborne در ارتفاع ۲۰ km از منطقه‌ی جنگلی / کشاورزی در ایالت ایندیانا‌ی کشور آمریکا تصویربرداری شده است. قدرت تفکیک مکانی آن در حد ۲۰ m و قدرت رادیومتریک آن برابر ۱۰ بیت است. این تصویر دارای ۱۶ کلاس و ۲۲۰ باند طیفی است، که در محدوده‌ی طیفی $0.4 - 2.5 \mu m$ تهیه شده‌اند.

باند‌های ۱۰۸-۱۰۴، ۱۶۳-۱۵۰، و ۲۲۰ آن جزو باند‌های جذبی بخار آب هستند، و اطلاعات مفیدی برای استخراج اطلاعات تفکیک‌پذیری کلاس‌های مورد نظر در اختیار نمی‌گذارند. از این‌رو، این باندها از لیست باند‌های مورد استفاده حذف شدند. از بین ۱۶ کلاس تصویر، ۱۰ کلاس (که دارای بیشترین نمونه‌های برچسب‌دار^۲ هستند)، برای بررسی الگوریتم‌های استخراج ویژگی انتخاب گردیدند. نام کلاس‌های انتخاب‌شده و همچنین تعداد نمونه‌های آنها در جدول ۱ آمده است.

۲-۲- بررسی شباهت طیفی کلاس‌های تصویر

Indiana Pine و تعیین کلاس‌های بحرانی

آنچه تفکیک‌پذیری کلاس‌ها را با دشواری و اشکال مواجه می‌سازد، در واقع شباهت طیفی آن کلاس‌هاست. از این‌رو، در اینجا قبل از به‌کارگیری داده‌ها در الگوریتم‌های استخراج ویژگی، شباهت طیفی آن کلاس‌ها بررسی شده است. در نوشتار حاضر، شباهت‌های طیفی کلاس‌های داده‌ی تصویری Indiana Pine با استفاده از معیارهای فاصله‌ی Bhattacharyya و JM مورد ارزیابی قرار گرفته‌اند (Fukunaga, 1990 و Theodoridis and Koutroumbas, 2003).

اکثر روش‌های استخراج ویژگی براساس محاسبه‌ی ماتریس‌های پراکندگی داخل‌کلاسی (S_w) و بین‌کلاسی (S_b) کلاس‌های تصویر و بیشینه‌سازی معیار فیشر ($S_b S_w^{-1}$)، ویژگی‌های مطلوب را استخراج می‌کنند. روش استخراج ویژگی غیرپارامتریک وزن‌دار^۱ (NWFE) به دلیل استفاده از همه‌ی نمونه‌های آموزشی کلاس‌ها و نیز محاسبه‌ی میانگین‌های وزن‌دار مختلف و ارائه‌ی تعریف غیرپارامتریک جدیدی از ماتریس‌های پراکندگی داخل‌کلاسی و بین‌کلاسی، منجر به دقت‌های طبقه‌بندی مناسب‌تر و مطلوب‌تری نسبت به سایر روش‌های استخراج ویژگی (مانند DAFE، aPAC-LDR، DBFE، و NDA) می‌گردد (Kuo and Landgrebe, 2001, 2004). اما وزن محاسباتی در این روش نمی‌تواند پراکندگی کلاس‌های بحرانی را به‌طور کامل مدل کند. در نوشتار حاضر با ارائه‌ی تابع وزن جدیدی، تابع وزن به کار رفته در روش NWFE کامل‌تر شده و بهبود یافته است.

۲- مواد و روش‌ها

روش‌های استخراج ویژگی، روش‌هایی هستند که با محاسبه‌ی ماتریس‌های پراکندگی داخل‌کلاسی (S_w) و بین‌کلاسی (S_b) و نیز با بیشینه‌کردن یک معیار مشخص، ویژگی‌هایی را استخراج می‌کنند که قادرند در حین حل مشکلاتی مانند پدیده‌ی Hughes (Hughes, 1968) نتیجه‌ی طبقه‌بندی را نیز بهبود بخشند. معیاری که در این مقاله مورد استفاده قرار گرفته، معیار فیشر ($S_b S_w^{-1}$) است، و استخراج‌گرهای ویژگی مورد بررسی، ویژگی‌های مطلوب را با بیشینه‌سازی ماتریس آن حاصل می‌کنند.

۲-۱- منطقه مورد مطالعه

به‌منظور بررسی و ارزیابی روش‌های استخراج ویژگی

1. Non-Parametric Weighted Feature Extraction
2. labeled samples

محسن فمری اصل و همکاران

جدول ۱. نام و تعداد نمونه‌های برچسب‌دار کلاس‌های انتخاب شده از تصویر Indiana Pine

تعداد نمونه‌های برچسب‌دار کلاس	برچسب کلاس	نام کلاس
۳۸۰	۱	Bldg-Grass-Tree-Drives
۴۸۹	۲	Hay-windrowed
۴۹۷	۳	Grass/Pasture
۶۱۴	۴	Soybean-clean
۷۴۷	۵	Grass/Trees
۸۳۴	۶	Corn-min
۹۶۸	۷	Soybeans-notill
۱۲۹۴	۸	Woods
۱۴۳۴	۹	Corn-notill
۲۴۶۸	۱۰	Soybeans-min
۹۷۲۵		Total Samples

جدول ۲. مقادیر معیارهای فاصله B و JM مربوط به هر زوج کلاس در تصویر Indiana Pine که براساس همین مقادیر (JM و B) مرتب شده است.

زوج کلاس				زوج کلاس			
کلاس اول	کلاس دوم	B	JM	کلاس اول	کلاس دوم	B	JM
۹	۱۰	۵/۷۴۲۳	۱/۹۹۳۶	۱	۳	۲۷/۳۷۳	۲
۷	۱۰	۶/۷۵۷۴	۱/۹۹۷۷	۵	۶	۲۸/۴۰۶	۲
۶	۱۰	۷/۸۵۴۱	۱/۹۹۹۲	۱	۱۰	۳۱/۰۳۹	۲
۷	۹	۸/۵۷۹۸	۱/۹۹۹۶	۱	۴	۳۲/۱۹۳	۲
۶	۹	۸/۸۶۶۷	۱/۹۹۹۷	۳	۶	۳۲/۶۲۵	۲
۴	۱۰	۱۰/۸۸۹	۲	۱	۷	۳۴/۴۷۹	۲
۶	۷	۱۱/۵۹۹	۲	۲	۷	۳۴/۸۵۲	۲
۴	۹	۱۳/۹۲۱	۲	۲	۱۰	۳۵/۷۷۵	۲
۴	۶	۱۴/۵۸۹	۲	۱	۹	۳۵/۸۴۵	۲
۴	۷	۱۴/۹۱۸	۲	۲	۳	۳۶/۵۰۱	۲
۵	۱۰	۱۷/۸۳۶	۲	۲	۴	۳۶/۹۱	۲
۱	۸	۱۸/۲۵۹	۲	۲	۵	۳۸/۹۱۸	۲
۵	۷	۱۸/۸۲۶	۲	۲	۹	۴۱/۷۷۱	۲
۳	۵	۱۹/۵۷۲	۲	۱	۶	۴۴/۵۹۱	۲
۵	۹	۲۰/۸۰۹	۲	۱	۲	۴۴/۶۵۱	۲
۵	۸	۲۱/۱۷۸	۲	۸	۱۰	۴۵/۷۲۲	۲
۳	۱۰	۲۱/۴۶	۲	۲	۶	۵۲/۷۸۴	۲
۳	۸	۲۲/۱۵۷	۲	۴	۸	۵۲/۹۰۵	۲
۱	۵	۲۲/۴۹۱	۲	۸	۹	۵۸/۸۵۶	۲
۳	۷	۲۳/۹۲۲	۲	۷	۸	۵۹/۷۰۹	۲
۳	۹	۲۶/۰۶۵	۲	۶	۸	۶۲/۵۹	۲
۴	۵	۲۶/۲۲۸	۲	۲	۸	۶۹/۰۳۲	۲
۳	۴	۲۷/۰۵۴	۲				

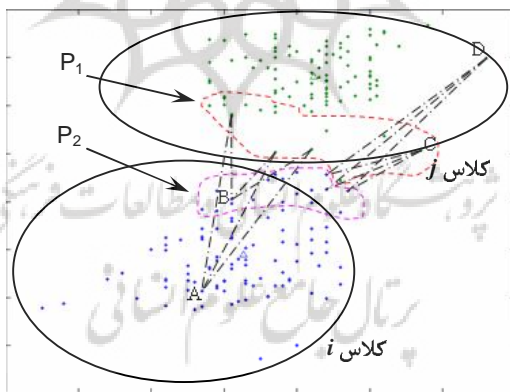
بردن کتا نزدیک‌ترین همسایگی، نمی‌توان تمام اطلاعات پراکندگی دو یا چند کلاس را نسبت به یکدیگر مورد ارزیابی دقیق قرار داد. به عبارت بهتر، همه نمونه‌های یک کلاس در چگونگی پراکندگی نمونه‌های آن کلاس نسبت به کلاس‌های دیگر نقش دارند. شکل ۲، پراکندگی نمونه‌های آموزشی دو کلاس i و j را نشان می‌دهد.

همان‌گونه در این شکل (شکل ۲) نیز مشاهده می‌شود، تنها بخشی از نمونه‌های یک کلاس برای محاسبه میانگین آن کلاس و نیز محاسبه پراکندگی آن نسبت به کلاس دیگر مورد استفاده قرار گرفته است (روش NDA). اما تعداد بیشتری از نمونه‌های آموزشی این کلاس‌ها در حوالی مرکز آنها پخش شده، و تنها تعداد معدودی از آنها (نمونه‌های آموزشی) در نزدیکی مرز دو کلاس قرار گرفته‌اند و همین امر نشان می‌دهد که برای تعریف کامل یک کلاس، همه نمونه‌های آن مورد نیاز است و به کار بردن تنها بخشی از نمونه‌های

همان‌طور که در جدول ۲ نیز مشاهده می‌شود، زوج کلاس‌های حاصل از کلاس‌های ۶، ۷، ۹، و ۱۰ جزو کلاس‌های بحرانی^۱ به‌شمار می‌آیند و زوج کلاس به‌دست آمده از کلاس‌های ۲ و ۸ کمترین شباهت طیفی را با سایر کلاس‌ها دارند.

۳-۲- روش استخراج ویژگی غیرپارامتریک وزن‌دار (NWFE)

Kuo و Landgrebe در سال ۲۰۰۴ و Fukunaga در سال ۱۹۹۰ با روش استخراج ویژگی NDA^۲ نشان دادند که استفاده از اطلاعات محلی و نقاط مرزی بسیار پراهمیت‌اند. این روش برای هر نمونه از یک کلاس، یک میانگین محلی را (با استفاده از کتا نزدیک‌ترین همسایگی) در کلاس دیگر حساب می‌کند، و سپس برای محاسبه ماتریس پراکندگی بین‌کلاسی دو کلاس، پراکندگی نمونه‌های کلاس اول را برحسب آن میانگین‌های محلی به‌دست می‌آورد. اما تنها با به‌کار



شکل ۲. پلی‌گون‌های P_1 و P_2 نشان می‌دهند که نزدیک‌ترین همسایگی‌های هر یک از کلاس‌ها تنها در بخش‌های کوچکی از آنها و در نزدیکی مرزشان، متمرکز شده‌اند. نقاط A و B (واقع در کلاس i) دارای کتا نزدیک‌ترین همسایگی مشترک در کلاس j ، و نقاط C و D (واقع در کلاس j) دارای کتا نزدیک‌ترین همسایگی مشترک در کلاس i هستند.

۱. کلاس‌هایی که پراکندگی نمونه‌های آن نسبت به یک کلاس خاص، به گونه‌ای است که به سادگی تفکیک‌شدنی نیستند.

2. Nonparametric Discriminant Analysis

صفر و در غیر این صورت به سمت ۱ میل خواهد کرد. از روش NDA می‌دانیم، که نقاط مرزی باید در محاسبه ماتریس‌های پراکندگی، وزن بیشتری را نسبت به نقاط دورتر از مرز داشته باشند. روش $NWFE$ این وزن را به صورت زیر تعریف می‌کند:

$$\lambda_1^{(i,j)} = \frac{\text{dist}(\mathbf{x}_1^{(i)}, M_j(\mathbf{x}_1^{(i)}))^{-1}}{\sum_{l=1}^{N_j} \text{dist}(\mathbf{x}_1^{(i)}, M_j(\mathbf{x}_1^{(i)}))^{-1}} \quad \text{رابطه (۳)}$$

که در این رابطه، $\lambda_1^{(i,j)}$ تابع وزنی است که بایستی بر بردارهای بین‌کلاسی اعمال گردد.

تابع وزن $\lambda_{lk}^{(i,j)}$ تشابه زیادی به تابع وزن $w_{lk}^{(i,j)}$ دارد، از این‌رو خصوصیات آن نیز بسیار مشابه خصوصیات تابع وزن $w_{lk}^{(i,j)}$ خواهند بود:

۱. با به‌کار بردن معکوس فاصله، نمونه‌های نزدیک‌تر به مرز دارای وزن بیشتر و نمونه‌های دورتر از آن دارای وزن کمتری خواهند شد. بدین ترتیب، مشکل نمونه‌های $Outlier$ نیز از بین می‌رود.
۲. مجموع وزن‌های $\lambda_1^{(i,j)}$ ، برای تمام نمونه‌های کلاس i ، $l = 1, 2, \dots, N_i$ ، برابر ۱ است ($\sum_{l=1}^{N_i} \lambda_1^{(i,j)} = 1$).

۳. هر چه فاصله اقلیدسی بین نمونه $\mathbf{x}_1^{(i)}$ و میانگین متناظرش در کلاس j ($M_j(\mathbf{x}_1^{(i)})$)، افزایش یابد، آنگاه مقدار وزن $\lambda_1^{(i,j)}$ به سمت صفر و در غیر این صورت به سمت ۱ میل خواهد کرد.

روش $NWFE$ با استفاده از تابع وزن $\lambda_1^{(i,j)}$ ، ماتریس پراکندگی بین‌کلاسی (S_b) را به صورت غیرپارامتریک رابطه (۴) ارائه می‌دهد:

$$S_b^{NW} = \sum_{i=1}^L P_i \sum_{j=1}^L \sum_{l=1}^{N_i} \frac{\lambda_l^{(i,j)}}{N_i} (\mathbf{x}_1^{(i)} - M_j(\mathbf{x}_1^{(i)})) (\mathbf{x}_1^{(i)} - M_j(\mathbf{x}_1^{(i)}))^T \quad \text{رابطه (۴)}$$

۱. نمونه‌هایی که در فواصل دورتر نسبت به یک نمونه مشخص قرار گرفته‌اند، و از نظر پراکندگی حالت بحرانی ندارند و به آسانی از آن تفکیک‌پذیرند.

آموزشی نمی‌تواند بیان خوبی از خود کلاس به ما بدهد. بنابراین، برای بیان بهتر و دقیق‌تر پراکندگی بین دو کلاس، بایستی از همه نمونه‌های آموزشی آن کلاس‌ها بهره‌گرفت و همه آنها را در محاسبه ماتریس S_b شرکت داد. در عین حال، باید به گونه‌ای عمل شود که نمونه‌های $Outlier$ هر نمونه مشخص وزن کمتر و داده‌های نزدیک‌تر به آن، وزن بیشتری را به خود اختصاص دهند.

برای رسیدن به این مقصود، روش $NWFE$ تعریف جدیدی از وزن را ارائه کرده است. این وزن از فاصله اقلیدسی بین دو نمونه استفاده می‌کند و به صورت ذیل تشکیل می‌یابد (Kuo and Landgrebe, 2001, 2004):

$$w_{lk}^{(i,j)} = \frac{\text{dist}(\mathbf{x}_l^{(i)}, \mathbf{x}_k^{(j)})^{-1}}{\sum_{t=1}^{N_j} \text{dist}(\mathbf{x}_l^{(i)}, \mathbf{x}_t^{(j)})^{-1}} \quad \text{رابطه (۱)}$$

که در آن $\text{dist}(\mathbf{x}_l^{(i)}, \mathbf{x}_k^{(j)})$ بیانگر فاصله اقلیدسی بین نمونه l -ام کلاس i و نمونه k -ام کلاس j و $w_{lk}^{(i,j)}$ تابع وزن مربوط به $\mathbf{x}_l^{(i)}$ و متناظر با $\mathbf{x}_k^{(j)}$ است. میانگین کلاس j به ازای $\mathbf{x}_1^{(i)}$ از طریق مجموع وزن‌دار نمونه‌های آن (کلاس j) حاصل می‌شود:

$$M_j(\mathbf{x}_1^{(i)}) = \sum_{k=1}^{N_j} w_{lk}^{(i,j)} \mathbf{x}_k^{(j)} \quad \text{رابطه (۲)}$$

در این رابطه، $M_j(\mathbf{x}_1^{(i)})$ میانگین کلاس j ، متناظر با نمونه $\mathbf{x}_1^{(i)}$ است.

خصوصیات تابع وزن $w_{lk}^{(i,j)}$ اینها هستند:

۱. با به‌کار بردن معکوس فاصله، نمونه‌های نزدیک‌تر به $\mathbf{x}_1^{(i)}$ دارای وزن بیشتر و نمونه‌های دورتر از آن دارای وزن کمتری خواهند شد. بدین ترتیب، مشکل نمونه‌های $Outlier$ نیز از بین می‌رود.

۲. مجموع وزن‌های $w_{lk}^{(i,j)}$ ، برای تمام نمونه‌های کلاس j ، $k = 1, 2, \dots, N_j$ ، برابر ۱ است ($\sum_{k=1}^{N_j} w_{lk}^{(i,j)} = 1$).

۳. هر چه فاصله اقلیدسی بین نمونه‌های $\mathbf{x}_k^{(j)}$ و $\mathbf{x}_1^{(i)}$ ، افزایش یابد، آنگاه مقدار وزن $w_{lk}^{(i,j)}$ به سمت

اشکال روش NWFE نیز در این است که توابع وزن مورد استفاده در آن ($w_{lk}^{(i,j)}$ و λ_{ij}) تنها از یک پارامتر فاصله استفاده می‌کنند، در حالی که علاوه بر فاصله بین دو نمونه، رابطه ترکیب خطی بین آنها نیز در تعیین میزان شباهت طیفی آنها مؤثر است و آزمایش‌ها نشان داده‌اند که لزوماً فاصله کوتاه‌تر بیانگر میزان شباهت طیفی بیشتر نیست.

۲-۴- روش پیشنهادی استخراج ویژگی ترکیب خطی غیرپارامتریک وزن‌دار (LC-NWFE)

روش LC-NWFE برای رفع عیب روش NWFE ارائه شده است (Ghamary Asl et al., 2006). در روش استخراج ویژگی غیرپارامتریک وزن‌دار (NWFE) تنها از فاصله بین هر زوج نمونه برای تشکیل تابع وزن استفاده می‌گردد. اما، فقط با استفاده از این عامل نمی‌توان وزن یک نمونه را در قبال نمونه دیگر به‌طور کامل مشخص کرد. مسئله این است که نمونه‌های آموزشی موجود در یک کلاس بایستی در همه باندها ترکیب خطی از یکدیگر باشند، و از طرفی نمونه‌های آموزشی موجود در دو کلاس متفاوت بایستی در همه باندها استقلال خطی از یکدیگر داشته باشند. هر چه میزان شباهت طیفی دو کلاس بالا باشد، آنگاه شدت وابستگی نمونه‌های آن دو کلاس نیز افزایش خواهد یافت (شکل ۳). هر چه وابستگی بین دو نمونه بیشتر گردد، آنگاه می‌توان مقادیر یکی از آن دو نمونه را (تقریباً در تمام باندها) تا حد زیادی به وسیله نمونه دیگر برآورد کرد. عکس این مطلب نیز صادق است (شکل ۴)، یعنی اگر استقلال خطی بین دو نمونه بالا باشد، آنگاه آن دو نمونه برآورد مناسبی را از یکدیگر به‌دست نخواهند داد؛ باید در نظر داشت که این وضعیت با کاهش شباهت طیفی بین کلاس‌ها شدیدتر می‌شود.

در این روش، تعریف جدید غیرپارامتریک نیز از ماتریس پراکندگی داخلی کلاسی ارائه شده است:

رابطه (۵)

$$S_w^{NW} = \sum_{i=1}^L P_i \sum_{j=1}^{N_i} \frac{\lambda_{ij}}{N_i} (\mathbf{x}_i^{(i)} - M_i(\mathbf{x}_i^{(i)})) (\mathbf{x}_i^{(i)} - M_i(\mathbf{x}_i^{(i)}))^T$$

در روابط (۴) و (۵)، N_i و N_j به ترتیب، تعداد نمونه‌های آموزشی کلاس‌های i و j هستند و ضریب P_i بیانگر پیش‌احتمال کلاس i است:

$$P_i = \frac{N_i}{\sum_{c=1}^L N_c}$$

روش NWFE برای غلبه بر مشکل یکتایی ماتریس S_w آن را با یکی از روش‌های عادی‌سازی^۱ (Kuo and Landgrebe, 2001) برآورد می‌کند:


رابطه (۶)

$$S_{w_{regularized}}^{NW} = \alpha S_w^{NW} + (1-\alpha) \text{diag}(S_w^{NW})$$

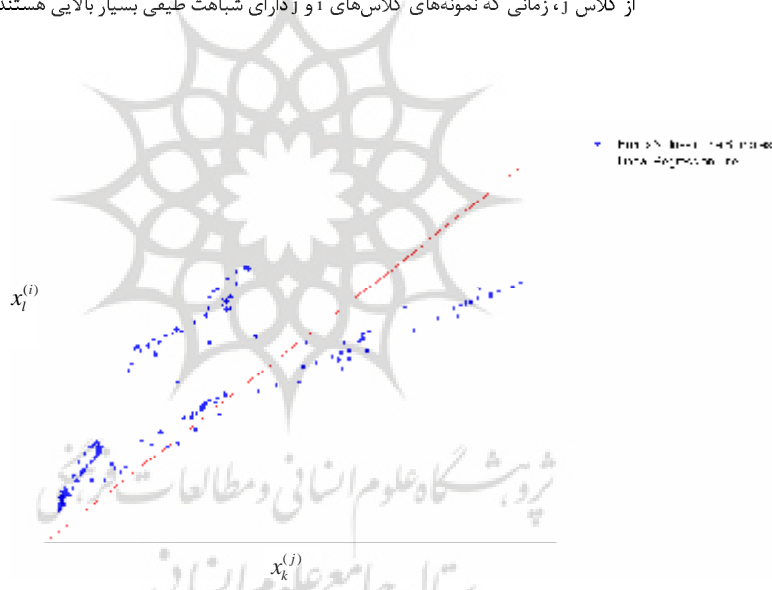
که در این رابطه، ماتریس پراکندگی داخلی کلاسی عادی‌سازی شده و $\text{diag}(S_w^{NW})$ شکلی قطری ماتریس پراکندگی داخلی کلاسی (S_w^{NW}) است. مزایای روش NWFE را می‌توان چنین برشمرد:

۱. استخراج بیش از $L-1$ ویژگی؛
۲. رسیدن به دقت‌های بالاتر در تعداد ویژگی‌های کمتر؛
۳. بالا رفتن دقت طبقه‌بندی در مقایسه با روش‌های قبلی؛
۴. حذف شکل یکتایی ماتریس پراکندگی داخلی کلاسی (که خود باعث کاهش تعداد مجهولات می‌شود)؛ و
۵. پوشش دادن تمام نمونه‌ها و استفاده از همه اطلاعات موجود در کلاس‌ها (که سبب ارزیابی دقیق‌تر پراکندگی آنها نسبت به یکدیگر می‌گردد).

1. regularization
2. Linear Combination-Nonparametric Weighted Feature Extraction



شکل ۳. پراکندگی مقادیر باندهای یک نمونه از کلاس i در مقابل مقادیر باندهای یک نمونه از کلاس j ، زمانی که نمونه‌های کلاس‌های i و j دارای شباهت طیفی بسیار بالایی هستند.



شکل ۴. پراکندگی مقادیر باندهای یک نمونه از کلاس i در مقابل مقادیر باندهای یک نمونه از کلاس j زمانی که نمونه‌های کلاس‌های i و j دارای شباهت طیفی بسیار پایینی هستند.

برآورد خوبی را از هم حاصل کرده‌اند. اما در شکل ۴ درست عکس این مطلب اتفاق افتاده است. برآورد یک نمونه از طریق نمونه دیگر را می‌توان به صورت رابطه (۷) مطرح کرد.

در شکل‌های ۳ و ۴ خط برازش در واقع شامل مقادیر برآورد شده نمونه $x_k^{(i)}$ از نمونه $x_k^{(j)}$ است. در شکل ۳ دو نمونه مورد بررسی، در تمام باندها شباهت طیفی بسیار زیادی به یکدیگر دارند و به همین دلیل

$$\hat{x}_1^{(i)} = ax_k^{(j)} \Rightarrow \text{RMSE}(x_1^{(i)}, x_k^{(j)}) = \sqrt{((x_1^{(i)} - \hat{x}_1^{(i)})^t (x_1^{(i)} - \hat{x}_1^{(i)}))} \quad \text{رابطه (۷)}$$

باید توجه داشت که با محاسبه وزن‌های فوق، ماتریس‌های پراکندگی داخل کلاسی و بین کلاسی به روش مشابه در استخراج‌گر ویژگی NWFEE حاصل می‌شوند. در این روش نیز ویژگی‌های مطلوب با بیشینه کردن معیار فیشر به دست می‌آیند.

۳- نتایج

برای بررسی و ارزیابی الگوریتم‌های فوق، هر دو روش در محیط برنامه‌نویسی MATLAB پیاده‌سازی و بر روی داده تصویری منطقه Indiana Pine (بخش ۱-۲) آزمایش شدند.

به منظور ارزیابی روش‌های استخراج ویژگی غیرپارامتریک وزن‌دار (NWFEE) و روش ترکیب خطی - غیرپارامتریک وزن‌دار (LC-NWFEE) ۱۵ مجموعه داده از داده تصویری Indiana Pine مورد استفاده قرار گرفتند که در هر یک از آنها برای هر کلاس، ۶۰ تا نمونه آموزشی (به صورت تصادفی) انتخاب شد و بقیه نمونه‌ها به عنوان نمونه‌های آزمایشی در نظر گرفته شدند.

پس از استخراج ویژگی‌ها از طریق روش‌های NWFEE و LC-NWFEE، با به‌کارگیری ۱ تا ۲۰ ویژگی (که به‌ازای هر تعداد ویژگی، ۱۵ مجموعه داده مذکور استفاده شدند)، اقدام به طبقه‌بندی تصویر به روش بیش‌ترین احتمال^۲ گردید.

در مجموع ۳۰۰ بار طبقه‌بندی برای هر روش انجام گرفت که در ادامه به منظور ارزیابی نتایج آنها، بهترین نتیجه به دست آمده، بدون توجه به تعداد ویژگی‌های به کار رفته در هر کدام از روش‌ها (بدین معنا که ممکن است بهترین نتیجه برای دو روش فوق در تعداد ویژگی‌های یکسان رخ ندهد) و تنها بر اساس دقت کاپای حاصل شده برای هر کدام، مورد استفاده قرار می‌گیرد.

در رابطه مذکور، a پارامتر ترکیب خطی بین نمونه‌های $x_1^{(i)}$ ، $x_k^{(j)}$ و $\hat{x}_1^{(i)}$ برآورد نمونه i -ام کلاس i از طریق نمونه k -ام کلاس j و ریشه مجموع مربعات خطا^۱ (RMSE) بیانگر فاصله بین مقدار برآورد شده $\hat{x}_1^{(i)}$ و مقدار واقعی $x_1^{(i)}$ است.

هر چه مقدار برآورد شده به مقدار واقعی نزدیک‌تر باشد (شکل ۳) آنگاه مقدار ریشه مجموع مربعات خطا (RMSE) کوچک‌تر خواهد شد، و برعکس. بنابراین، می‌توان از RMSE حاصل از ترکیب خطی بین هر زوج نمونه، برای تکمیل تابع وزن به کار رفته در روش NWFEE و بهبود نتایج این روش استفاده کرد. در این روش توابع وزن مورد نظر به صورت رابطه (۸) معرفی می‌گردند:

رابطه (۸)

$$w_{lk}^{(i,j)} = \frac{\text{dist}(x_1^{(i)}, x_k^{(j)})^{-1} \times \text{RMSE}(x_1^{(i)}, x_k^{(j)})^{-1}}{\sum_{k=1}^{N_j} \text{dist}(x_1^{(i)}, x_k^{(j)})^{-1} \times \text{RMSE}(x_1^{(i)}, x_k^{(j)})^{-1}}$$

$w_{lk}^{(i,j)}$ وزنی است که در این روش معرفی شده است. برای افزایش نقش کلاس‌های بحرانی، معکوس RMSE مورد استفاده قرار گرفته است.

با استفاده از این وزن، میانگین به صورت زیر محاسبه می‌شود (که همان شیوه به کار گرفته شده در روش NWFEE است):

$$M_j(x_1^{(i)}) = \sum_{k=1}^{N_j} w_{lk}^{(i,j)} x_k^{(j)} \quad \text{رابطه (۹)}$$

$M_j(x_1^{(i)})$ میانگین کلاس j ، متناظر با نمونه $x_1^{(i)}$ است.

با استفاده از $M_j(x_1^{(i)})$ وزن $\lambda_1^{(i,j)}$ به کمک رابطه (۱۰) محاسبه می‌گردد.

رابطه (۱۰)

$$\lambda_1^{(i,j)} = \frac{\text{dist}(x_1^{(i)}, M_j(x_1^{(i)}))^{-1} \times \text{RMSE}(x_1^{(i)}, M_j(x_1^{(i)}))^{-1}}{\sum_{j=1}^{N_j} \text{dist}(x_1^{(i)}, M_j(x_1^{(i)}))^{-1} \times \text{RMSE}(x_1^{(i)}, M_j(x_1^{(i)}))^{-1}}$$

1. Residual Mean Square Error
2. Maximum Likelihood

۳-۱- ارزیابی استخراج ویژگی غیرپارامتریک وزن دار (NWFE)

در ادامه، ماتریس خطای بهترین نتیجه حاصل از ۳۰۰ بار طبقه‌بندی براساس بیشترین مقدار دقت کاپا آمده است (جدول ۳). لازم به ذکر است که این نتیجه (برای روش NWFE) در استفاده از ۱۰ ویژگی استخراج شده، حاصل گردیده است.

با توجه به جدول ماتریس خطای فوق و ستون Product Accuracy آن (جدول ۳) می‌توان گفت که کلاس‌های ۲، ۳، ۴، ۵ و ۸ به خوبی طبقه‌بندی شده‌اند، و کلاس‌های ۶، ۷، ۹ و ۱۰ دارای دقت طبقه‌بندی نسبتاً مناسبی هستند. علت این امر را می‌توان در چگونگی انتخاب نمونه‌های آموزشی این کلاس‌ها در مجموعه داده متناظر با ماتریس خطای فوق (جدول ۳) و همچنین در توانمندی ویژگی‌های استخراج شده به‌وسیله روش NW در جداسازی کلاس‌ها جست‌وجو کرد. بدین معنی که این نمونه‌های آموزشی نماینده‌های

مناسبی برای نمایش و تعریف کلاس‌ها هستند و نیز ویژگی‌های استخراج شده از طریق NWFE به خوبی توانسته‌اند آنها را طبقه‌بندی کنند.

علاوه بر موارد مذکور، با توجه به پارامترهای تفکیک‌پذیری جدول ۲ که قبل از استخراج ویژگی در فضای کامل داده‌ها محاسبه گردیده‌اند، می‌توان مشاهده کرد که کلاس‌های ۲، ۳، ۴، ۵ و ۸ که در فضای اولیه دارای تفکیک‌پذیری مناسبی هستند، پس از به‌کارگیری استخراج‌گر ویژگی غیرپارامتریک وزن دار نیز از سایر کلاس‌ها به خوبی مجزا شده‌اند. در عین حال کلاس‌های ۶، ۷، ۹ و ۱۰ که طبق جدول ۲ دارای شباهت طیفی بسیار بالایی هستند، به‌وسیله روش استخراج ویژگی NW با دقت طبقه‌بندی نسبتاً خوبی از سایر کلاس‌ها تفکیک گردیده‌اند. این در حالی است که کلاس ۱ (با توجه به این‌که جزو کلاس‌های بحرانی نیست) با دقت مناسبی جدا نشده است.

جدول ۳. ماتریس خطای بهترین نتیجه حاصل از ۳۰۰ بار طبقه‌بندی داده تصویری Indiana Pine که به‌وسیله ویژگی‌های استخراج شده از روش NWFE انجام شده‌اند. این نتیجه در استفاده از ۱۰ ویژگی استخراج شده، حاصل گردیده‌است.

Class Number	Product Accuracy (%)	Number of Test Samples	Class Number									
			1	2	3	4	5	6	7	8	9	10
1	75.6	320	242	0	10	3	4	1	0	60	0	0
2	98.8	429	5	424	0	0	0	0	0	0	0	0
3	92.7	437	9	0	405	13	1	0	0	8	0	1
4	94.8	554	4	0	3	525	0	10	5	0	0	7
5	91	687	56	0	3	0	625	0	1	1	0	1
6	75.8	774	1	0	0	101	0	587	0	0	24	61
7	80.7	908	6	0	7	0	5	27	733	0	48	82
8	92.6	1234	88	0	3	0	0	0	0	1143	0	0
9	77.1	1374	10	0	3	16	4	50	88	0	1059	144
10	68.9	2408	13	0	24	241	1	125	144	0	201	1659
Total		9125	434	424	458	899	640	800	971	1212	1332	1955
User Accuracy (%)			55.8	100	88.4	58.4	97.7	73.4	75.5	94.3	79.5	84.9
Overall Accuracy:			81.1%			Kappa Accuracy: 78.2%						

بهبود روش استخراج ویژگی غیرپارامتریک وزن‌دار با استفاده از ترکیب خطی نمونه‌های آموزشی در تصاویر ابرطیفی

۳-۲- ارزیابی استخراج‌گر ویژگی ترکیب

غیرخطی پارامتریک وزن‌دار (LC-NWFE)

در ادامه، ماتریس خطای بهترین نتیجه حاصل از ۳۰۰ بار طبقه‌بندی براساس بیشترین مقدار دقت کاپا آمده است (جدول ۴). لازم به ذکر است که این نتیجه (برای روش LC-NWFE) در استفاده از ۱۱ ویژگی استخراج شده، حاصل گردیده است.

با توجه به جدول ماتریس خطای فوق و ستون Product Accuracy آن (جدول ۴) می‌توان گفت که کلاس‌های ۲، ۳، ۴، ۵ و ۸ به خوبی طبقه‌بندی شده‌اند و کلاس‌های ۶، ۷، ۹ و ۱۰ دارای دقت طبقه‌بندی مناسبی هستند. علت این امر را می‌توان در چگونگی انتخاب نمونه‌های آموزشی این کلاس‌ها در مجموعه داده متناظر با ماتریس خطای فوق (جدول ۴) و همچنین در توانمندی ویژگی‌های استخراج شده به‌وسیله روش LC-NW در جداسازی کلاس‌ها جستجو کرد.

بدین معنی که این نمونه‌های آموزشی نماینده‌های مناسبی برای نمایش و تعریف کلاس‌ها به‌شمار می‌آیند و ویژگی‌های استخراج شده از طریق LC-NWFE نیز به خوبی آنها را طبقه‌بندی کرده‌اند.

علاوه بر موارد مذکور، با توجه به پارامترهای تفکیک‌پذیری جدول ۲، می‌توان مشاهده کرد که کلاس‌های ۲، ۳، ۴، ۵ و ۸ که در فضای اولیه دارای تفکیک‌پذیری مناسبی هستند، پس از به‌کارگیری استخراج‌گر ویژگی LC-NW نیز از سایر کلاس‌ها به خوبی مجزا شده‌اند. این در حالی است که، کلاس‌های ۶، ۷، ۹ و ۱۰ (که طبق جدول ۲ دارای شباهت طیفی بسیار بالایی هستند)، به‌وسیله روش استخراج ویژگی LC-NW به خوبی و با دقت طبقه‌بندی مناسبی از سایر کلاس‌ها تفکیک گردیده‌اند. ضمناً طبقه‌بندی کلاس ۱ (با توجه به این که جزو کلاس‌های بحرانی به‌شمار نمی‌آید) پس از استفاده از روش LC-NW دقت مناسبی یافته است.

جدول ۴. ماتریس خطای بهترین نتیجه حاصل از ۳۰۰ حالت طبقه‌بندی داده تصویر Indiana Pine که از طریق ویژگی‌های استخراج شده از روش LC-NWFE انجام شده‌اند. این نتیجه در استفاده از ۱۱ ویژگی استخراج شده، حاصل گردیده است.

Class Number	Product Accuracy (%)	Number of Test Samples	Class Number									
			1	2	3	4	5	6	7	8	9	10
1	79.1	320	253	0	2	3	5	1	0	56	0	0
2	98.8	429	5	424	0	0	0	0	0	0	0	0
3	95.7	437	3	0	418	13	1	0	0	1	0	1
4	94	554	6	0	2	521	0	11	5	0	2	7
5	94	687	35	0	2	0	646	0	0	3	0	1
6	81	774	1	0	0	53	0	627	1	0	26	66
7	83.6	908	3	0	5	2	7	18	759	0	32	82
8	93.4	1234	78	0	3	0	1	0	0	1152	0	0
9	81.1	1374	6	0	5	8	3	61	80	0	1114	97
10	68.3	2408	8	0	32	250	3	135	151	0	185	1644
Total		9125	398	424	469	850	666	853	996	1212	1359	1898
User Accuracy (%)			63.6	100	89.1	61.3	97	73.5	76.2	95	82	86.6
Overall Accuracy:			82.8%			Kappa Accuracy: 80.2%						

۴- بحث و نتیجه‌گیری

بدیهی است که مهمترین هدف در طبقه‌بندی، دستیابی به بهترین دقت جداسازی کلاس‌های تصویر است. از این رو می‌توان گفت که آنچه در بررسی ۳۰۰ بار طبقه‌بندی (برای هر روش) اهمیت دارد، این است که کدام روش در مجموع، بهترین دقت طبقه‌بندی را حاصل کرده است.

با مقایسه جداول ۳ و ۴ مشاهده می‌شود که میزان دقت‌های طبقه‌بندی کلاس‌های بحرانی ۶، ۷ و ۹ در جدول ۴ (که از طریق ویژگی‌های استخراج شده به‌وسیله روش LC-NWFE حاصل شده‌اند) در مقایسه با مقادیر متناظرشان در جدول ۳ (که از طریق ویژگی‌های استخراج شده به‌وسیله روش NWFE حاصل گردیده‌اند) بسیار بالاترست. دلیل این امر را می‌توان در اعمال تابع وزن جدید دانست که پراکندگی کلاس‌های بحرانی را نسبت به هم و نسبت به کلاس‌های دیگر بهتر تعریف می‌کند. از طرفی، نتایج طبقه‌بندی کلاس‌های ۲ و ۸ در جدول‌های ۳ و ۴ تغییرات شاخصی ندارند، چرا که به دلیل تشابه بسیار کم آنها (جدول ۲)، هر دو روش توانسته‌اند به خوبی آنها را طبقه‌بندی کنند. اما کلاس‌های ۳ و ۵ بعد از اعمال استخراج‌گر ویژگی LC-NW دارای دقت‌های طبقه‌بندی بهتر و مناسب‌تری نسبت به نتایج حاصل از روش NWFE (جدول ۳) شده‌اند. همان‌طور که اشاره شد، کلاس‌های ۲ و ۸ شباهت طیفی بسیار کمی با سایر کلاس‌ها دارند، لیکن کلاس‌های ۳ و ۵ با برخی کلاس‌ها تشابه طیفی بالایی دارند (مانند زوج کلاس‌های (۳، ۱۰) و (۵، ۱۰)) و این امر بیان می‌دارد که روش LC-NWFE حساسیت بالاتری نسبت به کلاس‌های Outlier و نیز کلاس‌های بحرانی دارد و نقش کلاس‌های بحرانی را در محاسبه ماتریس‌های پراکندگی داخل کلاسی و بین کلاسی بیش از پیش افزایش می‌دهد. از این رو، استخراج‌گر ویژگی LC-NW زمانی که وضعیت کلاس‌ها بحرانی‌تر باشد بهتر از روش NWFE عمل خواهد کرد.


لازم به ذکر است که در این روش دقت نتیجه طبقه‌بندی کلاس ۱ در مقایسه با روش NWFE افزایش شدیدی یافته است، که علت این امر را می‌توان در چگونگی انتخاب نمونه‌های آموزشی این کلاس در مجموعه داده متناظر با ماتریس خطای فوق (جدول ۴) و توانمندی ویژگی‌های استخراج شده به‌وسیله روش LC-NWFE در جداسازی کلاس ۱ از سایر کلاس‌ها جست‌وجو کرد. بدین معنی که این نمونه‌های آموزشی نماینده‌های مناسبی برای نمایش و تعریف کلاس ۱ به‌شمار می‌آیند و نیز ویژگی‌های استخراج شده از طریق استخراج‌گر ویژگی LC-NW به خوبی توانسته‌اند که این کلاس را از سایر کلاس‌ها جدا کنند.

بررسی نتیجه طبقه‌بندی کلاس ۱۰ نشان می‌دهد که نتایج حاصل برای دو روش NWFE و LC-NWFE تغییرات عمده‌ای نسبت به هم ندارند، که دلیل آن نیز می‌تواند در چگونگی انتخاب نمونه‌های آموزشی این کلاس در مجموعه داده متناظر با ماتریس خطای فوق (جدول ۴) و ویژگی‌های استخراج شده به‌وسیله روش LC-NWFE باشد؛ به‌طوری که هیچ یک از این دو عامل (چگونگی انتخاب نمونه‌های آموزشی و ویژگی‌های استخراج شده) نتوانسته‌اند تأثیری جدی بر جداسازی کلاس ۱۰ از سایر کلاس‌ها بگذارند.

به‌منظور مقایسه بهتر روش‌های استخراج ویژگی LC-NW و NW، نتایج حاصل از ارزیابی آنها در شکل ۵ ترکیب شده و در قالب دو نمودار نمایش داده شده است. در ضمن نتایج مربوط به نمودارهای موجود در این شکل در جدول ۵ آمده‌اند که بیشترین مقادیر حاصل برای هر روش با هاشور مشخص گردیده‌اند. اعداد واقع در ستون Features این جدول بیانگر تعداد ویژگی‌های استفاده شده برای طبقه‌بندی هستند.

شکل ۵ و جدول ۵، به خوبی نشان می‌دهند که در همه ویژگی‌ها (به‌جز ویژگی ۵، که اختلافشان بسیار جزئی است)، نتایج دقت کاپای حاصل از روش LC-NWFE بهتر از نتایج متناظر به‌دست آمده از روش NWFE هستند.

بهبود روش استخراج ویژگی غیرپارامتریک وزن‌دار با استفاده از ترکیب خطی نمونه‌های آموزشی در تصاویر ابرطیفی



شکل ۵. نتایج طبقه‌بندی تصویر Indiana Pine با استفاده از ویژگی‌های استخراج شده به‌وسیله روش‌های NWFE و LC-NWFE

جدول ۵. مقادیر میانگین‌های دقت‌های کاپای حاصل از روش‌های NWFE و LC-NWFE

Features	NW	LC-NW
1	31.624	31.835
2	48.072	48.077
3	54.159	54.067
4	59.799	62.224
5	66.704	66.021
6	68.663	69.431
7	70.346	72.435
8	72.793	73.687
9	74.257	76.62
10	74.719	77.095
11	74.506	77.919
12	73.995	77.808
13	73.486	77.407
14	72.974	76.885
15	72.533	76.356
16	71.949	75.87
17	71.287	75.321
18	70.609	74.834
19	70.231	74.357
20	69.832	74.044

روش LC-NWFE که در این مقاله ارائه گردید، همه مزایای استخراج گر ویژگی غیرپارامتریک وزن‌دار را داراست و علاوه بر این بر عیب آن نیز غلبه می‌کند و با تعریف توابع وزن جدید، توابع وزن تعریف شده در

- Ghamary Asl M., Mobasheri M.R., Valadan Zouj M.J., Mojarradi B., 2006, **Using Nonparametric Weighted Feature Extractor for Dimensionality Reduction of the Hyperspectral Images**, M.Sc. Thesis, Remote Sensing Department, Faculty of Geodesy and Geomatics, Khajeh Nasir-addin Toosi University.
- Hughes G.F., 1968, **On the Mean Accuracy of Statistical Pattern Recognition**, IEEE Trans. Information Theory, Vol. IT-14, No. 1, pp. 55-63.
- Kuo B-C. and Landgrebe D.A., 2001, **Improved Statistics Estimation And Feature Extraction for Hyperspectral Data Classification**, Ph.D. Thesis and School of Electrical & Computer Engineering Technical Report, TR-ECE 01-6.
- Kuo B-C. and Landgrebe D.A., 2004, **Nonparametric Weighted Feature Extraction for Classification**, IEEE Transactions on Geoscience and Remote Sensing, Vol. 42 No. 5, pp. 1096-1105.
- Theodoridis S. and Koutroumbas K., 2003, **Pattern Recognition**, Department of Informatics and Telecommunications, University of Athens, Greece: Academic Press Inc., Second Edition.
- روش NWFE را کامل تر می کند. این وزن های جدید، نقش کلاس های بحرانی را پررنگ تر و نقش کلاس های Outlier را کم رنگ تر می کنند. ارزیابی ها و مقایسه های واقع در بخش ۳ نشان می دهند که:
۱. روش LC-NWFE تقریباً در مورد همه کلاس ها و به ویژه در مورد کلاس های بحرانی، عملکرد بهتری در مقایسه با روش NWFE دارد.
 ۲. روش LC-NWFE در تعداد ویژگی های برابر، دقت های طبقه بندی مطلوب تری را به دست می دهد. به عنوان مثال، روش NWFE با استفاده از ۱۰ تا ویژگی، دقت ۷۴/۷۲ درصد را برای طبقه بندی حاصل کرده است، در حالی که روش LC-NWFE با استفاده از همین تعداد ویژگی، دقت ۷۷/۱۰ درصد را برای طبقه بندی تصویر Indiana Pine به دست داده است.
 ۳. در روش LC-NWFE پدیده Hughes در مقایسه با روش NWFE دیرتر رخ می دهد.
 ۴. با افزایش تعداد ویژگی های مورد استفاده، اختلاف بین نتایج روش های LC-NWFE و NWFE نیز افزایش می یابد.
 ۵. روش LC-NWFE توانسته است در تعداد ویژگی های کمتر به دقت های طبقه بندی بالاتری در مقایسه با روش NWFE برسد. برای مثال روش NWFE در ۱۰ تا ویژگی، دقت ۷۴/۷۲ درصد (که بالاترین دقت میانگین آن است) و روش LC-NWFE با استفاده از ۹ ویژگی، دقت ۷۶/۶۲ درصد را (که بالاترین دقت میانگین آن نیست) به دست داده است.

۵- منابع

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