



دانشکده مهندسی معدن، نفت و ژئوفیزیک

رساله دکتری اکتشاف مواد معدنی

# طبقه‌بندی مناطق دگرسانی با استفاده از ماشین بردار پشتیبان مقاوم در برابر نویز و تصویر ابرطیفی هایپریون

دانشجو: امیر سلیمی

استاد راهنما

دکتر منصور ضیائی

اساتید مشاور

دکتر علی امیری

دکتر مهدیه حسینجانی‌زاده

بهمن ۱۳۹۵

شماره: ۲۰۰۲-۹۵۱۱۹۰۰۲  
 تاریخ: ۱۷/۱۲/۹۵  
 ویرایش:

باسمه تعالی



مدیریت تحصیلات تکمیلی

فرم شماره ۱۲. صورت جلسه نهایی دفاع از رساله دکتری (Ph.D)  
 (ویژه دانشجویان ورودی های ۹۴ و ما قبل)

بدینوسیله گواهی می شود آقای امیر سلیمی دانشجوی دکتری رشته مهندسی معدن به شماره دانشجویی ۹۰۲۳۳۴۵ ورودی مهر ماه سال ۱۳۹۰ در تاریخ ۱۵/۱۱/۹۵ از رساله نظری/عملی خود با عنوان: استفاده از ماشین بردار پشتیبان مقاوم در برابر نویز برای طبقه بندی داده های ابرطیفی سنجنده هایپر یون دفاع و با نخذ نمره ۱۸/۵۵ به درجه بسیار خوب، نقل گردید.

<input checked="" type="checkbox"/> الف) درجه عالی: نمره ۱۹-۲۰	<input type="checkbox"/> ب) درجه بسیار خوب: نمره ۱۸/۹۹-۱۷
<input type="checkbox"/> ج) درجه خوب: نمره ۱۶/۹۹-۱۵	<input type="checkbox"/> د) غیر قابل قبول و نیاز به دفاع مجدد دارد.
<input type="checkbox"/> ه) رساله نیاز به اصلاحات دارد.	

ردیف	هیئت داوران	نام و نام خانوادگی	مرتبه علمی	امضاء
۱	دکتر منصور شبلی	استاد استادیار راهنا	دانشیار	
۲	دکتر علی امیری - دکتر مهدیه حسینجانی زاده	مشاور استادیار	استادیار	
۳	دکتر رضا خالوقاکنی	استاد مدعو داخلی / خارجی	استاد	
۴	دکتر پرویز شایبان فیروز آبادی	استاد مدعو داخلی / خارجی	دانشیار	
۵	دکتر حمید افشاری	استاد مدعو داخلی / خارجی	دانشیار	
۶	دکتر ابوالقاسم کمالگر روحلی	سرپرست ( نماینده ) تحصیلات تکمیلی دانشکده	دانشیار	

مدیر محترم تحصیلات تکمیلی دانشگاه:

ضمن تأیید مراتب فوق مقرر فرمائید اقدامات لازم در خصوص انجام مراحل دانش آموختگی آقای امیر سلیمی بعمل آید.

نام و نام خانوادگی دانشجو: امیر سلیمی  
 تاریخ امضاء و مهر دانشکده:  
 ۹۵/۱۲/۱۷



## تقدیم اثر

خدای رابی شاکرم که از روی کرم پدر و مادری فداکار نصیم ساخته تا در سایه درخت پر بار وجودشان بیایم و از ریشه آنها شاخ و برگ بگیرم و از سایه وجودشان در راه کسب علم و دانش تلاش نمایم. والدینی که بودنشان تاج افتخاری است بر سرم و نشان دلیلی است بر بودنم چرا که این دو وجود پس از پروردگاریه، هستی ام بوده اند دستم را گرفتند و راه رفتن را در این وادی زندگی پر از فراز و نشیب آموختند آموزگاری که برایم زندگی؛ بودن و انسان بودن را معنا کردند

حال که به تقدیر الهی در ددی جانمگاه از فراق پدر به سرمی برم، این برگ سبزی است تخمه درویش تقدیم به روح پدر بزرگوارم...

## شکر و قدردانی

سپاس خدای عزوجل را که همواره زندگانش را مورد لطف و عنایتش قرار داده است، خدایی که بار دیگر مرا تحت الطاف بیکرانش قرار داد تا بتوانم قدمی دیگر در سیر اعتلا و پیشرفت تحصیلی به پیش بردارم.

بی شک در ابتدا بایستی قدردان پدر، مادر و همسری مهربان باشم که یک بار دیگر با فرام نمودن اسباب رفاه و آسایش، در گذر از این مرحله زندگانی نیز یاریم نمودند و البته امیدوارم به روزی که تنها بتوانم گوشه ای بسیار کوچک از زحماتشان را جبران نمایم. در ادامه مراتب سپاس و قدردانی خویش را نثار استاد راهنمای عزیزم آقای دکتر منصور ضیائی نموده و از خداوند متعال سلامتی، موفقیت و بهروزی را برای ایشان خواستارم.

همچنین وظیفه خویش می دانم که از راهنمایی های بی دریغ و کراتقدر استادی مشاور عزیزم جناب آقای دکتر علی امیری و خانم دکتر مهدیه حسینجانی زاده شکر می ویژه داشته و از درگاه خداوند متعال سلامتی و موفقیت ایشان را خواستار باشم.

در خاتمه پاسکندار کلیه دوستان و عزیزانی می باشم که مراد به پایان رسانیدن این پایان نامه یاری نمودند مطمئناً موفقیت و

سلامتی ایشان آرزوی قلبی این تحسیر خواهد بود.

## تهیه‌نامه

اینجانب امیر سلیمی دانشجوی دوره دکتری رشته مهندسی معدن دانشکده مهندسی معدن، نفت و ژئوفیزیک دانشگاه صنعتی شاهرود نویسنده پایان‌نامه طبقه‌بندی مناطق دگرسانی با استفاده از ماشین بردار پشتیبان مقاوم در برابر نویز و تصویر ابرطیفی هایپریون تحت راهنمایی دکتر منصور ضیائی متعهد می‌شوم:

- تحقیقات در این پایان‌نامه توسط اینجانب انجام شده است و از صحت و اصالت برخوردار است.
- در استفاده از نتایج پژوهشهای محققان دیگر به مرجع مورد استفاده استناد شده است.
- مطالب مندرج در پایان‌نامه تاکنون توسط خود یا فرد دیگری برای دریافت هیچ نوع مدرک یا امتیازی در هیچ جا ارائه نشده است.
- کلیه حقوق معنوی این اثر متعلق به دانشگاه صنعتی شاهرود می‌باشد و مقالات مستخرج با نام « دانشگاه صنعتی شاهرود » و یا « Shahrood University of Technology » به چاپ خواهد رسید.
- حقوق معنوی تمام افرادی که در به دست آمدن نتایج اصلی پایان‌نامه تأثیرگذار بوده اند در مقالات مستخرج از پایان‌نامه رعایت می‌گردد.
- در کلیه مراحل انجام این پایان‌نامه ، در مواردی که از موجود زنده (یا بافتهای آنها) استفاده شده است ضوابط و اصول اخلاقی رعایت شده است.
- در کلیه مراحل انجام این پایان‌نامه، در مواردی که به حوزه اطلاعات شخصی افراد دسترسی یافته یا استفاده شده است اصل رازداری ، ضوابط و اصول اخلاق انسانی رعایت شده است.

## تاریخ

### امضای دانشجو

#### مالکیت نتایج و حق نشر

کلیه حقوق معنوی این اثر و محصولات آن (مقالات مستخرج ، کتاب ، برنامه های رایانه ای ، نرم افزار ها و تجهیزات ساخته شده است) متعلق به دانشگاه صنعتی شاهرود می‌باشد. این مطلب باید به نحو مقتضی در تولیدات علمی مربوطه ذکر شود. استفاده از اطلاعات و نتایج موجود در پایان‌نامه بدون ذکر مرجع مجاز نمی‌باشد.

## چکیده

سنجنده‌های ابرطیفی نسبت به سنجنده‌های چندطیفی از باندهای طیفی بسیار بیشتری برخوردار بوده و در نتیجه قادر به ثبت اطلاعات طیفی دقیق‌تری از عارضه‌های سطح زمین هستند. این ویژگی می‌تواند در فرآیند طبقه‌بندی تصاویر ابرطیفی خلل وارد کرده و با کاهش محسوسی در دقت طبقه‌بندی مواجه نماید. علاوه بر این، تصویر ابرطیفی هایپریون از وجود نویز در داده‌ها نیز رنج می‌برد. در این تحقیق سعی بر آن است که با استفاده از روش‌های داده‌کاوی، اثر مشکلات مذکور تا حد امکان تعدیل گردند. بدلیل آنکه روش‌های مبتنی بر کرنل از کارایی بالایی برای طبقه‌بندی داده‌های بیش‌ابعاد برخوردار هستند، از روش طبقه‌بندی ماشین بردار پشتیبان (SVM) برای طبقه‌بندی داده‌های ابرطیفی هایپریون استفاده شد. همچنین نویز موجود در داده‌های هایپریون با پیاده‌سازی نسخه مقاوم SVM نسبت به داده‌های نویزی (Robust-SVM)، تحت پوشش قرار گرفت. یکی دیگر از راه‌های غلبه بر مشکلات مذکور، استفاده از روش‌های کاهش ابعاد داده است. روش‌های مذکور و تصویر هایپریون برای شناسایی دگرسانی‌های معادن سرچشمه، دره زار و منطقه سریدون استفاده شدند. در گام نخست، استفاده از یک روش انتخاب ویژگی منجر به شناسایی حدوداً ۱۱٪ (۱۸ باند) از کل باندهای طیفی قابل استفاده هایپریون (۱۶۵ باند) شد. نتایج نشان داد که روش Robust-SVM، نقشه‌های دگرسانی دقیق‌تری را نسبت به SVM استاندارد تولید می‌کند. اما دقیق‌ترین نتایج زمانی بدست آمد که طبقه‌بندی با استفاده از Robust-SVM و باندهای منتخب حاصله از روش انتخاب ویژگی انجام شد. در این حالت، ضریب کاپای طبقه‌بندی برابر با ۰/۶۱ شد که در مقایسه با SVM استاندارد با استفاده از باندهای طیفی منتخب (۰/۵۳)، Robust-SVM با کل باندهای طیفی (۰/۴۹) و SVM استاندارد با کل باندهای طیفی (۰/۴۱)، دقیق‌ترین حالت است. همچنین از رگرسیون بردار پشتیبان (SVR) برای انجام طبقه‌بندی زیرپیکسلی استفاده شد. مشاهده شد که نقشه زیرپیکسلی بدست آمده از روش SVR حتی با کل باندهای طیفی و در حالت استاندارد (و نه مقاوم) از نقشه‌های پیکسل پایه SVM و Robust-SVM دقیق‌تر بوده و مناطق دگرسانی را با دقت بیشتری تفکیک می‌نماید.

**کلمات کلیدی:** دگرسانی، سنجش از دور، طبقه‌بندی، ابرطیفی، ماشین بردار پشتیبان، هایپریون

## لیست مقالات مستخرج از پایان نامه

- 1- Amir Salimi, Mansour Ziaai, Mahdieh Hosseinjani Zadeh, Ali Amiri, Sadegh Karimpouli "High Performance of the Support Vector Machine in Classifying Hyperspectral Data Using a Limited Dataset" Journal of Mining and Engineering, Vol.49, No.2, 2015, pp.253-268.
- 2- Amir. Salimi, Mansour Ziaai, Ali Amiri, Mahdieh Hosseinjani Zadeh "Sub-pixel classification of hydrothermal alteration zones using a kernel-based method and hyperspectral data; A case study of Sarcheshmeh Porphyry Copper Mine and surrounding area, Kerman, Iran" Journal of Mining and Environment, Vol.8, No.4, 2017, pp. 555-565.
- 3- Amir Salimi, Mansour Ziaai, Ali Amiri, Mahdieh Hosseinjani Zadeh, Sadegh Karimpouli, Mostafa Moradkhani "Using a Feature Subset Selection method and Support Vector Machine to address curse of dimensionality and redundancy in Hyperion hyperspectral data classification" Egyptian Journal of Remote Sensing and Space Sciences, Vol.21, No.1, 2018, pp. 27-36.
- ۴- امیر سلیمی، منصور ضیائی، علی امیری و مهدیه حسینجانی زاده "ارزیابی روش انتخاب ویژگی برای شناسایی بهترین باندهای طیفی تصویر ابرطیفی هایپریون" مجله زمین‌شناسی اقتصادی، جلد ۱۰، شماره ۱، ۱۳۹۷.
- ۵- امیر سلیمی، منصور ضیائی، مهدیه حسینجانی زاده، علی امیری، صادق کریم پولی "طبقه‌بندی مناطق دگرسانی با استفاده از تصویر ابرطیفی هایپریون و ماشین بردار پشتیبان" سی و چهارمین گردهمایی بین المللی علوم زمین، اسفند ۹۴، تهران.
- ۶- امیر سلیمی، منصور ضیائی، مهدیه حسینجانی زاده، علی امیری "کاربرد یک روش انتخاب ویژگی جهت شناسایی بهترین باندهای طیفی تصویر ابرطیفی هایپریون و حذف باندهای نامربوط مطالعه موردی: شناسایی مناطق دگرسانی معدن مس پورفیری دره زار- کرمان" بیستمین همایش انجمن زمین‌شناسی ایران، شهریور ۹۵، تهران.
- ۷- امیر سلیمی، منصور ضیائی، علی امیری مهدیه حسینجانی زاده "استفاده از روش رگرسیون بردار پشتیبان برای طبقه‌بندی زیرپیکسلی تصویر ابرطیفی هایپریون با هدف شناسایی دگرسانی- های گرمابی" بیستمین همایش انجمن زمین‌شناسی ایران، شهریور ۹۵، تهران.



## فهرست مطالب

ل	فهرست جداول
م	فهرست اشکال
۱	فصل اول: کلیات
۲	۱-۱- مقدمه
۳	۲-۱- تعریف مسأله و بیان سؤال‌های اصلی تحقیق
۹	۳-۱- ضرورت انجام تحقیق
۱۰	۴-۱- اهداف تحقیق
۱۱	۵-۱- روش تحقیق
۱۱	۶-۱- منطقه مطالعاتی
۱۴	۷-۱- سازماندهی تحقیق
۱۷	فصل دوم: مروری بر مطالعات قبلی
۱۸	۱-۲- مقدمه
۱۸	۲-۲- مروری بر کاربرد SVM در سنجش از دور
۱۹	۱-۲-۲- کاربرد SVM برای طبقه‌بندی پوشش سطح زمین
۱۹	۱-۲-۲-۱- پوشش گیاهی و کشاورزی
۲۰	۱-۲-۲-۲- مناطق شهری
۲۲	۲-۲-۲- کاربردهای بیوفیزیکی SVM
۲۲	۳-۲-۲- کاربردهای SVM با اهداف زمین‌شناسی و اکتشاف ذخایر معدنی
۲۴	۴-۲-۲- استفاده از SVM برای انجام طبقه‌بندی نرم یا زیرپیکسلی
۲۵	۳-۲-۳- مروری بر کاربرد سنجش از دور ابرطیفی در اکتشاف ذخایر معدنی
۲۶	۱-۳-۲- مروری بر کاربرد سنجنده ابرطیفی هایپریون در شناسایی
۲۸	۴-۲-۴- مروری بر کاربرد روش‌های انتخاب ویژگی در زمینه سنجش از دور ابرطیفی
۳۰	۵-۲- نتیجه‌گیری
۳۱	فصل سوم: روش‌ها و داده‌ها
۳۲	۱-۳- روش‌ها
۳۲	۱-۳-۱- روش‌های طبقه‌بندی
۳۳	۱-۳-۱-۱- ماشین بردار پشتیبان برای مسائل جداپذیر خطی
۳۵	۲-۳-۱-۱- ماشین بردار پشتیبان برای مسائل جداناپذیر خطی
۳۶	۳-۳-۱-۱- ماشین بردار پشتیبان برای مسائل غیرخطی
۳۸	۴-۳-۱-۱- ماشین بردار پشتیبان مقاوم

۴۶	..... ۳-۱-۲- رگرسیون بردار پشتیبان (SVR)
۴۷	..... ۳-۱-۳- روش‌های کاهش ابعاد داده
۵۳	..... ۳-۱-۴- روش‌های تخمین خطا
۵۵	..... ۳-۱-۵- ارزیابی دقت طبقه‌بندی
۵۵	..... ۳-۱-۵-۱- ماتریس خطا و ضریب کاپا
۵۸	..... ۳-۱-۵-۲- خطای RMS
۵۸	..... ۳-۲- داده‌ها
۵۸	..... ۳-۲-۱- مجموعه داده ابرطیفی هایپریون
۵۹	..... ۳-۲-۱-۱- مشخصات سنجنده هایپریون
۵۹	..... ۳-۲-۱-۲- مشخصات مجموعه داده هایپریون متعلق به محدوده مطالعاتی...
۶۱	..... ۳-۲-۱-۳- مقایسه کیفیت سنجنده‌های هوابرد و فضابرد
۶۴	..... ۳-۲-۲- مجموعه داده آموزشی، آزمایشی و اعتبارسنجی
۶۵	..... ۳-۲-۲-۱- مجموعه داده ۱
۶۹	..... ۳-۲-۲-۲- مجموعه داده ۲
۷۳	..... <b>فصل چهارم: کاهش ابعاد مجموعه داده هایپریون</b>
۷۴	..... ۴-۱- مقدمه
۷۵	..... ۴-۲- کاهش ابعاد مجموعه داده هایپریون
۷۶	..... ۴-۳- طبقه‌بندی کانی‌های دگرسانی توسط SVM و ANN
۷۹	..... ۴-۳-۱- طبقه‌بندی با کل باندهای طیفی هایپریون
۸۱	..... ۴-۳-۲- طبقه‌بندی با باندهای طیفی منتخب
۸۲	..... ۴-۴- نتیجه‌گیری
۸۵	..... <b>فصل پنجم: طبقه‌بندی نرم مناطق دگرسانی</b>
۸۶	..... ۵-۱- مقدمه
۸۶	..... ۵-۲- طبقه‌بندی نرم و سخت
۹۰	..... ۵-۳- طبقه‌بندی نرم مناطق دگرسانی با استفاده از SVR
۹۴	..... ۵-۴- اعتبارسنجی نتایج
۹۴	..... ۵-۴-۱- اعتبارسنجی با استفاده از نمونه‌های برداشت شده از منطقه
۹۶	..... ۵-۴-۲- مقایسه با مطالعات قبلی
۹۹	..... ۵-۵- نتیجه‌گیری
۱۰۱	..... <b>فصل ششم: طبقه‌بندی سخت مناطق دگرسانی</b>
۱۰۲	..... ۶-۱- مقدمه

۱۰۳	..... طبقه‌بندی سخت مناطق دگرسانی
۱۰۳	..... SVM -۱-۲-۶ طبقه‌بندی توسط
۱۱۰	..... Robust-SVM -۲-۲-۶ طبقه‌بندی توسط
۱۱۵	..... اعتبارسنجی نتایج -۳-۲-۶
۱۱۵	..... اعتبارسنجی با استفاده از نمونه‌های برداشتی از منطقه مطالعاتی -۱-۳-۲-۶
۱۱۷	..... مقایسه با مطالعات قبلی -۲-۳-۲-۶
۱۱۹	..... مقایسه نتایج و نتیجه‌گیری -۴-۲-۶
۱۲۵	..... <b>فصل هفتم: نتیجه‌گیری</b>
۱۲۶	..... نتیجه‌گیری -۱-۷
۱۲۹	..... پیشنهادات -۲-۷
۱۳۱	..... <b>مراجع</b>

## فهرست جداول

۱۳	جدول (۱-۱) - مشخصات ۳ ذخیره مهم واقع شده در محدوده مطالعاتی.....
۶۰	جدول (۱-۳) - مشخصات سنجنده هایپریون (Chang, 2007).....
۶۳	جدول (۲-۳) - مقایسه دو سنجنده اوپریس و هایپریون (Kruse, 2003).....
۶۶	جدول (۳-۳) - مشخصات نمونه‌های مجموعه داده ۱ برای آموزش و آزمایش الگوریتم‌ها...
۶۸	جدول (۴-۳) - مشخصات نمونه‌های مجموعه داده ۱ برای اعتبارسنجی نتایج.....
۷۰	جدول (۵-۳) - اعتبارسنجی نتایج روش MTMF در شناسایی کانی‌های دگرسانی... ..
۷۱	جدول (۶-۳) - مشخصات مجموعه داده ۲ بدست آمده از روش MTMF.....
۷۸	جدول (۱-۴) - اندازه مجموعه داده استفاده شده متشکل از ۶ مجموعه آموزشی... ..
۸۰	جدول (۲-۴) - نتایج طبقه‌بندی توسط SVM و ANN با استفاده از... ..
۸۱	جدول (۳-۴) - نتایج طبقه‌بندی توسط SVM و ANN با استفاده از ۱۸ باند طیفی منتخب
۹۲	جدول (۱-۵) - تعیین مقادیر بهینه پارامترهای SVR با استفاده از روش... ..
۹۴	جدول (۲-۵) - مقادیر بهینه پارامترهای SVR بدست آمده از جدول (۱-۵).....
۹۵	جدول (۳-۵) - مقادیر فراوانی کانی‌های شاخص دگرسانی برای ۳۳ نمونه... ..
۹۷	جدول (۴-۵) - مقادیر فراوانی کانی‌های شاخص دگرسانی برای ۱۳ نمونه برداشت... ..
۱۰۶	جدول (۱-۶) - تعیین مقادیر بهینه پارامترهای SVM با استفاده از روش... ..
۱۰۷	جدول (۲-۶) - طبقه‌بندی توسط SVM با مقادیر بهینه C و $\epsilon$ به روش L-O-O.....
۱۰۷	جدول (۳-۶) - ماتریس خطای مربوط به طبقه‌بندی توسط SVM با مقادیر... ..
۱۱۱	جدول (۴-۶) - مقادیر بهینه متغیر $\alpha$ به ازای هر نمونه برای طبقه‌بندی‌های... ..
۱۱۳	جدول (۵-۶) - مقادیر بهینه متغیر $\alpha$ به ازای هر نمونه برای طبقه‌بندی‌های... ..
۱۱۵	جدول (۶-۶) - دقت طبقه‌بندی با استفاده از ۳۳ نمونه برداشت شده از منطقه که... ..
۱۱۶	جدول (۷-۶) - ماتریس خطای مربوط به جدول (۶-۶).....
۱۱۶	جدول (۸-۶) - دقت طبقه‌بندی با استفاده از ۱۳ نمونه برداشت شده از منطقه که... ..
۱۱۷	جدول (۹-۶) - ماتریس خطای مربوط به جدول (۸-۶).....
۱۱۹	جدول (۱۰-۶) - دقت طبقه‌بندی روش‌های SVM و Robust-SVM در مقایسه... ..
۱۱۹	جدول (۱۱-۶) - ماتریس خطای مربوط به جدول (۱۰-۶).....
۱۲۲	جدول (۱۲-۶) - مقایسه دقت روش‌های SVM و Robust-SVM بر اساس... ..

## فهرست اشکال

- شکل (۱-۱) - رابطه بین میانگین دقت طبقه‌بندی با ابعاد فضای ویژگی و... ۵
- شکل (۲-۱) - طبقه‌بندی روش‌های پردازش طیفی بر اساس استفاده یا عدم... ۷
- شکل (۳-۱) - الف - موقعیت جغرافیایی محدوده مطالعاتی در ایران، ب - نقشه... ۱۲
- شکل (۴-۱) - دگرسانی‌های محدوده اکتشافی: ۱ و ۲ - دگرسانی پروپیلیتیک... ۱۵
- شکل (۱-۲) - تحقیقات انجام شده در زمینه استفاده از SVM در سنجش از دور... ۱۹
- شکل (۱-۳) - بهترین خط جداکننده با بیشترین فاصله از هر دو کلاس... ۳۵
- شکل (۲-۳) - SVM برای مسائل جداناپذیر خطی... ۳۶
- شکل (۳-۳) - استفاده از توابع کرنل برای طبقه‌بندی مسائل غیرخطی... ۳۷
- شکل (۴-۳) - الف - طبقه‌بندی نمونه‌هایی با ویژگی ثابت و مشخص، ب - تأثیر نویز... ۳۹
- شکل (۵-۳) - ماتریس خطا... ۵۵
- شکل (۶-۳) - الف - بخشی از تصویر سنجش از دور هایپریون به عنوان... ۶۲
- شکل (۷-۳) - مقدار SNR سنجنده هایپریون در فصل زمستان (چپ) و... ۶۴
- شکل (۸-۳) - مقایسه SNR سنجنده‌های هایپریون و اویریس در فصول تابستان و... ۶۴
- شکل (۹-۳) - جانمایی نمونه‌های مجموعه داده ۱ بر روی تصویر هایپریون... ۶۹
- شکل (۱۰-۳) - جانمایی نمونه‌های مجموعه داده ۲ بر روی تصویر هایپریون... ۷۱
- شکل (۱-۴) - بالا: خصوصیات طیفی کانی‌های شاخص مناطق دگرسانی. بازه‌ای که... ۷۶
- شکل (۲-۴) - پراکندگی کانی‌های اکسید آهن در محدوده مطالعاتی در کنار... ۷۷
- شکل (۳-۴) - نتایج طبقه‌بندی با استفاده از کل باندهای طیفی هایپریون: الف... ۸۰
- شکل (۴-۴) - مقایسه نتایج طبقه‌بندی در دو حالت استفاده از ۱۶۵ و ۱۸ باند... ۸۲
- شکل (۵-۴) - مقایسه پیچیدگی محاسباتی طبقه‌بندی در دو حالت استفاده... ۸۲
- شکل (۱-۵) - تجزیه طیفی تصویر به اجزاء سازنده: الف - تصویر اولیه دارای... ۸۷
- شکل (۲-۵) - از دست دادن بخشی از اطلاعات مفید در نتیجه طبقه‌بندی... ۸۸
- شکل (۳-۵) - انواع مدل ترکیبی الف - خطی ب - غیرخطی... ۸۹
- شکل (۴-۵) - مراحل انجام طبقه‌بندی نرم توسط SVR... ۹۱
- شکل (۵-۵) - نقشه زیرپیکسلی کانی‌های شاخص مناطق دگرسانی: الف... ۹۵
- شکل (۶-۵) - مقایسه نتایج طبقه‌بندی دگرسانی الف - پروپیلیتیک (کلریت)... ۹۹
- شکل (۷-۵) - مقایسه نتایج طبقه‌بندی دگرسانی الف - پروپیلیتیک (کلریت)... ۱۰۰
- شکل (۱-۶) - مراحل انجام طبقه‌بندی توسط SVM و Robust-SVM... ۱۰۴
- شکل (۲-۶) - نقشه دگرسانی طبقه‌بندی شده توسط SVM و کل ۱۶۵... ۱۰۸

- شکل (۳-۶) - نقشه دگرسانی طبقه‌بندی شده توسط SVM و ۹ باند طیفی منتخب..... ۱۰۹
- شکل (۴-۶) - نقشه دگرسانی طبقه‌بندی شده توسط Robust-SVM و کل... ۱۱۲
- شکل (۵-۶) - نقشه دگرسانی طبقه‌بندی شده توسط Robust-SVM و ۹ باند... ۱۱۴
- شکل (۶-۶) - نقشه دگرسانی منطقه بدست آمده از نقشه دگرسانی... ۱۱۸
- شکل (۷-۶) - مقایسه نقشه دگرسانی روش‌های SVM و Robust-SVM با... ۱۲۱

## فصل اول: کلیات

## ۱-۱- مقدمه

تلاش برای شناخت زمین و منابع نهفته در آن همواره یکی از مهمترین دغدغه‌های بشر بوده است. ذخایر معدنی که یکی از مهم‌ترین منابع و موهبت‌های الهی جای گرفته در دل زمین می‌باشند، در تمام ادوار بشری به عنوان یکی از اصلی‌ترین ارکان گرداننده چرخ صنعت جوامع بشری مطرح بوده و نقش انکارناپذیری در میزان توسعه و پیشرفت کشورها داشته‌اند. آگاهی از اهمیت و ارزش این ذخایر منجر گردیده است که بشر نسبت به اکتشاف این ذخایر اقدام کرده و از تمام لوازم و امکانات موجود استفاده نماید. با توجه به عدم گستردگی یکنواخت این ذخایر، نخست بایستی مناطق مستعدی که به احتمال زیاد حاوی ذخایر معدنی می‌باشند شناسایی گردند تا در مراحل بعدی تحت اکتشافات تفصیلی قرار گیرند. یکی از روش‌های شناسایی مناطق مذکور، پیمایش و بازدید محلی است که در صورت انجام توسط نیروهای متخصص، نتایج بسیار مطلوبی حاصل می‌گردد. در این روش با بررسی ویژگی‌های کانی‌شناسی، هوازدگی، دگرسانی و خواص ژئوشیمیایی، نواحی دارای پتانسیل بالا برای بررسی‌های تفصیلی‌تر انتخاب می‌گردند. اما تهیه نقشه اختلافات بسیار ظریف کانی‌شناسی که برای تفکیک سازندهای سنگی یا شناسایی دگرسانی‌های مختلف مرتبط با ذخایر اقتصادی حائز اهمیت می‌باشند، زمانی که توسط کارهای میدانی و با حضور فیزیکی در منطقه انجام می‌گیرند با صرف هزینه‌های بالای زمانی و مالی همراه خواهند بود. بنابراین علی‌رغم حصول نتایج قابل قبول، این روش‌ها در اکتشافات کوچک مقیاس و ناحیه‌ای که منطقه وسیعی می‌بایست تحت پی‌جویی قرار گیرد مقرون به صرفه نمی‌باشند. در چنین شرایطی فن آوری سنجش از دور<sup>۱</sup> راهگشا بوده و در فازهای مطالعاتی اولیه پی‌جویی و شناسایی، اطلاعات ارزشمندی را در اختیار فعالان این عرصه قرار می‌دهد.

امروزه با درک اهمیت دستیابی به فن آوری سنجش از دور، تلاش‌های فراوانی در این حوزه صورت پذیرفته است که نتیجه آن تهیه میلیون‌ها مجموعه داده سنجش از دوری است که در اختیار محققان

---

1- Remote sensing



و مؤسسات تحقیقاتی قرار می‌گیرد. از نخستین روزهای تولد این فن‌آوری در اواخر دهه ۶۰ و اوایل دهه ۷۰ میلادی تا به امروز و در نتیجه ظهور سیستم‌های پیشرفته‌تر، هر روز بیش از پیش کیفیت و کمیت داده‌های سنجش از دور دستخوش پیشرفت‌های قابل توجه شده است. همراه با پیشرفت‌های حاصله که امکان جمع‌آوری حجم فراوانی از داده‌ها را فراهم می‌سازد، توسعه روش‌هایی که قادر به پردازش و استخراج اطلاعات ارزشمند از این داده‌ها باشند نیز ضروری است (Van der Meer and Van der Werff, 2007).

از اواخر دهه هشتاد میلادی گام بلندی در این حوزه با توسعه فن‌آوری تصویربرداری طیفی<sup>۱</sup> برداشته شد که حاصل آن تولید داده‌های ابرطیفی<sup>۲</sup> است. داده‌های ابرطیفی بدلیل داشتن توان تفکیک طیفی<sup>۳</sup> بیشتر نسبت به داده‌های چندطیفی<sup>۴</sup> امکان مطالعه دقیق‌تر عارضه‌های سطح زمین را فراهم می‌آورند. از سویی دیگر بالا بودن دقت تفکیک طیفی موجب حجیم گشتن داده‌های ابرطیفی می‌شود و آن را در زمره داده‌های بیش‌ابعاد<sup>۵</sup> قرار می‌دهد. از آنجایی که مطالعه و تجزیه و تحلیل داده‌های بیش‌ابعاد یکی از مسائل چالش برانگیز در علم داده‌کاوی<sup>۶</sup> است، در نتیجه داده‌های ابرطیفی نیز از این امر مستثنی نخواهند بود. بنابراین در این رساله سعی بر استفاده از روش‌هایی است که مناسب برای طبقه‌بندی<sup>۷</sup> داده‌های ابرطیفی هستند.

## ۱-۲- تعریف مسأله و بیان سؤال‌های اصلی تحقیق

با پیشرفت‌های اخیر صورت گرفته در فن‌آوری سنجنده‌های سنجش از دور و تولید سنجنده‌های ابرطیفی، اطلاعات طیفی دقیق‌تری در اختیار بشر قرار گرفته است که قابل استفاده در بسیاری از علوم

---


1- Imaging spectrometry  
2- Hyperspectral data  
3- Spectral resolution  
4- Multispectral data  
5- High dimensional  
6- Data mining  
7- Classification

از جمله زمین‌شناسی، محیط زیست و معدن است. یکی از اهداف اصلی استفاده از سنجش از دور ابرطیفی در علوم زمین‌شناسی و معدن، تهیه نقشه پراکندگی کانی‌ها<sup>۱</sup> با هدف اکتشاف ذخایر اقتصادی معدنی است چراکه سنجنده‌های ابرطیفی توانایی شناسایی کانی‌های سازنده سطح زمین را با جزئیات خیلی بیشتری دارند (Zhang and Peijun, 2014). معمولاً پی‌جویی ذخایر معدنی توسط سنجش از دور با شناسایی سنگ‌ها و کانی‌های شاخص مرتبط با ذخایر انجام می‌شود که در مقایسه با آنومالی‌های ژئوشیمیایی یا ژئوفیزیکی، از آنها با عنوان آنومالی‌های سنگی<sup>۲</sup> یاد می‌شود. سنگ‌های دگرسان شده با محلول‌های گرمایی نوعی از آنومالی‌های سنگی می‌باشند که به لحاظ موقعیت رخداد با ذخایر در ارتباط بوده، لذا می‌توانند به عنوان راهنمای اکتشافی مورد استفاده قرار گیرند (Carranza, 2002).

اگرچه تفکیک‌پذیری طیفی بالای داده‌های ابرطیفی امکان مطالعه دقیق‌تر عارضه‌های سطح زمین را فراهم می‌آورد ولی در سوی مقابل منجر به ظهور چالش‌های محاسباتی جدیدی نیز می‌گردد (Camps-Valls, 2014). یکی از حوزه‌های چالشی مرتبط با داده‌های ابرطیفی، طبقه‌بندی این نوع داده‌ها می‌باشد. طبقه‌بندی یکی از روش‌های رایج استخراج اطلاعات از تصویر و یا به عبارتی تبدیل داده‌های موجود در تصویر به اطلاعات معنی‌دار است (Oommen, 2008). طبقه‌بندی نظارت‌شده<sup>۳</sup> که بر اساس مجموعه‌ای از داده‌های برچسب‌دار<sup>۴</sup> به نام نمونه‌های آموزشی<sup>۵</sup> است، بدلیل حجم زیاد داده‌های ابرطیفی با مشکلات انفجار ابعادی<sup>۶</sup> و پدیده هیوز<sup>۷</sup> همراه است. این مشکلات می‌توانند دقت طبقه‌بندی داده‌های ابرطیفی را تحت تأثیر قرار دهند (Plaza et al, 2009; Waske, 2009; Pal and Foody, 2010; Camps-Valls, 2014). در حقیقت اساس روش‌های طبقه‌بندی نظارت‌شده، یادگیری قوانین حاکم بر الگوها<sup>۸</sup> با استفاده از ویژگی‌های<sup>۹</sup> اندازه‌گیری شده برای نمونه‌های آموزشی است (این ویژگی‌ها

- 
- 1- Mineral mapping
  - 2- Lithological anomaly
  - 3- Supervised classification
  - 4- Labeled data
  - 5- Training samples
  - 6- Curse of dimensionality
  - 7- Hughes phenomenon
  - 8- Pattern rules
  - 9- Features

در سنجش از دور همان باندهای طیفی هستند). بطور کلی کم یا ناکافی بودن تعداد نمونه‌های آموزشی در مقابل تعداد ویژگی‌ها منجر به وقوع مشکل انفجار ابعادی می‌گردد که در نتیجه آن دقت طبقه‌بندی کاهش یافته و مشکل هیوز رخ می‌دهد که یکی از مشکلات بد حالت<sup>۱</sup> در طبقه‌بندی مجموعه داده‌های بیش‌ابعاد است (Plaza et al, 2009; Gheyas and Smith, 2010; Camps-Valls, 2014). رابطه بین تعداد نمونه‌های آموزشی، ابعاد فضای ویژگی<sup>۲</sup> و دقت طبقه‌بندی در شکل (۱-۱) نشان داده شده است (Landgrebe, 2002). همانطور که مشاهده می‌شود تغییرات دقت طبقه‌بندی ارتباط مستقیم با تعداد نمونه‌های آموزشی و ویژگی‌ها دارد، اما پس از رسیدن به بیشترین مقدار دقت، ارتباط آن نسبت به فضای ویژگی‌ها (محور افقی) معکوس شده و با افزایش تعداد ویژگی‌ها کاهش می‌یابد. این مشکل از آنجا ناشی می‌شود که با ثابت ماندن تعداد نمونه‌ها ولی افزایش تعداد ویژگی‌ها، شرایط انفجار ابعادی رخ می‌دهد بطوریکه نمونه‌های آموزشی در چنین فضایی کم پشت و پراکنده<sup>۳</sup> می‌شوند (Plaza et al, 2009; Camps-Valls, 2014). در نتیجه پارامترهای آماری مربوط به داده‌ها اشتباه تخمین زده شده و در نهایت دقت طبقه‌بندی کاهش می‌یابد (Waske et al., 2009).



شکل (۱-۱) - رابطه بین میانگین دقت طبقه‌بندی با ابعاد فضای ویژگی و تعداد نمونه‌های آموزشی ثابت ( $m$ ) (Landgrebe, 2002).


- 
- 1- Ill-posed
  - 2- Feature space size
  - 3- Sparse

مشکلات مذکور در کنار دیگر مشکلات همراه با طبقه‌بندی تصاویر ابرطیفی باعث می‌شوند که روش‌های آماری قدیمی (مثل روش‌های بیشترین تشابه<sup>۱</sup> و شبکه‌های عصبی مصنوعی<sup>۲</sup>) که برای طبقه‌بندی تصاویر چندطیفی استفاده می‌شوند در مواجهه با تصاویر ابرطیفی نتایج قابل قبولی نداشته باشند (Gómez-Chova et al., 2011; Fauvel, 2013) بطوریکه محققان به استفاده از روش‌های داده‌کاوی و یادگیری ماشینی<sup>۳</sup> ترغیب کردند (Tan et al., 2005; Bioucas-Dias et al., 2013; Camps-Valls, 2014). از این منظر، دو راهکار پیشنهادی برای غلبه بر مشکل هیوز عبارت هستند از (۱) تهیه نمونه‌های آموزشی کافی و (۲) کاهش ابعاد فضای ویژگی با حذف باندهای نامربوط و افزونه<sup>۴</sup>. در رابطه با مورد اول بجای تهیه نمونه‌های آموزشی، استفاده از روش‌های طبقه‌بندی مبتنی بر کرنل<sup>۵</sup> مثل ماشین بردار پشتیبان (SVM)<sup>۶</sup> پیشنهاد شده و مورد دوم نیز می‌تواند در مرحله پیش‌پردازش داده‌ها و با استفاده از روش‌های کاهش ابعاد داده<sup>۷</sup> مدیریت گردد.

قبل از پرداختن به این روش‌ها نیاز است که ابتدا به روش‌های پردازش طیفی موجود برای مطالعه داده‌های سنجش از دور اشاره شده و با طبقه‌بندی آنها جایگاه روش SVM نیز مشخص گردد. در کنار طبقه‌بندی‌های مختلف ارائه شده بر اساس معیارهای مختلف، اسدزاده و دسوزا فیلهو<sup>۸</sup> (۲۰۱۶) این روش‌ها را بر اساس نیاز یا عدم نیاز به داده‌های مرجع اولیه<sup>۹</sup> به دو دسته روش‌های دانش محور<sup>۱۰</sup> و روش‌های داده محور<sup>۱۱</sup> تقسیم کرده‌اند (شکل ۱-۲). روش‌های دانش محور برای استخراج اطلاعات ارزشمند طیفی در مورد هدفی خاص تنها از دانش کارشناسی و از امضای طیفی آن هدف استفاده می‌کنند. اما در مقابل روش‌های داده محور نیازمند استفاده از داده‌های مرجعی هستند که متناسب با

- 
- 1- Maximum likelihood
  - 2- Artificial Neural Networks (ANNs)
  - 3- Machine learning
  - 4- Irrelevant and redundant
  - 5- Kernel-based
  - 6- Support Vector Machine (SVM)
  - 7- Feature reduction methods
  - 8- Asadzadeh and De Souza Filho
  - 9- Priori reference data
  - 10- Knowledge-based approaches
  - 11- Data driven approaches

نوع روش، داده‌های آموزشی و اعضای انتهایی<sup>۱</sup> نامیده می‌شوند.



شکل (۱-۲) - طبقه‌بندی روش‌های پردازش طیفی بر اساس استفاده یا عدم استفاده از داده‌های مرجع (Asadzadeh and De Souza Filho, 2016)

همانطور که اشاره گردید یکی از روش‌های پیشنهادی برای غلبه بر مشکلات پیش رو در طبقه‌بندی داده‌های ابرطیفی، استفاده از روش‌های مبتنی بر کرنل است. این روش‌ها از توانایی بالایی برای تحلیل داده‌های سنجنش از دور ثبت شده توسط سنجنده‌های هوایی و فضایی<sup>۲</sup> برخوردار هستند، بویژه هنگامی که مسئله طبقه‌بندی دارای فضای ویژگی بزرگ (مثل داده‌های ابرطیفی) و مجموعه داده آموزشی کوچک است (Gómez-Chova et al., 2011). از بین روش‌های مبتنی بر کرنل نیز، روش SVM نسبت به دیگر روش‌ها نتایج بهتری را ارائه کرده و به کرات برای طبقه‌بندی داده‌های ابرطیفی در شاخه‌های علمی مختلف استفاده شده است (Pal and Mather, 2005; Chang, 2007; Waske et al., 2009; Pal and Foody, 2010; Mountrakis et al., 2011; Camps-Vallas et al., 2014). ارائه شده در شکل (۱-۲) مشاهده می‌شود که SVM در گروه روش‌های داده محور طبقه‌بندی شده

1- Endmember

2- Airborne and satellite sensors

است. همچنین در این طبقه‌بندی مشخص است که SVM هم می‌تواند برای انجام طبقه‌بندی سخت<sup>۱</sup> (در مقیاس پیکسل) و هم طبقه‌بندی نرم<sup>۲</sup> یا تجزیه طیفی<sup>۳</sup> (مقیاس زیرپیکسل) استفاده شود.

داده‌های سنجنده ابرطیفی هایپریون<sup>۴</sup> که مجموعه داده مورد استفاده در این تحقیق است، نه تنها از امتیاز ابرطیفی بودن بهره می‌برند، بلکه در مقایسه با دیگر داده‌های ابرطیفی با سهولت بیشتری قابل تهیه می‌باشند.\* دسترسی آسان و رایگان به داده‌های هایپریون امتیاز مثبت دیگری می‌باشد که امکان استفاده محققان ایرانی از داده‌های ابرطیفی ثبت شده از مناطق مختلف ایران را فراهم می‌آورد.

در کنار این مزایا، هایپریون دارای کاستی‌هایی نیز است. یکی از مهمترین معایب، وجود عدم قطعیت<sup>۵</sup> در داده‌های هایپریون است که ناشی از کیفیت پایین و بالا بودن میزان نویز در داده‌ها در مقایسه با سنجنده‌های هوابرد است. در منابع مختلف به نسبت سیگنال به نویز کم داده‌های هایپریون اشاره شده است. از سویی دیگر دقت فرآیند طبقه‌بندی که بر اساس میزان انطباق خصوصیات طیفی عارضه ناشناخته با طیف مرجع است، به صورت قابل توجهی متأثر از میزان سطح نویز موجود در داده‌ها می‌باشد (Sgavetti et al., 2006).

مزایا و معایب داده‌های هایپریون یکی از دلایل انجام این تحقیق است، چراکه دسترسی آسان به یک مجموعه داده ابرطیفی در شرایطی که امکان دسترسی به هیچ نوع داده ابرطیفی دیگری وجود ندارد، موجب می‌شود که فرصت استفاده از این مجموعه داده ارزشمند را از دست نداده و در مقابل بدنبال راهکارهایی مناسب جهت غلبه بر محدودیت‌ها و معایب آن باشیم.

در این تحقیق از داده‌های ثبت شده توسط سنجنده هایپریون برای طبقه‌بندی نواحی دگرسان

- 
- 1- Hard classification
  - 2- Soft classification
  - 3- Spectral unmixing
  - 4- Hyperion

\* دسترسی رایگان از طریق پایگاه اینترنتی سازمان زمین شناسی ایالات متحده به نشانی الکترونیکی <http://earthexplorer.usgs.gov>

- 5- Uncertainty

شده مناطق سرچشمه، سریدون و دره زار استفاده خواهد شد. سعی خواهد گردید در کنار استفاده از SVM به عنوان یک روش مطلوب برای طبقه‌بندی داده‌های ابرطیفی به مشکلات زیر نیز پرداخته شود:

۱- ماهیت عدم قطعیت موجود در داده‌های هایپریون

۲- انجام طبقه‌بندی زیرپیکسلی یا تجزیه طیفی

۳- کاهش ابعاد مجموعه داده هایپریون بصورت شناسایی باندهای دارای بیشترین تأثیر در شناسایی

مناطق دگرسانی

## ۱-۳- ضرورت انجام تحقیق

علی‌رغم قابلیت بالا در پردازش تصاویر ابرطیفی، روش طبقه‌بندی SVM آن‌گونه که در سایر زمینه‌ها مورد استفاده قرار گرفته است، برای طبقه‌بندی کانی‌ها و سنگ‌های سازنده سطح زمین استفاده نشده است. کاربردهای محدودی که این روش در حوزه علوم زمین و بخصوص طبقه‌بندی سنگ‌ها و کانی‌ها داشته است غالباً محدود به استفاده از SVM استاندارد بوده است. بنابراین لزوم استفاده از SVM و ارزیابی کارایی آن در طبقه‌بندی تصاویر ابرطیفی با هدف تفکیک مناطق دگرسانی احساس می‌گردد. بزرگ بودن ابعاد فضای ویژگی بخاطر تعداد باندهای طیفی فراوان و همپوشانی بالای باندهای طیفی و در نتیجه وجود باندهای افزونه و نامربوط از مهمترین مشکلات همراه با داده‌های ابرطیفی می‌باشند. از سویی دیگر و در صورتی که از داده‌های سنجنده هایپریون استفاده شود، ناگزیر باید به موارد فوق مشکل وجود عدم قطعیت و نویز را نیز افزود. اگرچه SVM بدلیل ماهیت عملکردی خود، بطور طبیعی تا حدی نارسایی عدم قطعیت را پوشش داده و اثر آن را کاهش می‌دهد ولی استفاده از نسخه‌های کارآمدتری از SVM بطوریکه مشکلات مذکور در آن با حساسیت بیشتری مورد توجه قرار گیرند، ضروری است.

طبقه‌بندی زیرپیکسلی یکی دیگر از موضوعات مهم در طبقه‌بندی تصاویر ابرطیفی است که روش‌های مبتنی بر مدل‌های ترکیبی خطی و غیرخطی متنوعی نیز برای انجام آن ارائه شده است. اما تاکنون از SVM به عنوان روشی که می‌تواند با استفاده از توابع کرنل، عملکردی مشابه با مدل‌های ترکیبی غیرخطی داشته باشد، برای طبقه‌بندی زیرپیکسلی مناطق دگرسانی استفاده نشده است.

## ۱-۴- اهداف تحقیق

هدف اولیه در این تحقیق، طبقه‌بندی مناطق دگرسانی معادن سرچشمه و دره زار و محدوده سریدون با استفاده از تصویر ابرطیفی هایپریون است. بدین منظور و با توجه به کارآمدی روش‌های مبتنی بر کرنل برای طبقه‌بندی مجموعه داده‌های بیش‌ابعاد (همچون تصاویر ابرطیفی)، روش کرنل پایه SVM بنای اصلی روش‌های طبقه‌بندی کننده در این تحقیق را تشکیل می‌دهد. اما اهداف اصلی تحقیق استفاده از نسخه‌های کارآمدتری از SVM است بطوریکه در کنار استفاده از یک روش توانمند برای طبقه‌بندی داده‌های ابرطیفی، تعدادی از دیگر مسائل و مشکلات مطرح در حوزه سنجش از دور نیز تحت پوشش قرار گیرند. ۳ موضوع مهمی که در این تحقیق بررسی خواهند شد عبارت هستند از:

۱- ماهیت عدم قطعیت موجود در داده‌های ابرطیفی سنجنده هایپریون که به منظور پوشش این

مشکل ماشین بردار پشتیبان مقاوم (Robust-SVM)<sup>۱</sup> مورد استفاده قرار خواهد گرفت.

۲- یکی دیگر از مسائل مهم مطرح در جوامع سنجش از دور، تجزیه طیفی است که در این تحقیق

با استفاده از رگرسیون بردار پشتیبان (SVR)<sup>۲</sup> به آن پرداخته خواهد شد.

۳- استفاده از روش‌های کاهش ابعاد داده‌ها که یک گام ضروری در مرحله پیش‌پردازش اغلب

داده‌های بیش‌ابعاد است، یکی دیگر از اهداف اصلی این تحقیق است. در این تحقیق از یک

---

1- Robust-SVM

2- Support Vector Regression (SVR)



روش انتخاب ویژگی برای انتخاب باندهای مهم و حذف باندهای افزونه و تکراری استفاده خواهد شد.

## ۱-۵- روش تحقیق

در جهت نیل به اهداف تحقیق، در گام نخست و در مرحله پیش‌پردازش داده‌های هایپریون از یک روش انتخاب ویژگی برای کاهش ابعاد مجموعه داده هایپریون استفاده خواهد شد. این مرحله که بر اساس استفاده از یک مجموعه داده مصنوعی می‌باشد، با هدف شناسایی بهترین باندهای طیفی و حذف باندهای نامربوط انجام می‌شود. در ادامه مجموعه داده مصنوعی مذکور، برای سنجش مقاومت و حساسیت روش SVM نسبت به اندازه مجموعه داده آموزشی (و در نتیجه مشکل هیوز) نیز استفاده خواهد شد.


پس از انتخاب بهترین باندهایی از هایپریون که بیشترین اطلاعات را در رابطه با شناسایی مناطق دگرسانی فراهم می‌آورند، در گام بعدی طبقه‌بندی سخت مناطق دگرسانی با استفاده از روش‌های SVM و Robust-SVM، در طی دو مرحله (با استفاده از کل باندهای طیفی و همچنین باندهای طیفی منتخب) انجام خواهد شد. این مرحله بر اساس ۴۶ نمونه سنگی برداشت شده از دگرسانی‌های منطقه مطالعاتی است که پیش از استفاده تحت آزمایش طیف‌سنجی قرار گرفته‌اند. ارزیابی عملکرد روش Robust-SVM در پوشش نویز و عدم قطعیت موجود در داده‌های هایپریون هدف این مرحله است که در نتیجه مقایسه با نتایج SVM میسر می‌گردد. در نهایت با انجام طبقه‌بندی نرم مناطق دگرسان شده توسط SVR که با استفاده از ۴۶ نمونه مذکور انجام می‌شود، امکان مقایسه نتایج طبقه‌بندی نرم و سخت مناطق دگرسانی فراهم می‌گردد.

## ۱-۶- منطقه مطالعاتی

منطقه مطالعاتی در جنوبی‌ترین بخش کمر بند ماگمایی ایران مرکزی قرار دارد. این کمر بند که متعلق

به دوران سنوزوئیک است بدلیل داشتن کانی‌زایی‌های مهمی از فلزات مس، مولیبدن و طلا از اهمیت زیادی برخوردار می‌باشد. کمر بند مذکور با گسترش قطری به طول حدوداً ۱۸۰۰ کیلومتر از شمال غرب تا جنوب شرق کشور، حاوی ذخایر بسیار مهمی مثل سرچشمه، سونگون و میدوک است (شکل ۱-۳-الف). این کمر بند ماگمایی در نتیجه نفوذ صفحه عربی به زیر صفحه ایران مرکزی تشکیل شده و در ادامه در طول دوره‌های ائوسن میانی و الیگومیوسن تحت فعالیت‌های شدید ماگمایی قرار گرفته است (Boomeri et al., 2009).

سه ذخیره مهم شامل دو معدن مس پورفیری سرچشمه و دره زار بعلاوه اندیس سریدون در محدوده مطالعاتی قرار گرفته‌اند که موقعیت جغرافیایی و مشخصات آنها به ترتیب در شکل (۱-۳-ب) جدول (۱-۱) نشان داده شده است.



شکل (۱-۳)- الف- موقعیت جغرافیایی محدوده مطالعاتی در ایران، ب- نقشه زمین‌شناسی محدوده (Hosseinjani Zadeh et al., 2014a)

جدول (۱-۱) - مشخصات ۳ ذخیره مهم واقع شده در محدوده مطالعاتی (Shahriari et al., 2015)

نام ذخیره	جنس توده نفوذی	سنگ میزبان	زمان کانی‌زایی	دگرسانی‌های غالب
سرچشمه	گرانودیوریت پورفیری	آندزیت، توف، ایگنمبریت و آگولومرا	اولیگوسن - میوسن	فیلیک و پروپیلیتیک
دره زار	دیوریت-کوارتز دیوریت	آذرآواری، آندزیت، تراکی آندزیت و سنگ‌های رسوبی	اولیگوسن - میوسن	فیلیک و پروپیلیتیک
سربدون	گرانودیوریت	آندزیت و تراکی آندزیت	میوسن فوقانی	آرژیلیک، فیلیک و پروپیلیتیک

معدن بزرگ سرچشمه در ۶۵ کیلومتری جنوب غربی شهر کرمان با توجه به نوع دگرسانی‌ها، شکل کانی‌زایی، اندازه و عیار ماده معدنی، ویژگی‌های تکتونیکی و شاخصه‌های توده آذرین در برگیرنده به عنوان یک ذخیره مس پورفیری تیپیک شناخته می‌شود. ذخیره آن بیضوی شکل با طول و عرض ۲ و ۱ کیلومتر بوده و دارای عمقی برابر با ۱ کیلومتر است که در نتیجه نفوذ استوک دیوریتی تا گرانودیوریتی بوجود آمده است (Waterman and Hamilton, 1975; Aftabi and Atapour, 2010). میزان ذخیره سولفیدی آن بر اساس تخمین‌های اولیه برابر بوده است با ۴۵۰ میلیون تن با میانگین عیار ۱/۱۳٪ و ۰/۰۳٪ به ترتیب برای فلزات مس و مولیبدن که در نتیجه محاسبات اخیر و افزوده شدن بخش بزرگی از ذخیره هیپوژن در اعماق، به ۱۲۰۰ میلیون تن با میانگین ۰/۷٪ و ۰/۰۳٪ ارتقا یافته است (Boomeri et al., 2010). ترتیب رخداد مکانی دگرسانی‌های گرمایی سرچشمه از مرکز به سمت حاشیه شامل دگرسانی‌های پتاسیک، بیوتیتی، فیلیک، آرژیلیک و پروپیلیتیک است بوده و به لحاظ زمانی نیز در ابتدا دگرسانی‌های پتاسیک و پروپیلیتیک و در ادامه انواع فیلیک و آرژیلیک تشکیل گردیده‌اند (Waterman and Hamilton, 1975; Shafiei and Shahabpour, 2012).

محدوده دره زار در ۸ کیلومتری جنوب شرق معدن سرچشمه قرار گرفته است. ذخیره تخمینی معدن دره زار در حدود ۶۷ میلیون تن با عیار ۰/۳۷٪ است (NICICO, 2008). سنگ‌های آتشفشانی رسوبی ائوسن متشکل از آندزیت و تراکی آندزیت میزبان تشکیلات نفوذی دیوریتی تا گرانودیوریتی الیگوسن - میوسن می‌باشند. در نتیجه تأثیر محلول‌های گرمایی بر سنگ‌های منطقه، دگرسانی‌های پتاسیک، فیلیک، آرژیلیک و پروپیلیتیک در سرتاسر منطقه قابل مشاهده است. همچنین در نتیجه فرآیندهای سوپرژن و شستشوی اسیدی سولفیدها، مقادیر زیادی کانی‌های اکسید آهن دار قرمز تا زرد


رنگ نیز در منطقه دیده می‌شود (Ranjbar et al., 2001). منطقه دگرسانی تقریباً بیضی شکل با طول ۲/۲ و عرض ۰/۷-۱ کیلومتر می‌باشد بطوریکه بخش اعظمی از منطقه توسط دگرسانی‌های پروپیلیتیک و فیلیک و درصد کمتری نیز با دگرسانی آرژیلیکی پوشیده شده است. همچنین دگرسانی پتاسیک گسترش چندانی در بخش‌های سطحی منطقه ندارد (Geological survey of Iran, 1973a).

منطقه سریدون با قرارگیری در همسایگی شرقی معدن سرچشمه شامل دگرسانی‌های پروپیلیتیک (کلریت - اپیدوت)، فیلیک (کوارتز - سریسیت)، آرژیلیک (کوارتز - رس‌ها)، آرژیلیک پیشرفته (کوارتز، آلونیت، پروپیلیت) و سیلیسیتی (کوارتز ± پروپیلیت) می‌باشد. به لحاظ چینش مکانی، دگرسانی فیلیک توسط دگرسانی آرژیلیک پیشرفته دنبال شده و دگرسانی آرژیلیکی توسط دگرسانی پروپیلیتیک از جهات شرق، جنوب و غرب محدود می‌گردد (Barzegar, 2007).

در شکل (۱-۴) نمونه‌هایی از دگرسانی‌های مختلف محدوده مطالعاتی به تصویر کشیده شده است.

## ۱-۷- سازماندهی تحقیق

نحوه ارائه مطالب در فصول آتی به شرح زیر است. مروری بر مطالعات قبلی در فصل دوم ارائه شده است. در فصل سوم جزئیات کلیه روش‌ها و داده‌های مورد استفاده در تحقیق بیان می‌شود. فصل چهارم به مرحله کاهش ابعاد داده‌ها اختصاص یافته و نتایج حاصل از آن بررسی می‌شود. در فصول پنجم و ششم به ترتیب نتایج طبقه‌بندی نرم و سخت بدست آمده از روش‌های SVR، SVM و Robust-SVM ارائه شده و در نهایت فصل هفتم به بخش نتیجه‌گیری و پیشنهادات اختصاص دارد.



شکل (۱-۴) - دگرسانی‌های محدوده اکتشافی (۱ و ۲) دگرسانی پروپیلیتیک سرچشمه، (۳) دگرسانی فیلیک دره زار، (۴) دگرسانی پروپیلیتیک دره زار، (۵) دگرسانی فیلیک سریدون (۶) دگرسانی آرژیلیک سریدون



## فصل دوم: مروری بر مطالعات قبلی

## ۲-۱- مقدمه


این بخش اختصاص دارد به خلاصه‌ای از مطالعات انجام شده در حوزه سنجش از دور و شناسایی مناطق دگرسان شده که در آن‌ها SVM و تصاویر ابرطیفی مورد استفاده قرار گرفته‌اند. مطالب در دو بخش کلی کاربردهای SVM در طبقه‌بندی تصاویر سنجش از دور (بخش ۲-۲) و استفاده از سنجش از دور ابرطیفی با هدف اکتشاف ذخایر معدنی و طبقه‌بندی مناطق دگرسانی (بخش ۲-۳) ارائه شده‌اند. همچنین بخش (۲-۴) نیز به موضوع کاهش ابعاد مجموعه داده‌های سنجش از دور ابرطیفی با استفاده از روش‌های انتخاب ویژگی اختصاص یافته و به تعدادی از تحقیقات انجام شده در این زمینه اشاره شده است.

## ۲-۲- مروری بر کاربرد SVM در سنجش از دور

تحقیقات فراوانی در زمینه استفاده از SVM در پردازش داده‌های سنجش از دور انجام شده است بطوریکه طیف گسترده‌ای از موضوعات مختلف را فرا می‌گیرند. برای مثال شکل (۲-۱)، که اشاره به تعداد مقالات چاپ شده در بازه زمانی حدوداً دو ساله (تا آوریل سال ۲۰۱۰ میلادی) با موضوع کاربرد SVM در پردازش تصاویر سنجش از دور دارد، نشان از مقبولیت بالای روش SVM در شاخه سنجش از دور است (Mountrakis et al., 2011).

به دلیل تنوع و تعدد فراوان تحقیقات با محوریت کاربرد SVM در سنجش از دور، در این بخش به اختصار به حوزه‌های کاربردی مختلف آن پرداخته و مثال‌هایی در این خصوص ذکر می‌شود.





شکل (۱-۲) - تحقیقات انجام شده در زمینه استفاده از SVM در سنجش از دور در فاصله زمانی ۲۰۰۹ تا ۲۰۱۱ (Mountrakis et al, 2011)

## ۲-۲-۱- کاربرد SVM برای طبقه‌بندی پوشش سطح زمین

### ۲-۲-۱-۱- پوشش گیاهی و کشاورزی

SVM روش بسیار مناسبی برای طبقه‌بندی گیاهان ارزیابی شده است. اولین مطالعات انجام شده در این زمینه توسط گوالتیری و کرامپ<sup>۱</sup> (۱۹۹۸) با نتایج مطلوبی در طبقه‌بندی تصویر ابرطیفی اوپریس<sup>۲</sup> همراه بود. کرامیتسوقلو<sup>۳</sup> و همکاران (۲۰۰۶) برای طبقه‌بندی گیاهان با SVM از داده‌های سنجنده آیکونوس<sup>۴</sup> استفاده کردند. روش طبقه‌بندی SVM برای ارزیابی دقت طبقه‌بندی پوشش جنگلی استفاده شد و تأثیر توپوگرافی و موقعیت نسبی درختان نسبت به یکدیگر در نتایج طبقه‌بندی مورد ارزیابی قرار گرفت. پس از اعمال تصحیحات توپوگرافی، افزایش ۳/۶٪ دقت طبقه‌بندی مشاهده گردید (Huang et al., 2008). لاردکس<sup>۵</sup> و همکاران (۲۰۰۹) از SVM برای طبقه‌بندی گیاهان انبوه مناطق گرمسیری

1- Gualtieri and Cromp

2- AVIRIS

3- Keramitsoglou

4- Ikonos

5- Lardeux

استفاده کردند. آنها از داده های سار<sup>۱</sup> استفاده کرده و به دقتی در حدود ۲۰٪ بیشتر از دقت نتایج روش طبقه بندی توزیع ویشارت<sup>۲</sup> دست یافتند. در تحقیقی دیگر برای طبقه بندی پوشش جنگلی، ترکیبی از داده های لیدار و آيسا<sup>۳</sup> مورد استفاده قرار گرفت. نتایج حاصله حاکی از دقت بالای SVM نسبت به روش بیشترین تشابه گوسی و شبکه عصبی بود (Dalponte et al., 2008). در راستای تحقیق بر روی طبقه بندی مناطق جنگلی پیچیده، تأثیر میزان دقت طیفی تصویر و نوع روش طبقه بندی بکار رفته سنجیده شد. نتایج نشان داد که دقت طبقه بندی توسط SVM نسبت به روش های دیگر بیشتر است. نتیجه این تحقیق، کارایی مطلوب روش SVM در طبقه بندی تصاویر ابرطیفی پیچیده بود (Dalponte et al., 2009). در ارتباط با طبقه بندی محصولات کشاورزی و با هدف شناسایی محصولات کشاورزی در معرض عناصر سمی، از اندازه گیری های در محل<sup>۴</sup> ابرطیفی استفاده شد. بدین منظور دو روش SVM و تمایز لوجستیک<sup>۵</sup> استفاده شده و مشاهده گردید که SVM با نتایج بهتری همراه است (Wilson et al., 2004). SVM و تصویر ابرطیفی های مپ<sup>۶</sup> برای طبقه بندی محصولات استفاده شدند که نتایج بدست آمده حاکی از برتری SVM نسبت به روش شبکه عصبی از جنبه های دقت، سادگی و تعمیم پذیری<sup>۷</sup> بود. عدم حساسیت SVM نسبت به اندازه نمونه های آموزشی و شناسایی باندهای نویزی توسط آن، دیگر نتیجه بدست آمده از تحقیق بود (Camps-Valls et al., 2004).

## ۲-۲-۱-۲- مناطق شهری

هوانگ و ژانگ<sup>۸</sup> (۲۰۰۹) از تصاویر آیکونوس برای طبقه بندی جاده ها استفاده کردند. ایده بکار رفته استفاده از اطلاعات طیفی و ویژگی های شکلی<sup>۹</sup> بود. تحقیق دیگری برای شناسایی جاده ها و با استفاده

---

1- SAR  
2- Wishart distribution  
3- LIDAR and AISA  
4- In Situ  
5- Logistic discriminant  
6- HyMap  
7- Robusnesst  
8- Huang and Zhang  
9- Shape characteristics

از تصاویر آیکونوس انجام شد. روش SVM استفاده شده در این تحقیق در مقایسه با روش بیشترین تشابه گوسی، با خطای کمتری همراه بود. نتایج این تحقیق نشان داد که فرض نرمال بودن توزیع داده‌ها همیشه نمی‌تواند فرض مطلوبی باشد (Song and Civco, 2004). همچنین از SVM و تصاویر اسپات ۱۵ برای طبقه‌بندی عارضه‌های انسانی (مثل پل‌ها، جاده‌ها و میادین) استفاده شد (Inglada, 2007). لوو<sup>۲</sup> و همکاران (۲۰۰۷) نیز از SVM و تصاویر پانکروماتیک آیکونوس برای طبقه‌بندی پل‌ها استفاده کردند. آنها از یک ایده بسیار ساده که پل‌ها همواره در مجاورت آب بوده و آب نیز معمولاً تیره‌تر از مواد دیگر می‌باشد، استفاده کردند. تصویر استر برای ارزیابی قابلیت SVM در شناسایی و طبقه‌بندی نواحی شهری استفاده شد که نتایج مختلفی متناسب با دقت تصاویر استفاده شده و نوع کرنل‌های بکار رفته برای SVM حاصل گردید (Zhu and Blumberg, 2002). بطور مشابه از تصاویر لندست برای کسب اطلاعات از مناطق صنعتی و مسکونی استفاده شد (Esch et al., 2009). تصویر هایپریون با استفاده از دو روش SVM و شبکه عصبی برای طبقه‌بندی تنوع پوششی سطح زمین بکار گرفته شد. نتایج بدست آمده نشان از برتری نامحسوس روش SVM نسبت به شبکه عصبی بود (Petropoulos, 2012). اکوجنی<sup>۳</sup> و همکاران (۲۰۱۳) از SVR و داده‌های آموزشی مصنوعی ترکیبی<sup>۴</sup> برای تخمین کمی زیرپیکسلی مناطق شهری استفاده کردند. روش ایشان بر روی داده‌های ابرطیفی های‌مپ مربوط به شهر برلین آلمان اجرا شد و نتایج تخمین با نقشه‌های موجود اعتبارسنجی شده و با نتایج روش MESMA<sup>۵</sup> مقایسه گردید. نتایج حاکی از دقت بالای تخمین فراوانی چهار نوع پوشش مختلف یعنی پشت بام‌های نفوذ ناپذیر، پیاده روها، چمن زارها و درختان بود. از SVM برای طبقه‌بندی پیکسل‌های خالص<sup>۶</sup> و ترکیبی<sup>۷</sup> تصویر ابرطیفی اویریس استفاده شد. به این صورت که به جای استفاده از یک طیف واحد برای هر پیکسل خالص، از مجموعه‌ای از طیف‌های مشابه استفاده شده و بدین ترتیب تنوع پذیری طیفی درون

---

1- SPOT5

2- Luo

3- Okujeni

4- Synthetically mixed training data

5- Multiple Endmember Spectral Mixture Analysis

6- Pure

7- Mixed

کلاسی نیز لحاظ گردید. نتایج حاکی از کارایی بهتر روش ارائه شده در مقایسه با روش تجزیه طیفی حداقل مربعات بود (Wang and jia, 2009).

## ۲-۲-۲- کاربردهای بیوفیزیکی SVM

SVM در سنجش از دور برای تخمین پارامترهای بیوفیزیکی مثل میزان کلروفیل استفاده شده است. ویاتکووسکا و فارگیون<sup>۱</sup> (۲۰۰۳) از داده‌های سنجنده‌های مختلفی برای این کار استفاده نمودند. همچنین میزان کلروفیل در نواحی ساحلی با استفاده از داده‌های مریس<sup>۲</sup> تخمین زده شد. نتایج نشان داد که روش استفاده شده در مقایسه با SVM استاندارد مؤثرتر و نسبت به نمونه‌های آموزشی از حساسیت بسیار کمتری برخوردار است (Bazy and Melgani, 2007). در تحقیقی دیگر از اندازه‌گیری در محل ابرطیفی برای تخمین مقدار کلروفیل استفاده شد (Sun et al., 2009).

## ۲-۲-۳- کاربردهای SVM با اهداف زمین‌شناسی و اکتشاف ذخایر

### معدنی

اگرچه این بخش اختصاص به کاربردهای SVM در طبقه‌بندی سنگ‌ها و کانی‌ها با استفاده از داده‌های سنجش از دور دارد ولی تحقیقات متعددی نیز در حوزه استفاده از SVM در زمین‌شناسی و اکتشاف ذخایر معدنی بدون استفاده از داده‌های سنجش از دور گزارش شده است. برای مثال در زمینه پی‌جویی مواد معدنی<sup>۳</sup> (Abedi et al., 2011; Zuo and Carranza, 2011)، طبقه‌بندی سنگ‌های کانه‌دار<sup>۴</sup> (Seng and Chen, 2009) و تفکیک مناطق دگرسانی مرتبط با ذخایر مس پورفیری (Abbaszadeh et al., 2013) از SVM استفاده شده است. اما در رابطه با استفاده از SVM از داده‌های سنجش از دور در

---

1- Kwiatkowska and Fargion

2- MERIS

3- Mineral mapping prospectivity

4- Ore-rock classification

حوزه علوم زمین می‌توان به نمونه‌های زیر اشاره کرد.

ایران‌زاد<sup>۱</sup> (۲۰۱۳) کارایی دو روش طبقه‌بندی نظارت‌شده SVM و غیرنظارتی SOM<sup>۲</sup> را برای شناسایی کانی‌های مختلف ارزیابی نمود. مجموعه داده ابرطیفی سنجنده اوپریس مربوط به منطقه کوپریت<sup>۳</sup> واقع در نوادای ایالات متحده به عنوان یکی از بهترین مجموعه داده‌های تحقیقاتی استاندارد استفاده شد. همچنین مجموعه داده پیچیده‌تری مربوط به منطقه بافین آیلند<sup>۴</sup> نیز مورد استفاده قرار گرفت.

با هدف طبقه‌بندی واحدهای سنگی منطقه‌ای آتشفشانی در ایسلند، SVM با روش‌های SAM و MLC مقایسه شد. نتایج کاربرد SVM برای طبقه‌بندی ۲۲ نوع واحد سنگی مختلف در منطقه مذکور با استفاده از داده‌های سنجنده اوپریس، نشان داد که SVM در مقایسه با دو روش دیگر با نتایج بهتری همراه است (Waske et al., 2009). در تحقیق دیگری، برای طبقه‌بندی ذخایر سولفوری از SVM با کرنل‌های خطی و گوسی و تصویر هایپریون استفاده شد که در نتیجه آن، سه منطقه با پوشش‌های سنگی، پوشیده از برف و رگه‌های سولفوری به خوبی شناسایی گردید (Mandrake et al., 2009). ۵ کلاس متنوع از واحدهای سنگی (سری‌های افیولیتی، واحدهای دگرگونی، واحدهای آتشفشانی اولیگوسن - میوسن تا کواترنری، سنگ آهک و واحدهای فلیشی) منطقه‌ای در شرق ایران با دقت ۵۲٪ توسط SVM و داده‌های هایپریون طبقه‌بندی شدند که به گمان محققان، با توجه به پیچیدگی‌های موجود در تنوع کلاسی، دقت قابل قبولی می‌باشد (Moeinzadeh et al., 2013).

برای تهیه نقشه واحدهای سنگی و کاهش مشکل حضور پوشش گیاهی در تصویر، از ترکیب روش SVM با ACA<sup>۵</sup> بر روی تصاویر سنجنده‌های TM و ETM+ استفاده شد و در پایان روش SVM-ACA به عنوان روشی کارآمد در نواحی دارای پوشش گیاهی معرفی گردید (Wang et al., 2011).

---

1- Iranzad  
2- Self -Organizing Machine  
3- Cuprite  
4- Baffin Island  
5- Adaptive Cellular Automata

اومن<sup>۱</sup> و همکاران (۲۰۰۸) از روش SVM برای طبقه‌بندی واحدهای لیتولوژیک استفاده کردند و نتایج آن را با روش MLC مقایسه کردند. نتایج بدست آمده حاکی از بالاتر بودن دقت SVM نسبت به روش MLC بود.

گودرزی مهر و همکاران (۱۳۹۱) برای تهیه نقشه زمین‌شناسی منطقه‌ای در همدان از SVM استفاده کرده و نتایج استفاده از این روش با کرنل‌های مختلف را با دو روش بیشترین تشابه و شبکه‌های عصبی مقایسه کردند. نتایج بدست آمده نشان داد که روش SVM در هر سه کرنل خود به بیشترین دقت (۰.۸۳/۴۲) در مقایسه با دو روش دیگر دست یافته است. همچنین SVM توانسته است با نیمی از داده‌های آموزشی نیز به دقتی معادل استفاده از کلیه داده‌های آموزشی برسد درحالی‌که دو روش دیگر چنین قابلیت‌هایی را نداشته‌اند. نتایج حاصله گویای این حقیقت است که SVM برای طبقه‌بندی داده‌هایی با تفکیک پذیری پایین، بسیار کارآمدتر از دو روش دیگر بوده و برای تهیه نقشه زمین‌شناسی مناسب‌تر می‌باشد.

## ۲-۲-۴- استفاده از SVM برای انجام طبقه‌بندی نرم یا زیرپیکسلی

طبقه‌بندی زیرپیکسلی با استفاده از SVM اگرچه در زمینه‌های مختلفی مثل طبقه‌بندی محصولات کشاورزی، مناطق مسکونی و شهری ( Jia et al., 2010; Mianji and Zhang, 2011; Yaozhong et al., 2012; Shirvani and Aghagolzadeh, 2014) استفاده شده است ولی آنگونه که باید در شاخه زمین‌شناسی و اکتشاف ذخایر معدنی (Yanfeng et al., 2013) مورد توجه قرار نگرفته است. هیلن<sup>۲</sup> و همکاران (۲۰۱۴) در مطالعات مروری خود در مورد تجزیه طیفی غیرخطی داده‌های ابرطیفی بخشی را نیز به تجزیه طیفی و طبقه‌بندی نرم توسط SVM اختصاص داده‌اند.

از SVM و کرنل‌های چندگانه<sup>۳</sup> برای طبقه‌بندی چند کلاسه داده‌های مصنوعی و واقعی ابرطیفی

---

1- Oommen

2- Heylen

3- Multiple-Kernel Learning

استفاده شد. نتایج بدست آمده نشان داد که اختلافات طیفی درون کلاسی<sup>۱</sup> در نتیجه استفاده از روش پیشنهادی تحقیق، بخوبی مورد توجه قرار گرفته و در مقایسه با دیگر روش‌های تجزیه طیفی مرسوم، دقت بالاتری بدست آمد. همچنین نتیجه‌گیری شد که در مواجهه با مسائل غیرخطی، استفاده از کرنل‌های چندگانه بجای روش‌های یادگیری تک‌کرنل<sup>۲</sup> با نتایج دقیق‌تری همراه خواهد بود. محققان روش پیشنهادی خود را بر روی چندین داده ابرطیفی از جمله مجموعه داده کوپریت واقع در نوادا پیاده سازی کرده و کانی‌های مختلف منطقه را طبقه‌بندی کردند (Yanfeng et al., 2013).

از SVR و داده‌های آموزشی مصنوعی برای طبقه‌بندی زیرپیکسلی داده‌های ابرطیفی های‌مپ مربوط به شهر برلین استفاده گردید و فراوانی چهار عارضه پشت بام‌ها، پیاده روها، فضای سبز و درختان تخمین زده شد. اعتبارسنجی یافته‌های آنها نشان داد که با ترکیب SVR و داده‌های آموزشی مصنوعی می‌توان نقشه‌های زیرپیکسلی کمی تولید نمود (Okujeni et al., 2013).

## ۲-۳- مروری بر کاربرد سنجش از دور ابرطیفی در اکتشاف ذخایر

### معدنی

همانطور که پیشتر نیز اشاره گردید، استفاده از سنجش از دور ابرطیفی برای اکتشاف ذخایر معدنی غالباً به صورت شناسایی کانی‌های مرتبط با ذخایر گرمایی می‌باشند. تحقیقات فراوانی در رابطه با استفاده از سنجش از دور ابرطیفی با هدف شناسایی دگرسانی‌های مرتبط با طلای اپی‌ترمال انجام شده است (Crosta et al., 1998; Rowan et al., 2000; Kruse et al., 2006; Chen et al., 2007; Gersman et al., 2009; Bedini et al., 2009). اخیراً سیستم‌های گرمایی فعال مرتبط با ذخایر زمین گرمایی توسط محققان متعددی مطالعه شده‌اند (Yang et al., 2000, 2001; Hellman and Ramsey, 2004;).

---

1- Interclass spectral differences  
2- Single kernel

(Vaughan et al., 2005; Kratt et al., 2010; Kevin and Ramsey, 2013). تحقیقاتی نیز در مورد شناسایی مشهورترین انواع ذخایر معدنی با استفاده از تصاویر ابرطیفی انجام شده است مثل سیستم‌های نوع کارلین<sup>۱</sup> (Rockwell and Hofstra, 2008)، سیستم‌های رگه‌ای آرکنن (Bierwirth et al, 2002)، اسکارن‌ها (Windeler, 1993)، اسکارن‌های کلسیک (Kozak et al, 2004; Bedini, 2009) و ماسیوسولفیدهای آتشفشانی (Berger et al, 2003). تأکید کلیه این تحقیقات بر پایه شناسایی کانی‌های سازنده سنگ‌های سطح زمین به عنوان نشانه‌هایی از ذخایر معدنی است. تحقیقات متعددی نیز در رابطه با کاربرد تصاویر ابرطیفی در شناسایی و تهیه نقشه‌های لیتولوژی در مناطق قطبی (Harris et al, 2005)، مناطق گرانیتی (Rivard et al, 2009) و سکانس‌های افیولیتی (Roy et al, 2009) و پریدوتیتی (Chabrilat et al, 2000) وجود دارد.

## ۲-۳-۱- مروری بر کاربرد سنجنده ابرطیفی هایپریون در شناسایی

### مناطق دگرسان شده

مطالعات متعددی با هدف استفاده از داده‌های سنجنده هایپریون برای طبقه‌بندی سنگ‌ها و اکتشاف ذخایر معدنی انجام شده است. قابلیت بالای سنجنده هایپریون در بازه طیفی VNIR<sup>۲</sup> و SWIR<sup>۳</sup> برای شناسایی کانی‌های مختلف در جنوب استرالیا ارزیابی شده است (Cudahy et al, 2001). نتایج ایشان نشان داد که نقشه کانی شناختی بدست آمده از پردازش داده‌های تصویر هایپریون همبستگی مکانی بالایی با نقشه زمین‌شناسی و نقشه دگرسانی‌های منطقه داشته لذا هایپریون و اطلاعات طیفی آن در بازه SWIR برای شناسایی کانی‌ها مناسب می‌باشند.

کوداهی و بری<sup>۴</sup> (۲۰۰۲) از روش MTMF<sup>۵</sup> و داده‌های هایپریون کانی‌های دگرسان شده در غرب استرالیا

---

1- Carlin- type

2- Visible Near-Infrared

3- Short-Wave Infrared

4- Cudahy and Barry

5- Mixed Tuned Match Filtering



را شناسایی کردند. در این تحقیق دو نوع میکای سفید یعنی کلریت (غنی از آلومینیوم) و پیروفیلیت (تهی از آلومینیوم) شناسایی شدند. نتایج حاصله با نقشه کانی شناختی تهیه شده با استفاده از سنجنده هوابرد های مپ و نقشه زمین شناسی موجود از منطقه انطباق بالایی نشان دادند.

برای شناسایی کانی های منطقه کوپریت در نوادای ایالات متحده، مقایسه ای بین سنجنده هوابرد اوپریس و سنجنده هایپریون انجام شد (Kruse et al., 2003). مقایسه بصری حاکی از شباهت بالای نتایج بدست آمده است.

سنگ های دگرسان شده هیدروترمالی و تشکیلات دگرگون شده پرکامبرین در اریتره با استفاده از داده های سنجنده هایپریون شناسایی شد که در نتیجه این تحقیق، توانایی سنجنده هایپریون در شناخت ویژگی طیفی آمونیوم اثبات گردید (Gersman et al., 2008).

داده های هایپریون و استر برای تهیه نقشه کانی شناختی در چین استفاده شدند. داده های استر برای شناسایی مناطق دگرسانی و داده های هایپریون برای مطالعه دقیق تر کانی ها استفاده شدند (Bishop et al, 2011).

SVM و داده های سنجنده هایپریون برای شناسایی و طبقه بندی مناطق دگرسانی مورد استفاده قرار گرفتند. در گام نخست از روش <sup>1</sup>ASP که مبتنی بر همبستگی باندهای طیفی مجاور هم می باشد برای کاهش ابعاد فضای ویژگی استفاده شد و در ادامه از SVM برای طبقه بندی داده ها استفاده گردید. همبستگی بالای نتایج بدست آمده با نقشه زمین شناسی منطقه و نتایج مطالعات قبلی، حاکی از قابلیت بالای SVM در طبقه بندی مناطق دگرسانی با استفاده از تصاویر سنجنده هایپریون بود (Wang and Zheng, 2010).

بیرانوندپور و هاشیم<sup>2</sup> (۲۰۱۱) از داده های هایپریون و ALI برای شناسایی مناطق دگرسانی همراه با ذخایر مس پورفیری در بخش جنوب شرقی کمربند آتشفشانی ایران مرکزی استفاده کردند. نتایج

---

1- Automatic Subspace Partition  
2- Beiranvand Pour and Hashim

تحقیقات آنها نشان داد که واحدهای زمین‌شناسی، سنگ‌های دگرسان شده هیدروترمالی و مناطق دگرسانی همراه با کانی‌زایی مس پورفیری در هر دو مقیاس منطقه‌ای و ناحیه‌ای توسط تصاویر هایپریون قابل شناسایی می‌باشند.

نجفیان و همکاران (۱۳۹۲) از داده‌های سنجنده هایپریون برای بهبود بارزسازی مناطق دگرسانی مرتبط با کانسارهای مس پورفیری و به ویژه کانی‌های گروه اکسید آهن استفاده کردند. در این تحقیق از طیف‌های کتابخانه‌ای به عنوان طیف مرجع استفاده شده و مناطق حاوی اکسیدهای آهن مناطق دگرسانی توسط نقشه بردار زاویه طیفی (SAM<sup>۱</sup>) با دقت بالایی شناسایی و با کنترل زمینی اعتبارسنجی شدند.

حسین‌جانی زاده<sup>۲</sup> و همکاران (۲۰۱۴a) قابلیت داده‌های هایپریون را در شناسایی کانی‌های مناطق دگرسانی مرتبط با ذخایر مس پورفیری ارزیابی کردند. ایشان از روش MTMF برای طبقه‌بندی زیرپیکسلی دگرسانی مناطق سرچشمه، دره زار و سریدون واقع در کمپلکس آتشفشانی- رسوبی ایران مرکزی استفاده کردند. نتایج بدست آمده توسط پیمایش‌های صحرائی و آنالیز آزمایشگاهی اعتبارسنجی گردید. نتایج نشان داد در صورتیکه عملیات پیش پردازش بر روی داده‌ها بخوبی اعمال گردد، هایپریون از ظرفیت بالایی برای شناسایی کانی‌های مناطق دگرسانی برخوردار است.

## ۲-۴- مروری بر کاربرد روش‌های انتخاب ویژگی در زمینه

### سنجش از دور ابرطیفی

تحقیقات فراوانی در ارتباط با انتخاب بهترین باندهای طیفی از تصاویر ابرطیفی انجام شده است. در قالب یک تحقیق مروری و با هدف کاربرد تصاویر ابرطیفی در بارزسازی محصولات غذایی، لیو<sup>۳</sup> و همکاران

---

1- Spectral Angle Mapper

2- Hosseinjani Zadeh

3- Liu

(۲۰۱۴) و دای<sup>۱</sup> و همکاران (۲۰۱۵)، روش‌های مختلف بکاررفته برای انتخاب بازه‌های طیفی مناسب را تقسیم بندی و بررسی کرده و به معرفی مزایا و معایب هر یک پرداختند.

قابلیت چهار روش انتخاب ویژگی از انواع مختلف فیلتر و پوششی، برای انتخاب بهترین باندهای داده‌های ابرطیفی<sup>۲</sup> DAIS و<sup>۳</sup> AVIRIS، با هدف طبقه‌بندی عوارض طبیعی مورد ارزیابی قرار گرفت (Pal and Foody, 2010). نتایج بدست آمده نشان داد که استفاده از روش‌های انتخاب ویژگی پیش از انجام طبقه‌بندی سودمند بوده و در افزایش دقت طبقه‌بندی مؤثر است.

انتخاب بهترین باندهای طیفی در شرایطی که همبستگی بالایی بین باندها وجود دارد، توسط افراد مختلفی مطالعه شده است (Guo et al., 2008). سان و گائو<sup>۴</sup> (۲۰۰۰) نخست با استفاده از نظریه مجموعه فازی<sup>۵</sup>، فضای باندی اولیه را به چندین دسته تقسیم کرده، سپس با انتخاب باندهای معرف یا ترکیب خطی آن‌ها، تعداد باندها را کاهش دادند. راهکار دیگری نیز به صورت تقسیم کل فضای باندی به چند زیرفضا بر اساس همبستگی بین باندها ارائه شد (Wang et al., 2005).

در قالب تحقیقی دیگر، یک روش ترکیبی مبتنی بر الگوریتم ژنتیک و بر اساس جستجوی محلی و ناحیه‌ای<sup>۶</sup> ارائه شد. این روش در مقیاس محلی، از اطلاعات متقابل<sup>۷</sup> به عنوان معیاری مستقل برای رتبه‌دهی به ویژگی‌ها استفاده می‌کند. درحالی‌که در مقیاس ناحیه‌ای، اطلاعات متقابل بین برچسب پیش‌بینی شده توسط یک روش طبقه‌بندی و برچسب واقعی به عنوان یک تابع برازش<sup>۸</sup> مورد استفاده قرار می‌گیرد (Huang et al., 2006).

لی<sup>۹</sup> و همکاران (۲۰۱۱) به نقش استفاده از روش‌های انتخاب باند بر افزایش دقت طبقه‌بندی اشاره کردند. ایشان از دو مجموعه داده مبنا و داده‌های تصویر ابرطیفی AVIRIS استفاده کرده و نتایج

---

1- Dai

2- Digital Airborne Imaging Spectrometer

3- Airborne Visible/Infrared Imaging Spectrometer

4- Sun and Gao

5- Fuzzy set theory

6- Local and global

7- Mutual information

8- Fitness function

9- Li

تحقیقات خود را با چندین روش انتخاب ویژگی دیگر مقایسه کردند.

## ۲-۵- نتیجه‌گیری

بطور کلی می‌توان گفت اگرچه SVM بطور گسترده‌ای در شاخه‌های گوناگون استفاده شده است، ولی در زمینه طبقه‌بندی سنگ‌ها و مناطق دگرسانی کاربرد زیادی نداشته است. همچنین مطالعات بسیار اندکی نیز از SVR برای طبقه‌بندی زیرپیکسلی تشکیلات زمین‌شناسی استفاده کرده‌اند. هیچ تحقیقی نیز در زمینه استفاده از Robust-SVM برای طبقه‌بندی تصاویر سنجش از دور و با هدف پوشش نوین موجود در داده‌ها انجام نشده است.

فصل سوم: روش باوداده‌ها

در این فصل کلیه روش‌ها و مجموعه داده‌های استفاده شده در تحقیق معرفی می‌شوند. در بخش روش‌ها به روش‌های طبقه‌بندی و تخمین SVM، Robust-SVM و SVR، روش کاهش ابعاد داده‌ها (روش انتخاب ویژگی) و روش‌های تخمین خطا پرداخته خواهد شد. در بخش داده‌ها نیز نخست به مجموعه داده ابرطیفی هایپریون و مشکلات همراه با آن اشاره شده و در ادامه، ۲ مجموعه داده استفاده شده برای آموزش، آزمایش و اعتبارسنجی نتایج معرفی خواهند شد.

### ۳-۱- روش‌ها

#### ۳-۱-۱- روش‌های طبقه‌بندی

در هر مسأله طبقه‌بندی با مفروض بودن مجموعه داده آموزشی  $T$  طبق رابطه (۳-۱) که در آن

$$(x_i, y_i) \in R^n \times Y, Y = \{1, -1\}, i = 1, \dots, l$$

$$T = \{(x_1, y_1), \dots, (x_l, y_l)\} \quad (۳-۱)$$

هدف یافتن تابع حقیقی  $g(x) \in R^n$  است بطوریکه مقدار  $y$  برای هر  $x$  ورودی جدید توسط تابع تصمیم زیر بدست آید:

$$f(x) = \text{sgn}(g(x)) \quad (۳-۲)$$

بایستی توجه گردد که در مجموعه  $T$  هر یک از  $n$  عضو بردار  $x_i \in R^n$  یک ویژگی برای نمونه  $i$ ام محسوب شده و  $y_i \in Y = \{1, -1\}$  برچسب یا خروجی مربوط به آن نمونه می‌باشد. با توجه به اینکه مجموعه  $Y$  دارای دو عضو می‌باشد، مسأله فوق یک طبقه‌بندی دو کلاسه<sup>۱</sup> می‌باشد که هدف آن پیدا کردن معیاری است که فضای  $R^n$  را به دو ناحیه مجزا تقسیم نماید. اگر برای نمونه  $i$ ام،  $y_i = 1$  باشد آن نمونه یک نمونه آموزشی مثبت و در حالت  $y_i = -1$  نمونه آموزشی منفی خواهد بود. همچنین در

---

1- Binary classification

رابطه (۲-۳) اگر  $g(x)$  یک تابع خطی مثل  $g(x) = (w \cdot x) + b$  باشد، مسأله یک طبقه‌بندی خطی خواهد بود بطوریکه ابرصفحه  $g(x)$  فضای  $n$  بعدی را به دو ناحیه تقسیم می‌کند (Deng et al., 2013).

### ۳-۱-۱-۱- ماشین بردار پشتیبان برای مسائل جدایی خطی

یک مسأله جدایی خطی به مسأله‌ای اطلاق می‌گردد که مجموعه داده آموزشی مربوط به دو کلاس مختلف توسط ابرصفحه‌ای بطور کامل از هم جدا گردند.

تعریف (مسأله جدایی خطی): با مفروض بودن مجموعه داده آموزشی رابطه (۳-۱)، اگر وجود

داشته باشند  $b \in R, w \in R^n$  و  $\varepsilon > 0$  بطوریکه به ازای هر  $i$  که  $y_i = 1$  داشته باشیم  $(w \cdot x) + b \geq \varepsilon$  و به ازای هر  $i$  که  $y_i = -1$  داشته باشیم  $(w \cdot x) + b \leq -\varepsilon$  آن‌گاه گفته می‌شود که مجموعه داده آموزشی و طبقه‌بندی متناظر با آن جدایی خطی هستند.

#### - طبقه‌بندی به روش بیشترین حاشیه<sup>۱</sup>

با در نظر گرفتن مسأله جدایی دو بعدی در شکل (۳-۱)، واضح است که خطوط بی‌شماری می‌توانند داده‌های دو کلاس را دقیقاً از یکدیگر تفکیک نمایند. برای مثال خط  $l_1$  با بردار نرمال  $w$  یکی از این خطوط می‌باشد. از میان بی‌شمار خطوط موازی با این خط، دو خط  $l_2$  و  $l_3$  که خطوط پشتیبان<sup>۲</sup> نام دارند در نزدیک‌ترین فاصله با یکی از کلاس‌ها و در دورترین فاصله از کلاس دیگر هستند. فاصله بین این دو خط حاشیه<sup>۳</sup> نام دارد و از بین همه انتخاب‌های ممکن، خطی که دقیقاً وسط دو خط  $l_2$  و  $l_3$  قرار گرفته و از هر یک از دو خط مذکور به اندازه نصف حاشیه فاصله داشته باشد بهترین جداکننده خواهد بود. عامل دیگر تأثیرگذار بر روی بهترین جداکننده بزرگی مقدار حاشیه است که در صورتیکه بیشینه مقدار ممکن باشد، بهینه‌ترین حالت ممکن رخ خواهد داد. از آنجایی که بزرگی حاشیه برابر با

---

1- Maximal margin method  
2- Support lines  
3- Margin

است لذا ایده حاشیه بیشینه منجر می شود به مسأله بهینه سازی (۳-۳~۳-۳) نسبت به متغیرهای  $\frac{2}{\|w\|}$

$w$  و  $b$  که با حل آن مقدار بهینه  $w$  بدست می آید (Deng et al., 2013).

$$\max_{w,b} \frac{2}{\|w\|} \quad (۳-۳)$$

$$s.t. \quad (w \cdot x) + b \geq 1, \quad \forall i : y_i = 1 \quad (۴-۳)$$

$$(w \cdot x) + b \leq -1, \quad \forall i : y_i = -1 \quad (۵-۳)$$

جهت سهولت در حل مسأله، روابط بیشینه سازی (۳-۳~۳-۳) به روابط کمینه سازی (۳-۳~۶-۳) تبدیل می شوند.

$$\min_{w,b} \frac{1}{2} \|w\|^2 \quad (۶-۳)$$

$$s.t. \quad y_i((w \cdot x_i) + b) \geq 1 \quad (۷-۳)$$

همانطور که گفته شد با حل مسأله بهینه سازی فوق و یافتن پاسخ های بهینه  $(w^*, b^*)$ ، بهترین

ابرفصله تفکیک کننده با معادله  $(w^* \cdot x) + b^* = 0$  بدست می آید. در نهایت تابع تصمیم برای تعیین

طبقه هر داده جدید برابر خواهد بود با  $f(x) = \text{sgn}((w^* \cdot x) + b^*)$  (Deng et al., 2013).

الگوریتم فوق که SVM خطی با حاشیه سخت<sup>۱</sup> نام دارد بر این فرض استوار است که همه نمونه های

مجموعه داده آموزشی بایستی بدرستی توسط ابرفصله خطی  $(w^* \cdot x) + b^* = 0$  طبقه بندی شوند

و اجازه هیچ گونه تخطی بطوریکه نمونه ای بتواند در بازه  $-1 < (w \cdot x) + b < 1$  قرار گیرد را نمی دهد.

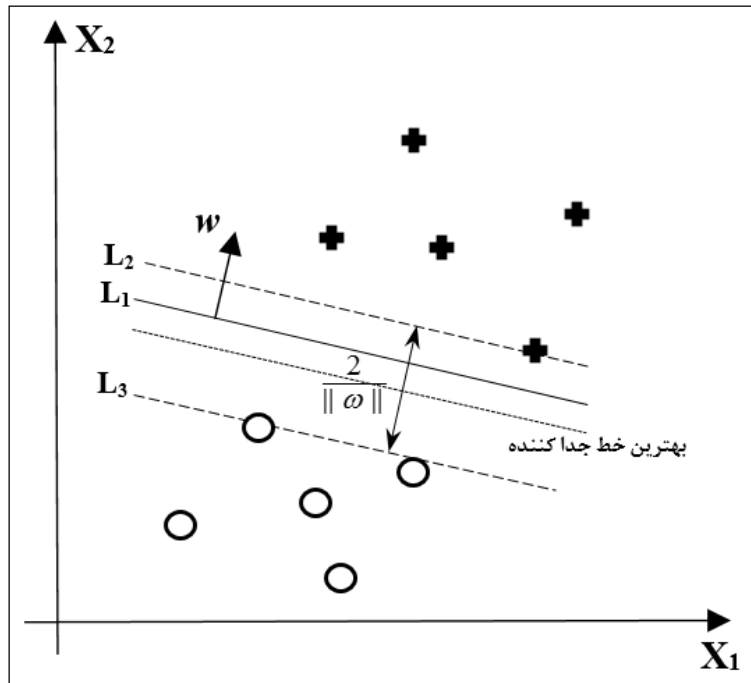
این موضوع تحت عنوان SVM برای مسائل جداناپذیر خطی و توسط الگوریتم SVM خطی با حاشیه

نرم<sup>۲</sup> حل شده است که در بخش بعدی به آن پرداخته شده است.

1- Linear hard margin SVM

2- Linear soft margin SVM





شکل (۳-۱) - بهترین خط جداکننده با بیشترین فاصله از هر دو کلاس (Deng et al., 2013)

### ۳-۱-۱ - ماشین بردار پشتیبان برای مسائل جداناپذیر خطی

برای افزایش قدرت تعمیم پذیری<sup>۱</sup> طبقه‌بندی در مسائل جداناپذیر خطی لازم است که قیود (۳-۴)~  
 (۳-۵) با معرفی متغیر اسلک<sup>۲</sup> ( $\xi$ ) و پارامتر جریمه<sup>۳</sup> ( $C$ ) برای هر نمونه نرم‌تر گشته و اجازه تخطی به  
 تعدادی از نمونه‌های جداناپذیر داده شود. برای مثال در شکل (۳-۲) نمونه ۱ (متعلق به کلاس +) اجازه  
 پیدا کرده است که به اندازه  $\xi_1$  از خط مربوط به کلاس خود تخطی کرده و در داخل حاشیه قرار گیرد  
 بطوریکه قید (۳-۷) در مورد آن صادق نمی‌باشد. این اغماض در میزان تخطی در مورد نمونه ۲ (متعلق  
 به کلاس O) بیشتر نیز شده است ( $\xi_2$ ) بطوریکه نه تنها قید (۳-۷) را رعایت نمی‌کند بلکه در طبقه  
 نادرست هم طبقه‌بندی شده است.


1- Generalization ability  
 2- Slack variable  
 3- Penalty parameter

با معرفی متغیرهای جدید، روابط (۳-۶~۳-۷) در حالت جداناپذیر خطی به روابط زیر تبدیل می‌شوند که مشابه با حالت قبل با محاسبه پاسخ‌های بهینه، ابرصفحه بهینه بدست می‌آید (Deng et al., 2013).

$$\min_{w,b,\xi} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \xi_i \quad (۳-۸)$$

$$s.t. \quad y_i((w \cdot x_i) + b) \geq 1 - \xi_i \quad (۳-۹)$$

$$\xi_i > 0 \quad (۳-۱۰)$$



شکل (۳-۲) - SVM برای مسائل جداناپذیر خطی (Deng et al., 2013)

### ۳-۱-۱-۳- ماشین بردار پشتیبان برای مسائل غیر خطی

در دو بخش قبلی SVM برای طبقه‌بندی مسائل خطی جداپذیر و جداناپذیر خطی معرفی و روابط مربوطه بیان گردید. اما SVM با استفاده از توابع کرنل<sup>۱</sup> می‌تواند برای طبقه‌بندی مجموعه داده‌های


1- Kernel functions

غیرخطی نیز استفاده شود. مطابق با شکل (۳-۳) نخست مجموعه داده‌های غیرخطی با استفاده از تابع کرنل  $h(x)$  به فضایی با ابعاد بالاتر نگاشته می‌شوند، بطوریکه ثابت شده است داده‌ها در فضای جدید بصورت خطی تفکیک‌پذیر می‌شوند. با نگاشت داده‌ها به فضای جدید، روابط (۳-۸~۳-۱۰) در حالت خطی به روابط (۳-۱۱~۳-۱۳) برای طبقه‌بندی مسائل غیرخطی تبدیل می‌شوند (Deng et al., 2013).

$$\min_{w,b,\xi} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \xi_i \quad (11-3)$$

$$s.t. \quad y_i((w \cdot h(x_i)) + b) \geq 1 - \xi_i \quad (12-3)$$

$$\xi_i > 0 \quad (13-3)$$



شکل (۳-۳) - استفاده از توابع کرنل برای طبقه‌بندی مسائل غیرخطی

کرنل‌های خطی<sup>۱</sup>، درجه دوم<sup>۲</sup>، چند جمله‌ای<sup>۳</sup>، تابع پایه‌ای شعاعی (RBF)<sup>۴</sup> و پرسپترون چند لایه (MLP)<sup>۵</sup> تعدادی از مهمترین توابع کرنل هستند. برای نمونه دو کرنل معروف چند جمله‌ای و تابع پایه‌ای شعاعی با روابط زیر تعریف می‌شوند (Deng et al., 2013).

- 
- 1- Linear
  - 2- Quadratic
  - 3- Polynomial kernel
  - 4- Radial Basis Function (RBF)
  - 5- Multi-Layer Perceptron (MLP)

۱- کرنل چند جمله‌ای: با فرض  $d$  به عنوان یک عدد صحیح مثبت، تابع چند جمله‌ای طبق رابطه

(۱۴-۲) تعریف می‌شود.

$$K(x, x') = ((x \cdot x') + 1)^d \quad (14-3)$$

۲- کرنل RBF: رابطه تابع کرنل RBF با متغیر  $\sigma$  به قرار زیر است.

$$K(x, x') = \exp(- \|x - x'\|^2 / \sigma^2) \quad (15-3)$$

در پایان لازم به ذکر است که برای حل کلیه مسائل فوق یعنی روابط (۳-۶~۳-۷)، (۳-۸~۳-۱۰) و

(۳-۱۱~۳-۱۳) که به ترتیب مربوط به SVM در حالت‌های جداپذیر خطی، جداناپذیر خطی و غیرخطی

می‌باشند، از روش ضرایب لاگرانژ و برنامه‌ریزی درجه دوم (QP)<sup>۱</sup> استفاده می‌شود.

### ۳-۱-۱-۴- ماشین بردار پشتیبان مقاوم

فرآیندهای تصادفی و غیرتصادفی<sup>۲</sup> در زندگی روزمره، منجر به تولید داده‌هایی با عدم قطعیت<sup>۳</sup> می‌گردد

(Trafalis and Gilbert, 2006) بطوریکه قطعیت ناپذیری موضوعی شایع در اغلب مجموعه داده‌ها

می‌باشد. قطعیت ناپذیری داده‌ها را می‌توان ناشی از نویز موجود در داده‌ها دانست که خود ناشی از

وجود خطا در اندازه‌گیری داده‌ها می‌باشد. در صورتی که این قطعیت ناپذیری و وجود نویز در داده‌ها در

فرآیند طبقه‌بندی مورد توجه قرار نگیرد موجب افزایش خطای طبقه‌بندی خواهد شد. موضوع قطعیت

ناپذیری داده‌ها معمولاً توسط روش‌های داده‌کاوی<sup>۴</sup> مورد توجه قرار نمی‌گیرد (Pant et al, 2011).

بنابراین توسعه روش‌های مبتنی بر یادگیری ماشین و داده‌کاوی که در مقابل انحرافات<sup>۵</sup> و همچنین

ماهیت قطعیت ناپذیری این نوع داده‌ها مقاوم باشند، ضروری می‌باشد. هدف از توسعه این روش‌های


طبقه‌بندی یا پیش‌بینی کننده، تأثیر ناپذیری از نویز موجود در داده‌های ورودی می‌باشد ( Trafalis )

---

1- Quadratic Programming  
2- Random and non-random  
3- Uncertainty  
4- Data mining  
5- perturbations

(and Gilbert, 2006).

SVM در بسیاری از مسائل طبقه‌بندی استفاده شده و روش مرسوم در داده‌کاوی می‌باشد. اگرچه SVM با حاشیه نرم راه حل مناسبی برای طبقه‌بندی داده‌های جدایی ناپذیر است ولی با وجود عدم قطعیت در داده‌ها، نسخه استاندارد SVM برای طبقه‌بندی بهینه داده‌ها مناسب نمی‌باشد (Pant et al, 2011). در SVM استاندارد، فرض بر این می‌باشد که ویژگی‌ها یا پارامترهای مجموعه داده آموزشی دقیقاً شناخته شده است. اما در کاربردهای واقعی، ویژگی‌ها و پارامترهای مذکور با انحرافات و اختلالاتی همراه می‌گردند زیرا در نتیجه تخمین توسط داده‌هایی بدست می‌آیند که از خطاهای اندازه‌گیری و آماری رنج می‌برند. اشاره شده است که مسائل بهینه‌سازی نسبت به انحرافات پارامتری حساس می‌باشند بطوریکه خطاهای موجود در پارامترهای ورودی، دامنه توابع تصمیم را وسعت بخشیده و در نهایت معمولاً منجر به طبقه‌بندی نادرست<sup>۱</sup> می‌شوند. به عنوان مثال در شکل (۳-۴-الف) نمونه‌هایی با ویژگی مشخص و ثابت<sup>۲</sup> با دقت بالایی از یکدیگر تفکیک گردیده‌اند. اما هنگامی که مطابق با شکل (۳-۴-ب) ویژگی نمونه‌ها مجاز به نوسان در فضای کروی شکل باشند، تابع تصمیم پیشین قادر به تفکیک نمونه‌های دو کلاس از یکدیگر نمی‌باشد. بنابراین بایستی روش طبقه‌بندی کننده جدیدی طراحی گردد که توانایی طبقه‌بندی دقیق مجموعه داده‌هایی که حاوی خطاهای اندازه‌گیری و آماری می‌باشند را نیز داشته باشد (۳-۴-ج) (Qi et al, 2013).



شکل (۳-۴)- الف- طبقه‌بندی نمونه‌هایی با ویژگی ثابت و مشخص، ب- تأثیر نویز موجود در داده‌ها بر طبقه‌بندی، ج- مدل مقاوم (Qi et al, 2013)

1- Misclassification  
2- Fixed examples

## الف- طبقه‌بندی مقاوم<sup>۱</sup> در مقابل عدم قطعیت<sup>۲</sup>

مطابق با رابطه (۱-۳)، مجموعه داده آموزشی برای یک مسأله طبقه‌بندی دو کلاسه بصورت  $T = \{(x_1, y_1), \dots, (x_l, y_l)\}$  تعریف شد. رابطه مذکور بر این فرض استوار است که مقدار داده‌ها به صورت کاملاً دقیق اندازه‌گیری شده‌اند، لذا می‌توانند توسط  $x_i \in R^n, i=1, \dots, l$  بیان گردند. با این حال در دنیای واقعیت معمولاً عامل عدم قطعیت نیز با اندازه‌گیری داده‌ها همراه می‌باشد، برای مثال در مواقعی که در اندازه‌گیری داده‌ها عامل خطا پدیدار می‌شود. در چنین شرایطی بهتر است که داده‌ها به شکلی تعریف گردند که عامل عدم قطعیت حاصله از خطا نیز لحاظ گردد. برای تعریف مجموعه داده‌های همراه با عدم قطعیت یا خطادار از اشکال مختلفی استفاده می‌شود مثل انواع چندوجهی<sup>۳</sup> و ابرکروی<sup>۴</sup>. در نوع چندوجهی، مجموعه داده  $X_i \in R^n, i=1, \dots, l$  که از  $x_i$  بدست آمده و عامل عدم قطعیت یا نویز را نیز پوشش می‌دهد توسط رابطه (۲-۱۶) تعریف می‌گردد (Deng et al., 2013).

$$X_i = \left\{ x \mid [x]_j = [x_i]_j + [\Delta x_i]_j [z_i]_j \right\} \quad j = 1, \dots, n \quad (۱۶-۳)$$

$$z_i = ([z_i]_1, \dots, [z_i]_n)^T, \quad \|z_i\|_1 \leq \Omega$$

متغیرها در رابطه فوق عبارت هستند از:

$x_i$ : مقدار اسمی<sup>۵</sup> داده  $i$  ام،  $\Omega$ : بزرگی اختلال یا نویز،  $z_i$ : تغییرات<sup>۶</sup>

$$\|z_i\|_1 = \sum_{j=1}^n |[z_i]_j| \quad \text{یعنی اول } z_i \text{ از } [z_i]_j$$

$\Delta x_i = ([\Delta x_i]_1, \dots, [\Delta x_i]_n)^T$  راستا و جهت مقدار اختلال<sup>۷</sup> یا نویز

- 
- 1- Robust classification
  - 2- Uncertainty
  - 3- Polyhedron
  - 4- Supersphere
  - 5- Nominal
  - 6- Variation
  - 7- Perturbation

در نوع ابرکروی، مجموعه داده  $X_i$  به شکل کره‌ای تعریف می‌گردد بطوریکه طبق رابطه (۳-۱۷) میزان عدم قطعیت یا اختلال موجود در مجموعه داده  $x_i$  توسط شعاع این کره بیان می‌شود. در این رابطه  $x_i$  مقدار اسمی داده  $i$  ام و  $r_i$  بزرگی اختلال در نمونه  $i$  ام است (Deng et al., 2013).

$$X_i = \left\{ x \mid \|x - x_i\| \leq r_i \right\} \quad (۳-۱۷)$$

با جایگزینی  $X_i$  به جای  $x_i$ ، مجموعه داده آموزشی برای طبقه‌بندی مقاوم از رابطه (۳-۱) به رابطه (۳-۱۸) تبدیل خواهد شد.

$$T = \{(X_1, Y_1), \dots, (X_l, Y_l)\} \quad (۳-۱۸)$$

با توجه به یکسان بودن برچسب همه نمونه‌ها می‌توان گفت  $Y_i = y_i$ . در نهایت یک مسأله طبقه‌بندی دو کلاسه مقاوم<sup>۱</sup> با مجموعه داده آموزشی رابطه (۳-۱۸) را می‌توان تعریف نمود بطوریکه  $X_i \in R^n$ ،  $Y_i \in \{-1, 1\}$  و  $(i=1, \dots, l)$ . در این حالت هر جفت داده  $(x_i, y_i)$  با  $Y_i=1$  اشاره به این دارد که هر  $x$  در مجموعه  $X_i$  متعلق به کلاس مثبت است و بطور مشابه  $Y_i=-1$  یعنی هر  $x$  در مجموعه  $X_i$  متعلق به کلاس منفی است. هدف نهایی یافتن یک تابع حقیقی  $g(x)$  در فضای  $R^n$  می‌باشد بطوریکه بتواند مقدار  $y$  متعلق به هر  $x$  جدید به عنوان ورودی را با تابع تصمیم زیر پیش‌بینی نماید (Deng et al., 2013):

$$f(x) = \text{sgn}(g(x)) \quad (۳-۱۹)$$

با این مقدمه، در ادامه ماشین بردار پشتیبان مقاوم با فرض ابرکروی بودن داده‌های ورودی معرفی می‌شود.

## ب- ماشین بردار پشتیبان مقاوم خطی

یک مسأله جداپذیر خطی با مجموعه داده آموزشی رابطه (۱۸-۳) مفروض است. تلاش برای یافتن ابرصفحه بهینه  $(w^* \cdot x) + b^* = 0$  با هدف دستیابی به بزرگترین حاشیه منجر به مسأله بهینه‌سازی زیر می‌گردد (Deng et al., 2013):

$$\min_{w,b} \frac{1}{2} \|w\|^2 \quad (20-3)$$

$$s.t. \quad y_i((w \cdot (x_i + r_i u_i)) + b) \geq 1, \quad \forall \|u_i\| \leq 1, \quad i=1, \dots, l \quad (21-3)$$

برای تعمیم مسأله فوق به حالت غیرخطی، روابط فوق با افزودن متغیرهای اسلک تبدیل خواهند شد به:

$$\min_{w,b,\xi} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l \xi_i \quad (22-3)$$

$$s.t. \quad y_i((w \cdot (x_i + r_i u_i)) + b) \geq 1 - \xi_i, \quad \forall \|u_i\| \leq 1, \quad i=1, \dots, l \quad (23-3)$$

$$\xi_i \geq 0, \quad i=1, \dots, l \quad (24-3)$$

جهت سهولت در حل مسأله بهینه‌سازی فوق، از قضایای (۱-۳) و (۲-۳) استفاده شده و مسأله مذکور به یک مسأله مخروطی درجه دوم<sup>۱</sup> تبدیل می‌شود.

قضیه ۱-۳.  $(w^*, b^*, \xi^*)$  جوابی برای مسأله (۲۲-۳~۲۴-۳) است اگر و تنها اگر جواب مسأله مخروطی درجه دوم زیر باشد (Deng et al., 2013):

$$\min_{w,b,\xi,u,v,t} \frac{1}{2}(u-v) + C \sum_{i=1}^l \xi_i \quad (25-3)$$

1- Second Order Cone Programming (SOCP)



$$s.t. \quad y_i((w \cdot x_i) + b) - r_i t \geq 1 - \xi_i, \quad i=1, \dots, l \quad (26-3)$$

$$\xi_i \geq 0, \quad i=1, \dots, l \quad (27-3)$$

$$u + v = 1 \quad (28-3)$$

$$\begin{pmatrix} u \\ t \\ v \end{pmatrix} \in L^3 \quad (29-3)$$

$$\begin{pmatrix} t \\ w \end{pmatrix} \in L^{n+1} \quad (30-3)$$

اثبات: چون  $\min\{y_i r_i (w \cdot u_i), \|u_i\| \leq 1\} = -r_i \|w\|$  بنابراین مسأله (۳-۲۲~۳-۲۴) معادل خواهد بود با:

$$\min_{w, b, \xi} \quad \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l \xi_i \quad (31-3)$$

$$s.t. \quad y_i((w \cdot x_i) + b) - r_i \|w\| \geq 1 - \xi_i, \quad i=1, \dots, l \quad (32-3)$$

$$\xi_i \geq 0, \quad i=1, \dots, l \quad (33-3)$$

به منظور تبدیل مسأله فوق به یک مسأله مخروطی درجه دوم، با تعریف متغیر  $t$  بطوریکه  $\|w\| \leq t$  خواهیم داشت:

$$\min_{w, b, \xi, t} \quad \frac{1}{2} t^2 + C \sum_{i=1}^l \xi_i \quad (34-3)$$

$$s.t. \quad y_i((w \cdot x_i) + b) - r_i t \geq 1 - \xi_i, \quad i=1, \dots, l \quad (35-3)$$

$$\xi_i \geq 0, \quad i=1, \dots, l \quad (36-3)$$

$$\|w\| \leq t \quad (37-3)$$

در ادامه با تعریف متغیرهای  $u$  و  $v$  بطوریکه  $u + v = 1$  و  $\sqrt{t^2 + v^2} \leq u$  خواهیم داشت

در نهایت با جایگذاری  $t^2 = u^2 - v^2 = u - v$  در روابط (۳-۳۴~۳-۳۷)، روابط

(۳-۲۵-۳) بدست می‌آیند. با تعریف تابع لاگرانژ برای روابط (۳-۲۵-۳)~(۳-۳۰)، مسأله دوگان آن

طبق رابطه زیر بدست می‌آید که در آن  $\alpha, \eta \in R^l, \beta, z_u, z_v, \gamma, z_t \in R, z_w \in R^n$  بردار ضرایب لاگرانژ هستند.

$$L = \frac{1}{2}(u - v) + C \sum_{i=1}^l \xi_i - \sum_{i=1}^l \alpha_i (y_i ((w \cdot x_i) + b) - r_i t - 1 + \xi_i) \quad (38-3)$$

$$- \sum_{i=1}^l \eta_i \xi_i - \beta(u + v - 1) - z_u u - z_v v - \gamma t - z_t t - z_w^T w$$

در حقیقت روابط (۳-۳۹)~(۳-۴۵) که در قالب قضیه (۲) ارائه می‌شوند معادل مسأله دوگان فوق می‌باشند.

قضیه ۳-۲. با فرض اینکه  $(\alpha^{*T}, \gamma^*) = ((\alpha_1^*, \dots, \alpha_l^*), \gamma^*)$  پاسخی برای مسأله مخروطی درجه دوم

زیر باشد (Deng et al., 2013):

$$\max_{\alpha, \beta, \gamma, z_u, z_v} \quad \beta + \sum_{i=1}^l \alpha_i \quad (39-3)$$

$$s.t \quad \gamma \leq \sum_{i=1}^l r_i \alpha_i - \sqrt{\sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j y_i y_j (x_i \cdot x_j)} \quad (40-3)$$

$$\beta + z_u = \frac{1}{2} \quad (41-3)$$

$$\beta + z_v = -\frac{1}{2} \quad (42-3)$$

$$\sum_{i=1}^l y_i \alpha_i = 0 \quad (43-3)$$

$$0 \leq \alpha_i \leq C, i=1, \dots, l \quad (44-3)$$

$$\sqrt{\gamma^2 + z_v^2} \leq z_u \quad (45-3)$$

اگر عضوی از  $\alpha^*$  وجود داشته باشد بطوریکه  $\alpha^*_{j \in (0,C)}$  آنگاه با استفاده از روابط زیر جواب بهینه‌ای برای مسأله (۳-۲۵~۳-۳۰) بدست خواهد آمد (Deng et al., 2013):

$$w^* = \frac{\gamma^*}{(\gamma^* - \sum_{i=1}^l r_i \alpha_i^*)} \sum_{i=1}^l \alpha_i^* y_i x_i \quad (۴۶-۳)$$

$$b^* = y_i - \frac{\gamma^*}{(\gamma^* - \sum_{i=1}^l r_i \alpha_i^*)} \sum_{i=1}^l \alpha_i^* y_i (x_i \cdot x_j) - y_j r_j \gamma^* \quad (۴۷-۳)$$

در نهایت ماشین بردار پشتیبان خطی مقاوم برای داده‌های نویزی هنگامی که از حالت ابرکروی برای نشان دادن اختلال در هر داده استفاده می‌شود را می‌توان با الگوریتم زیر خلاصه کرد:

۱- دریافت مجموعه داده آموزشی  $T$  (رابطه ۳-۱)

۲- انتخاب پارامتر جریمه مناسب ( $C > 0$ )

۳- ساخت و حل مسأله مخروطی درجه دوم (۳-۳۹~۳-۴۵) برای بدست آوردن پاسخ‌های بهینه

$$(\alpha^*, \gamma^*)$$

۴- محاسبه مقدار  $b^*$  توسط رابطه (۳-۴۷) با انتخاب عضوی از  $\alpha^*_{j \in (0,C)}$  بطوریکه

$$۵- \text{ساخت تابع تصمیم } \left( \frac{\gamma^*}{(\gamma^* - \sum_{i=1}^l r_i \alpha_i^*)} \sum_{i=1}^l \alpha_i^* y_i (x_i \cdot x) + b^* \right) \text{sgn}(f(x))$$

همانطور که اشاره شد، مسأله (۳-۳۹~۳-۴۵) یک مسأله بهینه‌سازی مخروطی درجه دوم است. با توجه به این نکته که جعبه ابزار بهینه‌سازی تعبیه شده در نرم‌افزار متلب<sup>۱</sup> قابلیت حل این نوع مسائل بهینه‌سازی را ندارد، در این تحقیق از نرم‌افزار SeDuMi<sup>۲</sup> برای حل مسأله بهینه‌سازی فوق استفاده شد. این نرم‌افزار ابزار مناسبی برای حل انواع مختلف مسائل بهینه‌سازی خطی، مخروطی درجه دوم و نیمه

1- MATLAB (MATrix LABoratory)

2- Self-Dual-Minimization

معین<sup>۱</sup> بوده و از طریق پایگاه الکترونیکی به آدرس <http://sedumi.mcmaster.ca> قابل دسترسی است (Deng et al., 2013).

### ۳-۱-۲- رگرسیون بردار پشتیبان (SVR)

SVR با استفاده از اصول روش SVM برای انجام رگرسیون و تخمین مقدار یک متغیر استفاده می‌شود. این روش نیز مشابه با SVM از نظریه کمینه کردن ریسک ساختاری<sup>۲</sup> استفاده کرده و ابرصفحه‌ای را تعریف می‌کند (Gómez-Chova et al., 2011; Okujeni et al., 2013) با این تفاوت که ابرصفحه تعریف شده توسط SVM نمونه‌های متعلق به دو طبقه مختلف را از یکدیگر تفکیک می‌کند ولی ابرصفحه بدست آمده توسط SVR در نقش یک تابع عمل کرده و برای تخمین مقدار یک متغیر هدف استفاده می‌شود.

SVR در حالت خطی وابستگی خطی موجود بین نمونه‌های آموزشی و متغیر هدف را اندازه‌گیری نموده و تخمین می‌زند. همچنین SVR توانایی تخمین روابط غیر خطی را نیز داشته و برای اینکار مشابه با SVM از توابع کرنل استفاده می‌کند. اگرچه پارامتر جریمه ( $C$ ) در هر دو روش SVM و SVR تعریف شده و دارای نقش مشابهی است اما SVR از متغیر دیگری به نام  $\epsilon$  نیز استفاده می‌کند که وظیفه آن کنترل میزان خطای مجاز در فرآیند تخمین است.

بطور کلی هدف SVR کمینه کردن مقدار یک تابع هزینه به همراه بیشینه کردن حاشیه و کمینه کردن خطای تخمین است (Okujeni et al., 2013). این هدف در حالت خطی توسط روابط (۳-۴۸~۳-۵۱) تأمین می‌گردد که در آن‌ها  $\xi$  و  $\xi^*$  متغیرهای اسلک بوده و  $C$  پارامتر جریمه است (Gómez-Chova et al., 2011). برای حل این مسئله بهینه‌سازی نیز از روش ضرایب لاگرانژ و برنامه‌ریزی درجه دوم (QP) استفاده می‌شود.

---

1- Semidefinite programming  
2- Structural risk minimization

$$\min \left\{ \frac{1}{2} \left\| \vec{W} \right\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \right\} \quad (48-3)$$

$$s.t \quad y_i - \vec{W} \cdot \vec{X}_i - b \leq \varepsilon + \xi_i \quad \forall i = 1, \dots, n \quad (49-3)$$

$$\vec{W} \cdot \vec{X}_i + b - y_i \leq \varepsilon + \xi_i^* \quad \forall i = 1, \dots, n \quad (50-3)$$

$$\xi_i, \xi_i^* \geq 0 \quad \forall i = 1, \dots, n \quad (51-3)$$

### ۳-۱-۳- کاهش ابعاد داده

امروزه در داده‌کاوی، شناسایی الگو، پردازش تصویر، بیوانفورماتیک و بسیاری از حوزه‌های دیگر ممکن است به مسائل بیش‌ابعادی برخورد شود که در آنها تعداد نمونه‌ها خیلی کم ولی در مقابل تعداد ویژگی‌های توصیف‌گر نمونه‌ها بسیار زیاد است (Yusta, 2009). در عمل و بدلائیل مختلف بسیاری از ویژگی‌های مجموعه داده‌های بیش‌ابعاد، افزونه و نامربوط هستند که فقط باعث بزرگتر گشتن اندازه فضای ویژگی می‌شوند. از سویی دیگر تجزیه و تحلیل فضاهای بیش‌ابعاد و شناسایی الگوهای حاکم بر آنها بدلیل پیچیده‌تر بودن با مشکل مواجه می‌گردد (Gheyas and Leslie, 2010). از این رو و برای مقابله با این مشکل، روش‌های کاهش ابعاد داده مورد توجه بسیاری از علوم کاربردی قرار گرفته‌اند. استفاده از این روش‌ها باعث افزایش دقت و سرعت طبقه‌بندی، کاهش پیچیدگی محاسباتی و هزینه زمانی در مرحله آموزش روش طبقه‌بندی کننده، کاهش احتمال رخداد بیش‌برازش<sup>۱</sup> و افزایش قدرت تعمیم‌پذیری طبقه‌بندی می‌شود (Yusta, 2009; Gheyas and Leslie, 2010; Wang and Wu, 2013).

روش‌های کاهش ابعاد داده به دو گروه روش‌های استخراج ویژگی<sup>۲</sup> و انتخاب ویژگی<sup>۳</sup> تقسیم می‌شوند. بر خلاف روش‌های استخراج ویژگی مثل روش تجزیه مؤلفه اصلی (PCA)<sup>۴</sup>، روش‌های انتخاب

---

1- Over fitting  
 2- Feature extraction  
 3- Feature selection  
 4- Principal Component Analysis (PCA)

ویژگی ترتیب و چینش ویژگی‌های موجود در فضای ویژگی را دگرگون نمی‌کنند (Wang and Wu, 2013)، بلکه تلاش می‌کنند با انتخاب ویژگی‌هایی که بیشترین اطلاعات را فراهم می‌کنند کارایی فرآیند داده‌کاوی را بهبود بخشند (Gheyas and Leslie, 2010; Wang and Wu, 2013).

روش‌های انتخاب ویژگی به سه دسته روش‌های فیلتر<sup>۱</sup>، پوششی<sup>۲</sup> و ترکیبی<sup>۳</sup> طبقه‌بندی می‌شوند. انواع فیلتر به هر یک از ویژگی‌ها وزنی را متناسب با خصوصیات آماری و درجه اهمیت آنها اختصاص داده و در نهایت با انتخاب ویژگی‌های حائز شرایط مورد نیاز، ویژگی‌های باقی مانده را حذف می‌کنند (Wang and Wu, 2013). این روش‌ها که مستقل از الگوریتم‌های یادگیری هستند خود به دو زیرگروه رنکینگ<sup>۴</sup> و جستجوگر فضا<sup>۵</sup> تقسیم می‌شوند (Lazar et al., 2012). در نوع رنکینگ با محاسبه همبستگی موجود بین ویژگی‌ها و برچسب طبقات، وزنی به هر طبقه تخصیص یافته و در ادامه ویژگی‌هایی با اوزان بیش از حد آستانه‌ای واجد شرایط قرارگیری در بین ویژگی‌های منتخب می‌گردند. اگرچه عملکرد روش‌های رنکینگ در رابطه با شناسایی ویژگی‌های نامربوط موفقیت‌آمیز است اما در شناسایی ویژگی‌های افزونه دچار مشکل می‌شوند. جهت شناسایی باندهای افزونه بایستی همبستگی بین ویژگی‌ها نیز محاسبه گردد که بویژه در رابطه با فضاهای ویژگی بزرگ نیازمند محاسبات سنگینی است. برای حل این مشکل روش‌های جستجوگر فضا توسعه یافته‌اند که در طی سه مرحله مبادرت به شناسایی ویژگی‌های منتخب می‌کنند. نخست زیرمجموعه‌ای از ویژگی‌ها را به صورت تصادفی انتخاب کرده سپس ویژگی‌هایی با اوزان بزرگتر از یک حد آستانه‌ای را جدا نموده و در پایان از یک تابع ارزیابی برای محاسبه همبستگی بین ویژگی‌ها و شناسایی و حذف ویژگی‌های افزونه استفاده می‌کنند. روش‌های جستجوگر فضا در مقایسه با انواع رنکینگ از بازدهی بیشتری برخوردار هستند (Wang and Wu, 2013).

---

1- Filter  
2- Wrapper  
3- Hybrid  
4- Ranking  
5- Space search

برخلاف روش‌های فیلتر که مستقل از روش‌های یادگیری هستند، روش‌های پوششی از یک مدل یادگیری و یک روش طبقه‌بندی کننده برای شناسایی زیرمجموعه ویژگی‌های منتخب استفاده می‌کنند. شیوه کاری این روش‌ها به این صورت می‌باشد که ابتدا توسط مدل یادگیری، زیرمجموعه‌های مختلفی از ویژگی‌ها از فضای ویژگی اولیه انتخاب و در ادامه کارایی آن‌ها توسط یک روش طبقه‌بندی کننده ارزیابی می‌شود. در نهایت نیز زیرمجموعه‌ای با بهترین کارایی به عنوان زیرمجموعه ویژگی منتخب انتخاب می‌شود. از آنجایی که الگوریتم‌های پوششی در مقایسه با انواع فیلتر هزینه محاسباتی بیشتری دارند لذا جهت کار با مجموعه داده‌های بیش‌ابعد مناسب نیستند ولی در مقابل از دقت بیشتری برخوردار می‌باشند (Hui-Huang and Cheng-Wei, 2011).

عملکرد روش‌های ترکیبی بر اساس ترکیب روش‌های فیلتر و پوششی می‌باشد. این روش‌ها در گام اول و با استفاده از یک روش فیلتر، تعداد ویژگی‌های مورد نیاز را کاهش می‌دهند سپس در گام دوم و با استفاده از یک روش پوششی، بهترین ویژگی‌ها را انتخاب می‌کنند (Bermejo et al., 2012). در این رساله برای انتخاب مجموعه ویژگی‌های منتخب از یک روش ترکیبی استفاده می‌شود. در این روش در مرحله فیلتر ویژگی‌ها وزن‌دهی شده سپس در مرحله پوششی و با استفاده از الگوریتم رقابت استعماری- فازی (FICA<sup>1</sup>) و الگوریتم IWSSr<sup>2</sup>، بهترین زیرمجموعه ویژگی‌ها انتخاب می‌شود. این روش در کنار دستیابی به زیرمجموعه فشرده‌تری از ویژگی‌ها از دقت بیشتری نیز در مقایسه با روش‌های مشابه برخوردار است (Moradkhani et al., 2015). در ادامه الگوریتم‌های مذکور و نحوه عملکرد الگوریتم ترکیبی استفاده شده در این تحقیق توضیح داده شده‌اند.

### – الگوریتم IWSSr

الگوریتم‌های IWSS و IWSSr از نوع روش‌های انتخاب ویژگی ترکیبی هستند. در این روش‌ها در مرحله فیلتر، ویژگی‌ها بر اساس وزن تعلق گرفته به آنها مرتب می‌شوند. سپس در مرحله پوششی، اولین ویژگی

1- Fuzzy Imperialist Competitive Algorithm

2- Incremental Wrapper Subset Selection with replacement

با بیشترین امتیاز با استفاده از یک روش طبقه بندی کننده ارزیابی و دقت بدست آمده ثبت می شود. در گام بعدی ویژگی دیگری با بالاترین امتیاز به مجموعه ویژگی ها اضافه شده و دقت زیرمجموعه جدید مجدداً ارزیابی می شود. در صورتی که با اضافه شدن ویژگی جدید، دقت طبقه بندی نسبت به حالت قبل افزایش یابد، ویژگی اضافه شده حفظ می شود، در غیر این صورت ویژگی مذکور حذف و ویژگی بعدی ارزیابی می شود. تفاوت الگوریتم Iwssr با Iwss در جایگزینی ویژگی جدید با یک یک ویژگی های زیرمجموعه منتخب و اندازه گیری دقت طبقه بندی در هر بار جایگزینی است. در حقیقت با این کار وابستگی یک ویژگی با کل ویژگی های منتخب قبلی سنجیده شده و در صورت نداشتن وابستگی با هیچ کدام از ویژگی ها، به مجموعه ویژگی های منتخب اضافه می شود. نتیجه این کار شناسایی ویژگی های افزونه و حذف آنها است.

#### - الگوریتم رقابت استعماری - فازی

الگوریتم رقابت استعماری یک روش انجام بهینه سازی است که علی رغم داشتن نتایج مطلوب در حل مسائل بهینه سازی مختلف، از مشکلات گیر افتادن در دام کمینه های محلی و سرعت پایین همگرایی رنج می برد (Arish et al., 2013). الگوریتم رقابت استعماری - فازی که نسخه بهبود یافته ای از این الگوریتم است، سرعت همگرایی بالایی داشته و در بهینه سازی مسائل با تعداد متغیرهای فراوان مورد استفاده قرار می گیرد. این الگوریتم برای حل مسائل بهینه سازی، نخست  $N$  کشور در یک فضای  $n$  بعدی در نظر می گیرد بطوری که هر کشور به صورت برداری از متغیرهای مختلف، یک نقطه در این فضای  $n$  بعدی می باشد. براساس تابع بهینه سازی، تعدادی از کشورها که کمترین هزینه را دارند به عنوان کشورهای استعمارگر و بقیه به عنوان مستعمره<sup>1</sup> انتخاب می شوند. الگوریتم رقابت استعماری - فازی، کشورهای استعمارگر را به عنوان یک مجموعه فازی فرض کرده و کشورهای مستعمره را با توابع عضویت فازی به کشورهای استعمارگر مربوط می سازد. این امتیازات فازی، میزان تأثیرپذیری کشورهای

---

1- Colony



مستعمره را از کشورهای استعمارگر نشان می‌دهد به این صورت که هرچه میزان عضویت فازی بیشتر باشد، در مرحله بعد تعداد متغیرهای بیشتری از کشور استعمارگر به کشور مستعمره منتقل می‌شود. با انتقال متغیرها از کشورهای استعمارگر به مستعمره، مجدداً کشورها بر اساس کمترین میزان هزینه مرتب و کشورهایی که کمترین هزینه را دارند به عنوان کشورهای استعمارگر انتخاب می‌شوند. با تکرار این مراحل به تعداد مشخص، در نهایت متغیرهای کشورهای استعمارگر در مرحله پایانی به عنوان متغیرهای بهینه انتخاب می‌شوند (Moradkhani et al., 2015).

### - روش انتخاب ویژگی ترکیبی مبتنی بر الگوریتم رقابت استعماری - فازی

همانطور که اشاره گردید در این تحقیق از یک روش انتخاب ویژگی ترکیبی برای انتخاب بهترین باندهای تصویر هایپریون استفاده می‌شود. الگوریتم بکار رفته برای وزن دهی به ویژگی‌ها (در این تحقیق باند-های طیفی) در مرحله فیلتر از معیار  $SU$  استفاده می‌کند (رابطه ۳-۵۲). بر این اساس، هر ویژگی بصورت مستقل میزان ارتباطش با برجسب کلاس ارزیابی شده و وزنی در بازه  $[0, 1]$  به هر ویژگی نسبت داده می‌شود. سپس در مرحله پوششی الگوریتم‌های رقابت استعماری - فازی و الگوریتم Iwssf برای جستجوی بهترین زیرمجموعه از ویژگی‌ها مورد استفاده قرار می‌گیرند. در ادامه فرآیند مرحله پوششی توضیح داده شده است.

$$SU_{i, c}(F_i, C) = 2 \frac{H(F_i) - H(F_i|C)}{H(F_i) + H(C)} \quad (3-52)$$

که در آن  $C$ : برجسب کلاس،  $F_i$ : ویژگی  $i$  ام و  $H$ : مقدار آنتروپی است.

در گام اول مرحله پوششی که مربوط به تشکیل کشورها است، ۵۰ زیرمجموعه برداری از باندهای طیفی با طول‌های متغیر انتخاب می‌شوند. این انتخاب بصورت وزن دار بوده و بر اساس اوزان تخصیص داده شده به هر باند در مرحله فیلتر می‌باشد. بنابراین باندهایی با وزن بیشتر احتمال انتخاب شدن بالاتری خواهند داشت.

پس از تشکیل کشورها، الگوریتم IWSSR برای شناسایی و حذف باندهای افزونه و تکراری مورد استفاده قرار می‌گیرد. در ادامه برای انتخاب کشورهای استعمارگر و مستعمره، میزان هزینه هر یک از کشورها محاسبه می‌شود. برای محاسبه مقدار هزینه، دقت طبقه‌بندی (بدست آمده از یک روش طبقه‌بندی کننده که از باندهای هر کشور به عنوان فضای ویژگی استفاده می‌کند) مطابق با رابطه (۵۳-۳) مورد استفاده قرار می‌گیرد.

$$Country-Cost_i = 1 - Classification-Accracy_i \quad (53-3)$$

پس از محاسبه هزینه مربوط به هر کشور، ۱۰ درصد از کشورها با کمترین هزینه به عنوان کشورهای استعمارگر و مابقی به عنوان مستعمره انتخاب می‌شوند. سپس میزان عضویت فازی هر یک از کشورهای مستعمره به کشورهای استعمارگر بر اساس تابع عضویت فازی نشان داده شده در روابط (۳-۵۴)~(۳-۵۶) محاسبه می‌شود.

$$\mu_j(Col_i) = \begin{cases} 0 & f_j(Col_i) \leq \alpha \\ 2 \left( \frac{f_j(Col_i) - \alpha}{\gamma - \alpha} \right)^2 & \alpha < f_j(Col_i) \leq \beta \\ 1 - 2 \left( \frac{f_j(Col_i) - \alpha}{\gamma - \alpha} \right) & \beta < f_j(Col_i) \leq \gamma \\ 1 & f_j(Col_i) > \gamma \end{cases} \quad (54-3)$$

$$f_j(Col_i) = \frac{NOC_j}{\sum_{k=1}^{N Imp} NOC_k} \left( 1 - \frac{D_{ij}(t)}{\sum_{k=1}^{N Imp} D_{ik}(t)} \right) \quad (55-3)$$

$$D_{ij}(t) = |Col_i(t) - Imp_j| \quad (56-3)$$

$D_{ij}(t)$ : فاصله بین استعمارگر زام و مستعمره i ام

$NOC_j$ : هزینه استعمارگر زام

با توجه به رابطه (۳-۵۵)، کم بودن هزینه کشور استعمارگر زام و همچنین کم بودن فاصله میان کشور استعمارگر زام و کشور مستعمره i ام (یعنی کم بودن تعداد باندهای غیرمشترک) باعث می‌شود

که  $f_j (Col_i)$  مقدار بزرگی بدست آمده و در نتیجه میزان عضویت فازی مطابق با رابطه (۳-۵۴) عدد بزرگی محاسبه گردد. هرچه مقادیر امتیاز فازی یک کشور مستعمره نسبت به کشورهای استعمارگر بیشتر باشد، بایستی در مرحله بعد تعداد بیشتری از باندهای طیفی کشور استعمارگر به کشور مستعمره منتقل گردد. این فرآیند تکرار شده و در نهایت باندهای طیفی کشور استعمارگری که کمترین هزینه را دارد به عنوان بهترین زیرمجموعه از باندهای طیفی انتخاب می‌شود.

### ۳-۱-۴- روش‌های تخمین خطا

بطور کلی برای ارزیابی کارایی و دقت روش طبقه‌بندی کننده طراحی شده، نیاز است که خطای واقعی<sup>۱</sup> آن محاسبه گردد. اما از آنجایی که در عمل محاسبه دقیق خطای واقعی امکان پذیر نمی‌باشد، لذا مقدار تقریبی خطای واقعی با استفاده از روش‌های تخمین گر خطا و مجموعه داده موجود تخمین زده می‌شود. برای این منظور مجموعه داده موجود به دو قسمت مجموعه داده آموزشی و آزمایشی<sup>۲</sup> تقسیم می‌گردد (Zollanvari et al., 2010). وظیفه اصلی مجموعه داده آموزشی، آموزش روش طبقه‌بندی کننده و تنظیم درست پارامترهای آن است بطوریکه روش طبقه‌بندی کننده بتواند الگوی حاکم بر مسأله را به خوبی فرا گیرد. از سوی دیگر وظیفه ارزیابی دقت طبقه‌بندی و اعتبارسنجی نتایج برعهده مجموعه داده آزمایشی است (Duda et al., 1973).

اندازه مجموعه داده موجود در یک مسأله طبقه‌بندی و یا به عبارتی تعداد نمونه‌های آموزشی و آزمایشی نقش مهمی دارد در انتخاب روش تخمین گر خطایی که مناسب برای آن مسأله باشد. معمولاً هنگامی که مجموعه داده بزرگی در اختیار باشد بخش مشخصی از آن به عنوان مجموعه داده آزمایشی برای اعتبارسنجی در نظر گرفته شده و باقی مانده برای آموزش روش طبقه‌بندی کننده استفاده می‌شود. در این حالت هیچگونه همپوشانی بین داده‌های آموزشی و آزمایشی وجود ندارد. روش هولد اوت<sup>۳</sup>

---

1- Actual error

2- Training and test data set

3 - Holdout

شاخص‌ترین تخمین‌گر خطایی است که از رویه فوق استفاده می‌کند. اما در بسیاری از مسائل دنیای واقعی به دلایل مختلف از جمله بالا بودن هزینه‌های زمانی و مالی، تهیه مجموعه داده بزرگ امکان‌پذیر نمی‌باشد. در چنین شرایطی و به دلیل محدود بودن تعداد داده‌های موجود امکان اینکه بخشی از داده‌ها جداگانه برای آزمایش و اعتبارسنجی نتایج استفاده شوند وجود ندارد. بنابراین به دلیل عدم کارایی روش هولداوت در این حالت نیاز به استفاده از تخمین‌گرهای دیگری که مناسب برای کار با مجموعه داده‌های محدود و کوچک باشند، احساس می‌شود مثل روش‌های جایگزینی مجدد<sup>۱</sup>، اعتبارسنجی متقابل K-بخشی<sup>۲</sup>، اعتبارسنجی متقابل لیو-وان-اوت<sup>۳</sup> (L-O-O) و غیره (Zollanvari et al., 2010).

در روش جایگزینی مجدد کل داده‌های موجود پس از استفاده برای آموزش و طراحی روش طبقه‌بندی کننده، مجدداً برای ارزیابی عملکرد آن نیز استفاده می‌شوند. چون مجموعه داده آموزشی و آزمایشی در این حالت دقیقاً مشابه هم و یکسان می‌باشند لذا نتایج حاصله توسط این روش خوش‌بینانه در نظر گرفته می‌شود (Heikkila, 1992). در روش اعتبارسنجی متقابل K-بخشی، مجموعه داده موجود به K قسمت تقریباً مساوی تقسیم می‌شود. مرحله آموزش روش طبقه‌بندی کننده K مرتبه تکرار می‌شود بطوریکه هر بار یکی از K قسمت موجود به مجموعه داده آزمایشی و K-۱ قسمت باقیمانده به مجموعه داده آموزشی تعلق می‌گیرد و در پایان میانگین خطای K مرتبه تکرار طبقه‌بندی به عنوان خطای نهایی روش طبقه‌بندی کننده در نظر گرفته می‌شود. روش اعتبارسنجی متقابل L-O-O نوع کاملی از روش اعتبارسنجی متقابل K-بخشی است به طوری که K در آن برابر با تعداد نمونه‌های مجموعه داده اولیه می‌باشد (Martin and Hirschberg, 1996).

---

1- Re-substitution  
2- K-fold cross-validation  
3- Leave-One-Out cross-validation

## ۳-۱-۵- ارزیابی دقت طبقه‌بندی

۳-۱-۵-۱- ماتریس خطا<sup>۱</sup> و ضریب کاپا<sup>۲</sup>

ماتریس خطا آرایه‌ای مربعی از اعداد است که تعداد نمونه‌های تخصیص یافته به طبقات مختلف را نمایش می‌دهد. وقتی داده‌ها نسبت به گروه مبنا یا داده‌های مرجع زمینی<sup>۳</sup> (که در مطالعات سنجش از دور از طرق مختلفی همچون تصاویر هوایی و مشاهدات یا اندازه‌گیری‌های زمینی بدست می‌آیند) بررسی می‌شوند معمولاً نتایج در ستون‌های ماتریس خطا قرار می‌گیرند. همین داده‌ها وقتی نسبت به تصویر سنجش از دور طبقه‌بندی شده و یا به عبارتی نقشه خروجی بررسی شوند، سازنده ردیف‌های ماتریس خطا خواهند بود (شکل ۳-۵) (Congalton and Green, 2009).

		داده‌های مرجع زمینی				مجموع ردیف
		A	B	C	D	
داده‌های طبقه‌بندی	A	۶۵	۴	۲۲	۲۴	۱۱۵
	B	۶	۸۱	۵	۸	۱۰۰
	C	۰	۱۱	۸۵	۱۹	۱۱۵
	D	۴	۷	۳	۹۰	۱۰۴
مجموع ستون		۷۵	۱۰۳	۱۱۵	۱۴۱	۴۳۴

دقت کل =  $(65 + 81 + 85 + 90) / 434 = 74\%$

دقت تولید کننده نقشه

$A = 65 / 75 = 87\%$

$B = 81 / 103 = 79\%$

$C = 85 / 115 = 74\%$

$D = 90 / 141 = 64\%$

دقت استفاده کننده نقشه

$A = 65 / 115 = 57\%$

$B = 81 / 100 = 81\%$

$C = 85 / 115 = 74\%$

$D = 90 / 104 = 87\%$

شکل (۳-۵) - ماتریس خطا (Congalton and Green, 2009)

ماتریس خطا روش مؤثری برای بیان دقت نقشه است بطوریکه با استفاده از این ماتریس بسادگی امکان ارزیابی دقت طبقه‌بندی هر کلاس به صورت خطای شمول<sup>۴</sup> و خطای عدم شمول<sup>۵</sup> وجود دارد. خطای شمول عبارت است از نمونه‌هایی که به طبقه خاصی اختصاص یافته‌اند در حالیکه در حقیقت متعلق به آن طبقه نیستند. از سوی دیگر خطای عدم شمول به معنی اختصاص نیافتن نمونه‌های یک طبقه به

1- Error Matrix

2- Kappa Value

3- Reference or ground truth data

4- Errors of inclusion or commission errors

5- Errors of exclusion or omission errors

آن طبقه است. در واقع هر خطایی می‌تواند خطای شمول نسبت به طبقه اشتباه<sup>۱</sup> و خطای عدم شمول نسبت به طبقه درست<sup>۲</sup> تلقی گردد (Congalton and Green, 2009). به عنوان مثال در شکل (۳-۵) که ماتریس خطای مربوط به یک طبقه‌بندی ۴ کلاسه را نمایش می‌دهد، تعداد ۲۲ نمونه که متعلق به طبقه C هستند به اشتباه در طبقه A قرار گرفته‌اند. بنابراین خطای شمول نسبت به طبقه نادرست (یعنی A) و خطای عدم شمول نسبت به طبقه درست (یعنی C) برابر با ۲۲ نمونه است.

ماتریس خطا علاوه بر توانایی در بیان خطای شمول و عدم شمول، می‌تواند برای محاسبه انواع دیگری از دقت مثل دقت کل<sup>۳</sup>، دقت تولید کننده<sup>۴</sup> و دقت استفاده کننده<sup>۵</sup> نیز بکار رود. دقت کل بصورت نسبت تعداد نمونه‌های بدرستی طبقه‌بندی شده (مجموع اعداد قطر اصلی ماتریس خطا) به کل نمونه‌ها محاسبه می‌شود. اگرچه دقت کل پرکاربردترین روش ارزیابی دقت طبقه‌بندی می‌باشد، ولی به تنهایی قادر به بیان مطلوب دقت طبقه‌بندی و آشکارسازی روابط موجود بین دقت کلاس‌های مختلف نمی‌باشد. دقت‌های تولید کننده و استفاده کننده طریق دیگری برای بیان دقت طبقه‌بندی کلاس‌های مختلف در یک مسئله طبقه‌بندی به جای دقت کل می‌باشند. گاهی تنها استفاده از بزرگترین دقت در بین دو دقت مذکور کافی نبوده و منجر به گمراهی و بروز اشتباه در تصمیم‌گیری می‌شود. مثال زیر نشان می‌دهد که چرا نیاز است که هر سه نوع دقت گفته شده برای یک مسئله طبقه‌بندی محاسبه شود.

با بررسی ماتریس خطای شکل (۳-۵) مشاهده می‌شود که دقت کل طبقه‌بندی برابر با ۷۴٪ است. با محاسبه نسبت تعداد نمونه‌های بدرستی طبقه‌بندی شده کلاس A (۶۵ نمونه) به کل نمونه‌های این کلاس بر اساس داده‌های مرجع (۷۵ نمونه)، دقت تولید کننده برای کلاس A برابر با ۸۷٪ خواهد بود که در مقایسه با دقت کل عدد قابل توجهی بوده و می‌تواند دقت مطلوبی محسوب گردد. ولی این دقت در ظاهر مناسب می‌تواند با محاسبه دقت استفاده کننده برای کلاس A به چالش کشیده شود. با محاسبه

---

1- Wrong category  
2- Correct category  
3- Overall accuracy  
4- Producer's accuracy  
5- User's accuracy

این دقت به صورت نسبت نمونه‌های بدرستی طبقه‌بندی شده در کلاس A (۶۵ نمونه) به کل نمونه‌هایی که در کلاس A طبقه‌بندی شده‌اند (۱۱۵ نمونه)، عدد ۰.۵۷ بدست می‌آید. به عبارتی اگرچه ۰.۸۷ نمونه‌های متعلق به کلاس A بدرستی طبقه‌بندی شده‌اند اما فقط ۰.۵۷ مکان‌هایی که در نقشه خروجی با برچسب کلاس A طبقه‌بندی می‌شوند متعلق به این کلاس خواهند بود. در حقیقت دقت تولید کننده به این دلیل عدد بزرگی بدست آمده است که تعداد نمونه‌های زیادی با برچسب A طبقه‌بندی شده‌اند. بنابراین با وجود دستیابی به دقت بالای ۰.۸۷، کاربری که از نقشه خروجی استفاده می‌کند تنها در ۰.۵۷ موارد می‌تواند به درستی مکان‌های طبقه‌بندی شده در نقشه خروجی با برچسب A اطمینان داشته باشد (Congalton and Green, 2009).

ضریب کاپا با وارد نمودن دقت‌های تولید کننده و استفاده کننده در محاسبات، میزان همراهی نتایج طبقه‌بندی با یک طبقه‌بندی تصادفی<sup>۱</sup> را ارزیابی می‌کند. در حقیقت این ضریب درجه و شاخصی است برای مقایسه دقت بدست آمده از ماتریس خطا با یک طبقه‌بندی کاملاً تصادفی. مقدار آن بین ۰ تا ۱ متغیر بوده و هر چه به ۱ نزدیک‌تر باشد حاکی از عملکرد مطلوب‌تر روش طبقه‌بندی کننده است. ضریب کاپا از رابطه زیر بدست می‌آید (Lillesand et al., 1994):

$$k = \frac{N \sum_{i=1}^r X_{ii} - \sum_{i=1}^r (X_{i+} \cdot X_{+i})}{N^2 - \sum_{i=1}^r (X_{i+} \cdot X_{+i})} \quad (57-3)$$

$r$ : تعداد سطرهای ماتریس خطا

$X_{ii}$ : تعداد مشاهدات در سطر  $i$  و ستون  $i$

$X_{i+}$ : تعداد کل مشاهدات در سطر  $i$

$X_{+i}$ : تعداد کل مشاهدات در ستون  $i$

$N$ : تعداد کل مشاهدات در ماتریس خطا

1- Agreement with a random classifier

### ۳-۱-۵-۲- خطای RMS<sup>۱</sup>

خطای RMS که برای ارزیابی بزرگی خطای مقادیر تخمین زده شده بکار می‌رود، با استفاده از روابط زیر محاسبه می‌شود (Congalton and Green, 2009).

$$RMSE = \sqrt{\sum_i^n (e_i)^2 / n} \quad (۵۸-۳)$$

$$e_i = e_{ri} - e_{mi} \quad (۵۹-۳)$$

که در آن  $e_{ri}$ : مقدار نمونه مرجع<sup>۲</sup>،  $e_{mi}$ : مقدار تخمین زده شده در نقشه<sup>۳</sup> و  $n$ : تعداد نمونه‌ها است.

### ۳-۲- داده‌ها

در این تحقیق، بطور کلی از دو مجموعه داده استفاده شده است: تصویر هایپریون و مجموعه داده استفاده شده برای آموزش روش طبقه‌بندی کننده و آزمایش نتایج طبقه‌بندی که به ترتیب در بخش‌های (۳-۱-۲) و (۳-۲-۲) معرفی شده‌اند.

### ۳-۲-۱- مجموعه داده ابرطیفی هایپریون

سنجنده فضا برد هایپریون با مشخصاتی بهبود یافته و هزینه کمتر توسط گروه TRW Space and Electronics و تحت قراردادی با سازمان فضانوردی ایالات متحده آمریکا (ناسا) ساخته شد (Chang, 2007). با ارسال سنجنده هایپریون توسط ماهواره مشاهده‌گر زمین-۱ (EO-1) در نوامبر سال ۲۰۰۰ میلادی، مطالعه ابرطیفی سطح زمین از فضا فراهم گردید.

---

1- Root Mean Square Error (RMSE)  
2- Reference value  
3- Map value  
4- Earth Observing-1 (EO-1)



### ۳-۲-۱-۱- مشخصات سنجنده هایپریون

سنجنده هایپریون با داشتن یک تلسکوپ و دو طیف‌سنج، بازه طیفی ۲۵۰۰-۴۰۰ نانومتری را توسط ۲۴۲ باند طیفی و با دقت فضایی ۳۰ متر پوشش می‌دهد. این باندهای طیفی اطلاعات فراوانی را در مورد بسیاری از کانی‌های سازنده سطح زمین فراهم می‌آورند (Liao et al., 2000). خلاصه‌ای از مشخصات سنجنده هایپریون در جدول (۳-۱) نشان داده شده است.

اگرچه داده‌های ارائه شده توسط هایپریون در مقایسه با سنجنده‌های هوابرد از کیفیت کمتری برخوردار است اما ارائه اطلاعات با ارزش طیفی توسط آن باعث شده است که کاربردهای متنوعی داشته باشد (Chang, 2007). داده‌های ابرطیفی هوابرد مثل های‌مپ و اویریس که از اوایل دهه هشتاد میلادی در دسترس قرار گرفته‌اند، از اهمیت بالایی در شناسایی و تفکیک کانی‌ها و تشکیلات سنگی برخوردار هستند ولی معمولاً دسترسی به این داده‌ها بدلیل مختلف مثل هزینه بالا یا پوشش مکانی کم مشکل می‌باشد (Hosseinjani Zadeh et al, 2014a; Beiranvand Pour et al, 2014). بر خلاف داده‌های هوابرد دسترسی آسان به داده‌های سنجنده هایپریون، فرصت‌های جدیدی را در اختیار جوامع سنجش از دور قرار داده است تا از اطلاعات طیفی ارزشمند این سنجنده در حوزه‌های مختلف استفاده شود (Petropoulos, 2012). بنابراین سنجنده هایپریون در مناطقی که امکان دسترسی به تصاویر هوابرد وجود ندارد، به عنوان ابزاری جهت انجام مطالعات کانی‌شناختی ابرطیفی می‌تواند مورد استفاده قرار گیرد (Kruse, 2003).

### ۳-۲-۱-۲- مشخصات مجموعه داده هایپریون متعلق به محدوده مطالعاتی

مشخصات مجموعه داده سنجش از دور ثبت شده توسط سنجنده هایپریون در ۲۶ ژوئیه ۲۰۰۴ میلادی در شکل (۳-۶-ج) نشان داده شده است. همچنین موقعیت جغرافیایی این مجموعه داده نسبت به شهرهای کرمان، رفسنجان و سیرجان در شکل (۳-۶-ب) قابل مشاهده است. بخش کوچکی از این

تصویر که حاوی معادن سرچشمه و دره زار و محدوده سریدون است به عنوان منطقه مطالعاتی در این تحقیق انتخاب شده است (شکل ۳-۶-الف).

جدول (۳-۱) - مشخصات سنجنده هایپریون (Chang, 2007)

ویژگی	توضیحات
اولین سال عملیاتی	۲۰۰۰ میلادی
اندازه	۶۶ cm × ۷۵ cm × ۳۹ cm
وزن	۴۹ km
قدرت	۱۲۶ W
اندازه دهانه	۱۲ cm
روش تصویربرداری مکانی	پوش بروم
میدان دید	۰/۰۱ rad
میدان دید لحظه‌ای	۴۰ μrad
تعداد کانال‌های طیفی	۲۴۲
بازه طیفی	۴۰۰-۲۵۰۰ nm
پهنای باند طیفی	۱۰ nm

به منظور افزایش کیفیت و حذف نویز، لازم است مجموعه داده مذکور تحت پیش‌پردازش‌های لازم قرار گرفته و نسبت به مشکلاتی مثل پیکسل‌های غیرنرمال<sup>۱</sup>، راه راه شدگی<sup>۲</sup> و اسمایل<sup>۳</sup> تصحیح گردد. اگرچه سنجنده هایپریون بازتاب امواج الکترومغناطیسی را در ۲۴۲ باند طیفی ثبت می‌کند ولی بدلیل نامطلوب بودن مقادیر مربوط به ۴۴ باند و همچنین وجود ۲ باند افزونه به علت همپوشانی مناطق طیفی VNIR و SWIR، در عمل تنها ۱۹۶ باند از بین ۲۴۲ باند هایپریون باقی مانده و پیش‌پردازش‌های لازم بر روی آنها انجام شد. این ۱۹۶ باند در بازه ۹۲۵/۴۱-۴۲۶/۸۲ نانومتر منطقه VNIR و بازه ۲۳۹۵/۵-۹۳۲/۶۴ نانومتر منطقه SWIR قرار دارند.

در گام نخست عملیات پیش‌پردازش، باندهای غیر کالیبره و دارای همپوشانی حذف شدند. با توجه به وجود مشکل راه راه شدگی بویژه در ۱۲ باند ابتدایی منطقه VNIR و بسیاری از باندهای منطقه

1- Abnormal pixels  
2- Striping  
3- Smile

SWIR، از یک الگوریتم بهبود مشکل راه شدگی<sup>۱</sup> در نرم‌افزار ENVI<sup>۲</sup> برای کاهش این مشکل استفاده شد (Ede, 2004; Darmawan, 2006; Hosseinjani Zadeh et al, 2014a). این الگوریتم میانگین هر ردیف را محاسبه کرده و سپس داده‌های آن ردیف را نسبت به میانگین اندازه‌گیری شده نرمالایز می‌کند (Ede, 2004). اگرچه این الگوریتم اثر مشکلات مذکور را کاهش می‌دهد ولی همچنان مشکلاتی مثل پیکسل‌های غیرنرمال با مقادیر DN<sup>۳</sup> منفی در برخی باندها مشاهده می‌شود. با توجه به قابلیت حل بخش اعظم این مشکلات بصورت بصری، مشکل راه شدگی و پیکسل‌های غیر نرمال باقیمانده شناسایی و مابقی حذف گردیدند. در ادامه باندهای حاوی پیکسل‌های غیر نرمال، باندهای واقع شده در بازه طیفی جذبی توسط مولکول‌های بخار آب و همچنین باندهایی که دارای اطلاعات نیستند نیز حذف شدند (Hosseinjani Zadeh et al, 2014a).

برای انجام تصحیحات اتمسفری از الگوریتم FLASH<sup>۴</sup> تعبیه شده در نرم‌افزار ENVI استفاده شد. در ادامه و با حذف باندهای متأثر از خطای بخار آب یعنی باندهای ۱۳۰-۱۲۱ (در بازه ۱۴۴۷/۲-۱۳۵۶/۴ نانومتر) و باندهای ۱۸۰-۱۶۵ (در بازه ۱۹۵۱/۵۷-۱۸۰۰/۲۹ نانومتر)، در نهایت ۱۶۵ باند طیفی باقی مانده و مطالعات آتی بر اساس این باندها خواهد بود (Hosseinjani Zadeh et al, 2014a). لیست دقیق باندهای مذکور در شکل (۳-۶-د) نشان داده شده است.

### ۳-۲-۱-۳- مقایسه کیفیت سنجنده‌های هوابرد و فضابرد

کیفیت داده‌های دیجیتالی سنجش از دور مستقیماً در ارتباط با نسبت سطح نویز سیستم به قدرت سیگنال آن می‌باشد. این موضوع که با SNR<sup>۵</sup> یا نسبت سیگنال به نویز بیان می‌شود عددی بدون بعد بوده و توصیف کننده کارایی رادیومتریک سیستم می‌باشد. نویز سیستم در ارتباط با طراحی سنجنده

---

1- De-strip algorithm


2- ENvironment for Visualizing Images

3- Digital Number

4- Fast Line-of sight Atmospheric Analysis of Spectral Hypercubes

5- Signal to Noise Ratio

بوده و عواملی مثل کارایی یا حساسیت موج گیر، دقت طیفی و مکانی و نویزهای الکترونیکی سیستم در آن دخیل می باشند.



شکل (۳-۶) الف- بخشی از تصویر سنجش از دور هایپریون به عنوان منطقه مطالعاتی و موقعیت مناطق سرچشمه، دره زار و ساریدون بر روی آن، ب- موقعیت جغرافیایی تصویر هایپریون نسبت به شهرهای بزرگ و منطقه مطالعاتی، ج- مشخصات مجموعه داده ثبت شده توسط سنجنده هایپریون، د- ۱۶۵ باند قابل استفاده تصویر هایپریون پس از انجام پیش پردازش های لازم

اگرچه مقدار نویز به ازای هر سنجنده معمولاً مقداری ثابت می باشد ولی عوامل خارجی دیگری همچون زاویه اوج خورشیدی<sup>۱</sup>، فاکتور میرایی و پراکندگی جوی<sup>۲</sup> و بازتاب سطحی<sup>۳</sup> بر روی SNR تأثیر گذار می باشند. تصویربرداری طیفی در شرایط بهینه (فصل تابستان، وجود اهداف شفاف<sup>۴</sup> و رخنمون مناسب

- 1- Solar zenith angle
- 2- Atmospheric attenuation and scattering
- 3- Surface reflectance
- 4- Bright targets


واحدهای سنگی) توسط سنجنده هایپریون، امکان ثبت ویژگی‌های طیفی با جزئیات بیشتری را فراهم می‌آورد. در چنین شرایطی به عنوان مثال امکان تفکیک کلسیت و دولومیت امکان پذیر می‌گردد. بطور کلی در شرایط ایده آل، اطلاعات کانی شناختی ارائه شده توسط سنجنده هایپریون تقریباً مشابه با سنجنده‌های هوابرد مثل اویریس می‌باشد. ولی هنگامی که شرایط دریافت داده‌ها بهینه نباشد (فصل زمستان و حضور اهداف تیره<sup>۱</sup>)، بدلیل پایین بودن SNR امکان ثبت ویژگی‌های طیفی با جزئیات بیشتر وجود ندارد. بنابراین اگرچه سنجنده‌های ابرطیفی فضابرد اطلاعات کانی شناختی سودمندی ارائه می‌نمایند ولی به منظور رسیدن به دقتی برابر با دقت سنجنده‌های هوابرد در شناسایی کانی‌های مختلف، بهبود کیفیت سنجنده‌های فضابرد جهت دستیابی به SNR مورد نیاز الزامی است.

مجموعه داده ثبت شده توسط هایپریون حاوی سطح بالایی از نویز بوده و از SNR پایین‌تری در مقایسه با سنجنده‌های هوابرد برخوردار است (Kruse, Boardman, and Huntington 2003). در حال حاضر سنجنده‌های هوابرد از SNR بالایی (بیشتر از ۵۰۰:۱) برخوردار هستند در حالی که این نسبت برای سنجنده هایپریون در شرایط ایده آل در حدود ۵۰:۱ است. در جدول (۲-۳) مشخصات سنجنده هوابرد اویریس با سنجنده فضابرد هایپریون مقایسه شده است (Kruse, 2003). بر اساس اشکال (۳-۷) و (۳-۸)، SNR محاسبه شده برای سنجنده هایپریون بر اساس ۱۴ سین<sup>۲</sup> مختلف از سرتاسر جهان نشان می‌دهد که مقدار آن در فصل تابستان برابر با بیشترین میزان و در فصل زمستان کمترین است (Kruse, 2003).

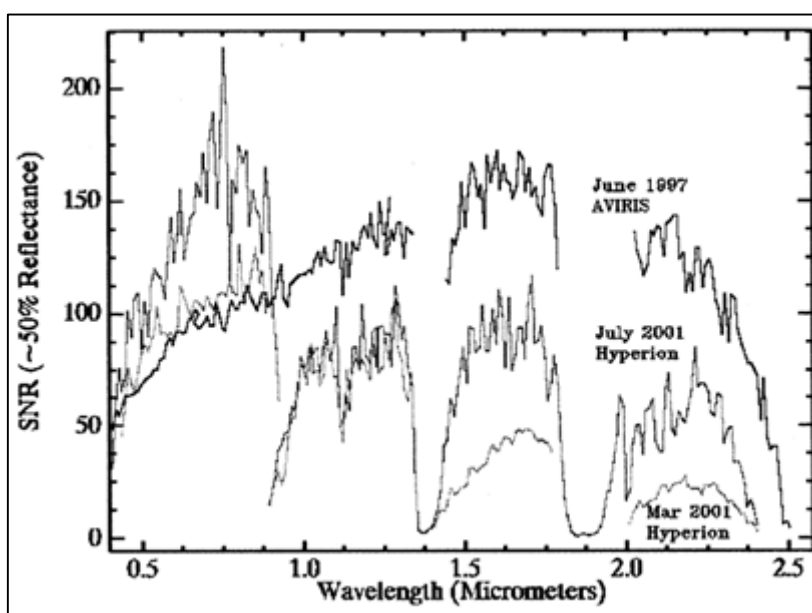
جدول (۲-۳) - مقایسه دو سنجنده اویریس و هایپریون (Kruse, 2003)

سنجنده	تعداد باند طیفی	تفکیک طیفی	تفکیک مکانی	عرض تصویر	SNR در بازه SWIR
اویریس	۲۲۴	۱۰ نانومتر	۲۰ متر	۱۲ کیلومتر	۵۰۰:۱
هایپریون	۲۴۲	۱۰ نانومتر	۳۰ متر	۷/۵ کیلومتر	۵۰:۱

1- Dark targets  
2- Scene



شکل (۷-۳) - مقدار SNR سنجنده هایپریون در فصل زمستان (چپ) و فصل تابستان (راست). منطقه سیاه رنگ محدوده مقادیر SNR را برای ۱۴ سین مختلف سنجنده هایپریون نشان می‌دهد (Kruse, 2003).



شکل (۸-۳) - مقایسه SNR سنجنده‌های هایپریون و اویریس در فصول تابستان و زمستان (Kruse, 2003)

### ۳-۲-۲ - مجموعه داده آموزشی، آزمایشی و اعتبارسنجی<sup>۱</sup>

روش‌های طبقه‌بندی نظارت‌شده برای یادگیری قوانین حاکم بر الگوها و همچنین برای ارزیابی میزان این یادگیری به ترتیب نیازمند مجموعه داده‌های آموزشی و آزمایشی هستند. در این تحقیق از دو

1- Train, test and validation data sets

مجموعه داده با اندازه‌های متفاوت برای مقاصد مختلف استفاده خواهد شد. مجموعه داده اول با تعداد نمونه‌های کمتر که از محدوده مطالعاتی جمع آوری شده‌اند برای طبقه‌بندی مناطق دگرسانی استفاده شده است. مجموعه داده دوم با تعداد نمونه‌های بیشتر برای کاهش ابعاد مجموعه داده هایپریون و همچنین برای سنجش حساسیت روش‌های طبقه‌بندی مختلف نسبت به اندازه مجموعه داده آموزشی استفاده شد. این مجموعه داده خروجی روش تجزیه طیفی پالایش تطبیقی تنظیم شده آمیخته (MTMF)<sup>۱</sup> است. در بخش بعدی جزئیات مجموعه داده‌های مذکور بیان می‌شود.

### ۳-۲-۱- مجموعه داده ۱

اولین مجموعه داده آموزشی شامل ۴۶ نمونه سنگی از دگرسانی‌های مختلف منطقه مطالعاتی است که در مرداد ماه سال ۱۳۹۴ و در طول ۳ روز عملیات صحرایی برداشت شدند. این نمونه‌ها پس از برداشت توسط دستگاه طیف‌سنج ASD<sup>۲</sup> در آزمایشگاه طیف‌سنجی دانشگاه تحصیلات تکمیلی و صنعتی و فناوری پیشرفته کرمان آنالیز شده و نتایج بدست آمده در کنار نظر کارشناسی برای مشخص کردن نوع دگرسانی نمونه‌ها استفاده شدند. با توجه به اینکه بر اساس گزارش‌های زمین‌شناسی و بررسی‌های میدانی، دگرسانی‌های پروپیلیتیک، فیلیک و آرژیلیک دارای بیشترین پراکندگی در سطح منطقه می‌باشند، در ادامه نتایج طیف‌سنجی توسط برنامه کامپیوتری PIMA View برای تخمین نیمه‌کمی فراوانی کانی‌های شاخص این دگرسانی‌ها یعنی کلریت (پروپیلیتیک)، موسکویت (فیلیک) و کائولینیت (آرژیلیک) استفاده شدند. این مقادیر در فصل (۵) برای آموزش SVR و طبقه‌بندی زیرپیکسلی مناطق دگرسانی استفاده خواهند شد.

۳۳ نمونه از بین ۴۶ نمونه برداشت شده برای آموزش و آزمایش الگوریتم‌ها اختصاص یافته و مابقی برای اعتبارسنجی نتایج منظور گردیدند. مشخصات این مجموعه داده در جداول (۳-۳) و (۴-۳) و شکل

1- Mixture Tuned Matched Filtering (MTMF)

2- Analytical Spectral Device FieldSp<sup>3</sup>

(۹-۳) نشان داده شده است.

جدول (۳-۳) - مشخصات نمونه‌های مجموعه داده ۱ برای آموزش و آزمایش الگوریتم‌ها

شماره نمونه	مختصات جغرافیایی	نوع دگرسانی	فراوانی کانی‌های شاخص دگرسانی بدست آمده با نرم‌افزار PIMA View (%)		
			کائولینیت	موسکویت	کلریت
۱	۳۹۳۸۰۲ E ۳۳۰۶۰۷۹ N	فیلیک	۳۰ < ۵۰	> ۵۰	< ۵
۲	۳۹۴۱۴۵ E ۳۳۰۵۲۴۸ N	"	< ۵	> ۵۰	< ۵
۳	۳۹۴۲۰۴ E ۳۳۰۶۱۳۴ N	"	< ۵	> ۵۰	< ۳۰
۴	۳۹۳۷۰۹ E ۳۳۰۶۶۴۰ N	"	< ۵	> ۵۰	< ۵
۵	۳۹۴۷۰۴ E ۳۳۰۶۷۲۲ N	"	< ۵	> ۵۰	< ۵
۶	۳۹۴۴۱۸ E ۳۳۰۶۳۳۹ N	"	< ۵	> ۵۰	< ۵
۷	۳۹۴۱۵۶ E ۳۳۰۶۴۴۲ N	"	< ۵	> ۵۰	< ۵
۸	۳۹۳۹۵۸ E ۳۳۰۶۳۲۳ N	"	۳۰ < ۵۰	> ۵۰	< ۵
۹	۳۹۳۹۳۷ E ۳۳۰۶۰۵۷ N	"	۳۰ < ۵۰	> ۵۰	< ۵
۱۰	۳۹۳۳۵۳ E ۳۳۱۷۴۷۳ N	"	< ۵	< ۳۰	< ۵
۱۱	۳۹۴۶۹۸ E ۳۳۱۵۳۶۶ N	"	< ۵	> ۵۰	< ۵
۱۲	۳۹۵۵۵۱ E ۳۳۱۴۰۹۵ N	"	< ۵	> ۵۰	< ۵
۱۳	۳۹۴۶۵۶ E ۳۳۰۶۳۱۹ N	آرژیلیک	> ۵۰	۳۰ < ۵۰	< ۵
۱۴	۳۹۳۸۸۱ E ۳۳۰۵۷۰۲ N	"	> ۵۰	۳۰ < ۵۰	< ۵
۱۵	۳۹۳۷۹۴ E ۳۳۰۶۱۴۴ N	"	> ۵۰	< ۳۰	< ۵
۱۶	۳۹۳۶۲۵ E ۳۳۰۵۹۲۰ N	"	۳۰ < ۵۰	< ۳۰	< ۵




ادامه جدول (۳-۳)

< ۵	۳۰ < < ۵۰	< ۵	"	۳۹۲۹۱۶ E ۳۳۱۶۴۱۶ N	۱۷
< ۵	> ۵۰	< ۵	"	۳۹۳۰۹۴ E ۳۳۱۶۷۶۱ N	۱۸
< ۵	۳۰ < < ۵۰	< ۵	"	۳۹۳۵۷۸ E ۳۳۱۵۷۵۳ N	۱۹
< ۵	۳۰ < < ۵۰	۳۰ < < ۵۰	"	۳۹۴۲۰۸ E ۳۳۱۵۷۱۳ N	۲۰
< ۵	۳۰ < < ۵۰	< ۵	"	۳۹۴۲۸۹ E ۳۳۱۵۶۱۹ N	۲۱
< ۵	> ۵۰	< ۵	"	۳۹۴۵۶۱ E ۳۳۱۵۵۶۸ N	۲۲
< ۵	> ۵۰	< ۵	"	۳۹۴۸۰۹ E ۳۳۱۵۳۹۵ N	۲۳
۳۰ < < ۵۰	< ۵	< ۳۰	پروپیلنیک	۳۹۲۹۶۶ E ۳۳۰۶۲۹۷ N	۲۴
۳۰ < < ۵۰	< ۵	۳۰ < < ۵۰	"	۳۹۳۴۸۳ E ۳۳۰۷۰۷۹ N	۲۵
۳۰ < < ۵۰	< ۵	< ۵	"	۳۹۳۸۸۰ E ۳۳۰۵۶۱۲ N	۲۶
۳۰ < < ۵۰	< ۵	۳۰ < < ۵۰	"	۳۹۴۷۶۹ E ۳۳۰۶۸۰۵ N	۲۷
۳۰ < < ۵۰	< ۵	۳۰ < < ۵۰	"	۳۹۴۷۴۳ E ۳۳۰۵۹۶۵ N	۲۸
> ۵۰	< ۵	< ۳۰	"	۳۹۳۱۰۶ E ۳۳۰۷۹۷۷ N	۲۹
> ۵۰	< ۵	< ۵	"	۳۹۴۰۴۸ E ۳۳۰۶۹۲۱ N	۳۰
< ۳۰	< ۳۰	< ۵	"	۳۹۴۹۵۰ E ۳۳۱۵۰۸۲ N	۳۱
> ۵۰	< ۵	< ۵	"	۳۹۵۳۴۰ E ۳۳۱۴۳۷۱ N	۳۲
< ۳۰	< ۳۰	< ۵	"	۳۹۵۵۹۹ E ۳۳۱۳۵۵۵ N	۳۳

جدول (۳-۴) - مشخصات نمونه‌های مجموعه داده ۱ برای اعتبارسنجی نتایج

شماره نمونه	مختصات جغرافیایی	نوع دگرسانی	فراوانی کانی‌های شاخص دگرسانی بدست آمده با نرم‌افزار PIMA View (%)		
			کائولینیت	موسکویت	کلریت
۱	۳۹۰۸۹۹ E ۳۳۱۳۲۷۵ N	فیلیک	< ۵	> ۵۰	< ۵
۲	۳۹۰۰۱۶ E ۳۳۱۳۸۰۵ N	"	< ۵	> ۵۰	< ۵
۳	۳۹۰۲۰۷ E ۳۳۱۳۳۱۸ N	"	< ۵	> ۵۰	< ۵
۴	۳۹۴۲۸۶ E ۳۳۱۵۶۳۷ N	"	< ۵	> ۵۰	< ۵
۵	۳۹۲۹۲۷ E ۳۳۱۶۴۳۹ N	"	< ۵	> ۵۰	< ۵
۶	۳۹۴۲۱۸ E ۳۳۱۵۶۶۷ N	"	۳۰ < < ۵۰	> ۵۰	< ۵
۷	۳۹۵۵۵۴ E ۳۳۱۴۰۸۷ N	"	< ۵	> ۵۰	۳۰ < < ۵۰
۸	۳۹۱۰۵۰ E ۳۳۱۳۶۵۶ N	آرژیلیک	> ۵۰	> ۵۰	< ۵
۹	۳۹۰۳۶۰ E ۳۳۱۳۹۲۱ N	"	۳۰ < < ۵۰	۳۰ < < ۵۰	< ۵
۱۰	۳۹۴۳۵۰ E ۳۳۱۵۶۳۵ N	"	> ۵۰	> ۵۰	< ۵
۱۱	۳۹۵۲۰۸ E ۳۳۱۴۸۰۹ N	پروپیلیتیک	< ۵	< ۵	۳۰ < < ۵۰
۱۲	۳۹۵۲۰۶ E ۳۳۱۳۰۶۶ N	"	< ۵	< ۵	> ۵۰
۱۳	۳۹۰۹۴۵ E ۳۳۱۱۶۸۵ N	"	< ۵	< ۵	۳۰ < < ۵۰



شکل (۳-۹) - جانمایی نمونه‌های مجموعه داده ۱ بر روی تصویر هایپریون منطقه مطالعاتی

### ۲-۳-۲-۲ - مجموعه داده ۲

کاهش ابعاد مجموعه داده هایپریون با استفاده از الگوریتم انتخاب ویژگی معرفی شده در بخش (۳-۱) و همچنین ارزیابی دقت روش‌های طبقه‌بندی کننده مختلف نسبت به اندازه مجموعه داده آموزشی، نیازمند استفاده از یک مجموعه داده بزرگ می‌باشد. از آنجایی که تهیه چنین مجموعه داده‌ای از منطقه مطالعاتی نیازمند صرف هزینه و زمان زیادی است لذا تلاش گردید که این مجموعه به صورت مصنوعی


تهیه گردد. بدین منظور نخست روش تجزیه طیفی MTMF برای طبقه‌بندی مناطق دگرسانی منطقه مطالعاتی استفاده شده و خروجی آن به عنوان مجموعه داده آموزشی منظور گردید. لازم به ذکر است که این روش پیش از این به عنوان یک روش زیرپیکسلی دقیق برای شناسایی کانی‌های دگرسانی در منطقه مطالعاتی این تحقیق توسط Hosseinjani Zadeh et al. (2014a) استفاده شده و با نتایج مطلوبی نیز همراه بوده است. ایشان اعتبار نتایج کار خود را با بازدید و برداشت نمونه‌های صحرایی، آنالیز طیفی توسط ASD و آنالیز کانی شناسی بوسیله<sup>۱</sup> XRD ارزیابی کردند که نتایج آن برای چهار کانی شاخص مناطق دگرسانی در جدول (۳-۵) نشان داده شده است. با توجه به نتایج اعتبارسنجی می‌توان گفت که MTMF از دقت بالایی در تفکیک کانی‌های دگرسانی برخوردار است. بنابراین نتایج این روش برای ساخت مجموعه داده آموزشی مصنوعی مطابق با جدول (۳-۶) مورد استفاده قرار گرفت. البته بایستی اشاره گردد از آنجایی که روش MTMF یک روش زیرپیکسلی بوده و فراوانی هر یک از کانی‌ها را در هر پیکسل تخمین می‌زند، لذا برای اطمینان بیشتر و داشتن خطای کمتر در ساخت این مجموعه داده، پیکسل‌هایی از تصویر انتخاب شد که فراوانی یکی از کانی‌ها بیش از ۵۰٪ باشد. در نهایت نیز پیکسل‌های انتخابی در طبقه این کانی قرار گرفته و برچسب گذاری شدند. در شکل (۳-۱۰) موقعیت نمونه‌ها در منطقه مطالعاتی نمایش داده شده است.

جدول (۳-۵) - اعتبارسنجی نتایج روش MTMF در شناسایی کانی‌های دگرسانی منطقه مطالعاتی ( Hosseinjani Zadeh et al., 2014a)

نوع کانی	ASD (%)	XRD (%)
مسکوویت	۶۷	۴۷
آلونیت	۸۴	۸۶
کائولینیت	۷۷	۷۶
کلریت	۸۰	۶۹

جدول (۳-۶) - مشخصات مجموعه داده ۲ بدست آمده از روش MTMF

رنگ	نوع دگرسانی	تعداد (پیکسل)	نوع کانی
آبی	فیلیک	۳۷۹	مسکوویت
قرمز	آرژلیک پیشرفته	۵۵۷	آلونیت
زرد	آرژلیک	۵۰۴	کائولینیت
سبز	پروپیلیتیک	۱۷۰۰	کلریت



شکل (۳-۱۰) - جانمایی نمونه‌های مجموعه داده ۲ بر روی تصویر هایپریون منطقه مطالعاتی





فصل چهارم: کاهش العاد. مجموعه داده های سیر یون





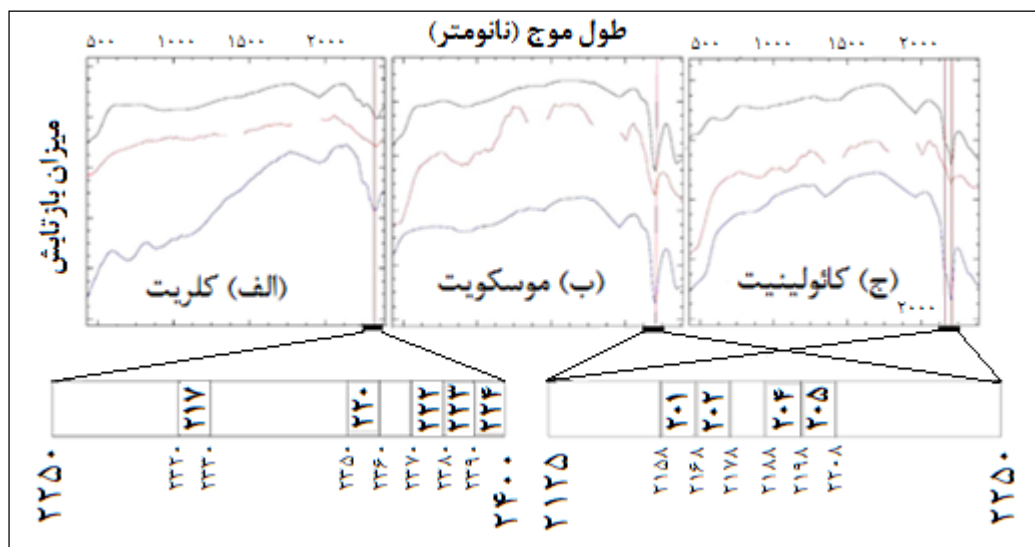
## ۴-۱- مقدمه

تصاویر ابرطیفی به دلیل داشتن باندهای طیفی فراوان در فضای ویژگی به عنوان مجموعه داده بیش‌ابعاد شناخته می‌شوند. در عمل بسیاری از ویژگی‌های مجموعه داده‌های بیش‌ابعاد، افزونه، غیر مرتبط و ناملزوم می‌باشند که تنها باعث افزایش اندازه و پیچیدگی فضای ویژگی می‌گردند. با پیچیده‌تر شدن فضای ویژگی، فرآیند تشخیص الگو نیز پیچیده‌تر می‌شود، یعنی الگوهای فضاهای بیش‌ابعاد به آسانی قابل شناسایی نخواهند بود (Gheyas and Smith, 2010). پیش‌تر گفته شد که ممکن است دقت طبقه‌بندی فضاهای بیش‌ابعاد تحت تأثیر مشکلات انفجار ابعادی و پدیده هیوز با کاهش زیادی همراه باشد. اگرچه استفاده از روش طبقه‌بندی کننده SVM یکی از راه‌های مقابله با مشکلات مذکور عنوان شده است، تحقیقات فراوانی نیز به نقش مهم و تأثیرگذار استفاده از روش‌های انتخاب ویژگی در کاهش اثرات مخرب مشکل هیوز اشاره دارند (Pal and Foody, 2010). این روش‌ها در مرحله پیش‌پردازش داده‌ها، با کم کردن اندازه فضای ویژگی بصورت حذف ویژگی‌های افزونه و نامربوط، می‌توانند دقت طبقه‌بندی را افزایش دهند. روش‌های کاهش ابعاد داده‌ها با توجه به نوع عملکرد به دو دسته روش‌های انتخاب ویژگی و روش‌های استخراج ویژگی تقسیم می‌شوند. یکی از مزایای نوع انتخاب ویژگی کمک به محققین در شناسایی بهترین ویژگی‌ها در فرآیند طبقه‌بندی است، لذا با استفاده از این روش‌ها امکان شناسایی تأثیرگذارترین باندهای طیفی برای طبقه‌بندی مناطق دگرسانی فراهم می‌گردد. از آنجایی که همه باندهای طیفی در تصاویر ابرطیفی برای انجام یک طبقه‌بندی دقیق مورد نیاز نمی‌باشند (Landgrebe, 2003; Bioucas-Dias et al., 2013)، در این بخش از یک روش انتخاب ویژگی برای کاهش ابعاد طیفی مجموعه داده هایپریون استفاده می‌شود. در ادامه به منظور سنجش کارایی باندهای طیفی انتخابی و همچنین برای مقایسه کارایی روش SVM در شرایط بیش‌ابعاد، طبقه‌بندی با همه باندهای طیفی و همچنین باندهای منتخب انجام شده و نتایج بدست آمده با نتایج یک روش طبقه‌بندی کننده قوی مثل شبکه‌های عصبی مصنوعی مقایسه می‌شود. برای اجرای کلیه مراحل فوق، از نرم‌افزار

متلب استفاده شده است.

## ۲-۴- کاهش ابعاد مجموعه داده هایپریون

روش انتخاب ویژگی معرفی شده در بخش (۳-۱-۳) برای کاهش ابعاد و انتخاب بهترین باندهای مجموعه داده هایپریون استفاده شد. با استفاده از مجموعه داده شماره (۲) گردآوری شده در بخش (۳-۲-۲-۳) به عنوان داده ورودی برای روش انتخاب ویژگی، از بین ۱۶۵ باند طیفی قابل استفاده هایپریون تنها ۱۸ باند به عنوان بهترین باندهایی انتخاب شدند که حاوی بیشترین اطلاعات در مورد کانی‌های شاخص مناطق دگرسانی هستند. ۱۸ باند مذکور متعلق به بازه طیفی ۶۱۴-۵۵۴، ۱۳۰۰-۱۲۶۰، ۲۲۵۰-۲۱۲۵ و ۲۴۰۰-۲۲۵۰ نانومتر هستند بطوریکه ۹ باند از بین این ۱۸ باند در دو بازه سوم و چهارم قرار می‌گیرند. این دو بازه خودشان متعلق به بازه ۲۵۰۰-۲۰۰۰ نانومتر هستند که به عنوان مناسب‌ترین بازه طیفی برای شناسایی کانی‌های رسی متعلق به دگرسانی‌های گرمایی شناخته شده است ( Kruse et al., 2003; Gersman et al., 2008; Bishop et al., 2011; Hosseinjani Zadeh et al., 2014a). بر اساس شکل (۴-۱) که موقعیت این باندها را در بازه طیفی مذکور با جزئیات بیشتری نشان می‌دهد، باندهای شماره ۲۰۱، ۲۰۲، ۲۰۴ و ۲۰۵ متعلق به بازه ۲۱۲۵-۲۲۵۰ نانومتر و باندهای ۲۱۷، ۲۲۰، ۲۲۲، ۲۲۳ و ۲۲۴ متعلق به بازه ۲۲۵۰-۲۴۰۰ نانومتر هستند. با توجه به نمودارهای بالای تصویر مشاهده می‌شود که باندهای مذکور دقیقاً در بازه‌هایی قرار گرفته‌اند که کانی‌های شاخص مناطق دگرسانی خصوصیات طیفی متمایز کننده‌ای (منطبق با خطوط عمودی) از خود نشان می‌دهند. با توجه به اینکه موسکویت و کائولینیت جذب طیفی شاخصی در بازه ۲۱۲۵-۲۲۵۰ نانومتر و بخصوص در باندهای ۲۰۱ و ۲۰۵ دارند و کلریت نیز در بازه ۲۲۵۰-۲۴۰۰ نانومتر و در باند ۲۱۸ دارای جذب طیفی شاخصی می‌باشد (Hosseinjani Zadeh et al., 2014a)، بنابراین نتایج بدست آمده حاکی از عملکرد مطلوب روش انتخاب ویژگی است.



شکل (۴-۱)- بالا- خصوصیات طیفی کانی‌های شاخص مناطق دگرسانی. بازه‌ای که جذب شاخص طیفی برای هر کانی رخ می‌دهد با خط سیاه رنگ افقی مشخص شده است (برگرفته از Hosseinjani Zadeh et al., 2014a) پایین- باند طیفی بدست آمده توسط الگوریتم انتخاب ویژگی

۹ باند دیگر شناسایی شده توسط روش انتخاب ویژگی (یعنی باندهای شماره ۱۴، ۱۵، ۱۶، ۱۷، ۱۹، ۸۲، ۸۳، ۸۴ و ۸۵) متعلق به بازه ۱۳۰۰-۴۰۰ نانومتر هستند که مناسب برای شناسایی کانی‌های اکسیدی آهن‌دار است (Bishop et al., 2011; Hosseinjani Zadeh et al., 2014a). علت انتخاب این باندها توسط الگوریتم را می‌توان در ارتباط با توزیع کانی‌های اکسیدی آهن در منطقه دانست که بخصوص در مناطق دارای دگرسانی فیلیکی مشاهده می‌شوند (شکل ۴-۲). به عبارت دیگر یعنی اگرچه کانی‌های اکسید آهن به عنوان یک طبقه مجزا (در کنار ۴ طبقه کائولینیت، موسکویت، آلونیت و کلریت) وارد الگوریتم انتخاب ویژگی نشده است، اما ترکیب طیفی<sup>۱</sup> بین کانی‌های اکسیدی آهن و کانی‌های رسی می‌تواند علت انتخاب باندهای طیفی مذکور باشد.

### ۴-۳- طبقه‌بندی کانی‌های دگرسانی توسط SVM و ANN

در این بخش کارایی روش SVM در طبقه‌بندی مناطق دگرسانی ارزیابی شده و نتایج آن با نتایج روش

1- Spectral mixture

ANN مقایسه می‌شود. هدف اصلی در این بخش سنجش حساسیت این دو روش نسبت به مشکل بیش‌ابعادی است. بدین‌منظور از مجموعه داده‌هایی با اندازه مختلف برای آموزش این روش‌ها استفاده شده و دقت نتایج بدست آمده با یکدیگر مقایسه می‌شوند. فرآیند طبقه‌بندی دو مرتبه و با دو فضای ویژگی مختلف، یک بار با ۱۶۵ و بار دیگر با ۱۸ باند طیفی بدست آمده توسط روش انتخاب ویژگی تکرار می‌گردد.



شکل (۴-۲) - پراکندگی کانی‌های اکسید آهن در محدوده مطالعاتی در کنار دگرسانی فیلیک (معدن دره زار)

مجموعه داده اصلی بکار رفته در این بخش برای مراحل آموزش و آزمایش عبارت است از مجموعه داده شماره ۲ که جزئیات آن در جدول (۳-۵) و شکل (۳-۱۱) قابل مشاهده است. این مجموعه داده دارای ۴ طبقه متشکل از کانی‌های شاخص دگرسانی‌های گرمابی می‌باشد. نخست کل نمونه‌های مجموعه داده مذکور به دو دسته نمونه‌های آموزشی و آزمایشی تقسیم شدند، بدین صورت که ۱۲۰ نمونه از هر کانی به صورت تصادفی برای آموزش روش‌های طبقه‌بندی کننده اختصاص یافته و در مجموع مجموعه داده آموزشی با ۴۸۰ نمونه را تشکیل می‌دهند. ۲۶۶۰ نمونه باقی مانده نیز برای سنجش دقت نتایج استفاده شده و مجموعه داده آزمایشی را تشکیل می‌دهند. مطابق با جدول (۴-۱)، مجموعه داده آموزشی ساخته شده به ۶ زیرمجموعه داده با تعداد ۴۸۰ نمونه (۱۲۰ نمونه برای هر کانی)، ۴۰۰ نمونه (۱۰۰ نمونه برای هر کانی)، ۳۲۰ نمونه (۸۰ نمونه برای هر کانی)، ۲۴۰ نمونه (۶۰ نمونه برای هر کانی)، ۱۶۰ نمونه (۴۰ نمونه برای هر کانی) و ۸۰ نمونه (۲۰ نمونه برای هر کانی) تقسیم می‌شود. مشخص است که به

ترتیب از مجموعه ۱ تا مجموعه ۶، با کاهش تعداد نمونه‌های آموزشی نسبت به اندازه فضای ویژگی (۱۶۵ باند طیفی)، مشکل انفجار ابعادی نیز افزایش می‌یابد.

جدول (۴-۱) - اندازه مجموعه داده استفاده شده متشکل از ۶ مجموعه آموزشی و ۱ مجموعه آزمایشی برای آموزش و ارزیابی طبقه‌بندی

اندازه مجموعه داده آموزشی (پیکسل)						اندازه مجموعه داده آزمایشی (پیکسل)			
مجموعه	مجموعه	مجموعه	مجموعه	مجموعه	مجموعه	موسکویت	آلونیت	کائولینیت	کلریت
۱	۲	۳	۴	۵	۶				
۴۸۰	۴۰۰	۳۲۰	۲۴۰	۱۶۰	۸۰	۲۵۹	۴۳۷	۳۸۴	۱۵۸۰

از آنجایی که هدف اصلی در این فصل مقایسه دقت طبقه‌بندی و میزان پیچیدگی محاسباتی روش‌های SVM و ANN می‌باشد لذا برای آموزش و ارزیابی هر دو روش از مجموعه داده‌های آموزشی و آزمایشی دقیقاً یکسانی استفاده می‌شود. همچنین جهت دستیابی به نتایج قابل اطمینان، کلیه مراحل فوق ۱۰ مرتبه و با ۱۰ مجموعه داده آموزشی و آزمایشی تصادفی تکرار شده و متوسط نتایج بدست آمده به عنوان نتیجه نهایی منظور می‌شود. برای بیان دقت طبقه‌بندی از میانگین دقت و ثابت کاپا و برای نمایش پیچیدگی محاسباتی از مدت زمان صرف شده برای آموزش الگوریتم استفاده خواهد شد.

بدلیل نتایج دقیق تر تابع کرنل RBF در مقایسه با سایر توابع (Huang et al., 2008; Petropoulos

et al., 2011)، از این تابع برای اجرای SVM غیرخطی استفاده می‌شود. برای تنظیم پارامترهای روش SVM و بدست آوردن مقادیر بهینه، از روش اعتبارسنجی متقابل ۵ بخشی<sup>۱</sup> استفاده شد که در نتیجه آن مقادیر  $C=10000$  و  $\sigma=0/1$  بدست آمد. همچنین بدلیل آنکه SVM یک روش طبقه‌بندی کننده دو کلاسه است از روش یک در مقابل یک<sup>۲</sup> (OAO) برای انجام طبقه‌بندی ۴ کلاسه استفاده می‌شود. برای ساخت شبکه روش ANN از یک لایه ورودی، یک لایه میانی و یک لایه خروجی استفاده می‌شود بطوریکه تعداد نرون‌های لایه ورودی برابر با اندازه فضای ویژگی (۱۶۵ و ۱۸ باند طیفی) و تعداد نرون‌های لایه خروجی برابر با تعداد طبقات موجود (۴ نوع کانی) می‌باشد. در نهایت با انتخاب ۲۵ نرون بدست

1- 5-fold cross-validation  
2- One Against One

آمده از روش سعی و خطا<sup>۱</sup> جهت تخصیص به لایه میانی، آموزش شبکه ساخته شده با روش BP<sup>۲</sup> و با استفاده از تابع سیگموئید و تابع LM<sup>۳</sup> انجام شد (Karimpouli and Malehmir, 2015).

### ۴-۳-۱- طبقه‌بندی با کل باندهای طیفی هایپریون


نتایج طبقه‌بندی با استفاده از مجموعه داده‌های ذکر شده در جدول (۴-۱) و کل باندهای طیفی (۱۶۵) باند طیفی قابل استفاده تصویر هایپریون) در جدول (۴-۲) و شکل (۴-۳) نشان داده شده است. نتایج نشان می‌دهند که کاهش تعداد نمونه‌های آموزشی از مجموعه ۱ تا مجموعه ۶ تأثیر محسوسی بر روی دقت روش SVM ندارد بطوریکه تنها به میزان ۱/۸٪ (از ۹۷/۵۳٪ به ۹۵/۷۳٪) کاهش یافته است. این در حالی است که دقت روش ANN با کاهش قابل توجهی به اندازه ۱۴/۰۱٪ (از ۹۲/۴۴٪ به ۷۸/۴۳٪) همراه بوده است. همچنین مشاهده می‌شود که اختلاف در دقت طبقه‌بندی روش‌های SVM و ANN به ازای مجموعه داده‌های آموزشی مشابه از مجموعه ۱ به مجموعه ۶ به صورت تدریجی افزایش می‌یابد. به عنوان مثال اختلاف بین دقت میانگین دو روش در مجموعه داده ۱ کمترین مقدار و برابر با ۵/۰۹٪ (از ۹۷/۵۳٪ به ۹۲/۴۴٪) است اما به ازای مجموعه ۶ به مقدار ۱۷/۳۰٪ (از ۹۵/۷۳٪ به ۷۸/۴۳٪) افزایش می‌یابد. این نتایج نشان می‌دهند که SVM در مقایسه با ANN حساسیت کمتری به اندازه مجموعه داده آموزشی دارد و با کاهش اندازه مجموعه آموزشی دارای افت کمتری در دقت طبقه‌بندی است. از دیدگاه پیچیدگی و زمان محاسباتی نیز مرحله آموزش SVM در مدت زمان خیلی کمتری نسبت به ANN انجام می‌شود. مدت زمان مورد نیاز برای آموزش این روش‌ها در شکل (۴-۳-ج) نشان داده شده است.

---

1- Trial and error  
2- back propagation  
3- Levenberg-Marquardt

جدول (۲-۴) - نتایج طبقه‌بندی توسط SVM و ANN با استفاده از کل باندهای طیفی هایپریون

دقت طبقه‌بندی طبقات (%)				زمان اجرا (ثانیه)	ضریب کاپا	میانگین دقت (%)	اندازه (پیکسل)	مجموعه داده آموزشی
طبقه ۴	طبقه ۳	طبقه ۲	طبقه ۱					
کلریت	کائولینیت	آلونیت	موسکویت	<b>SVM</b>				
۹۹/۳۴	۹۵/۶۸	۹۸/۸۶	۹۶/۲۵	۹/۲۲	۰/۹۷۳۷	۹۷/۵۳	۱۲۰	مجموعه ۱
۹۹/۲۵	۹۵/۵۵	۹۸/۸۶	۹۶/۱۴	۵/۲۰	۰/۹۷۲۳	۹۷/۴۵	۱۰۰	مجموعه ۲
۹۹/۲۹	۹۵/۰۰	۹۸/۸۳	۹۶/۵۶	۳/۰۸	۰/۹۷۲۰	۹۷/۴۲	۸۰	مجموعه ۳
۹۸/۷۸	۹۴/۸۲	۹۸/۸۸	۹۶/۳۷	۱/۶۹	۰/۹۶۶۷	۹۷/۲۱	۶۰	مجموعه ۴
۹۸/۳۸	۹۴/۲۴	۹۸/۸۳	۹۶/۱۰	۱/۲۰	۰/۹۶۱۰	۹۶/۸۹	۴۰	مجموعه ۵
۹۷/۲۳	۹۲/۴۷	۹۸/۷۴	۹۴/۴۸	۰/۸۱	۰/۹۴۳۴	۹۵/۷۳	۲۰	مجموعه ۶
<b>ANN</b>								
۹۸/۳۵	۸۶/۸۵	۹۸/۷۲	۸۵/۸۳	۶۱/۵۷	۰/۹۲۵۹	۹۲/۴۴	۱۲۰	مجموعه ۱
۹۸/۱۷	۸۲/۹۹	۹۸/۴۲	۸۱/۳۱	۶۲/۸۶	۰/۹۰۶۷	۹۰/۲۲	۱۰۰	مجموعه ۲
۹۷/۴۸	۸۱/۴۶	۹۷/۹۲	۷۹/۰۰	۶۰/۰۲	۰/۸۹۲۷	۸۸/۹۶	۸۰	مجموعه ۳
۹۷/۴۷	۷۴/۸۴	۹۷/۴۴	۸۰/۰۸	۵۷/۵۴	۰/۸۷۶۵	۸۷/۴۶	۶۰	مجموعه ۴
۹۶/۰۷	۷۰/۷۸	۹۵/۸۴	۷۲/۹۳	۴۲/۰۷	۰/۸۳۹۹	۸۳/۹۱	۴۰	مجموعه ۵
۹۳/۲۳	۶۳/۶۲	۸۹/۹۸	۶۶/۸۷	۳۰/۵۸	۰/۷۷۸۶	۷۸/۴۳	۲۰	مجموعه ۶



شکل (۳-۴) - نتایج طبقه‌بندی با استفاده از کل باندهای طیفی هایپریون: الف - SVM و ب - ANN، ج - زمان مورد نیاز برای آموزش SVM و ANN



### ۴-۳-۲- طبقه‌بندی با باندهای طیفی منتخب


به منظور مقایسه با بخش قبل، طبقه‌بندی مجدداً با استفاده از ۱۸ باند معرفی شده توسط روش انتخاب ویژگی و مجموعه داده‌های آموزشی و آزمایشی کاملاً یکسان با حالت ۱۶۵ باندهای انجام شد. بر اساس نتایج بدست آمده در جدول (۴-۳) می‌توان گفت که هر دو روش SVM و ANN توانسته‌اند که طبقه‌بندی را با دقتی نزدیک به حالت استفاده از ۱۶۵ باند انجام دهند بطوریکه حتی روش ANN به دقت بالاتری نیز دست یافته است. این موضوع در شکل (۴-۴) نیز قابل مشاهده است که دقت طبقه‌بندی را در هر دو حالت ۱۸ و ۱۶۵ باندهای نمایش می‌دهد. بر اساس شکل (۴-۴ الف)، SVM به جز کانی موسکویت هیچ گونه بهبودی در دقت کانی‌های دیگر ایجاد نکرده است اما ANN دقت طبقه‌بندی کلیه کانی‌ها را افزایش داده است (شکل ۴-۴ ب). دلیل بهبود در نتایج ANN می‌تواند به علت کاهش پیچیدگی فضای ویژگی از ۱۶۵ باند طیفی به ۱۸ باند باشد. به عبارت دیگر ANN با استفاده از ۱۸ باند طیفی توانسته است الگوهای حاکم بر مسئله طبقه‌بندی کانی‌ها را با دقت بیشتری فرا بگیرد. تأثیرات مثبت استفاده از فضای ویژگی کوچکتر را در زمان مورد نیاز برای آموزش ANN نیز می‌توان مشاهده کرد چراکه بر اساس شکل (۴-۵) هزینه محاسباتی ANN کاهش کاملاً محسوس و قابل توجهی در مقایسه با SVM داشته است. بنابراین تأثیر استفاده از روش انتخاب ویژگی را در نتایج روش ANN می‌توان مثبت قلمداد نمود چراکه با کاستن از پیچیدگی و هزینه محاسباتی در مرحله آموزش موجب افزایش دقت طبقه‌بندی نیز گردیده است.

جدول (۴-۳) - نتایج طبقه‌بندی توسط SVM و ANN با استفاده از ۱۸ باند طیفی منتخب


مجموعه داده آموزشی	اندازه (پیکسل)	میانگین دقت (%)	ضریب کاپا	زمان اجرا (ثانیه)	دقت طبقه‌بندی طبقات (%)			
					طبقه ۱	طبقه ۲	طبقه ۳	طبقه ۴
<b>SVM</b>								
مجموعه ۱	۱۲۰	۹۶/۹۸	۰/۹۶۲۵	۸/۲۶	۹۷/۲۶	۹۸/۸۶	۹۳/۲۰	۹۸/۶۲
مجموعه ۲	۱۰۰	۹۶/۹۰	۰/۹۶۱۴	۴/۷۵	۹۷/۳۴	۹۸/۸۶	۹۲/۸۴	۹۸/۵۸
مجموعه ۳	۸۰	۹۶/۷۸	۰/۹۵۹۶	۲/۷۶	۹۷/۱۰	۹۸/۸۳	۹۲/۷۱	۹۸/۴۷
مجموعه ۴	۶۰	۹۶/۶۴	۰/۹۵۵۵	۱/۴۵	۹۷/۱۸	۹۸/۸۳	۹۲/۴۷	۹۸/۰۷

ادامه جدول (۳-۴)

۹۷/۸۳	۹۱/۷۴	۹۸/۷۹	۹۶/۲۹	۰/۶۹	۰/۹۵۰۰	۹۶/۱۶	۴۰	مجموعه ۵
۹۶/۹۴	۸۹/۷۴	۹۸/۶۳	۹۳/۴۷	۰/۶۸	۰/۹۳۲۴	۹۴/۶۹	۲۰	مجموعه ۶
ANN								
۹۸/۱۰	۸۳/۶۲	۹۸/۷۶	۸۵/۲۹	۱/۲۱	۰/۹۱۵۳	۹۱/۴۴	۱۲۰	مجموعه ۱
۹۸/۰۹	۸۴/۸۴	۹۸/۵۶	۸۴/۲۹	۱/۳۵	۰/۹۱۵۹	۹۱/۴۴	۱۰۰	مجموعه ۲
۹۷/۷۲	۹۲/۷۱	۹۸/۶۵	۸۴/۱۳	۱/۰۶	۰/۹۰۷۶	۹۰/۸۲	۸۰	مجموعه ۳
۹۶/۷۷	۸۱/۸۵	۹۷/۸۰	۸۱/۱۶	۱/۰۶	۰/۸۹۰۵	۸۹/۴۰	۶۰	مجموعه ۴
۹۶/۳۰	۷۲/۳۷	۹۶/۷۰	۷۴/۶۷	۰/۹۳	۰/۸۵۰۹	۸۵/۰۱	۴۰	مجموعه ۵
۹۰/۸۹	۶۳/۲۰	۹۳/۵۷	۶۹/۷۷	۰/۷۱	۰/۷۷۶۶	۷۹/۳۶	۲۰	مجموعه ۶



شکل (۴-۴) - مقایسه نتایج طبقه‌بندی در دو حالت استفاده از ۱۸ و ۱۶۵ باند طیفی منتخب: الف - SVM و ب - ANN



شکل (۴-۵) - مقایسه پیچیدگی محاسباتی طبقه‌بندی در دو حالت استفاده از ۱۸ و ۱۶۵ باند طیفی منتخب: الف -

SVM و ب - ANN

## ۴-۴ - نتیجه‌گیری

طبقه‌بندی نظارت‌شده تصاویر سنجش از دور ابرطیفی بدلیل فراوانی تعداد باندهای طیفی این نوع

تصاویر تحت تأثیر مشکل هیوز قرار گرفته و از دقت آن کاسته می‌شود. این مشکل هنگامی که تعداد نمونه‌های آموزشی موجود برای آموزش روش طبقه‌بندی خیلی کمتر از تعداد باندهای طیفی باشد، تشدید می‌گردد. برای غلبه بر این مشکل روش‌های کاهش ابعاد فضای ویژگی مورد استفاده قرار می‌گیرند.

در این تحقیق از یک روش انتخاب ویژگی مبتنی بر الگوریتم رقابت استعماری- فازی برای شناسایی باندهای طیفی تأثیرگذار در شناسایی کانی‌های دگرسانی استفاده شد که در نتیجه آن تنها در حدود ۱۰٪ (۱۸ باند) از کل باندهای طیفی هایپرینون (۱۶۵ باند) به عنوان باندهای منتخب شناسایی شدند. با هدف ارزیابی توانایی روش SVM برای طبقه‌بندی در شرایط بیش ابعاد و سنجش مقاومت آن نسبت به پدیده هیوز، طبقه‌بندی در درجات مختلفی از انفجار ابعادی انجام شد و نتایج بدست آمده با نتایج روش ANN مقایسه گردید. نتایج مقایسه نشان داد که روش SVM نسبت به ANN مقاومت بیشتری در مقابل مشکل هیوز داشته و با افزایش میزان انفجار ابعادی، دقت طبقه‌بندی توسط آن با افت کمتری مواجه می‌شود. همچنین مشاهده گردید که با کاهش اندازه فضای باندی از ۱۶۵ به ۱۸ باند طیفی، کارایی روش ANN در قالب دقت طبقه‌بندی و پیچیدگی محاسباتی، افزایش بیشتری نسبت به SVM دارد. دلیل این افزایش را در کاهش میزان پیچیدگی فضای طیفی می‌توان جست. زیرا در فضای طیفی کوچک‌تر، امکان شناسایی قوانین حاکم بر الگوی مناطق دگرسانی با دقت بیشتری فراهم می‌گردد. بنابراین می‌توان گفت که استفاده از روش‌های انتخاب ویژگی در مرحله پیش پردازش داده‌های داده‌های ابرطیفی ضروری است، بویژه هنگامی که طبقه‌بندی توسط روش‌های آسیب‌پذیر در برابر پدیده هیوز انجام می‌شود. همچنین این کار برای آن دسته از داده‌های ابرطیفی که از مشکلات عدم قطعیت و نویز رنج برده (مثل هایپرینون) و دارای باندهای افزونه فراوانی می‌باشند ضروری‌تر است.

شناسایی مؤثرترین باندهای طیفی برای تفکیک مناطق دگرسانی، دیگر مزیت الگوریتم انتخاب ویژگی استفاده شده است که آن را از روش‌های استخراج ویژگی (برای مثال روش PCA) متمایز می‌کند. این موضوع از آن جهت حائز اهمیت است که محققان با آن دسته از باندهای طیفی که بیشترین

اطلاعات را در رابطه مناطق دگرسانی فراهم می‌کنند آشنا شده و مستقیماً می‌توانند این باندها را برای مطالعات مشابه مورد استفاده قرار دهند. درحالیکه در نتیجه استفاده از روش PCA اگرچه امکان کاهش ابعاد فضای طیفی وجود دارد ولی امکان شناخت بهترین باندهای طیفی وجود ندارد.

## فصل پنجم: طبقه‌بندی نرم مناطق دگرسانی

## ۵-۱- مقدمه

انجام طبقه‌بندی در مقیاس زیرپیکسلی که از آن با عنوان طبقه‌بندی نرم نیز یاد می‌شود، یکی از مباحث مهم در حوزه سنجش از دور است. در این بخش از SVR به عنوان نسخه‌ای از SVM که توانایی تخمین مقادیر پیوسته را دارد، برای طبقه‌بندی نرم مناطق دگرسانی استفاده خواهد شد. بدین منظور نخست در بخش (۲-۵) به مفاهیم طبقه‌بندی نرم و تفاوت آن با نوع سخت اشاره شده و پس از آن نتایج حاصل از طبقه‌بندی نرم مناطق دگرسانی با استفاده از SVR در بخش (۳-۵) ارائه می‌شود.

## ۵-۲- طبقه‌بندی نرم و سخت

بطور کلی طبقه‌بندی تصاویر سنجش از دور در دو مقیاس پیکسل و زیرپیکسلی<sup>۱</sup> قابل اجرا است که به ترتیب با عناوین طبقه‌بندی سخت و طبقه‌بندی نرم شناخته می‌شوند. طبقه‌بندی سخت بر این فرض استوار است که پیکسل‌های سازنده تصویر تنها از یک نوع ماده تشکیل شده و یا به عبارتی کاملاً خالص می‌باشند. در سوی مقابل طبقه‌بندی نرم که با عنوان تجزیه طیفی نیز شناخته می‌شود اشاره به پیکسل‌های ترکیبی دارد، یعنی طبقه‌بندی تصاویری که بیش از یک نوع ماده در ساخت پیکسل‌ها نقش داشته‌اند (شکل ۵-۱-الف). احتمال حضور پیکسل‌های ترکیبی در تصاویری با قدرت تفکیک مکانی کم<sup>۲</sup> بسیار زیاد است (Heylen et al., 2014). تفکیک مکانی پایین که نتیجه میدان دید لحظه‌ای (IFOV<sup>۳</sup>) بزرگ سنجنده است، باعث می‌شود که پیکسل‌های سازنده تصویر دارای ابعاد بزرگتری باشند. بنابراین احتمال حضور اشیاء و مواد مختلف در پیکسل‌های وسیع‌تر بیشتر بوده و در نتیجه پاسخ طیفی ثبت شده برای هر پیکسل ترکیبی از خصوصیات طیفی اجزاء تشکیل دهنده آن پیکسل خواهد بود. مشکل طیف‌های ترکیبی نه تنها می‌تواند ناشی از پیکسل‌های بزرگ باشد بلکه در مقیاس کوچک‌تری

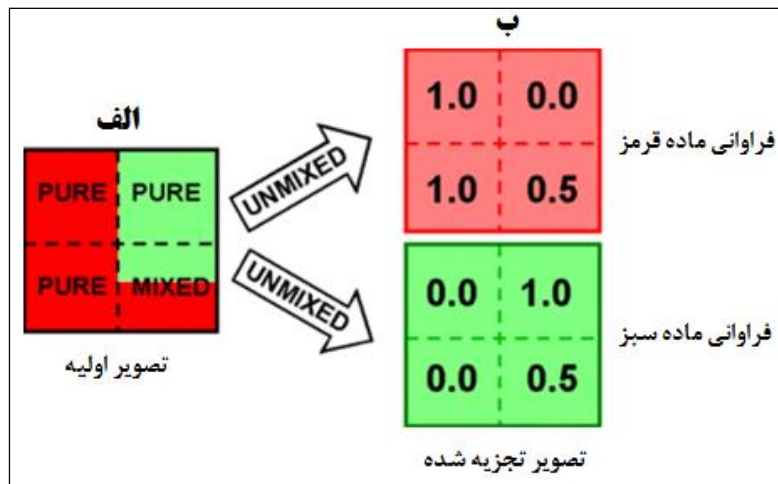
---

1- Pixel and sub-pixel

2- Low spatial resolution

3- Instantaneous Field Of View

مثل مطالعات کانی شناسی نیز می‌تواند رخ دهد، جایی که یک نمونه سنگ کوچک خود ترکیبی از چندین کانی مختلف با خصوصیات طیفی متفاوت می‌باشد (Heylen et al., 2014).

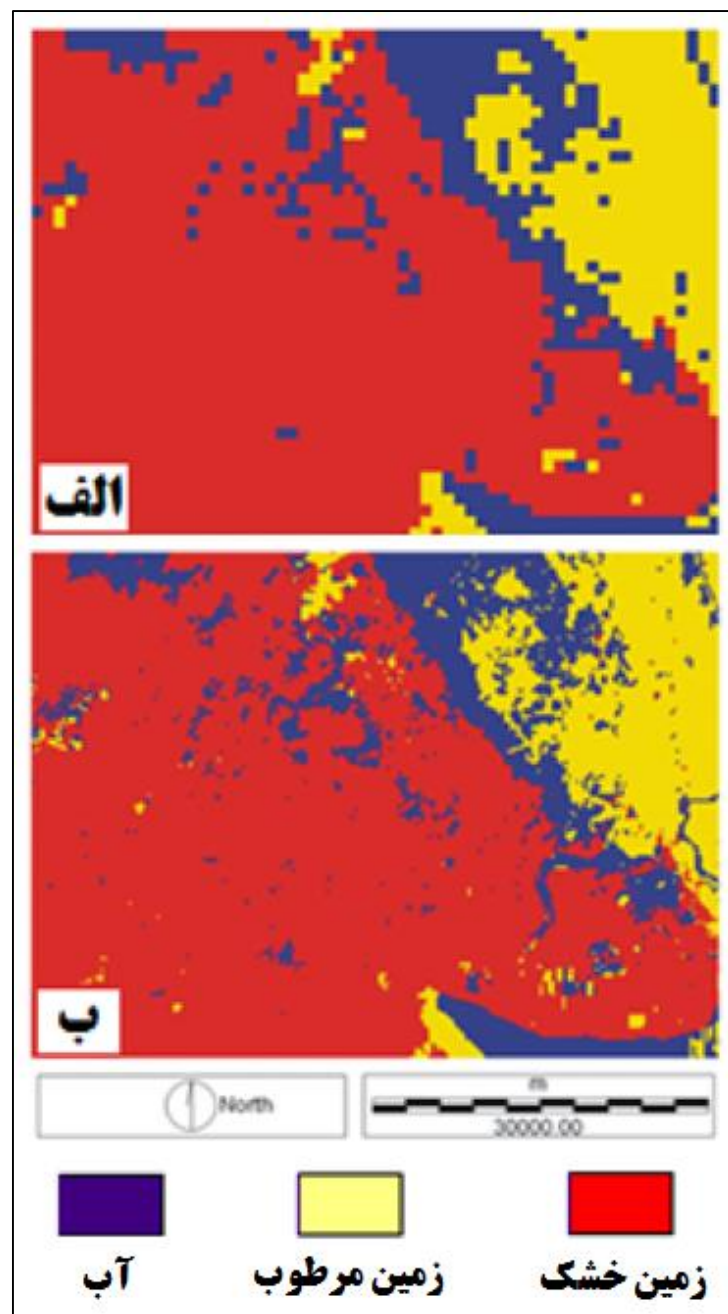


شکل (۵-۱) - تجزیه طیفی تصویر به اجزاء سازنده: (الف) تصویر اولیه دارای پیکسل‌های ترکیبی (ب) تجزیه تصویر به اجزاء سازنده قرمز و سبز رنگ و تخمین فراوانی هر یک از اجزای سازنده

بدلیل عدم انطباق پاسخ طیفی پیکسل‌های مرکب با ویژگی‌های طیفی اجزاء سازنده هر پیکسل، استفاده از روش‌های طبقه‌بندی سخت برای طبقه‌بندی تصاویر دارای پیکسل‌های ترکیبی معمولاً همراه با خطا بوده و نتایج مطلوب حاصل نمی‌گردد، چراکه می‌تواند منجر به حذف اطلاعات مفید سایر اجزای سازنده پیکسل گردد (شکل ۵-۲). لذا روش‌های تجزیه طیفی متنوعی توسعه پیدا کرده‌اند که هدف اصلی آن‌ها شناسایی و تخمین فراوانی اجزاء سازنده پیکسل‌های تصاویر است (شکل ۵-۱-ب) (Heylen et al., 2013; Yanfeng et al., 2014).


بطور کلی فرآیند تجزیه طیفی بر اساس دو مدل ترکیبی خطی و غیر خطی ۱ می‌باشد. همانطور که در شکل (۵-۳-الف) نیز مشاهده می‌شود، مدل ترکیبی خطی هنگامی رخ می‌دهد که امواج الکترومغناطیسی تابیده شده به سطح زمین فقط یکبار باز تابیده شده و در نتیجه یک رابطه خطی بین فراوانی اجزاء سازنده تصویر وجود خواهد داشت. اما در سوی مقابل، مدل ترکیبی غیرخطی نشان دهنده شرایط پیچیده‌تری است. در این حالت بدلیل فرض توزیع همگن و تصادفی مواد سازنده هر پیکسل،

اشعه تابیده شده بازتاب‌های چندگانه‌ای از سطح مواد سازنده داشته و در نتیجه رابطه بین اثر طیفی اندازه‌گیری شده و فراوانی اعضا سازنده پیکسل دیگر خطی نخواهد بود (۵-۳-ب). چون مدل غیرخطی شرایط فیزیکی حاکم بر تصاویر ابرطیفی را دقیق‌تر توصیف می‌کند، بنابراین مدل ترکیبی طیفی خطی برای توصیف این شرایط مناسب نبوده و استفاده از مدل‌های غیرخطی توصیه می‌گردند (Keshava, 2003).



شکل (۵-۲) - از دست دادن بخشی از اطلاعات مفید در نتیجه طبقه‌بندی سخت تصویر سنجنده SPOT (الف) طبقه‌بندی سخت (ب) طبقه‌بندی نرم





شکل (۵-۳) - انواع مدل ترکیبی (الف) خطی (ب) غیرخطی (Keshava, 2003)

بر اساس طبقه‌بندی شکل (۱-۲) روش‌های تجزیه طیفی در طبقه‌بندی روش‌های پردازش طیفی در گروه روش‌های داده محور قرار می‌گیرند (Asadzadeh and De Souza Filho, 2016). در این طبقه‌بندی، SVM به عنوان یکی از روش‌های داده‌کاوی، توانایی انجام هر دو نوع طبقه‌بندی سخت و نرم را دارد.

روش‌های داده‌کاوی مجموعه‌ای از ابزارهای خودکار و نیمه خودکار هستند که برای تحلیل مجموعه داده‌های حجیم با هدف کشف الگوهای معنی‌دار بکار می‌روند. این روش‌ها دو هدف کلی را دنبال می‌کنند: ۱- توصیف و ۲- پیش‌بینی. هدف در بخش توصیفی کشف روابط و الگوهای مخفی موجود در بطن داده‌ها است درحالی‌که هدف بخش پیش‌بینی عبارت است از پیش‌بینی مقدار یک ویژگی یا متغیر (به عنوان متغیر وابسته) با استفاده از مقادیر مجموعه‌ای از ویژگی‌ها یا متغیرهای دیگر (به عنوان متغیرهای مستقل). به عبارت دیگر روش‌های پیش‌بینی کننده به مانند یک تابع به تخمین متغیر وابسته بر اساس متغیرهای مستقل می‌پردازند. طبقه‌بندی و رگرسیون<sup>۱</sup> دو نوع مختلف از پیش‌بینی هستند که به ترتیب برای پیش‌بینی متغیرهای گسسته و پیوسته بکار می‌روند (Tan et al., 2005). در این فصل نوع رگرسیونی SVM یعنی رگرسیون بردار پشتیبان (SVR<sup>۲</sup>) برای طبقه‌بندی نرم یا تجزیه طیفی کانی‌های دگرسانی استفاده خواهد شد. SVM استاندارد تنها قادر به پیش‌بینی مقادیر گسسته است

1- Regression

2- Support Vector Regression

در حالیکه SVR نه تنها بر پایه مفاهیم SVM استوار است بلکه توانایی تخمین و پیش‌بینی مقادیر پیوسته را نیز دارد. با داشتن این توانایی، SVR می‌تواند برای تخمین فراوانی اجزای تشکیل دهنده پیکسل‌های تصویر استفاده شود.

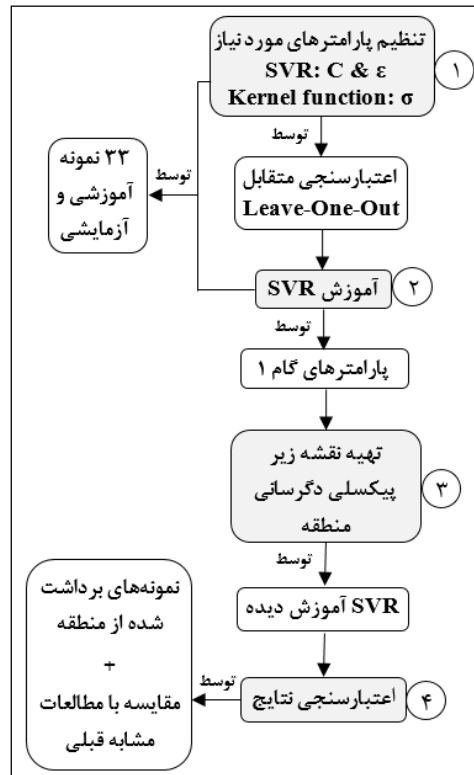
## ۵-۳- طبقه‌بندی نرم مناطق دگرسانی با استفاده از SVR

برای طبقه‌بندی نرم مناطق دگرسانی از مجموعه داده ۱ معرفی شده در جداول (۳-۳) و (۴-۳) و شکل (۳-۹) استفاده شد. ۳۳ نمونه سنگی برداشت شده از منطقه (جدول ۳-۳) متعلق به ۳ طبقه دگرسانی فیلیک، آرژیلیک و پروپیلیتیک برای آموزش و تخمین پارامترهای SVR مورد استفاده قرار گرفتند. همچنین برای اعتبارسنجی نتایج از مجموعه داده دیگری شامل ۱۳ نمونه (جدول ۴-۳) که در فرآیند آموزش بکار گرفته نشده بودند، استفاده شد. بدلیل کم بودن تعداد نمونه‌های اعتبارسنجی، مقایسه نتایج بدست آمده با نتایج مطالعات مشابه قبلی انجام شده در منطقه، یکی دیگر از روش‌های اعتبارسنجی نتایج است. در شکل (۴-۵) چهار گام اصلی انجام طبقه‌بندی به روش نرم نشان داده شده است. بر اساس این شکل در گام‌های اول و دوم، ۳۳ نمونه برداشت شده از منطقه به عنوان ورودی روش SVR برای بدست آوردن پارامترهای بهینه و همچنین آموزش آن استفاده می‌شوند. خروجی فلوچارت در گام سوم بدست می‌آید که طی آن نقشه زیرپیکسلی دگرسانی‌های منطقه توسط SVR تولید می‌شود. در نهایت گام چهارم اختصاص به اعتبارسنجی نتایج دارد که برای این کار ۴۶ نمونه برداشت شده از منطقه و همچنین مطالعات مشابه قبلی (برای مقایسه) استفاده خواهند شد.

با توجه به اینکه هدف SVR تخمین متغیر فراوانی کانی‌ها در هر پیکسل از تصویر هایپریون است بنابراین واضح است که به جای برچسب نمونه‌های آموزشی که مقادیری گسسته هستند بایستی فراوانی کانی‌های شاخص دگرسانی در هر نمونه به عنوان مقادیر پیوسته مورد استفاده قرار گیرند. این مقادیر پیوسته که خروجی نرم‌افزار PIMAView هستند در ۳ ستون آخر جدول (۳-۳) گنجانده شده‌اند.

**گام اول:** در گام نخست، برای تنظیم پارامترهای SVR یعنی  $C$ ،  $\sigma$  و  $\varepsilon$  از روش اعتبارسنجی متقابل L-O-O استفاده شد. این روش به ازای مقادیر مختلفی از متغیر  $C$  در بازه  $10^{-1}$  تا  $10^5$  ( $10$ ،  $100$ ،  $1000$ ،  $5000$ ،  $7000$  و  $10000$ )، به ازای متغیر  $\sigma$  در بازه  $0/5$  تا  $0/1$  با فواصل  $0/1$  و در نهایت به ازای  $\varepsilon$  در بازه  $30$  تا  $15$  و با فواصل  $5$  اجرا گردید که بخشی از نتایج بدست آمده (بدلیل حجم زیاد داده‌ها) در جدول (۱-۵-الف، ب و ج) به ترتیب برای کانی‌های کلریت، موسکویت و کائولینیت گردآوری شده است. در بخش (۳-۱-۲) اشاره گردید که متغیر  $\varepsilon$  در روش SVR متغیری است که وظیفه کنترل بیشینه مقدار خطای قابل قبول در تخمین را به عهده دارد. با توجه به نتایج نیمه کمی نرم افزار PIMA View در تخمین فراوانی کانی‌ها، تخصیص خطایی در بازه  $30$  تا  $15$  درصد می‌تواند انتخاب درست و قابل قبولی باشد.

در جدول (۲-۵) بهینه ترین مقادیر متغیرها که به ازای آن‌ها مجذور میانگین مربع خطا (RMSE)، کمینه مقدار بدست آمده است، نشان داده شده است. این مقادیر بهینه در گام بعدی برای آموزش SVR استفاده خواهند شد.



شکل (۴-۵) - مراحل انجام طبقه‌بندی نرم توسط SVR

جدول (۵-۱) - تعیین مقادیر بهینه پارامترهای SVR با استفاده از روش تخمین خطای اعتبارسنجی متقابل L-O-O (الف) کلریت (ب) موسکویت (ج) کائولینیت

الف) کلریت											
میانگین دقت (%)		پارامتر			ردیف	میانگین دقت (%)		پارامتر			ردیف
Re-sub	L-O-O	$\varepsilon$	$\sigma$	C		Re-sub	L-O-O	$\varepsilon$	$\sigma$	C	
۲۳/۰۶	۲۳/۴۶	۲۵	۰/۱	۱۰۰	۲۵	۲۱/۹۴	۲۲/۷۰	۱۵	۰/۱	۱۰۰	۱
۲۲/۲۱	۲۲/۹۳	"	"	۱۰۰۰	۲۶	۱۶/۴۴	۱۸/۲۲	"	"	۱۰۰۰	۲
۱۶/۴۷	۱۸/۷۶	"	"	۵۰۰۰	۲۷	۱۶/۱۸	۱۸/۶۲	"	"	۵۰۰۰	۳
۱۶/۵۴	۱۸/۵۴	"	"	۱۰۰۰۰	۲۸	۱۵/۶۲	۱۸/۵۹	"	"	۱۰۰۰۰	۴
۲۶/۲۵	۲۶/۴۵	"	۰/۳	۱۰۰	۲۹	۲۳/۱۳	۲۳/۳۱	"	۰/۳	۱۰۰	۵
۲۲/۱۳	۲۲/۵۷	"	"	۱۰۰۰	۳۰	۲۱/۲۲	۲۱/۹۳	"	"	۱۰۰۰	۶
۲۱/۷۱	۲۲/۱۵	"	"	۵۰۰۰	۳۱	۱۷/۴۲	۱۸/۸۸	"	"	۵۰۰۰	۷
۲۲/۰۰	۲۲/۷۶	"	"	۱۰۰۰۰	۳۲	۱۶/۹۰	۱۸/۲۶	"	"	۱۰۰۰۰	۸
۲۶/۵۸	۲۶/۷۶	"	۰/۵	۱۰۰	۳۳	۲۳/۷۸	۲۳/۸۹	"	۰/۵	۱۰۰	۹
۲۴/۹۵	۲۵/۲۲	"	"	۱۰۰۰	۳۴	۲۱/۷۶	۲۲/۰۵	"	"	۱۰۰۰	۱۰
۲۱/۷۳	۲۲/۲۶	"	"	۵۰۰۰	۳۵	۱۹/۰۶	۲۰/۰۲	"	"	۵۰۰۰	۱۱
۲۱/۷۰	۲۲/۲۰	"	"	۱۰۰۰۰	۳۶	۱۶/۵۲	۱۷/۹۹	"	"	۱۰۰۰۰	۱۲
۲۸/۹۵	۲۹/۴۶	۳۰	۰/۱	۱۰۰	۳۷	۲۱/۴۴	۲۱/۹۹	۲۰	۰/۱	۱۰۰	۱۳
۲۵/۶۲	۲۶/۳۱	"	"	۱۰۰۰	۳۸	۱۶/۵۷	۱۷/۹۲	"	"	۱۰۰۰	۱۴
۱۶/۹۹	۱۸/۶۷	"	"	۵۰۰۰	۳۹	۱۵/۷۷	۱۷/۹۸	۲۰	۰/۱	۵۰۰۰	۱۵
۱۸/۹۵	۲۰/۶۰	"	"	۱۰۰۰۰	۴۰	۱۵/۴۷	۱۸/۳۱	"	"	۱۰۰۰۰	۱۶
۲۹/۲۹	۲۹/۷۸	"	۰/۳	۱۰۰	۴۱	۲۴/۹۷	۲۵/۱۱	"	۰/۳	۱۰۰	۱۷
۲۸/۸۴	۲۹/۳۵	"	"	۱۰۰۰	۴۲	۲۰/۵۰	۲۱/۱۰	"	"	۱۰۰۰	۱۸
۲۶/۸۹	۲۷/۴۹	"	"	۵۰۰۰	۴۳	۱۷/۳۹	۱۸/۳۲	"	"	۵۰۰۰	۱۹
۲۴/۶۱	۲۵/۳۴	"	"	۱۰۰۰۰	۴۴	۱۶/۵۵	۱۸/۸۵	"	"	۱۰۰۰۰	۲۰
۲۹/۳۲	۲۹/۸۱	"	۰/۵	۱۰۰	۴۵	۲۵/۳۳	۲۵/۴۴	"	۰/۵	۱۰۰	۲۱
۲۹/۱۵	۲۹/۶۶	"	"	۱۰۰۰	۴۶	۲۳/۵۲	۲۳/۷۹	"	"	۱۰۰۰	۲۲
۲۸/۴۳	۲۸/۹۶	"	"	۵۰۰۰	۴۷	۱۸/۰۵	۱۹/۰۰	"	"	۵۰۰۰	۲۳
۲۷/۵۳	۲۸/۱۱	"	"	۱۰۰۰۰	۴۸	۱۷/۴۶	۱۸/۴۰	"	"	۱۰۰۰۰	۲۴
ب) موسکویت											
میانگین دقت (%)		پارامتر			ردیف	میانگین دقت (%)		پارامتر			ردیف
Re-sub	L-O-O	$\varepsilon$	$\sigma$	C		Re-sub	L-O-O	$\varepsilon$	$\sigma$	C	
۲۶/۴۵	۲۸/۰۳	۲۵	۰/۱	۱۰۰	۲۵	۲۵/۵۶	۲۷/۵۵	۱۵	۰/۱	۱۰۰	۱
۲۵/۰۶	۲۸/۶۸	"	"	۱۰۰۰	۲۶	۲۴/۳۹	۲۹/۴۲	"	"	۱۰۰۰	۲
۲۳/۳۸	۳۱/۹۲	"	"	۵۰۰۰	۲۷	۲۲/۱۰	۳۱/۵۶	"	"	۵۰۰۰	۳
۲۲/۳۹	۳۳/۱۵	"	"	۱۰۰۰۰	۲۸	۲۰/۷۷	۳۲/۱۴	"	"	۱۰۰۰۰	۴
۲۷/۲۲	۲۷/۷۳	"	۰/۳	۱۰۰	۲۹	۲۶/۳۴	۲۷/۴۷	"	۰/۳	۱۰۰	۵
۲۶/۵۰	۲۷/۹۴	"	"	۱۰۰۰	۳۰	۲۵/۷۰	۲۷/۵۳	"	"	۱۰۰۰	۶

ادامه جدول (۵-۱)

۲۵/۸۷	۲۸/۴۳	"	"	۵۰۰۰	۳۱	۲۵/۳۲	۲۸/۱۸	"	"	۵۰۰۰	۷
۲۵/۶۹	۲۹/۲۳	"	"	۱۰۰۰۰	۳۲	۲۴/۹۸	۲۹/۶۶	"	"	۱۰۰۰۰	۸
۲۷/۷۴	۲۸/۰۹	"	۰/۴	۱۰۰	۳۳	۲۶/۷۷	۲۷/۸۳	"	۰/۴	۱۰۰	۹
۲۶/۶۸	۲۷/۶۱	"	"	۱۰۰۰	۳۴	۲۶/۰۴	۲۷/۲۸	"	"	۱۰۰۰	۱۰
۲۶/۰۸	۲۷/۹۸	"	"	۵۰۰۰	۳۵	۲۵/۳۸	۲۷/۳۹	"	"	۵۰۰۰	۱۱
۲۵/۹۴	۲۸/۵۷	"	"	۱۰۰۰۰	۳۶	۲۵/۲۲	۲۸/۳۳	"	"	۱۰۰۰۰	۱۲
۲۶/۷۴	۲۸/۲۳	۳۰	۰/۱	۱۰۰	۳۷	۲۵/۹۳	۲۷/۱۲	۲۰	۰/۱	۱۰۰	۱۳
۲۶/۱۳	۲۹/۰۳	"	"	۱۰۰۰	۳۸	۲۴/۷۸	۲۹/۹۶	"	"	۱۰۰۰	۱۴
۲۴/۶۶	۳۰/۲۹	"	"	۵۰۰۰	۳۹	۲۲/۷۳	۳۳/۰۸	"	"	۵۰۰۰	۱۵
۲۳/۴۳	۲۹/۸۹	"	"	۱۰۰۰۰	۴۰	۲۱/۱۴	۳۳/۱۴	"	"	۱۰۰۰۰	۱۶
۲۷/۵۶	۲۷/۹۶	"	۰/۳	۱۰۰	۴۱	۲۶/۶۵	۲۷/۴۴	"	۰/۳	۱۰۰	۱۷
۲۶/۷۳	۲۸/۳۱	"	"	۱۰۰۰	۴۲	۲۶/۱۱	۲۷/۳۰	"	"	۱۰۰۰	۱۸
۲۶/۴۳	۲۸/۳۴	"	"	۵۰۰۰	۴۳	۲۵/۶۲	۲۸/۸۴	"	"	۵۰۰۰	۱۹
۲۶/۱۷	۲۸/۸۷	"	"	۱۰۰۰۰	۴۴	۲۵/۳۸	۲۸/۹۲	"	"	۱۰۰۰۰	۲۰
۲۷/۹۱	۲۸/۲۴	"	۰/۴	۱۰۰	۴۵	۲۶/۹۴	۲۷/۶۷	"	۰/۴	۱۰۰	۲۱
۲۶/۸۶	۲۸/۱۶	"	"	۱۰۰۰	۴۶	۲۶/۰۸	۲۶/۹۵	۲۰	۰/۴	۱۰۰۰	۲۲
۲۶/۶۴	۲۸/۲۰	"	"	۵۰۰۰	۴۷	۲۵/۸۲	۲۷/۹۹	"	"	۵۰۰۰	۲۳
۲۶/۳۹	۲۸/۳۴	"	"	۱۰۰۰۰	۴۸	۲۵/۷۲	۲۹/۲۰	"	"	۱۰۰۰۰	۲۴

ج) کائولینیت

میانگین دقت (%)		پارامتر			ردیف	میانگین دقت (%)		پارامتر			ردیف
Re-sub	L-O-O	$\sigma$	C	Re-sub		L-O-O	$\sigma$	C			
۲۵/۴۸	۲۵/۸۴	۲۵	۰/۱	۱۰۰	۲۵	۲۳/۷۴	۲۴/۷۵	۱۵	۰/۱	۱۰۰	۱
۲۳/۹۳	۲۵/۵۶	"	"	۱۰۰۰	۲۶	۲۰/۰۲	۲۳/۶۴	"	"	۱۰۰۰	۲
۲۱/۸۱	۲۴/۷۹	"	"	۵۰۰۰	۲۷	۱۸/۴۱	۲۵/۰۲	"	"	۵۰۰۰	۳
۲۱/۱۷	۲۵/۱۰	"	"	۱۰۰۰۰	۲۸	۱۷/۱۶	۲۵/۵۷	"	"	۱۰۰۰۰	۴
۲۵/۹۵	۲۶/۰۵	"	۰/۳	۱۰۰	۲۹	۲۴/۹۱	۲۵/۱۹	"	۰/۳	۱۰۰	۵
۲۵/۴۹	۲۵/۷۹	"	"	۱۰۰۰	۳۰	۲۳/۵۲	۲۴/۵۳	"	"	۱۰۰۰	۶
۲۴/۴۴	۲۵/۱۷	"	"	۵۰۰۰	۳۱	۲۰/۷۶	۲۲/۷۶	"	"	۵۰۰۰	۷
۲۳/۵۹	۲۴/۹۵	"	"	۱۰۰۰۰	۳۲	۱۹/۶۹	۲۲/۵۴	"	"	۱۰۰۰۰	۸
۲۶/۰۰	۲۶/۰۸	"	۰/۵	۱۰۰	۳۳	۲۵/۰۵	۲۵/۲۲	"	۰/۵	۱۰۰	۹
۲۵/۷۳	۲۵/۹۲	"	"	۱۰۰۰	۳۴	۲۴/۵۶	۲۴/۹۱	"	"	۱۰۰۰	۱۰
۲۵/۱۳	۲۵/۵۲	"	"	۵۰۰۰	۳۵	۲۲/۷۲	۲۳/۷۸	"	"	۵۰۰۰	۱۱
۲۴/۵۲	۲۵/۱۲	"	"	۱۰۰۰۰	۳۶	۲۱/۶۴	۲۳/۱۵	"	"	۱۰۰۰۰	۱۲
۲۶/۷۵	۲۶/۹۱	۳۰	۰/۱	۱۰۰	۳۷	۲۴/۱۹	۲۴/۸۷	۲۰	۰/۱	۱۰۰	۱۳
۲۶/۲۱	۲۶/۶۷	"	"	۱۰۰۰	۳۸	۲۲/۳۷	۲۵/۱۵	"	"	۱۰۰۰	۱۴
۲۴/۳۸	۲۵/۵۴	"	"	۵۰۰۰	۳۹	۱۹/۷۶	۲۵/۵۹	"	"	۵۰۰۰	۱۵
۲۴/۲۳	۲۵/۴۱	"	"	۱۰۰۰۰	۴۰	۱۸/۵۳	۲۶/۲۴	"	"	۱۰۰۰۰	۱۶

ادامه جدول (۱-۵)

۲۶/۹۴	۲۶/۹۷	"	۰/۳	۱۰۰	۴۱	۲۵/۱۹	۲۵/۲۹	"	۰/۳	۱۰۰	۱۷
۲۶/۷۳	۲۶/۸۷	"	"	۱۰۰۰	۴۲	۲۴/۲۱	۲۴/۷۵	"	"	۱۰۰۰	۱۸
۲۶/۴۹	۲۶/۸۰	"	"	۵۰۰۰	۴۳	۲۲/۵۷	۲۳/۹۷	"	"	۵۰۰۰	۱۹
۲۶/۴۰	۲۶/۸۱	"	"	۱۰۰۰۰	۴۴	۲۲/۰۸	۲۴/۱۷	"	"	۱۰۰۰۰	۲۰
۲۶/۹۷	۲۷/۰۲	"	۰/۵	۱۰۰	۴۵	۲۵/۲۹	۲۵/۳۵	"	۰/۵	۱۰۰	۲۱
۲۶/۹۱	۲۶/۹۴	"	"	۱۰۰۰	۴۶	۲۴/۷۹	۲۵/۰۲	"	"	۱۰۰۰	۲۲
۲۶/۶۱	۲۶/۷۸	"	"	۵۰۰۰	۴۷	۲۳/۷۹	۲۴/۵۱	"	"	۵۰۰۰	۲۳
۲۶/۵۲	۲۶/۷۴	"	"	۱۰۰۰۰	۴۸	۲۳/۱۲	۲۴/۲۲	"	"	۱۰۰۰۰	۲۴

جدول (۲-۵) - مقادیر بهینه پارامترهای SVR بدست آمده از جدول (۱-۵)

خطای تخمین RMSE (%)		متغیرهای SVR			طبقه	
<i>L-O-O</i>	<i>Re-substitution</i>	$\epsilon$	$C$	$\sigma$	کانی شاخص	دگرسانی
۱۷/۹۸	۱۵/۷۷	۲۰	۵۰۰۰	۰/۱	کلریت	پروپیلنیک
۲۶/۹۵	۲۶/۰۸	۲۰	۱۰۰۰	۰/۴	موسکویت	فیلیک
۲۲/۵۴	۱۹/۶۹	۱۵	۱۰۰۰۰	۰/۳	کائولینیت	آرژلیک

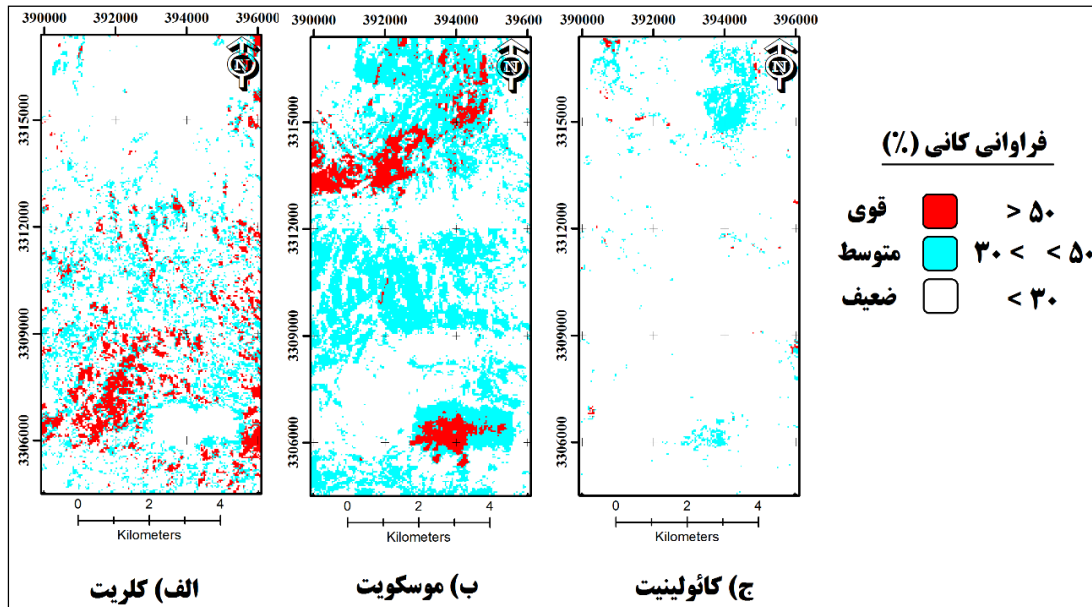
گام دوم و سوم: با آموزش SVR توسط مقادیر بهینه جدول (۲-۵)، نقشه پراکندگی مناطق دگرسانی برای کل منطقه بدست آمد که در حقیقت تخمینی از کانی‌های شاخص دگرسانی‌های فیلیک، آرژلیک و پروپیلنیک می‌باشد. در این نقشه که در شکل (۵-۵) قابل مشاهده است، محدوده مطالعاتی به سه طبقه شدید، متوسط و ضعیف بر اساس شدت دگرسانی تقسیم شده است.

## ۵-۴- اعتبارسنجی نتایج

### ۵-۴-۱- اعتبارسنجی با استفاده از نمونه‌های برداشت شده از منطقه

مقادیر تخمین زده شده فراوانی کانی‌های شاخص دگرسانی برای ۳۳ و ۱۳ نمونه برداشت شده از منطقه مطالعاتی به ترتیب در جداول (۳-۵) و (۴-۵) آورده شده است. همانطور که قبلاً نیز اشاره گردید مجموعه داده اول، در فرآیند آموزش SVR شرکت داده شده‌اند ولی مجموعه دوم هیچ مشارکتی در آموزش

نداشته‌اند. همچنین در این جداول فراوانی نیمه‌کمی محاسبه شده توسط نرم‌افزار PIMA View نیز جهت مقایسه قابل مشاهده است. خطای RMS تخمین نیز بر اساس این نتایج محاسبه و در جداول نشان داده شده است.



شکل (۵-۵) - نقشه زیرپیکسلی کانی‌های شاخص مناطق دگرسانی: (الف) کلریت کانی شاخص دگرسانی پروپیلیتیک (ب) موسکویت کانی شاخص دگرسانی فیلیک (ج) کائولینیت کانی شاخص دگرسانی آرژیلیک

جدول (۵-۳) - مقادیر فراوانی کانی‌های شاخص دگرسانی برای ۳۳ نمونه برداشت شده از منطقه تخمین زده شده توسط نرم‌افزار PIMA View و روش SVR

فراوانی تخمین زده شده (%)						نمونه
SVR			PIMA View			
کلریت	کائولینیت	موسکویت	کلریت	کائولینیت	موسکویت	
-۰/۵	۳۸/۳	۵۴/۴	< ۵	۴۰/۰	۵۵	۱
۱/۵	۳/۶	۵۷/۵	< ۵	< ۵	۷۰	۲
۶/۷	۱۵/۸	۴۹/۸	۱۰	< ۵	۵۵	۳
۱۸/۳	۲۵/۰	۳۵/۳	< ۵	< ۵	۷۰	۴
۲۴/۴	۱۵/۶	۳۳/۸	< ۵	< ۵	۶۰	۵
۲۳	۱۶/۹	۴۴/۴	< ۵	< ۵	۸۵	۶
-۲/۹	۲۶/۵	۴۷/۵	< ۵	< ۵	۸۰	۷
۶/۰	۱۸/۱	۵۳/۷	< ۵	< ۵	۳۵	۸
۰/۰	۳۱/۲	۵۵/۹	< ۵	< ۵	۵۰	۹
۱۳/۷	۲۹/۷	۳۳/۷	< ۵	< ۵	۲۵	۱۰

ادامه جدول (۵-۳)

۱/۳	۲۸/۹	۳۹/۹	< ۵	< ۵	۸۰	۱۱
۲۴/۱	۱۷/۱	۳۰/۴	< ۵	< ۵	۷۰	۱۲
۱۴/۱	۳۱/۵	۳۴/۶	< ۵	۶۵	۴۵	۱۳
۴/۷	۲۷/۴	۴۵/۶	< ۵	۵۵	۵۰	۱۴
۰/۰	۲۷/۶	۵۷/۵	< ۵	۶۵	۳۰	۱۵
-۰/۱	۳۲/۱	۵۳/۶	< ۵	۴۵	۳۰	۱۶
۲۴/۳	۱۴/۳	۳۲/۵	< ۵	۴۵	< ۵	۱۷
۲۳	۳۶/۹	۲۴/۵	< ۵	۵۵	< ۵	۱۸
۱۷/۱	۳۷/۱	۳۰/۱	< ۵	۵۰	< ۵	۱۹
۲۳/۰	۳۶/۰	۳۱/۶	< ۵	۴۵	۳۵	۲۰
۲۱/۷	۳۸/۶	۳۱/۳	< ۵	۴۵	< ۵	۲۱
۱۰/۷	۳۷/۳	۳۳/۶	< ۵	۵۵	< ۵	۲۲
۴/۹	۳۷/۴	۳۷/۳	< ۵	۶۰	< ۵	۲۳
۲۲/۰	۱۸/۱	۳۶/۷	۴۰	< ۵	۲۰	۲۴
۴۶/۶	۱۹/۷	۲۳/۰	۳۵	< ۵	۷۰	۲۵
۳۰/۴	۲۱/۰	۲۹/۹	۵۰	< ۵	< ۵	۲۶
۲۷/۰	۱۴/۹	۳۳/۵	۴۵	< ۵	۳۵	۲۷
۳۸/۲	۱۵/۲	۲۷/۳	۳۰	< ۵	۴۰	۲۸
۴۴/۰	۱۳/۴	۲۶/۷	۵۵	< ۵	۲۰	۲۹
۳۴/۶	۱۲/۱	۳۰/۲	۷۵	< ۵	< ۵	۳۰
۱۷/۳	۲۹/۴	۳۴/۱	۳۰	۳۰	< ۵	۳۱
۴۱/۲	۰/۰	۲۸/۵	۵۵	< ۵	< ۵	۳۲
۳۶/۸	۱۷/۱	۲۶/۵	۲۰	۳۰	< ۵	۳۳
۱۵/۷	۱۹/۷	۲۶/۰	خطای RMS			

## ۵-۴-۲- مقایسه با مطالعات قبلی

برای اعتبارسنجی نتایج روش SVR، از نتایج مطالعات (Shahriari et al. (2013, 2015) استفاده شد که از روش‌های فرکتال و SAM<sup>۱</sup> برای شناسایی مناطق آلتراسیونی محدوده مطالعاتی استفاده کرده‌اند. در اشکال (۵-۶) و (۵-۷) نقشه دگرسانی بدست آمده از هر سه روش برای مقایسه نشان داده شده است.

1- Spectral Angle Mapper



جدول (۴-۵) - مقادیر فراوانی کانی‌های شاخص دگرسانی برای ۱۳ نمونه برداشت شده از منطقه تخمین زده شده توسط نرم‌افزار PIMA View و روش SVR


فراوانی تخمین زده شده (%)						
SVR			PIMA View			نمونه
کلریت	کائولینیت	موسکویت	کلریت	کائولینیت	موسکویت	
۳۶/۶	۸/۵	۳۶/۵	< ۵	< ۵	۶۰	۱
۳۳/۹	-۶/۷	۴۴/۴	< ۵	< ۵	۷۵	۲
۲۴/۴	۰/۳	۴۲/۴	< ۵	< ۵	۷۵	۳
۲۴/۳	۱۴/۳	۳۲/۵	< ۵	< ۵	۶۰	۴
۲۶/۹	۳۲/۰	۳۳/۰	< ۵	< ۵	۵۵	۵
۱۸/۵	۳۶/۸	۳۳/۹	< ۵	۳۰	۵۰	۶
۲۴/۱	۱۷/۱	۳۰/۴	۳۰	< ۵	۷۵	۷
۳۳	۱۷/۸	۲۹/۹	< ۵	۵۰	۵۰	۸
۳۱/۵	۵/۳	۴۲/۳	< ۵	۴۵	۳۰	۹
۱۳/۶	۳۳/۷	۳۹/۴	< ۵	۵۰	۵۵	۱۰
۳۲/۴	۲۴/۲	۲۵/۳	۴۰	< ۵	< ۵	۱۱
۴۴/۹	۲۱/۰	۲۰/۶	۵۰	< ۵	< ۵	۱۲
۲۷/۶	۲۲/۹	۲۶/۹	۴۵	< ۵	< ۵	۱۳
۱۴/۵	۱۳/۳	۱۶/۰	خطای RMS			

مقایسه نقشه‌های بدست آمده حاکی از انطباق بالای نتایج می‌باشد که در شکل (۴-۵) سعی گردیده است این موضوع با رسم بیضی‌گون‌هایی در اطراف مناطقی که دارای بیشترین انطباق هستند، نشان داده شود. برای مثال نقشه‌های بدست آمده برای دگرسانی پروپیلیتیک با استفاده از روش‌های SAM فرکتال پایه<sup>۱</sup> و SVR، به ترتیب در شکل (۴-۵ الف-۱) و (۴-۵ الف-۲) نشان داده شده‌اند. در این اشکال در ۴ منطقه مشخص شده، همبستگی و شباهت بالایی بین دگرسانی پروپیلیتیک بارزسازی شده توسط روش SAM و فراوانی کانی کلریت (به عنوان کانی شاخص دگرسانی پروپیلیتیک) بدست آمده توسط SVR وجود دارد. انطباق بین نتایج دو روش در بارزسازی دگرسانی فیلیک مشهودتر است. همانطور که در شکل (۴-۵ ب-۱) دیده می‌شود دگرسانی فیلیک به دو قسمت فیلیک قوی (مناطق

1- Fractal-aided SAM method

به رنگ قرمز) و فیلیک ضعیف (مناطق به رنگ نارنجی) تقسیم شده است. این مناطق انطباق و همبستگی بسیار زیادی به ترتیب با مناطق طبقه‌بندی شده تحت عنوان قوی (مناطق به رنگ قرمز) و متوسط (مناطق به رنگ آبی) روش SVR دارند (شکل ۵-۶-ب - B-2). همین رویه در اشکال (۵-۶-ج - C-1) و (۵-۶-ج - C-2) نیز دیده می‌شود، بطوریکه پراکندگی دگرسانی آرژیلیک بر اساس نتایج روش SAM و فراوانی کانی آرژیلیک تخمین زده شده توسط SVR بسیار شبیه به یکدیگر بوده و منحصر به مناطق مجاور با پیت‌های در حال استخراج معادن سرچشمه و دره زار و همچنین بخش بزرگی از منطقه سریدون می‌باشد.

نتایج مطالعات شهریاری و همکاران (۲۰۱۳) برای بارزسازی دگرسانی‌های منطقه دره زار با استفاده از روش فرکتال نیز با توجه به طبقه‌بندی دگرسانی‌ها به انواع قوی و ضعیف، امکان اعتبارسنجی نتایج زیرپیکسلی روش SVR را به نحو مناسبی فراهم می‌کند. بر اساس نتایج ایشان، دگرسانی‌های فیلیک در منطقه دره زار در ۴ زیرگروه فیلیک (محدود به پیت معدن دره زار به رنگ زرد)، فیلیک قوی (به رنگ قرمز)، فیلیک ضعیف (به رنگ نارنجی) و منطقه گذار از فیلیک به پروپیلیتیک (به رنگ صورتی) طبقه‌بندی شده‌اند (شکل ۵-۷-ب - B-1). اگر دو زیرگروه اول به عنوان دگرسانی فیلیک قوی و دو زیرگروه بعدی تحت عنوان دگرسانی ضعیف طبقه‌بندی گردند، در این صورت باز هم انطباق بالایی با مناطق قوی (به رنگ قرمز) و متوسط (به رنگ آبی) SVR وجود خواهد داشت (شکل ۵-۷-ب - B-2). مشابه با دگرسانی فیلیک، انطباق بالایی نیز در مناطق شناسایی شده با عنوان دگرسانی پروپیلیتیک توسط روش فرکتال (شکل ۵-۷-الف - A-1) و فراوانی تخمین زده شده توسط SVR برای کانی کلریت (شکل ۵-۷-الف - A-2) قابل مشاهده است که همگی حاکی از توانایی و عملکرد مطلوب SVR در طبقه‌بندی زیرپیکسلی مناطق دگرسانی و اعتبار بالای نتایج بدست آمده است.

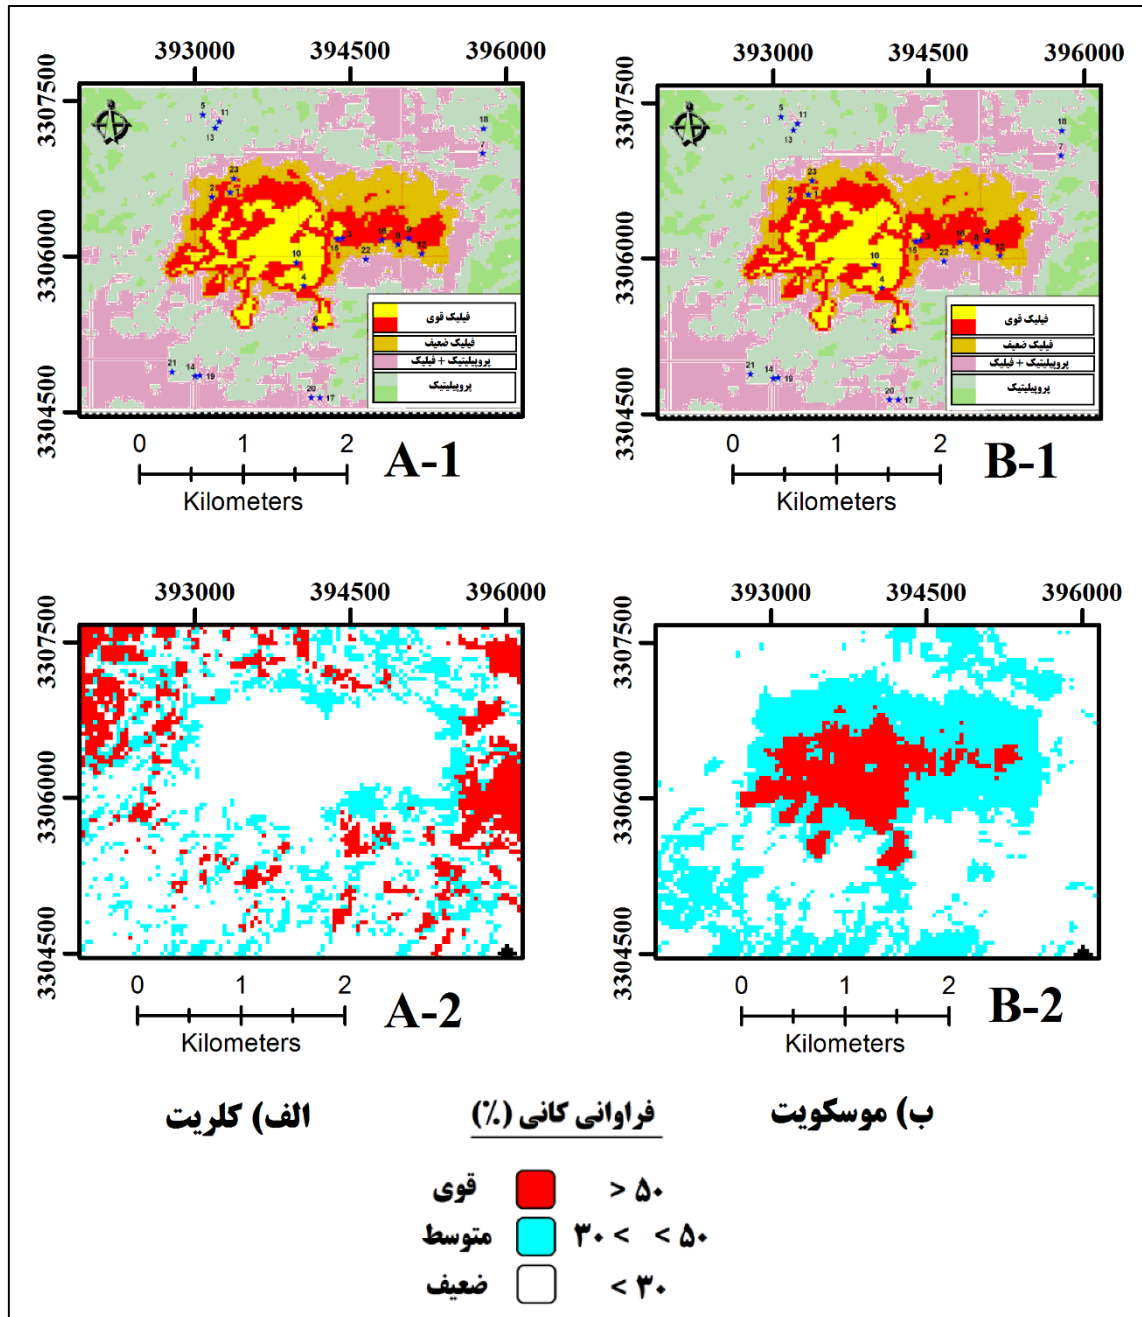


شکل (۵-۶) - مقایسه نتایج طبقه‌بندی دگرسانی الف - پروپیلیتیک (کلریت)، ب - فیلیک (موسکویت) و ج - آرژیلیک (کانولینیت) توسط روش (بالا) SAM (Shahriari et al., 2015) (پایین) SVR

## ۵-۵ - نتیجه‌گیری

جهت انجام طبقه‌بندی نرم یا زیرپیکسلی، از نسخه رگرسیونی SVM یعنی SVR استفاده شد. با توجه به اینکه اختصاص مقادیر مناسب به متغیرهای SVR نقش مهمی در دقت نتایج آن دارد، روش اعتبارسنجی متقابل L-O-O برای بدست آوردن مقادیر بهینه  $C$ ،  $\sigma$  و  $\epsilon$  مورد استفاده قرار گرفت. با آموزش SVR توسط مقادیر بدست آمده و ۳۳ نمونه برداشت شده از منطقه، نقشه زیرپیکسلی دگرسانی‌های منطقه تهیه شد. اعتبارسنجی نتایج بدست آمده توسط نمونه‌های برداشت شده از منطقه

و مطالعات قبلی انجام شده در منطقه نشان داد که SVR به عنوان یک روش مناسب، می‌تواند برای طبقه‌بندی نرم داده‌های ابرطیفی استفاده شود.



شکل (۷-۵) - مقایسه نتایج طبقه‌بندی دگرسانی الف - پروپیلیتیک (کلریت)، ب - فیلیک (موسکویت) توسط روش SVR (بالا) فرکتال (Shahriari et al., 2013) (پایین) SVR

## فصل ششم: طبقه‌بندی سخت مناطق دگرسانی

## ۶-۱- مقدمه

این فصل به طبقه‌بندی سخت مناطق دگرسانی توسط روش مبتنی بر کرنل SVM اختصاص دارد. روش‌های مبتنی بر کرنل با دارا بودن ویژگی‌هایی خاص از قابلیت بالایی برای تحلیل تصاویر سنجش از دور برخوردار هستند. این روش‌ها بویژه برای طبقه‌بندی مسائلی مناسب می‌باشند که دارای مجموعه داده آموزشی محدود (غالباً در مسائل بیش‌ابعاد) و نویزی هستند. در حقیقت آنها می‌توانند دقت نتایج روش‌های پارامتری خطی و شبکه‌های عصبی مصنوعی را بهبود بخشند (Chang, 2007; Mountrakis et al., 2011; Gómez-Chova et al., 2011; Camps-Vallas et al., 2014). از بین روش‌های پرکاربرد مبتنی بر کرنل، SVM در مقایسه با دیگر روش‌ها نتایج مطلوب‌تری ارائه می‌کند. این روش بطور گسترده‌ای برای طبقه‌بندی داده‌های سنجش از دور ابرطیفی در شاخه‌های مختلف استفاده شده است. ویژگی‌های ذاتی SVM باعث می‌شود که قدرت تعمیم و دقت بالایی در طبقه‌بندی مسائل بیش‌ابعاد داشته باشد (Pal and Mather, 2005; Chang, 2007; Camps-Vallas et al., 2014). برخلاف روش‌های پارامتری قدیمی، SVM بدون نیاز به اطلاعات اولیه در مورد توزیع احتمال داده‌ها و تنها با استفاده از نظریه کمینه کردن ریسک ساختاری، خطای طبقه‌بندی را کمینه می‌کند (Gómez-Chova et al., 2011).

در این فصل طبقه‌بندی سخت مناطق دگرسانی توسط روش‌های SVM و Robust-SVM انجام شده و دقت نتایج بدست آمده مقایسه خواهد شد. با توجه به وجود عدم قطعیت در داده‌های نویزی هایپریون، روش Robust-SVM می‌تواند برای افزایش دقت طبقه‌بندی استفاده شود. همچنین به منظور ارزیابی عملکرد روش انتخاب ویژگی در شناسایی باندهای طیفی مناسب برای تفکیک مناطق دگرسانی، طبقه‌بندی یکبار توسط کل باندهای قابل استفاده تصویر هایپریون انجام می‌شود و مجدداً توسط باندهای منتخب معرفی شده بوسیله روش انتخاب ویژگی (فصل سوم) تکرار می‌گردد. در نهایت نتایج حاصله از دو روش با یکدیگر مقایسه می‌شوند. البته بایستی خاطر نشان ساخت که علی‌رغم انتخاب ۱۸ باند طیفی

توسط روش انتخاب ویژگی، در این فصل تنها از ۹ بانندی برای طبقه‌بندی استفاده می‌شود که مناسب برای شناسایی کانی‌های رسی دگرسان شده هستند. در حقیقت، بدلیل آنکه اهداف طبقه‌بندی در این فصل تنها کانی‌های رسی هستند، بنابراین از باندهایی که مناسب برای شناسایی کانی‌های اکسیدی آهن می‌باشند، صرف نظر شده است.


## ۲-۶- طبقه‌بندی سخت مناطق دگرسانی

برای طبقه‌بندی سخت مناطق دگرسانی از مجموعه داده ۱ معرفی شده در جداول (۳-۳) و (۴-۳) و شکل (۳-۹) استفاده شد. ۳۳ نمونه سنگی برداشت شده از منطقه متعلق به ۳ طبقه دگرسانی فیلیک، آرژیلیک و پروپیلیتیک برای آموزش و تخمین پارامترهای روش SVM استفاده می‌شوند. همچنین برای اعتبارسنجی نتایج علاوه بر استفاده از ۳۳ نمونه مذکور (به روش LOO)، از ۱۳ نمونه دیگر که در فرآیند آموزش روش طبقه‌بندی کننده بکار گرفته نشده‌اند، استفاده می‌شود. بدلیل کم بودن تعداد نمونه‌های اعتبارسنجی، مقایسه نتایج بدست آمده با نتایج مطالعات مشابه قبلی انجام شده در منطقه یکی دیگر از روش‌های اعتبارسنجی نتایج است. در شکل (۶-۱) چهار گام اصلی انجام طبقه‌بندی نشان داده شده است.

### ۲-۶-۱- طبقه‌بندی توسط SVM

در گام اول و برای تنظیم پارامترهای SVM (C) و تابع کرنل RBF ( $\sigma$ ) از ۳۳ نمونه آموزشی و روش‌های تخمین خطای اعتبارسنجی متقابل L-O-O و جایگزینی دوباره استفاده شد که نتایج بدست آمده در جدول (۶-۱) گردآوری شده است. در این جدول دقت طبقه‌بندی به ازای مقادیر مختلفی از C (از ۱۰۰ تا ۱۰۰۰۰) و  $\sigma$  (از ۰/۰۱ تا ۱) محاسبه شده است. بدلیل آنکه مقادیر خارج از این بازه‌ها تأثیر محسوسی در نتایج ایجاد نمی‌کنند در جدول وارد نگردیده‌اند. برای انتخاب پارامترهای بهینه بطوریکه از خطای

بیش برآزش<sup>۱</sup> تا حد امکان جلوگیری به عمل آید، دو شرط زیر اعمال گردید:



شکل (۶-۱) - مراحل انجام طبقه‌بندی توسط SVM و Robust-SVM

۱- از آنجایی که روش تخمین خطای جایگزینی دوباره یک روش خوش‌بینانه<sup>۲</sup> است (Heikkila, 1992) لذا بیشترین دقت بدست آمده توسط روش L-O-O ملاک انتخاب پارامترهای بهینه خواهد بود. همچنین با این منطق که دقت بدست آمده از روش جایگزینی دوباره بایستی از روش L-O-O بیشتر باشد، از مواردی که عکس این حالت اتفاق بیفتد صرف نظر خواهد شد.

1- Over fitting

2- Optimistically method



۲- برای جلوگیری از بروز خطای بیش برآزش در فرآیند طبقه‌بندی، از مواردی که اختلاف زیادی

بین دقت روش‌های L-O-O و جایگزینی دوباره وجود دارد، صرف نظر می‌شود.

با رعایت دو شرط فوق، مقادیر  $C=500$  و  $\sigma=0.4$  در جدول (۶-۱-الف) به عنوان بهترین مقادیر

انتخاب می‌شوند. دقت طبقه‌بندی و ماتریس خطای آن نیز به ترتیب در جداول (۶-۲-الف) و

(۶-۳-الف) نشان داده شده است.

در گام دوم و پس از تعیین مقادیر بهینه پارامترهای  $C$  و  $\sigma$ ، این مقادیر برای آموزش SVM استفاده

شدند. در مرحله بعد SVM آموزش دیده برای طبقه‌بندی مناطق دگرسانی محدوده مطالعاتی مورد

استفاده قرار گرفت که نقشه دگرسانی بدست آمده در شکل (۶-۲) نشان داده شده است. در نهایت در

گام آخر اعتبارسنجی نتایج انجام گرفت که نتایج حاصله در بخش (۶-۲-۳) قابل مشاهده است.

همانطور که قبلاً نیز اشاره گردید به منظور انجام مقایسه، کلیه مراحل چهارگانه فوق، مجدداً با

استفاده از ۹ باند طیفی بدست آمده توسط روش انتخاب ویژگی تکرار گردید. با توجه به تغییر فضای

ویژگی از ۱۶۵ باند به ۹ باند طیفی، ضروری است که مجدداً مقادیر بهینه متغیرهای  $C$  و  $\sigma$  بدست آید.

مقادیر بهینه در این حالت و بر اساس جدول (۶-۱-ب) برابر با  $C=5000$  و  $\sigma=0.1$  بدست آمد که

جزئیات دقت بدست آمده و ماتریس خطای مربوطه نیز در جداول (۶-۲-ب) و (۶-۳-ب) گردآوری

شده است. طبقه‌بندی مناطق دگرسانی با استفاده از ۹ باند مذکور انجام شد که نقشه حاصله در شکل

(۶-۳) قابل مشاهده است. اعتبارسنجی نتایج نیز مشابه با حالت قبل انجام شد که نتایج آن در بخش

(۶-۲-۳) ارائه شده است.

جدول (۶-۱) - تعیین مقادیر بهینه پارامترهای SVM با استفاده از روش تخمین خطای اعتبارسنجی متقابل L-O-O (الف) ۱۶۵ باند طیفی هایپرین (ب) ۹ باند طیفی بدست آمده توسط روش انتخاب ویژگی

الف) با استفاده از کلیه ۱۶۵ باند طیفی قابل استفاده تصویر هایپرین											
Re-sub		L-O-O		پارامتر		Re-sub		L-O-O		پارامتر	
ضریب کاپا	میانگین دقت (%)	ضریب کاپا	میانگین دقت (%)	$\sigma$	C	ضریب کاپا	میانگین دقت (%)	ضریب کاپا	میانگین دقت (%)	$\sigma$	C
۱	۱۰۰	۰/۱۴	۴۳/۴۸	۰/۰۱	۱۰۰۰	۱	۱۰۰	۰/۳۲	۵۵/۴۰	۰/۰۱	۱۰
۰/۹۱	۹۴/۱۹	۰/۳۶	۵۸/۴۳	۰/۱	"	۰/۵۰	۶۷/۰۷	۰/۴۶	۶۴/۰۴	۰/۱	"
۰/۵۴	۷۰/۱۰	۰/۴۱	۶۱/۵۲	۰/۴	"	۰/۴۱	۶۱/۲۶	۰/۳۲	۵۵/۲۰	۰/۴	"
۰/۵۰	۶۷/۰۷	۰/۴۶	۶۴/۲۹	۰/۷	"	۰/۳۲	۵۵/۲۰	۰/۳۲	۵۵/۲۰	۰/۷	"
۰/۵۰	۶۷/۰۷	۰/۴۱	۶۱/۲۶	۱	"	۰/۳۲	۵۵/۲۰	۰/۳۲	۵۵/۲۰	۱	"
۱	۱۰۰	۰/۱۴	۴۳/۴۸	۰/۰۱	۵۰۰۰	۱	۱۰۰	۰/۱۸	۴۶/۸۲	۰/۰۱	۱۰۰
۱	۱۰۰	۰/۴۱	۶۱/۴۶	۰/۱	"	۰/۶۴	۷۵/۹۱	۰/۴۱	۶۱/۵۲	۰/۱	"
۰/۶۸	۷۸/۶۹	۰/۳۲	۵۵/۶۶	۰/۴	"	۰/۵۰	۶۷/۰۷	۰/۳۷	۵۸/۲۳	۰/۴	"
۰/۶۴	۷۵/۹۱	۰/۴۱	۶۱/۵۲	۰/۷	"	۰/۴۱	۶۱/۲۶	۰/۳۲	۵۵/۲۰	۰/۷	"
۰/۵۴	۷۰/۱۰	۰/۴۱	۶۱/۵۲	۱	"	۰/۴۱	۶۱/۲۶	۰/۳۲	۵۵/۲۰	۱	"
۱	۱۰۰	۰/۱۴	۴۳/۴۸	۰/۰۱	۱۰۰۰۰	۱	۱۰۰	۰/۱۸	۴۶/۸۲	۰/۰۱	۵۰۰
۱	۱۰۰	۰/۴۱	۶۱/۴۶	۰/۱	"	۰/۸۲	۸۸/۰۸	۰/۳۶	۵۸/۴۳	۰/۱	"
۰/۷۳	۸۱/۷۲	۰/۳۲	۵۵/۶۶	۰/۴	"	۰/۵۴	۷۰/۱۰	۰/۴۶	۶۴/۲۹	۰/۴	"
۰/۶۴	۷۵/۹۱	۰/۳۲	۵۵/۴۰	۰/۷	"	۰/۵۰	۶۷/۰۷	۰/۴۱	۶۱/۲۶	۰/۷	"
۰/۶۴	۷۵/۹۱	۰/۴۱	۶۱/۵۲	۱	"	۰/۴۶	۶۴/۲۹	۰/۳۲	۵۵/۲۰	۱	"
ب) با استفاده از ۹ باند طیفی انتخابی توسط روش انتخاب ویژگی											
Re-sub		L-O-O		پارامتر		Re-sub		L-O-O		پارامتر	
ضریب کاپا	میانگین دقت (%)	ضریب کاپا	میانگین دقت (%)	$\sigma$	C	ضریب کاپا	میانگین دقت (%)	ضریب کاپا	میانگین دقت (%)	$\sigma$	C
۰/۹۱	۹۴/۱۹	۰/۱۴	۴۳/۴۸	۰/۰۱	۱۰۰۰	۰/۵۹	۷۲/۶۳	۰/۳۲	۵۵/۴۰	۰/۰۱	۱۰
۰/۵۰	۶۶/۵۷	۰/۳۶	۵۸/۴۳	۰/۱	"	۰/۳۲	۵۴/۶۵	۰/۴۶	۶۴/۰۴	۰/۱	"
۰/۳۷	۵۷/۹۸	۰/۴۱	۶۱/۵۲	۰/۴	"	۰/۳۲	۵۴/۶۵	۰/۳۲	۵۵/۲۰	۰/۴	"
۰/۳۲	۵۴/۶۵	۰/۴۶	۶۴/۲۹	۰/۷	"	۰/۳۲	۵۴/۶۵	۰/۳۲	۵۵/۲۰	۰/۷	"
۰/۳۲	۵۴/۶۵	۰/۴۱	۶۱/۲۶	۱	"	۰/۳۲	۵۴/۶۵	۰/۳۲	۵۵/۲۰	۱	"
۰/۹۵	۹۶/۹۷	۰/۱۴	۴۳/۴۸	۰/۰۱	۵۰۰۰	۰/۷۷	۸۵/۳۵	۰/۱۸	۴۶/۸۲	۰/۰۱	۱۰۰
۰/۵۴	۷۰/۴۰	۰/۴۱	۶۱/۴۶	۰/۱	"	۰/۴۱	۶۱/۰۱	۰/۴۱	۶۱/۵۲	۰/۱	"
۰/۳۷	۵۷/۹۸	۰/۳۲	۵۵/۶۶	۰/۴	"	۰/۳۲	۵۴/۶۵	۰/۳۷	۵۸/۲۳	۰/۴	"
۰/۴۱	۶۱/۰۱	۰/۴۱	۶۱/۵۲	۰/۷	"	۰/۳۲	۵۴/۶۵	۰/۳۲	۵۵/۲۰	۰/۷	"
۰/۳۲	۵۴/۶۵	۰/۴۱	۶۱/۵۲	۱	"	۰/۳۲	۵۴/۶۵	۰/۳۲	۵۵/۲۰	۱	"
۱	۱۰۰	۰/۱۴	۴۳/۴۸	۰/۰۱	۱۰۰۰۰	۰/۸۶	۹۱/۱۶	۰/۱۸	۴۶/۸۲	۰/۰۱	۵۰۰
۰/۵۴	۷۰/۴۰	۰/۴۱	۶۱/۴۶	۰/۱	"	۰/۴۵	۶۳/۵۴	۰/۳۶	۵۸/۴۳	۰/۱	"

ادامه جدول (۱-۶)

۰/۴۱	۶۰/۷۶	۰/۳۲	۵۵/۶۶	۰/۴	"	۰/۳۲	۵۴/۶۵	۰/۴۶	۶۴/۲۹	۰/۴	"
۰/۴۱	۶۱/۰۱	۰/۳۲	۵۵/۴۰	۰/۷	"	۰/۳۲	۵۴/۶۵	۰/۴۱	۶۱/۲۶	۰/۷	"
۰/۴۱	۶۱/۰۱	۰/۴۱	۶۱/۵۲	۱	"	۰/۳۲	۵۴/۶۵	۰/۳۲	۵۵/۲۰	۱	"

جدول (۲-۶) - طبقه‌بندی توسط SVM با مقادیر بهینه C و ε به روش L-O-O

الف) طبقه‌بندی با استفاده از کل ۱۶۵ باند طیفی

دقت طبقه (%)			ضریب کاپا	دقت میانگین (%)	دقت کل (%)
پروپیلتیک	آرژلیک	فیلیک			
۸۰/۰۰	۵۴/۵۵	۵۸/۳۳	۴۶/۰۰	۶۴/۲۹	۶۳/۶۴

ب) طبقه‌بندی با استفاده از ۹ باند طیفی منتخب

دقت طبقه (%)			ضریب کاپا	دقت میانگین (%)	دقت کل (%)
پروپیلتیک	آرژلیک	فیلیک			
۷۰/۰۰	۷۲/۷۳	۴۱/۶۷	۰/۴۱	۶۱/۴۶	۶۰/۶۱


جدول (۳-۶) - ماتریس خطای مربوط به طبقه‌بندی توسط SVM با مقادیر بهینه C و ε به روش L-O-O

الف) طبقه‌بندی با استفاده از کل ۱۶۵ باند طیفی


مجموع	پروپیلتیک	آرژلیک	فیلیک	طبقه
۱۰	۰	۳	۷	فیلیک
۱۱	۲	۶	۳	آرژلیک
۱۲	۸	۲	۲	پروپیلتیک
۳۳	۱۰	۱۱	۱۲	مجموع

ب) طبقه‌بندی با استفاده از ۹ باند طیفی منتخب

مجموع	پروپیلتیک	آرژلیک	فیلیک	طبقه
۹	۲	۲	۵	فیلیک
۱۲	۱	۸	۳	آرژلیک
۱۲	۷	۱	۴	پروپیلتیک
۳۳	۱۰	۱۱	۱۲	مجموع



شکل (۲-۶) - نقشه دگرسانی طبقه‌بندی شده توسط SVM و کل ۱۶۵ باند طیفی قابل استفاده هایپریون



شکل (۳-۶) - نقشه دگرسانی طبقه‌بندی شده توسط SVM و ۹ باند طیفی منتخب

## ۶-۲-۲- طبقه‌بندی توسط Robust-SVM


در بخش (۳-۲-۱-۳) اشاره گردید که به دلیل ماهیت نویزی داده‌های سنجنده هایپریون، این داده‌ها از وجود نوعی عدم قطعیت رنج برده و در مقایسه با داده‌های سنجنده‌های ابرطیفی دیگر، از نسبت سیگنال به نویز پایین‌تری برخوردار می‌باشند. در جهان واقعی وجود عدم قطعیت در داده‌ها امری شایع است که می‌تواند منجر به وقوع خطاهای بزرگی در نتایج طبقه‌بندی گردد. بدلیل آنکه در اکثر روش‌های داده‌کاوی موضوع عدم قطعیت بطور مستقیم مورد توجه قرار نمی‌گیرد، لذا نسخه‌های مقاوم این روش‌ها برای پوشش این مشکل ارائه می‌شوند. اگرچه روش SVM با حاشیه نرم و با استفاده از توابع کرنل توانایی طبقه‌بندی داده‌های جداناپذیر و غیرخطی را دارد اما در مواجهه با مشکل عدم قطعیت در داده‌ها نمی‌تواند طبقه‌بندی بهینه‌ای انجام دهد (Pant et al., 2011). در این بخش از نسخه مقاوم SVM برای طبقه‌بندی مناطق دگرسانی شده و نتایج بدست آمده با نتایج SVM استاندارد مقایسه می‌شوند.

مشابه با طبقه‌بندی توسط SVM استاندارد، ۴ مرحله اشاره شده در شکل (۶-۱) در این بخش نیز مجدداً با ۱۶۵ و ۹ باند طیفی انجام شد. به منظور انجام مقایسه، دقیقاً مقادیر اختصاص یافته به پارامترهای SVM استاندارد و تابع کرنل یعنی  $C=500$  و  $\sigma=0/4$  در حالت ۱۶۵ باندی و  $C=5000$  و  $\sigma=0/1$  در حالت ۹ باندی، برای آموزش Robust-SVM نیز استفاده شدند. بر اساس قضیه (۳-۲)، با حل مسأله بهینه‌سازی روابط (۳-۳۹~۳-۴۵) مقادیر بهینه متغیر  $\alpha$  بدست می‌آید. بدلیل آنکه طبقه‌بندی مناطق دگرسانی، یک مسأله سه کلاسه است بنابراین سه طبقه‌بندی دو کلاسه نیز بایستی انجام شود. در نهایت نیز برای هر طبقه‌بندی یک بردار از مقادیر  $\alpha$  بدست می‌آید که در جدول (۶-۴) قابل مشاهده است. بر اساس الگوریتم ارائه شده در بخش (۳-۱-۱-۴-ب)، در نتیجه حل مسئله بهینه‌سازی توسط نرم‌افزار بهینه‌سازی SeDuMi، بخش اعظم بردار  $\alpha$  شامل مقادیر صفر و  $C$  بوده و تنها مقادیری از  $\alpha$  که  $\alpha_j \in (0, C)$  باشد برای بدست آوردن پارامترهای ابرصفحه تفکیک‌کننده استفاده می‌شوند. با انتخاب مقادیری از بردار  $\alpha$  از جدول (۶-۴) که در بازه  $(0, C)$  هستند یعنی

۱۶۹/۸۴ (برای تفکیک دگرسانی‌های فیلک و آرژیلیک)، ۱۸۲/۲۴، ۱۳۷/۶۰ و ۳۱۹/۰۲ (برای تفکیک دگرسانی‌های فیلک و پروپیلیتیک) و ۱۹۵/۴۹، ۲۰۹/۷۱ و ۴۸۵/۷۷ (برای تفکیک دگرسانی‌های آرژیلیک و پروپیلیتیک)، طبقه‌بندی با استفاده از Robust-SVM و ۱۶۵ باند طیفی انجام شد که نقشه دگرسانی حاصله در شکل (۴-۶) قابل مشاهده است. بطورمشابه با استفاده از نتایج جدول (۵-۶)، طبقه‌بندی با استفاده از ۹ باند طیفی نیز انجام شد که نقشه دگرسانی بدست آمده در شکل (۵-۶) نشان داده شده است.

جدول (۴-۶) - مقادیر بهینه متغیر  $\alpha$  به ازای هر نمونه برای طبقه‌بندی‌های دو کلاسه توسط Robust-SVM و ۱۶۵ باند طیفی. مقادیر استفاده شده برای تهیه نقشه دگرسانی شکل (۴-۶) علامت‌گذاری شده‌اند.

ردیف	فیلک و آرژیلیک	فیلک و پروپیلیتیک	آرژیلیک و پروپیلیتیک
۱	۵۰۰	.	۵۰۰
۲	.	.	.
۳	۱۶۹/۸۴	.	.
۴	۵۰۰	۵۰۰	.
۵	۵۰۰	۵۰۰	۵۰۰
۶	۵۰۰	۱۸۲/۲۴	۵۰۰
۷	۵۰۰	.	۵۰۰
۸	.	.	۵۰۰
۹	.	.	۵۰۰
۱۰	۵۰۰	۵۰۰	۱۹۵/۴۹
۱۱	۵۰۰	۱۳۷/۶۰	۵۰۰
۱۲	.	۰/۸	.
۱۳	۵۰۰	۵۰۰	۵۰۰
۱۴	۵۰۰	.	۵۰۰
۱۵	۵۰۰	۳۱۹/۰۲	۲۰۹/۷۱
۱۶	۵۰۰	۵۰۰	.
۱۷	۵۰۰	.	۵۰۰
۱۸	.	.	۵۰۰
۱۹	۱۶۹/۸۴	.	.
۲۰	۵۰۰	۵۰۰	۴۸۵/۷۷
۲۱	.	.	۵۰۰
۲۲	۵۰۰	.	-
۲۳	۵۰۰	-	-




شکل (۴-۶) - نقشه دگرسانی طبقه‌بندی شده توسط Robust-SVM و کل ۱۶۵ باند طیفی قابل استفاده هایپرین



جدول (۶-۵) - مقادیر بهینه متغیر  $\alpha$  به ازای هر نمونه برای طبقه‌بندی‌های دو کلاسه توسط Robust-SVM و ۹ باند طیفی منتخب. مقادیر استفاده شده برای تهیه نقشه دگرسانی شکل (۶-۵) علامت‌گذاری شده‌اند.

ردیف	فیلیک و آرژیلیک	فیلیک و پروپیلیتیک	آرژیلیک و پروپیلیتیک
۱	۵۰۰۰	.	۵۰۰۰
۲	.	.	۴۱۰۹/۹۱
۳	.	.	.
۴	۲۸۴۷/۷۹	۵۰۰۰	.
۵	۵۰۰۰	۵۰۰۰	۵۰۰۰
۶	۵۰۰۰	۶۱۰/۵۰	۵۰۰۰
۷	.	.	۵۰۰۰
۸	.	.	۵۰۰۰
۹	۴۳۳۲/۴۹	.	۵۰۰۰
۱۰	۵۰۰۰	۵۰۰۰	۲۷۵۹/۹۸
۱۱	۵۰۰۰	.	۵۰۰۰
۱۲	.	۰/۵۷	۵۰۰۰
۱۳	۵۰۰۰	۵۰۰۰	۵۰۰۰
۱۴	۵۰۰۰	.	۵۰۰۰
۱۵	۵۰۰۰	.	۵۰۰۰
۱۶	۵۰۰۰	۵۰۰۰	۳۱۴۵/۳۵
۱۷	۵۰۰۰	.	۳۷۲۴/۴۶
۱۸	.	.	۵۰۰۰
۱۹	۲۱۸۰/۲۵	۴۶۸۵/۵۶۵	.
۲۰	.	۹۲۴/۴۶	.
۲۱	.	.	۵۰۰۰
۲۲	۵۰۰۰	.	-
۲۳	۵۰۰۰	-	-



شکل (۵-۶) - نقشه دگرسانی طبقه‌بندی شده توسط Robust-SVM و ۹ باند طیفی منتخب

## ۶-۲-۳- اعتبارسنجی نتایج

برای اعتبارسنجی نتایج بدست آمده توسط روش‌های SVM و Robust-SVM، مشابه با فصل پنجم، از نمونه‌های برداشت شده از منطقه مطالعاتی و همچنین نتایج مطالعات شهریاری و همکاران (۲۰۱۵) و (۲۰۱۳) استفاده شد.

## ۶-۲-۳-۱- اعتبارسنجی با استفاده از نمونه‌های برداشت شده از منطقه مطالعاتی

۳۳ و ۱۳ نمونه برداشت شده از منطقه مطابق با جداول (۲-۳) و (۳-۳) برای اعتبارسنجی نتایج استفاده شدند. دقت طبقه‌بندی و ماتریس خطای روش‌های SVM استاندارد و Robust-SVM در دو حالت استفاده از کل باندهای طیفی و باندهای منتخب در جداول (۶-۶)، (۷-۶)، (۸-۶) و (۹-۶) نشان داده شده است.

بر اساس نتایج بدست آمده در جداول (۶-۶) و (۸-۶) مشاهده می‌شود که در اکثر حالات روش Robust-SVM نسبت به SVM طبقه‌بندی دقیق‌تری انجام داده و تنها در حالت اعتبارسنجی با ۳۳ نمونه آموزشی است که SVM دقیق‌تر عمل کرده است.

جدول (۶-۶) - دقت طبقه‌بندی با استفاده از ۳۳ نمونه برداشت شده از منطقه که در فرآیند آموزش طبقه‌بندی شرکت داده شده‌اند.

الف) طبقه‌بندی با استفاده از کل ۱۶۵ باند طیفی

روش	دقت کل (%)	دقت میانگین (%)	ضریب کاپا	دقت طبقه (%)		
				فیلیک	آرژیلیک	پروپیلیتیک
SVM	۶۹/۷۰	۷۰/۱۰	۰/۵۴	۶۶/۶۷	۶۳/۶۴	۸۰/۰۰
Robust-SVM	۶۰/۶۱	۶۰/۱۰	۰/۴۰	۶۶/۶۷	۶۳/۶۴	۵۰/۰۰

ب) طبقه‌بندی با استفاده از ۹ باند طیفی منتخب

روش	دقت کل (%)	دقت میانگین (%)	ضریب کاپا	دقت طبقه (%)		
				فیلیک	آرژیلیک	پروپیلیتیک
SVM	۶۹/۷۰	۷۰/۴۰	۰/۵۴	۶۶/۶۷	۵۴/۵۵	۹۰/۰۰
Robust-SVM	۷۲/۷۳	۷۱/۷۷	۰/۵۸	۹۱/۶۷	۶۳/۶۴	۶۰/۰۰

جدول (۶-۷) - ماتریس خطای مربوط به جدول (۶-۶)

الف) طبقه‌بندی با استفاده از کل ۱۶۵ باند طیفی

SVM					Robust-SVM				
مجموع	پروپیلیتیک	آرژلیک	فیلیک	طبقه	مجموع	پروپیلیتیک	آرژلیک	فیلیک	طبقه
۱۲	۱	۳	۸	فیلیک	۱۴	۳	۳	۸	فیلیک
۱۰	۱	۷	۲	آرژلیک	۱۳	۲	۷	۴	آرژلیک
۱۱	۸	۱	۲	پروپیلیتیک	۶	۵	۱	۰	پروپیلیتیک
۳۳	۱۰	۱۱	۱۲	مجموع	۳۳	۱۰	۱۱	۱۲	مجموع

ب) طبقه‌بندی با استفاده از ۹ باند طیفی منتخب

SVM					Robust-SVM				
مجموع	پروپیلیتیک	آرژلیک	فیلیک	طبقه	مجموع	پروپیلیتیک	آرژلیک	فیلیک	طبقه
۱۴	۱	۵	۸	فیلیک	۱۹	۴	۴	۱۱	فیلیک
۷	۰	۶	۱	آرژلیک	۸	۰	۷	۱	آرژلیک
۱۲	۹	۰	۳	پروپیلیتیک	۶	۶	۰	۰	پروپیلیتیک
۳۳	۱۰	۱۱	۱۲	مجموع	۳۳	۱۰	۱۱	۱۲	مجموع

جدول (۶-۸) - دقت طبقه‌بندی با استفاده از ۱۳ نمونه برداشت شده از منطقه که در فرآیند آموزش طبقه‌بندی مشارکتی نداشتند.

الف) طبقه‌بندی با استفاده از کل ۱۶۵ باند طیفی

دقت طبقه (%)			ضریب کاپا	دقت میانگین (%)	دقت کل (%)	روش
پروپیلیتیک	آرژلیک	فیلیک				
۱۰۰/۰۰	۳۳/۳۳	۲۸/۵۷	۰/۲۵	۵۳/۹۷	۴۶/۱۵	SVM
۱۰۰/۰۰	۳۳/۳۳	۷۱/۴۳	۰/۴۹	۶۸/۲۵	۶۹/۲۳	Robust-SVM

ب) طبقه‌بندی با استفاده از ۹ باند طیفی منتخب

دقت طبقه (%)			ضریب کاپا	دقت میانگین (%)	دقت کل (%)	روش
پروپیلیتیک	آرژلیک	فیلیک				
۱۰۰/۰۰	۳۳/۳۳	۵۷/۱۴	۰/۴۱	۶۳/۴۹	۶۱/۵۴	SVM
۱۰۰/۰۰	۳۳/۳۳	۷۱/۴۳	۰/۵۲	۶۸/۲۵	۶۹/۲۳	Robust-SVM

جدول (۶-۹) - ماتریس خطای مربوط به جدول (۶-۸)

الف) طبقه‌بندی با استفاده از کل ۱۶۵ باند طیفی

SVM					Robust-SVM				
مجموع	پروپلیتیک	آرژلیک	فیلیک	طبقه	مجموع	پروپلیتیک	آرژلیک	فیلیک	طبقه
۲	۰	۰	۲	فیلیک	۷	۰	۲	۵	فیلیک
۳	۰	۱	۲	آرژلیک	۳	۰	۱	۲	آرژلیک
۸	۳	۲	۳	پروپلیتیک	۳	۳	۰	۰	پروپلیتیک
۱۱	۳	۳	۷	مجموع	۱۱	۳	۳	۷	مجموع


ب) طبقه‌بندی با استفاده از ۹ باند طیفی منتخب

SVM					Robust-SVM				
مجموع	پروپلیتیک	آرژلیک	فیلیک	طبقه	مجموع	پروپلیتیک	آرژلیک	فیلیک	طبقه
۵	۰	۱	۴	فیلیک	۶	۰	۱	۵	فیلیک
۳	۰	۱	۲	آرژلیک	۲	۰	۱	۲	آرژلیک
۵	۳	۱	۱	پروپلیتیک	۴	۳	۱	۰	پروپلیتیک
۱۱	۳	۳	۷	مجموع	۱۱	۳	۳	۷	مجموع

### ۶-۲-۳-۲ - مقایسه با مطالعات قبلی

در بخش (۵-۳-۲) مشاهده شد که نقشه زیرپیکسلی بدست آمده توسط روش SVR با نتایج مطالعات شهریار و دیگران (۲۰۱۵) و (۲۰۱۳) انطباق بالایی داشته و لذا از اعتبار خوبی برخوردار است. بنابراین در این بخش برای سنجش کمی دقت و اعتبار نتایج، نتایج حاصله از روش‌های SVM و Robust-SVM بجای مقایسه با نتایج شهریار و دیگران (۲۰۱۵) و (۲۰۱۳)، با نتایج SVR مقایسه می‌شوند. بدین‌منظور و بدلیل آنکه نتایج SVM و Robust-SVM در مقیاس پیکسلی هستند، نخست نقشه‌های زیرپیکسلی روش SVR (شکل ۵-۵) که در آن‌ها فراوانی کانی‌ها در هر پیکسل تخمین زده شده است، به نقشه پیکسل‌پایه جهت مقایسه تبدیل شد. برای این کار فراوان‌ترین کانی موجود در هر پیکسل جستجو و سپس برای برچسب گذاری همان پیکسل استفاده شد که نقشه بدست آمده در شکل (۶-۶) نشان داده شده است. با در نظر گرفتن نتایج این نقشه به عنوان مرجع، نتایج روش‌های SVM و Robust-SVM در دو حالت استفاده از کل باندهای طیفی و ۹ باند طیفی منتخب با نقشه مذکور مقایسه

شد که دقت طبقه‌بندی و ماتریس خطای مربوطه به ترتیب در جداول (۶-۱۰) و (۶-۱۱) آورده شده است.



شکل (۶-۶) - نقشه دگرسانی منطقه بدست آمده از نقشه دگرسانی زیرپیکسلی روش SVR

جدول (۶-۱۰) - دقت طبقه‌بندی روش‌های SVM و Robust-SVM در مقایسه با نقشه (۶-۶) به عنوان نقشه مبنا

الف) طبقه‌بندی با استفاده از کل ۱۶۵ باند طیفی

روش	دقت کل (%)	دقت میانگین (%)	ضریب کاپا	دقت طبقه (%)		
				فیلیک	آرژلیک	پروپلیتیک
SVM	۶۹/۰۰	۶۶/۸۲	۰/۴۴	۲۸/۹۶	۷۱/۵۱	۱۰۰/۰۰
Robust-SVM	۷۵/۴۲	۷۲/۰۹	۰/۵۹	۶۳/۶۳	۶۶/۷۷	۸۵/۸۸

ب) طبقه‌بندی با استفاده از ۹ باند طیفی منتخب

روش	دقت کل (%)	دقت میانگین (%)	ضریب کاپا	دقت طبقه (%)		
				فیلیک	آرژلیک	پروپلیتیک
SVM	۸۰/۱۸	۷۱/۱۲	۰/۶۴	۶۳/۶۶	۵۲/۶۷	۹۷/۰۳
Robust-SVM	۸۴/۱۰	۷۳/۷۲	۰/۷۲	۸۱/۹۷	۴۸/۳۷	۹۰/۸۲

جدول (۶-۱۱) - ماتریس خطای مربوط به جدول (۶-۱۰)

الف) طبقه‌بندی با استفاده از کل ۱۶۵ باند طیفی

SVM					Robust-SVM				
مجموع	پروپلیتیک	آرژلیک	فیلیک	طبقه	مجموع	پروپلیتیک	آرژلیک	فیلیک	طبقه
۵۸۰۴	۰	۰	۵۸۰۴	فیلیک	۱۶۸۳۶	۳۵۹۲	۴۹۳	۱۲۷۵۱	فیلیک
۶۶۶۷	۰	۲۵۹۳	۴۰۷۴	آرژلیک	۹۶۱۹	۲۰	۲۴۲۱	۷۱۷۸	آرژلیک
۳۶۷۸۲	۲۵۵۸۸	۱۰۳۳	۱۰۱۶۱	پروپلیتیک	۲۲۷۹۸	۲۱۹۷۶	۷۱۲	۱۱۰	پروپلیتیک
۴۹۲۵۳	۲۵۵۸۸	۳۶۲۶	۲۰۰۳۹	مجموع	۴۹۲۵۳	۲۵۵۸۸	۳۶۲۶	۲۰۰۳۹	مجموع

ب) طبقه‌بندی با استفاده از ۹ باند طیفی منتخب

SVM					Robust-SVM				
مجموع	پروپلیتیک	آرژلیک	فیلیک	طبقه	مجموع	پروپلیتیک	آرژلیک	فیلیک	طبقه
۱۳۲۶۶	۳۵۵	۱۵۵	۱۲۷۵۶	فیلیک	۱۸۸۷۳	۱۷۶۰	۶۸۷	۱۶۴۲۶	فیلیک
۴۳۰۲	۴۰۶	۱۹۱۰	۱۹۸۶	آرژلیک	۴۳۰۲	۵۸۷	۱۷۵۴	۱۹۶۱	آرژلیک
۳۱۶۸۵	۲۴۸۲۷	۱۵۶۱	۵۲۹۷	پروپلیتیک	۲۶۰۷۸	۲۳۲۴۱	۱۱۸۵	۱۶۵۲	پروپلیتیک
۴۹۲۵۳	۲۵۵۸۸	۳۶۲۶	۲۰۰۳۹	مجموع	۴۹۲۵۳	۲۵۵۸۸	۳۶۲۶	۲۰۰۳۹	مجموع

## ۶-۲-۴ - مقایسه نتایج و نتیجه‌گیری

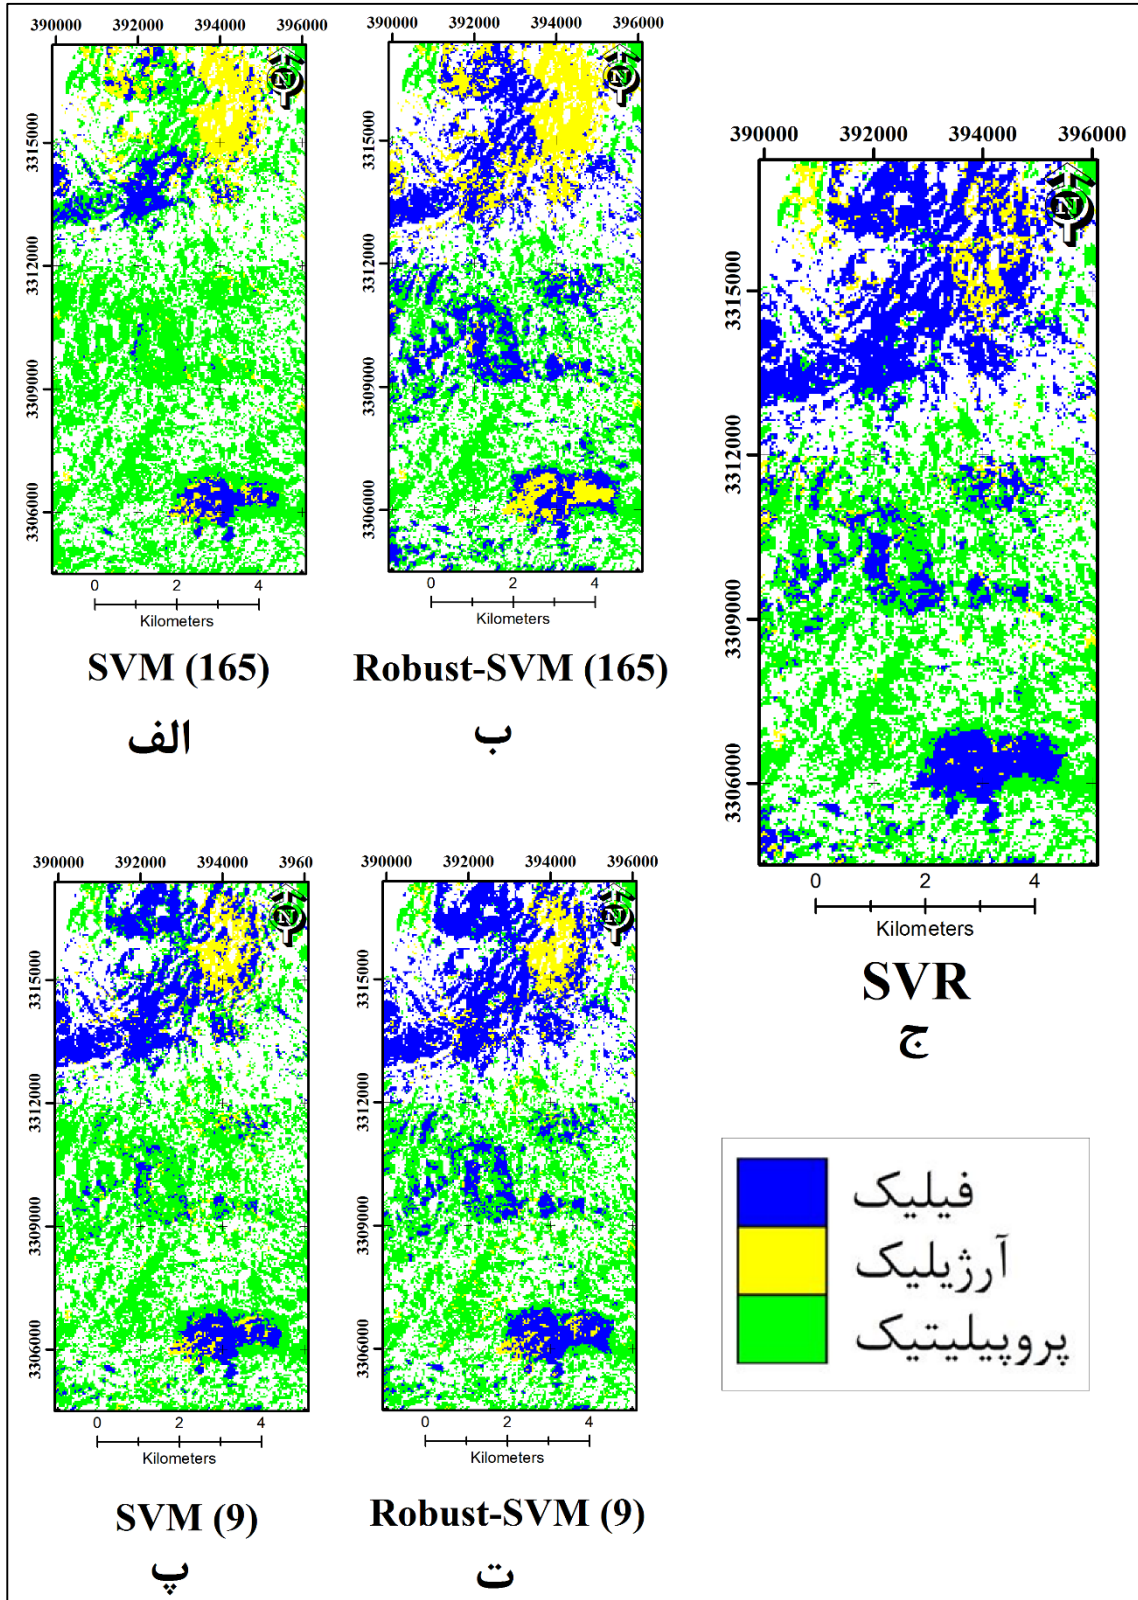
در شکل (۶-۷) نقشه‌های دگرسانی بدست آمده از روش‌های SVM و Robust-SVM جهت انجام

مقایسه بصری با نقشه خروجی SVR (به عنوان نقشه مرجع) نشان داده شده است. مقایسه ظاهری

نقشه‌ها نشان می‌دهد که نقشه بدست آمده از روش Robust-SVM در شرایطی که از ۹ باند طیفی منتخب برای طبقه‌بندی استفاده می‌کند (شکل ۶-۷-ت)، بیشترین شباهت را با نقشه زیرپیکسلی مرجع دارد. همچنین نقشه حاصله از روش SVM در حالتی که برای طبقه‌بندی از ۹ باند طیفی استفاده می‌کند (شکل ۶-۷-پ) در رده بعدی بیشترین مشابهت با نقشه مرجع قرار دارد. به همین ترتیب در رده سوم، نقشه خروجی از روش Robust-SVM با ۱۶۵ باند طیفی (شکل ۶-۷-ب) قرار گرفته و در نهایت نیز نقشه بدست آمده از روش SVM وقتی که از ۱۶۵ باند طیفی برای طبقه‌بندی استفاده می‌کند (شکل ۶-۷-الف) در رتبه آخر بیشترین تشابه نسبت به نقشه مرجع قرار می‌گیرد.

با مقایسه کمی نتایج روش‌های مذکور در قالب دقت طبقه‌بندی و ضریب کاپا نیز مشاهده می‌شود که تا حدود زیادی روند مذکور رعایت شده است. در جدول (۶-۱۲) دقت نتایج روش‌های SVM و Robust-SVM بر اساس ۳ مجموعه داده مرجعی که در بخش (۵-۳) برای اعتبارسنجی نتایج استفاده شد بصورت یکجا آورده شده است. با میانگین‌گیری از نتایج دقت بدست آمده نسبت به ۳ مجموعه مرجع، مشاهده می‌شود که روش Robust-SVM وقتی از ۹ باند طیفی منتخب برای طبقه‌بندی استفاده می‌کند به بالاترین دقت با میانگین  $71/25$  و ضریب کاپایی برابر با  $0/61$  می‌رسد. دقیق‌ترین نتایج پس از این حالت تعلق دارد به روش SVM با ۹ باند طیفی که به میانگین دقتی برابر با  $68/34$  و ضریب کاپای  $0/53$  رسیده است. در نهایت روش‌های Robust-SVM و SVM وقتی از ۱۶۵ باند طیفی برای انجام طبقه‌بندی استفاده می‌کنند به ترتیب با دستیابی به دقت  $66/81$  و  $63/63$  و ضریب کاپای  $0/49$  و  $0/41$  در رده‌های بعدی از لحاظ دقت طبقه‌بندی قرار می‌گیرند.





شکل (۶-۷) - مقایسه نقشه دگرسانی روش‌های SVM و Robust-SVM با نقشه دگرسانی زیرپیکسلی روش SVR به عنوان نقشه مبنا: الف - SVM با استفاده از کل باندهای طیفی، ب - Robust-SVM با استفاده از کل باندهای طیفی، پ - SVM با استفاده از ۹ باند طیفی منتخب و ج - نقشه زیرپیکسلی SVR به عنوان نقشه مرجع

جدول (۶-۱۲) - مقایسه دقت روش‌های SVM و Robust-SVM بر اساس ۳ مجموعه داده مرجع مختلف

ضریب کاپا	دقت میانگین (%)	دقت کل (%)	مجموعه داده مرجع	تعداد باند استفاده شده	روش
۰/۵۸	۷۱/۷۷	۷۲/۷۳	۳۳ نمونه برداشت شده از منطقه	۹	Robust SVM
۰/۵۲	۶۸/۲۵	۶۹/۲۳	۱۳ نمونه برداشت شده از منطقه		
۰/۷۲	۷۳/۷۲	۸۴/۱۰	نقشه زیرپیکسلی روش SVR		
۰/۶۱	۷۱/۲۵	۷۵/۶۸	میانگین		
۰/۴۰	۶۰/۱۰	۶۰/۶۱	۳۳ نمونه برداشت شده از منطقه	۱۶۵	Robust SVM
۰/۴۹	۶۸/۲۵	۶۹/۲۳	۱۳ نمونه برداشت شده از منطقه		
۰/۵۹	۷۲/۰۹	۷۵/۴۲	نقشه زیرپیکسلی روش SVR		
۰/۴۹	۶۶/۸۱	۶۸/۴۲	میانگین		
۰/۵۴	۷۰/۴۰	۶۹/۷۰	۳۳ نمونه برداشت شده از منطقه	۹	SVM
۰/۴۱	۶۳/۴۹	۶۱/۵۴	۱۳ نمونه برداشت شده از منطقه		
۰/۶۴	۷۱/۱۲	۸۰/۱۸	نقشه زیرپیکسلی روش SVR		
۰/۵۳	۶۸/۳۴	۷۰/۴۷	میانگین		
۰/۵۴	۷۰/۱۰	۶۹/۷۰	۳۳ نمونه برداشت شده از منطقه	۱۶۵	SVM
۰/۲۵	۵۳/۹۷	۴۶/۱۵	۱۳ نمونه برداشت شده از منطقه		
۰/۴۴	۶۶/۸۲	۶۹/۰۰	نقشه زیرپیکسلی روش SVR		
۰/۴۱	۶۳/۶۳	۶۱/۶۲	میانگین		

بر اساس آنچه که گفته شد می‌توان نتیجه گرفت که وجود باندهای افزونه و نامربوط در داده‌های ابرطیفی نقش بیشتری در افت دقت طبقه‌بندی در مقایسه با مشکل عدم قطعیت و نویز موجود در داده‌ها دارند. آنچه که در شکل (۶-۷) مشهود می‌باشد، بارزسازی دقیق‌تر مناطق آرژیلیکی است که در نتیجه استفاده از ۹ باند طیفی به جای کل باندهای طیفی روی می‌دهد. همانطور که مشاهده می‌شود مناطق آرژیلیکی (به رنگ زرد) در نقشه‌های ۹ باندهای (شکل ۶-۷-۳ و ۶-۷-۴) با دقت بیشتری شناسایی شده و با مناطق آرژیلیکی بارزسازی شده در نقشه زیرپیکسلی بدست آمده از SVR همبستگی بیشتری نشان می‌دهند. بنابراین به وضوح مشاهده می‌شود که باندهای طیفی فراوان تصویر هایپریون نه تنها کمکی به افزایش دقت طبقه‌بندی نمی‌کنند بلکه با افزایش پیچیدگی‌های محاسباتی مانع آموزش دقیق الگوریتم‌های طبقه‌بندی می‌گردند. از سویی دیگر ۹ باند طیفی شناسایی شده به عنوان باندهای طیفی که بیشترین اطلاعات را برای طبقه‌بندی مناطق دگرسازی فراهم می‌کنند، جهت یادگیری مطلوب‌تر و

دقیق‌تر قوانین حاکم بر الگوی دگرسانی‌ها کافی می‌باشند.

از سویی دیگر نسخه مقاوم در برابر نویز یعنی Robust-SVM نیز توانسته است با تفکیک دقیق‌تر دگرسانی فیلیک از دگرسانی پروپیلیتیک (بویژه در مناطق مرکزی منطقه مطالعاتی) بر دقت نتایج حاصل افزوده و نقشه‌های به مراتب شبیه‌تری به نقشه زیرپیکسلی تولید نماید (شکل ۶-۷-۲ و ۶-۷-۴). در نهایت دقیق‌ترین نقشه (شکل ۶-۷-۴) زمانی بدست آمد که روش Robust-SVM از ۹ باند طیفی منتخب برای طبقه‌بندی استفاده می‌کند. زیرا در این حالت مشکلات وجود باندهای افزونه و عدم قطعیت موجود در داده‌ها بصورت همزمان لحاظ شده و تأثیرات نامطلوب آنها تعدیل می‌گردد.





فصل ہفتم: نتیجہ گیری



## ۷-۱- نتیجه‌گیری

در این تحقیق سعی گردید که به مشکلات و چالش‌های احتمالی پیش رو در طبقه‌بندی داده‌های سنجش از دور ابرطیفی پرداخته شده و تا حد امکان از اثرات نامطلوب آن‌ها بر روی دقت نتایج طبقه‌بندی کاسته شود.

در ابتدا به مشکلات انفجار ابعاد و پدیده هیوز به عنوان عوامل مخربی اشاره گردید که معمولاً در طبقه‌بندی داده‌های بیش‌ابعاد دیده شده و می‌توانند تهدیدی برای دقت طبقه‌بندی باشند. با توجه به این که روش‌های طبقه‌بندی مبتنی بر کرنل از قابلیت خوبی برای طبقه‌بندی مسائل بیش‌ابعاد برخوردار هستند، در این تحقیق SVM که یک روش مبتنی بر کرنل است، به عنوان روش طبقه‌بندی کننده اصلی انتخاب گردید. در ادامه، قابلیت SVM برای طبقه‌بندی داده‌های ابرطیفی هایپریون (به عنوان یک مجموعه داده بیش‌ابعاد) در مقام مقایسه با روش طبقه‌بندی کننده مهمی مثل شبکه‌های عصبی مصنوعی قرار گرفت. بدین منظور، هر دو روش بصورت یکسان برای طبقه‌بندی داده‌های ابرطیفی با درجات متفاوتی از انفجار ابعاد (با تغییر تعداد نمونه‌های آموزشی نسبت به تعداد باندهای طیفی) استفاده شدند. نتایج بدست آمده نشان داد که اگرچه هر دو روش در طبقه‌بندی مجموعه داده‌هایی با انفجار ابعاد کم، عملکرد مطلوبی دارند ولی با افزایش این خاصیت (در نتیجه کاهش تعداد نمونه‌های آموزشی نسبت به فضای باندی)، SVM در مقابل کاهش دقت طبقه‌بندی از مقاومت بیشتری برخوردار بوده و با نرخ کمتری در افت دقت طبقه‌بندی مواجه می‌شود.

کاهش ابعاد فضای باندی به عنوان راه حل ثانویه‌ای برای مقابله با مشکل هیوز مطرح گردید. پیشنهاد گردید که بجای افزایش تعداد نمونه‌های آموزشی که معمولاً نیازمند صرف هزینه‌های زمانی و اقتصادی است، از روش‌های کاهش ابعاد داده استفاده شود. بدین منظور از نوعی از روش‌های کاهش ابعاد داده به نام روش‌های انتخاب ویژگی استفاده شد که یکی از مهمترین مزایای آن نسبت به روش‌های استخراج ویژگی، شناسایی باندهای تاثیرگذار و مهم با توجه به هدف مطالعاتی است. این مزیت مهم،



امکان آن را فراهم می‌کند که کاربر بصورت دقیق ویژگی‌های تأثیرگذار را شناسایی کند. این امکان در روش‌های استخراج ویژگی، بدلیل آنکه فضای ویژگی اولیه را دگرگون می‌نمایند، وجود ندارد. در این تحقیق از یک روش انتخاب ویژگی ترکیبی استفاده شد که مهمترین مزیت آن انتخاب زیر مجموعه کوچکی از فضای ویژگی‌ها است. در نتیجه کاربرد این روش، از میان ۱۶۵ باند طیفی قابل استفاده در مجموعه داده هایپریون، تنها ۹ باند شناسایی شدند، بطوریکه بیشترین اطلاعات طیفی برای تفکیک و شناسایی کانی‌های دگرسانی را فراهم می‌کنند. ۹ باند مذکور که تنها تشکیل دهنده حدوداً ۵٪ از فضای باندهای موجود در داده‌ها هستند، دقیقاً در بازه SWIR طیف الکترومغناطیسی قرار دارند که برای شناسایی کانی‌های دگرسانی حائز اهمیت است. همچنین مشاهده گردید که ۴ باند از ۹ باند مذکور دقیقاً در بازه‌ای از طیف الکترومغناطیسی قرار دارند که برای شناسایی کانی‌های شاخص مناطق دگرسانی آرژیلیکی (کائولینیت) و فیلیک (موسکویت) مناسب هستند. همچنین ۵ باند دیگر شناسایی شده نیز در بازه‌ای قرار دارند که کانی کلریت به عنوان کانی شاخص دگرسانی پروپلیتیک خصوصیات طیفی شاخصی نشان می‌دهد. این یافته‌ها حاکی از عملکرد مطلوب و دقیق روش کاهش ابعاد استفاده شده است.

کارایی ۹ باند مذکور در شرایط مختلفی از انفجار ابعادی توسط داده‌های مصنوعی مورد آزمون قرار گرفت و مشاهده شد که استفاده از ۹ باند در مقایسه با ۱۶۵ باند طیفی، کمتر تحت تأثیر اثرات نامطلوب انفجار ابعادی قرار گرفته و دقت طبقه‌بندی با افت کمتری مواجه می‌شود. با توجه به این یافته‌ها، عملکرد این ۹ باند انتخابی بر روی داده‌های حقیقی برداشت شده از منطقه مطالعاتی نیز ارزیابی شد و مشاهده گردید که نقشه دگرسانی بدست آمده از دقت بیشتری نسبت به حالتی که از کلیه باندهای طیفی استفاده می‌شود، برخوردار است. در حقیقت در نتیجه استفاده از باندهای منتخب و کاهش پیچیدگی موجود در داده‌ها، الگوی حاکم بر داده‌ها جهت تفکیک دگرسانی‌های آرژیلیکی و فیلیک دقیق‌تر شناسایی شدند.

عامل دیگری که به عنوان یک پدیده مشکل زا در داده‌های ابرطیفی مطرح بوده و می‌تواند فرآیند طبقه‌بندی را با مشکل مواجه سازد، وجود عدم قطعیت در داده‌ها در نتیجه نسبت سیگنال به نویز پایین و وجود نویز در داده‌ها است. مشکل مذکور، بدلیل ماهیت فضا بردی داده‌های ابرطیفی هایپریون، شکل حادثری به خود گرفته که در نتیجه آن، هایپریون در مقایسه با سنجنده‌های هوا برد، داده‌هایی با کیفیت پایین‌تر تولید می‌کند. برای پوشش این مشکل، نسخه‌ای از SVM مورد استفاده قرار گرفت که از قابلیت بالایی برای طبقه‌بندی داده‌های نویزی برخوردار است. Robust-SVM با در نظر گرفتن فضایی در اطراف داده‌های اولیه، احتمالی برای نوسان مقادیر داده‌ها در فضای مذکور (به علت وجود نویز) قائل شده و به این صورت به ماهیت عدم قطعیت در داده‌ها توجه کرده و آن را در روابط مربوطه وارد می‌نماید. با بکارگیری Robust-SVM برای طبقه‌بندی داده‌ها، بهبود دقت در نتایج طبقه‌بندی مشاهده گردید. این افزایش دقت در طبقه‌بندی بیشتر در شناسایی و تفکیک دگرسانی‌های پروپیلیتیک و فیلیک دیده شد. به این صورت که بیشتر مناطقی که در نتیجه طبقه‌بندی توسط SVM استاندارد و به صورت نادرست به عنوان مناطق حاوی دگرسانی پروپیلیتیک طبقه‌بندی شده بودند، در نتیجه استفاده از Robust-SVM، تحت عنوان دگرسانی فیلیک طبقه‌بندی شدند.

با توجه به تأثیر مثبت استفاده از روش‌های کاهش ابعاد داده و Robust-SVM بر نتایج طبقه‌بندی و افزایش دقت طبقه‌بندی، در مرحله بعد تأثیر استفاده توأمان از Robust-SVM و نتایج روش کاهش ابعاد داده مورد ارزیابی قرار گرفت. بدین منظور روش Robust-SVM با استفاده از ۹ باند طیفی معرفی شده توسط روش کاهش ابعاد داده، برای طبقه‌بندی مناطق دگرسانی استفاده شد. بر طبق انتظار در این حالت دقیق‌ترین نتایج در دقت طبقه‌بندی حاصل گردید.

بدلیل آنکه موضوع تجزیه طیفی و انجام طبقه‌بندی نرم از مباحث روز و پرچالش در جوامع سنجش از دور است، سعی شد در این تحقیق به این موضوع نیز پرداخته شود. هدف طبقه‌بندی سخت پیش‌بینی مقادیر گسسته (نوع دگرسانی) است، درحالی‌که در طبقه‌بندی نرم، فراوانی کانی‌های موجود در هر پیکسل از تصویر که دارای مقادیر پیوسته هستند، تخمین زده می‌شود. برای نیل به این هدف، نسخه‌ای

از SVM مورد استفاده قرار گرفت که قابلیت پیش‌بینی مقادیر پیوسته را نیز دارد. بدین‌منظور، SVR یا رگرسیون بردار پشتیبان به صورت تابعی که توانایی تخمین مقادیر پیوسته را دارد، برای طبقه نرم یا زیرپیکسلی مناطق دگرسانی استفاده شد. در نتیجه مقایسه با تحقیقات قبلی انجام شده در منطقه، مشاهده گردید که نقشه زیرپیکسلی دگرسانی‌های منطقه از دقت بیشتری نسبت به نقشه‌های پیکسل‌پایه برخوردار است. این موضوع به دلیل دقیق‌تر بودن نتایج طبقه‌بندی نرم نسبت به حالت سخت (فارغ از نوع هدف مورد مطالعه)، قابل انتظار بود. در حقیقت، دقیق‌ترین و شبیه‌ترین نقشه پراکندگی دگرسانی پیکسل‌پایه (بدست آمده از طبقه‌بندی سخت) به نقشه دگرسانی زیرپیکسلی (بدست آمده از طبقه‌بندی نرم) در نتیجه استفاده همزمان از Robust-SVM و ۹ باند طیفی منتخب حاصل گردید.

اهمیت و ارزش نتایج بدست آمده از طبقه‌بندی نرم از آنجا مشخص می‌شود که SVR بدون استفاده از باندهای طیفی منتخب و همچنین بدون استفاده از نسخه مقاوم، توانسته است به دقتی دست یابد که برای SVM استاندارد، تنها در نتیجه استفاده از نسخه مقاوم و فضای باندهای گاهش یافته قابل دسترسی است.

## ۷-۲- پیشنهادات

با توجه به کارهای انجام شده و نتایج حاصل شده، موارد زیر می‌توانند به عنوان اهداف مطالعاتی آتی مورد توجه قرار گیرند:

- ۱- انجام طبقه‌بندی سخت توسط Robust-SVM بر روی داده‌های ابرطیفی هوابرد به منظور مقایسه داده‌های هوابرد و هایپریون از لحاظ میزان نویز موجود در داده‌ها.
- ۲- پیاده‌سازی الگوریتم کاهش ابعاد داده بر روی داده‌های ابرطیفی هوابرد به منظور مقایسه داده‌های هوابرد و هایپریون از لحاظ وجود و تعداد باندهای نامربوط و افزونه.

- ۳- پیاده‌سازی الگوریتم Robust-SVR جهت انجام طبقه‌بندی نرم و مقاوم در برابر عدم قطعیت و نویز که در نتیجه تلفیق مفاهیم پایه روش SVR و الگوریتم مقاوم امکان‌پذیر است.
- ۴- پیاده‌سازی نسخه‌ای از SVM با عنوان SVM چند برچسبی<sup>۱</sup> برای انجام طبقه‌بندی نرم و زیرپیکسلی و مقایسه نتایج بدست آمده با نتایج SVR.

---

1- Multi-Label SVM

مراج

گودرزی مهر س.، عباسپور ر.، احد نژاد و.، خاکباز ب. (۱۳۹۱) "مقایسه روش ماشین بردار پشتیبان با روش‌های حداکثر احتمال و شبکه‌های عصبی برای تفکیک واحدهای سنگ شناسی" فصل نامه زمین شناسی ایران، ۱۳۹۱، سال ۶، شماره ۲۲، ۷۵-۹۲.

نجفیان ط.، رنجبر ح.، فتحیان پور ن. (۱۳۹۲) "بهبود تفکیک دگرسانی‌های مرتبط با کانسارهای مس پورفیری با استفاده از داده‌های سنجنده ابرطیفی هایپریون" اولین کنفرانس ملی مهندسی اکتشاف منابع زیرزمینی، دانشگاه صنعتی شاهرود، شاهرود.

Abbaszadeh M., Hezarkhani A., Soltani-Mohammadi S. (2013) "An SVM-based machine learning method for the separation of alteration zones in Sungun porphyry copper deposit" **Chemie der Erde**, 73, pp 545-554.

Abedi M., Norouzi G.H., Bahroudi A., (2011) "Support vector machine for multi-classification of mineral prospectivity areas" **Comput. Geosci.**, 46, pp 272-283.

Aftabi A. and Atapour H. (2010) "Alteration Geochemistry of Volcanic Rocks around Sarcheshmeh Porphyry Copper Deposit, Rafsanjan, Kerman, Iran: Implications for Regional Exploration" **Resour. Geol.**, 61(1), pp 76-90.

Arish S., Amiri A., Noori K. (2013) "FICA: fuzzy imperialist competitive algorithm" **Journal of Zhejiang University-SCIENCE C (Computers & Electronics)**, 15(5), pp 363-371.

Asadzadeh S. and De Souza Filho C.R. (2016) "A review on spectral processing methods for geological remote sensing" **Int. J. Appl. Earth Obs. Geoinf.**, 47, pp 69-90.

Barzegar H., (2007), Ph.D. thesis, "Geology, petrology and geochemical characteristics of alteration zones within the Seridune prospect, Kerman, Iran".

Bazi Y., Melgani F. (2007) "Semisupervised PSO-SVM regression for biophysical parameter estimation" **IEEE Trans. Geosci. Remote Sens.**, 45, pp 1887-1895.

Bedini E., van der Meer F., van Ruitenbeek F. (2009) "Use of HyMap imaging spectrometer data to map mineralogy in the Rodalquilar caldera, southeast Spain" **Int J Remote Sens.**, 30, pp 327-348.

Berger B.R., King T.V.V., Morath L.C., Phillips J.D. (2003) "Utility of high-altitude infrared spectral data in mineral exploration: application to northern Patagonia mountains, Arizona" **Econ. Geol. Bull. Soc. Econ. Geol.**, 98, pp 1003-1018.

Beiranvand Pour B.A. and Hashim M. (2011) "The Earth Observing-1 (EO-1) satellite data for geological mapping, southeastern segment of the Central Iranian Volcanic Belt, Iran" **Int. J. Phys. Sci.**, 6, pp 7638-7650.

Beiranvand Pour A. and Hashim M. (2014) "ASTER, ALI and Hyperion sensors data for lithological mapping and ore minerals exploration" **SpringerPlus Open Journal, Earth Science**, <http://www.springerplus.com/content/3/1/130>.

Bermejo p., de la Ossa L., Gámez J.A., Puerta J.M. (2012) "Fast wrapper feature subset selection in high-dimensional datasets by means of filter re-ranking" **Knowl-based Syst.**, 25, pp 35–44.

Bierwirth P., Huston D., Blewett R., (2002) "Hyperspectral mapping of mineral assemblages associated with gold mineralization in the Central Pilbara, Western Australia" **Econ. Geol. Bull. Soc. Econ. Geol.**, 97, pp 819-826.

Bioucas-Dias J.M., Plaza A., Camps-Valls G., Scheunders P., Nasrabadi N.M., Chanussot, J. (2013) "Hyperspectral Remote Sensing Data Analysis and Future Challenges" **IEEE Geosci. Remote Sens. Mag.**, 1(2), pp 6-36.

Bishop CA., Liu JG., Mason PJ. (2011) "Hyperspectral remote sensing for mineral exploration in Pulang, Yunnan Province, China" **Int J Remote Sens.**, 32, pp 2409-2426.

Boomeri M., Nakashima K., Lentz D.R. (2010) "The Sarcheshmeh porphyry copper deposit, Kerman, Iran: A mineralogical analysis of the igneous rocks and alteration zones including halogen element systematic related to Cu mineralization processes" **Ore Geol. Rev.**, 38(4): pp 367-381.

Camps-Valls G., Gomez-Chova L., Calpe-Maravilla J., Martin-Guerrero J.D., Soria-Olivas E., Alonso-Chorda L., Moreno J., (2004) "Robust support vector method for hyperspectral data classification and knowledge discovery" **IEEE Trans. Geosci. Remote Sens.**, 42, pp 1530-1542.

Camps-Valls G., Tuia D., Bruzzone L., Benediktsson J. (2014) "Advances in Hyperspectral Image Classification" **IEEE Signal Process. Mag.**, 31, pp 45-54.

Carranza E.J.M., (2002), Ph.D. thesis, "Geologically-Constrained Mineral Potential Mapping", Delft University of Technology, the Netherlands, 480p.

Chabrillat S., Pinet P.C., Ceuleneer G., Johnson P.E., Mustard J.F. (2000) "Ronda peridotite massif: methodology for its geological mapping and lithological discrimination from airborne hyperspectral data" **Int J Remote Sens.**, 21, pp 2363-2388.

Chang C. (2007) "**Hyperspectral Data Exploitation, Theory and Applications**", Published by John Wiley & Sons, Inc., Hoboken, New Jersey, 430p.

Chen X., Warner T.A., Campagna D.J. (2007) "Integrating visible, near-infrared and short wave infrared hyperspectral and multispectral thermal imagery for geologic mapping: simulated data" **Int J Remote Sens.**, 28, pp 2415-2430.

Congalton R.G. and Green K. (2009) "**Assessing the Accuracy of Remotely Sensed Data, Principles and Practices**", Published by Taylor & Francis Group, LLC, Second

Edition, Printed in the United States of America on acid-free paper, International Standard Book Number-13: 978-1-4200-5512-2 (Hardcover), 177p.

Crosta A.P., Sabine C., Taranik J.V. (1998) "Hydrothermal alteration mapping at Bodie, California, using AVIRIS hyperspectral data" **Remote Sens Environ.**, 65, pp 309-319.

Cudahy T.J. and Barry P.S. (2002) "Earth magmatic-seawater hydrothermal alteration revealed through satellite-borne Hyperion imagery at Panorama" Western Aust IEEE IGARSS proc, 1, pp 590-592.

Cudahy T.J., Hewson R., Huntington J.F., Quigley M.A., Barry P.S. (2001) "The performance of the satellite-borne Hyperion hyperspectral VNIR-SWIR imaging system for mineral mapping at Mount Fitton" South Aust IEEE IGARSS proc, pp 9-13.

Dai Q., Cheng J.H., Sun D.W., Zeng X.A. (2015) "Advances in Feature Selection Methods for Hyperspectral Image Processing in Food Industry Applications: A Review" **Int J Food Sci Nutr.**, 55(10), pp 1368-1382.

Dalponte M., Bruzzone L., Gianelle D. (2008) "Fusion of hyperspectral and LIDAR remote sensing data for classification of complex forest areas" **IEEE Trans. Geosci. Remote Sens.**, 46, pp 1416-1427.

Dalponte M., Bruzzone L., Vescovo L., Gianelle D. (2009) "The role of spectral resolution and classifier complexity in the analysis of hyperspectral images of forest areas" **Remote Sens Environ.**, 113, pp 2345-2355.

Darmawan A., (2006), M.Sc. Thesis, "Mapping soil mineral using Hyperion imagery in relation to the level of structural damage in the Bam earthquake", The University of Melbourne, 86p.

Deng N., Tian Y., Zhang C. (2013) "**Support Vector Machines: Optimization Based Theory, Algorithms, and Extensions**", Published by Chapman and Hall/CRC; 1 edition, 363p.

Duda R.O., Hart P.E., Stork D.G. (1973) "**Pattern Classification**", Published by Wiley-Interscience ©2000, 2nd Edition.

Ede R.V. (2004) "Destriping and Geometric Correction of an ASTER Level 1A Image" Utrecht University, Utrecht., 36p.

Esch T., Himmler V., Schorcht G., Thiel M., Wehrmann T., Bachofer F., Conrad C., Schmidt M., Dech S. (2009) "Large-area assessment of impervious surface based on integrated analysis of single-date Landsat-7 images and geospatial vector data" **Remote Sens Environ.**, 113, pp 1678-1690.

Fauvel M., Tarabalka Y., Benediktsson J.A., Chanussot J., Tilton J.C. (2013) "Advances in Spectral-Spatial Classification of Hyperspectral Images" **Proceedings of the IEEE**, 101, pp 652-675.



Geological survey of Iran. (1973a) "Exploration for Ore deposits in Kerman region" Report No, Yu/53. Tehran, Iran: Ministry of Economy Geological Survey of Iran.

Gersman R., Ben-Dor E., Beyth M., Avigad D., Abraha M., Kibreba A. (2008) "Mapping of hydrothermally altered rocks by the EO-1 Hyperion sensor, northern Danakil, Eritrea" **Int J Remote Sens.**, 29, pp 3911-3936.

Gheyas A. and Smith L.S. (2010) "Feature subset selection in large dimensionality domains" **PATTERN RECOGN**, 43, pp 5-13.

Gómez-Chova L., Muñoz-Marí J., Laparra V., Malo-López J., Camps-Valls G. (2011) "A Review of Kernel Methods in Remote Sensing Data Analysis" In book: **Optical Remote Sensing - Advances in Signal Processing and Exploitation Techniques**, Publisher: Springer-Verlag, Editors: Saurabh, P. and Bruce, L. and Chanussot, J, pp171-206.

Gualtieri J.A. and Cromp R.F. (1998) "Support vector machines for hyperspectral remote sensing classification" Proceedings of the 27th AIPR Workshop: Advances in Computer Assisted Recognition, Washington, DC, SPIE, pp 221-232.

Guo B., Damper R.I., Gunn S.R. (2008) "A fast separability-based feature-selection method for high-dimensional remotely sensed image classification" **Pattern Recognit.** 41(5), pp 1653-1662.

Harris J.R., Rogge D., Hitchcock R., Ijewliw O., Wright, D. (2005) "Mapping Lithology in Canada's Arctic: application of hyperspectral data using the minimum noise fraction transformation and matched filtering" **Can. J. Earth Sci.**, 42, pp 2173-2193.

Heikkila J. (1992) "ESTIMATION OF CLASSIFIER'S PERFORMANCE WITH ERROR COUNTING" XVIIth ISPRS Congress, Technical Commission III: Mathematical Analysis of Data, Washington, D.C., USA, August 2-14, 325-334.

Hellman M.J. and Ramsey M.S. (2004) "ER and AVIRIS remote sensing" **J. Volcanol. Geotherm. Res.**, 135, pp 195-219.

Heylen R., Parente M., Gader P. (2014) "A review of nonlinear hyperspectral unmixing methods" **IEEE J. Sel. Topics Appl. Earth Observ. in Remote Sens.**, 7(6), pp 1844-1868

Hosseinjani Zadeh M., Tangestani M.H., Velasco Roldan F., Yusta I. (2014a) "Sub-pixel mineral mapping of a porphyry copper belt using EO-1 Hyperion data" **Adv. Space Res.**, 53(3), pp 440-451.

Hosseinjani Zadeh M., Tangestani M.H., Velasco Roldan F., Yusta I. (2014b) "Mineral exploration and alteration zone mapping using mixture tuned matched filtering approach on ASTER data at the central part of Dehaj-Sarduiyeh copper belt, SE Iran" **IEEE J-STARS.**, 7(1), pp 284-289.

- Huang J., Cai Y., Xu X. (2006) A wrapper for feature selection based on mutual information, in: Proceedings of the 18th International Conference on Pattern Recognition (August 20-24, 2006), ICPR, vol. 02, IEEE Computer Society, Washington, DC, pp. 618–621.
- Huang C., Song K., Kim S., Townshend J.R.G., Davis P., Masek J.G., Goward S.N. (2008) “Use of dark object concept and support vector machines to automate forest cover change analysis” **Remote Sens. Environ.**, 112(3), pp 970-985.
- Huang H., Gong P., Clinton N., Hui F. (2008) “Reduction of atmospheric and topographic effect on Landsat TM data for forest classification” **Int J Remote Sens.**, 29 (19), pp 5623-5642.
- Huang X. and Zhang L. (2009) “Road centerline extraction from high-resolution imagery based on multi scale structural features and support vector machines” **Int J Remote Sens.**, 30, pp 1977-1987.
- Hui-Huang H., Cheng-Wei H. (2011) “Hybrid feature selection by combining filters and wrappers” **Expert Syst. Appl.**, 38, pp 8144-8150.
- Inglada J. (2007) “Automatic recognition of man-made objects in high resolution optical remote sensing images by SVM classification of geometric image features” **ISPRS J. Photogramm. Remote Sens.**, 62, pp 236-248.
- Iranzad A., (2013), Msc thesis, “Hyperspectral Mineral Identification using SVM and SOM”, Faculty of Mathematics and Science, Brock University St. Catharines, Ontario.
- Jia X., Dey C., Fraser D., Lymburner L., Lewis A., (2010) “Controlled spectral unmixing using extended support vector machines” *Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS)*, pp 1-4, Reykjavik.
- Karimpouli S. and Malehmir A. (2015) “Neuro-Bayesian facies inversion of prestack seismic data from a carbonate reservoir in Iran” **J. Pet. Sci. Eng.**, 131, pp 11-17.
- Keramitsoglou I., Sarimveis H., Kiranoudis C.T., Kontoes C., Sifakis N., Fitoka E. (2006) “The performance of pixel window algorithms in the classification of habitats using VHSR imagery” **ISPRS J. Photogramm. Remote Sens.**, 60, pp 225-238.
- Kevin A.R. and Ramsey M.S. (2013) “Exploration of geothermal systems using hyperspectral thermal infrared remote sensing” **J. Volcanol. Geotherm. Res.**, 265, pp 27-38.
- Kozak P.K., Duke E.F., Roselle G.T. (2004) “Mineral distribution in contact metamorphosed siliceous dolomite at Ubehebe Peak, California, based on airborne imaging spectrometer data” **Am. Mineral.**, 89, pp 701-713.

Kratt C., Calvin W.M., Coolbaugh M.F. (2010) "Mineral mapping in the Pyramid Lake basin: hydrothermal alteration, chemical precipitates and geothermal energy potential" **Remote Sens. Environ.**, 114, pp 2297-2304.

Kruse F.A. (2003) "Mineral Mapping with AVIRIS and EO-1 Hyperion" Presented at the 12th JPL Airborne Geoscience Workshop, Pasadena, California.

Kruse F.A., Boardman J.W., Huntigton J.F. (2003) "Comparison of airborne Hyperspectral data and EO-1 Hyperion for mineral mapping" **IEEE Trans. Geosci. Remote Sens.**, 41, pp 1388-1400.

Kruse F.A., Perry SL, Caballero A. (2006) "District-level mineral survey using airborne hyperspectral data, Los Menucos, Argentina" **Ann Geophys**, 49, pp 83-92.

Kwiatkowska E.J., Fargion G.S. (2003) "Application of machine-learning techniques toward the creation of a consistent and calibrated global chlorophyll concentration baseline dataset using remotely sensed ocean color data" **IEEE Trans. Geosci. Remote Sens.**, 41, pp 2844-2860.

Landgrebe D.A. (2002) "Hyperspectral Image Data Analysis" **IEEE Signal processing Magazine**, 19, pp 17-28.

Lardeux C., Frison P.L., Tison C., Souyris J.C., Stoll B., Fruneau B., Rudant J.P. (2009) "Support vector machine for multifrequency SAR polarimetric data classification" **IEEE Trans. Geosci. Remote Sens.**, 47, pp 4143-4152.

Lazar C., Taminau J., Meganck S., Steenhoff D., Coletta A., Molter C., de Schaet-zen V., Duque R., Bersini H., Nowe A. (2012) "A survey on filter techniques for feature selection in gene expression microarray analysis" **IEEE/ACM Trans. Comput. Biol. Bioinf.**, 9(4), pp 1106-1119.

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" **KNOWL-BASED SYST**, 24, pp 40-48.

Liao L., Jarecke P., Gleichauf D., Hedman T. (2000) "Performance and characterization of the Hyperion imaging spectrometer instrument" **Earth Observing Systems**, V, 22-34.

Lillesand, T.M., Kiefer, R.W., Chipman, J.W. (1994) "**Remote Sensing and Image Interpretation**" New York, John Wiley & Sons.

Liu D., Sun DW., Zeng XA. (2014) "Recent Advances in Wavelength Selection Techniques for Hyperspectral Image Processing in the Food Industry" **FOOD BIOPROCESS TECH**, 7(2), pp 307-323.

Luo J, Ming D, Liu W, Shen Z, Wang M., Sheng H. (2007) "Extraction of bridges over water from IKONOS panchromatic data" **Int J Remote Sens.**, 28, pp 3633-3648.

- Mandrake L., Wagstaff K.L., Gleeson D., Rebbapragada U., Tran D., Castaño R., Chien S., Pappalardo R.T. (2009) "Onboard SVM analysis of Hyperion data to detect sulfur deposits in arctic regions" pp 1-4, Grenoble.
- Martin G.K. and Hirschberg D.S. (1996) "Small Sample Statistics for Classification Error Rates" Technical report, No, 96-21. Department of Information and Computer Science, University of California.
- Mianji F.A. and Zhang Y. (2011) "SVM-Based Unmixing-to-Classification Conversion for Hyperspectral Abundance Quantification" **IEEE Trans. Geosci Remote Sens.**, 49, pp 4318-4327.
- Moeinzadeh H., Fallahi H., Abbasnejad A., Goodarzi Mehr S., Bahrambeygi B. (2013) "Application of Support Vector Machine method in Hyperspectral mapping of Ophiolite mélanges-a Case study from eastern Iran" **JTethys**, 1, pp 315-326.
- Moradkhani M., Amiri A., Javaherian M., Safari H. (2015) "A hybrid algorithm for feature subset selection in high-dimensional data sets using FICA and IWSSr algorithm" **Appl Soft Comput.**, 35, pp 123-135.
- Mountrakis G., Im J., Ogole C. (2011) "Support vector machines in remote sensing: A review" **ISPRS J Photogramm Remote Sens**, 66, pp 247-259.
- NICICO. (2008) "Darrehzar ore reserve estimates" Internal report of National Iranian Copper Industries Company.
- Okujeni A., van der Linden S., Tits L., Somers B., Hostert P. (2013) "Support vector regression and synthetically mixed training data for quantifying urban land cover" **Remote Sens Environ.**, 137, pp 184-197.
- Oommen T. (2008) "An objective analysis of Support Vector Machine based classification for remote sensing" **Math Geosci**, 40, pp 409-424.
- Pal M. and Foody G.M. (2010) "Feature Selection for Classification of Hyperspectral Data by SVM" **IEEE Trans. Geosci Remote Sens.**, 48(5), pp 2297-2307.
- Pal M. and Mathur P. M. (2005) "Support vector machines for classification in remote sensing" **Int J Remote Sens.**, 26, pp 1007-1011.
- Pant R., Trafalis T.B., Barker K. (2011) "Support Vector Machine Classification of Uncertain and Imbalanced data using Robust Optimization" 15th World Scientific and Engineering Academy and Society International Conference on Computers, pp 369-374, Corfu Islands, Greece.
- Petropoulos G.P., Kalaitzidis C., Prasad Vadrevu K. (2012) "Support vector machines and object-based classification for obtaining land-use/cover cartography from Hyperion hyperspectral imagery" **Comput. Geosci.**, 41, pp 99-107.

Petropoulos G.P., Kontoes C., Keramitsoglou I. (2011) "Burnt Area Delineation from a uni-temporal perspective based on Landsat TM imagery classification using Support Vector Machines" **Int. J. Appl. Earth Obs. Geoinf.**, 13(1), pp 70-80.

Plaza A., Benediktsson J.A., Boardman J.W., Brazile J., Bruzzone L., Camps-Valls G., Chanussot J., Fauvel M., Gamba P., Gualtieri A., Marconcini M., Tilton J.C., Trianni G. (2009) "Recent advances in techniques for hyperspectral image processing" **Remote Sens Environ.**, 113, pp 110-122.

Qi Z., Tian Y., Shi Y. (2013) "Robust twin support vector machine for pattern classification" **PATTERN RECOGN**, 46, pp 305-316.

Ranjbar H., Hassanzadeh H., Torabi M. (2001) "Integration and analysis of airborne geophysical data of the Darrehzar area, Kerman Province, Iran, using principal component analysis" **J. Appl. Geophys.**, 48(1), pp 33-41.

Rivard B., Zhang J., Feng J., Sanchez-Azofeifa G.A. (2009) "Remote predictive lithologic mapping in the Abitibi Greenstone Belt, Canada, using airborne hyperspectral imagery" **Can J Remote Sens.**, 35, pp 95-105.

Rockwell B.W., Hofstra A.H. (2008) "Identification of quartz and carbonate minerals across northern Nevada using ASTER thermal infrared emissivity data-implications for geologic mapping and mineral resource investigations in well-studied and frontier areas" **Geosphere**, 4, pp 218-246.

Rowan L.C., Crowley J.K., Schmidt R.G., Ager C.M., Mars J.C. (2000) "Mapping hydrothermally altered rocks by analyzing hyperspectral image (AVLRIS) data of forested areas in the Southeastern United States" **J. Geochem. Explor.**, 68, pp 145-166.

Roy R., Launeau P., Carrere V., Pinet P., Ceuleneer G., Clenet H., Daydou Y., Girardeau J., Amri I. (2009) "Geological mapping strategy using visible near-infrared-shortwave infrared hyperspectral remote sensing: Application to the Oman ophiolite (Sumail Massif)" **Geochem. Geophys. Geosyst.**, 10, pp 1-23.

Seng D., and Chen W. (2009) "Application of RS theory and SVM in the ore-rock classification" **Computational Intelligence and Software Engineering, International Conference on CiSE**, pp 11-13 December, 1-4.

Scavetti M., Longhi I., Meli S., Pompilio L. (2006) "Accuracy in mineral identification: image spectral and spatial resolutions and mineral spectral properties" **ANNALS OF GEOPHYSICS**, 49(1), pp 261-270.

Shafiei B. and Shahabpour J. (2012) "Geochemical aspects of molybdenum and precious metals distribution in the Sarcheshmeh porphyry copper deposit Iran" **Miner Deposita**, 47(5), pp 535-543.

Shahriari H., Honarmand M., Ranjbar H. (2015) "Comparison of multi-temporal ASTER images for hydrothermal alteration mapping using a fractal-aided SAM method" **Int. J. Remote Sens.**, 36(5), pp 1271-1289.

- Shahriari H., Ranjbar H., Honarmand, M. (2013) "Image Segmentation for Hydrothermal Alteration Mapping Using PCA and Concentration-Area Fractal Model" **Natural Resources Research**, 22(3), pp 191-206.
- Shirvani S.H.E. and Aghagolzadeh A. (2014) "Rapid Classification of Mixed Hyperspectral Data by ROAA SVM" Intelligent Systems (ICIS), pp 1-6, Iran.
- Song M., Civco D. (2004) "Road extraction using SVM and image segmentation" **Photogramm Eng Remote Sensing**, 70, pp 1365-1371.
- Sun L. and Gao W. (2000) "Selection the optimal classification bands based on rough sets" **Pattern Recognit. Artif. Intell.**, 13 (2), pp 181–186.
- Sun D., Li Y., Wang Q. (2009) "A unified model for remotely estimating chlorophyll a in Lake Taihu, China, based on SVM and in situ hyperspectral data" **IEEE Trans. Geosci. Remote Sens.**, 47, pp 2957-2965.
- Tan P.N., Steinbach M., Kumar V. (2005) "**Introduction to Data Mining**", 1st Edition, Published by Addison-Wesley Longman, Inc., Boston, MA, USA, 769p.
- Van der Meer F. and Van der Werff H. (2007) "Spatial-spectral contextual image analysis of hyperspectral data to aid in the characterisation of hydrothermal alteration in epithermal gold deposits" *New Developments and Challenges in Remote Sensing*, pp 275-285, Rotterdam, Netherland.
- Vaughan R.G., Hook S.J., Calvin W.M., Taranik J.V., (2005) "Surface mineral mapping at Steamboat Springs, Nevada, USA, with multi-wavelength thermal infrared images" **Remote Sens. Environ.**, 99, pp 140-158.
- Wang L., Jia X. (2009) "Integration of Soft and Hard Classifications Using Extended Support Vector Machines" **IEEE Trans. Geosci. Remote Sens.**, 6, pp 543-547.
- Wang X., Niu R., Wu K. (2011) "Lithology intelligent identification using support vector machine and adaptive cellular automata in multispectral remote sensing image" **Opt. Eng.**, 50, pp 1-13.
- Wang J. and Wu L. (2013) "Maximum weight and minimum redundancy: A novel framework for feature subset selection" **Pattern Recognit.**, 46(6), pp 1616-1627.
- Wang L., Gu Y., Zhang Y. (2005) "Band selection method based on combination of support vector machines and subspectral partition" **Syst. Eng. Electron.**, 279(6), pp 974-977.
- Wang ZH. and Zheng, CY. (2010) "Rocks/Minerals Information Extraction from EO-1 Hyperion Data Base on SVM" *International Conference on Intelligent Computation Technology and Automation*, 229-232.

- Waske B., Benediktsson J.A, Arnason K., Sveinsson J.R. (2009) "Mapping of hyperspectral AVIRIS data using machine-learning algorithms" **Can J Remote Sens.**, 35, pp 106-116.
- Waterman G. and Hamilton N. (1975) "The Sarcheshme Phorphyr copper deposit" **Econ. Geol.**, 70, pp 568–576.
- Wilson M.D., Ustin S.L., Rocke D.M. (2004) "Classification of contamination in salt marsh plants using hyperspectral reflectance" **IEEE Trans. Geosci. Remote Sens.**, 42, pp 1088-1095.
- Windeler D.S. (1993) "Garnet-pyroxene alteration mapping in the Ludwig Skarn (Yerington, Nevada) with Geoscan airborne multispectral data" **Photogramm. Eng. Remote Sens.**, 59, pp 1277-1286.
- Yanfeng Gu., Wang S., Xiuping J. (2013) "Spectral Unmixing in Multiple-Kernel Hilbert Space for Hyperspectral Imagery" **IEEE Trans. Geosci Remote Sens.**, 51, pp 3968-3981.
- Yang K., Browne P.R.L., Huntington J.F., Walshe J.L., (2001) "Characterising the hydrothermal alteration of the Broadlands-Ohaaki geothermal system, New Zealand, using short-wave infrared spectroscopy" **J. Volcanol. Geotherm. Res.**, 106, pp 53-65.
- Yang K., Huntington J.F., Browne P.R.L., Ma C. (2000) "An infrared spectral reflectance study of hydrothermal alteration minerals from the Te Mihi sector of the Wairakei geothermal system, New Zealand" **Geothermics**, 29, pp 377-392.
- Yaozhong P., Tangao H., Xiufang Z., Jinshui Z., Xiaodong W. (2012) "Mapping Cropland Distributions Using a Hard and Soft Classification Model" **IEEE Trans. Geosci Remote Sens.**, 50(11), pp 4301-4312.
- Yusta S.C. (2009) "Different metaheuristic strategies to solve the feature selection problem" **Pattern Recognit. Lett.**, 30(5), pp 525-534.
- Zhang X. and Peijun L. (2014) "Lithological mapping from hyperspectral data by improved use of spectral angle mapper" **Int. J. Appl. Earth Obs. Geoinf**, 31, pp 95-109.
- Zhu G., Blumberg D.G. (2002) "Classification using ASTER data and SVM algorithms" **Remote Sens Environ.**, 80, pp 233-240.
- Zollanvari A., Braga-Neto U.M, Dougherty E.R. (2010) "Joint Sampling Distribution Between Actual and Estimated Classification Errors for Linear Discriminant Analysis" **IEEE Trans. Inf. Theory**, 56(2), 784 – 804.
- Zuo R. and Carranza M.E.J. (2011) "Support vector machine: a tool for mapping mineral prospectivity" **Comput. Geosci.**, 37, pp 1967-1975.





# Abstract

Hyperspectral sensors have more spectral bands than multispectral types, and thus are capable of recording more accurate spectral information of ground surface. This advantage can disturb process of hyperspectral data classification and reduces its accuracy. In addition, Hyperion data as a kind of the hyperspectral images also suffers from noise.

In this research, we try to minimize the effects of these problems by means of data mining techniques. Because of the high efficiency of kernel-based methods for high dimensional data classification, the Support Vector Machine (SVM) method was used to classify Hyperion hyperspectral Data. The noise in the Hyperion data was also covered by the implementation of the Robust-SVM – the noise resistant version of SVM. Another way to overcome these problems is to use data reduction techniques.

The above mentioned methods and Hyperion image were used to identify alterations of Sarcheshmeh and Darrehzar mines and Sereidun district. In the first step, the use of a feature selection method led to the identification of approximately 11% (18 bands) of the entire spectral bands of Hyperion (165 bands). The results revealed that the Robust-SVM produces more accurate alteration maps than standard SVM. But the most accurate results were obtained when the classification was performed using Robust-SVM and selected bands introduced by the feature selection method. In this case, the Kappa coefficient of classification was 0.61, which compared with the standard SVM using selected spectral bands (0.53), the Robust-SVM with total spectral bands (0.49) and the standard SVM with total spectral bands (0.41) is the most accurate.

Also, Support Vector Regression (SVR) was used to perform subpixel classification. It was resulted that the sub-pixel map obtained by the SVR even with the entire spectral bands (i.e. not with the selected spectral bands) and in the standard mode (i.e. not robust SVR) is more precise than the pixel based maps of SVM and Robust-SVM.

**Keywords:** Alteration, Remote sensing, Classification, Hyperspectral, SVM, Hyperion





Shahrood University of Technology

Faculty of Mining, Petroleum and Geophysics  
Engineering

Ph.D. Thesis in Mineral Exploration

# Using robust noise Support Vector Machine and Hyperion hyperspectral data to classify alteration zones

By: Amir Salimi

Supervisor:  
Dr. Mansour Ziari

Advisors:  
Dr. Ali Amiri  
Dr. Mahdiah Hosseinjani Zadeh

February 2017