

## ترکیب تصاویر ابر طیفی هوایی و داده های لیدار برای تولید عوارض شهری

سید یوسف سجادی<sup>۱\*</sup>، امید آینه<sup>۲</sup>

۱- استادیار دانشکده نقشه برداری دانشگاه تفرش

۲- دانشجوی کارشناسی ارشد دانشکده نقشه برداری دانشگاه تفرش

تاریخ دریافت مقاله: ۱۳۹۶/۱۰/۲۰ تاریخ پذیرش مقاله: ۱۳۹۶/۱۰/۲۰

### چکیده

در این مقاله به منظور شناسایی و استخراج عوارض مختلف شهری به صورت خودکار از تصاویر فتوگرامتری روشی ارائه شده که در آن از ترکیب داده های لیدار و ابر طیفی استفاده می شود. مهمترین مشکل تصاویر ابر طیفی تعداد زیاد باندها و وابستگی بالای بین آنها و نیز نسبت سیگنال به نویز متفاوت در باندهای مختلف می باشد، در این تحقیق به منظور کاهش ابعاد فضای داده، کمینه کردن نویز و وابستگی طیفی بین باندها، جهت دست یافتن به نتایج بهتر، از روش کاهش نویز کمینه (MNF) استفاده می شود، با اعمال این روش تصاویر ابر طیفی با ۱۴۴ باند به ۱۹ باند تبدیل یافته مناسب کاهش می یابند. سپس از ابر نقاط لیدار تصاویر ارتفاعی و شدت بازگشت های اول و آخر لیزر تولید می شوند. در نهایت ۱۹ تصویر تبدیل یافته حاصل از تصاویر ابر طیفی با ۴ تصویر تولید شده از داده های لیدار در سطح پیکسل باهم ادغام می شوند و تصویری با ۲۳ ویژگی مناسب به وجود می آید. به منظور شناسایی و استخراج هر کدام از عوارض منطقه، هفت ماشین یادگیری بردار پشتیبان (SVM) اجرا می شوند و نهایتاً با ادغام اطلاعات در سطح تصمیم که با رأی گیری بین ۷ جواب به دست آمده، انجام می شود، کلاس مربوط به هر پیکسل مشخص می گردد. در ادامه از عملکر انسداد مورفو لوژی ریاضی برای ترمیم ساختمان ها و از تبدیل هاف برای بازسازی شبکه حمل و نقل استفاده می شود تا عوارض ساخت دست بشر دارای ساختاری منظم تر بشوند و حضور پیکسل های منفرد نیز کاهش یابد. روش فوق روی یک مجموعه داده مربوط به محوطه دانشگاه هیوستن آمریکا پیاده سازی شده است. این مجموعه داده همراه با داده های جانی شامل نمونه های آموزشی و آزمایشی دقیق، توسط انجمن سنجش از دور و علوم زمین مهندسان برق و الکترونیک در سال ۲۰۱۲ برداشت شده و پیشتر در یک مسابقه بین المللی ادغام داده مورد استفاده قرار گرفته اند.

کلید واژه ها : تصاویر ابر طیفی، لیدار، ماشین بردار پشتیبان، مورفو لوژی، ادغام.

\* نویسنده مکاتبه کننده: تفرش، ابتدای جاده تهران، دانشگاه تفرش، دانشکده مهندسی نقشه برداری، کد پستی ۳۹۵۱۸-۷۹۶۱۱

تلفن: ۰۹۱۲۶۹۴۱۸۸۵ - ۰۸۶۳۶۲۴۱۲۹۰

## ۱- مقدمه

اما در صورتی که فرایند ادغام داده‌ها به درستی صورت بگیرد، مجموعه‌ای از اطلاعات در اختیار خواهد بود که به کمک آن‌ها می‌توان عوارض را با بالاترین دقت ممکن استخراج کرد. از آنجایی که داده‌های مورد استفاده در این مقاله، داده لیدار و تصویر ابرطیفی می‌باشد، داده‌ی لیدار می‌تواند خصوصیات هندسی و مکانی عوارض موجود در منطقه را به خوبی نمایش دهد، اما تصویر ابرطیفی قابلیت بسیار بالایی در شناسایی انواع عوارض بر اساس خصوصیات طیفی را داراست و کارکرد آن از لحاظ برداشت خصوصیات هندسی ضعیف است. کاربرد داده‌ی لیدار در سنجش از دور و فتوگرامتری محدود به عوارضی است که دارای تغییرات ارتفاعی محلی نسبت به عوارض مجاور خود هستند و امکان شناسایی کلاس‌های طیفی در آن ممکن نیست. در استخراج عوارض شهری بویژه ساختمان خصوصیات هندسی و مکانی مناسب‌ترین ویژگی‌ها هستند. بنابراین، استفاده از داده‌ی لیدار در کنار تصویر ابرطیفی می‌تواند به عنوان یک مکمل یکدیگر عمل کنند. ادغام داده‌های سنجش از دوری می‌تواند در چندین سطح صورت گیرد. به‌طور کلی سه سطح برای ادغام داده‌ها مطرح است: ادغام تصاویر در سطح پیکسل، ادغام تصاویر در سطح عارضه و ادغام تصاویر در سطح تصمیم. در ادغام تصاویر در سطح پیکسل، همه‌ی تصاویر به صورت مستقیم و بدون انجام هر گونه پردازش‌های ثانویه با یکدیگر تلفیق می‌شوند. در ادغام تصاویر در سطح عارضه، تمامی تصاویر در راستای استخراج یک عرضه با یکدیگر ادغام می‌شوند و در ادغام داده‌ها در سطح تصمیم، همه‌ی عوارض در هر کدام از تصاویر به کمک روش‌های استخراج عارضه از تصاویر استخراج می‌شوند و پس از استخراج تمامی عوارض مورد نظر در همه‌ی تصاویر، عوارض با یکدیگر ادغام می‌شوند. اغلب روش‌های ادغام داده‌ی موجود، از روش ادغام داده در سطح تصمیم و عارضه استفاده می‌کنند. در ادغام داده‌ها در سطح پیکسل، امکان حضور نویز در هر کدام

با پیشرفت علم فتوگرامتری در زمینه‌ی تولید سنجنده‌های جدید با قدرت تفکیک طیفی و مکانی بالاتر و تهییه‌ی تصاویری از سطح زمین با سطح نویز پایین‌تر، همواره ارائه‌ی روش‌هایی جهت استخراج عوارض گوناگون از این تصاویر به عنوان موضوعی مهم مد نظر دانشمندان و محققین بوده است. وجود سنجنده‌های مختلف همواره باعث مطرح شدن از سنجنده‌های مختلف همواره باعث مطرح شدن این سوال بوده است که آیا وجود تفاوت بین داده‌های مختلف امکان تکمیل اطلاعات موجود از عوارض را فراهم می‌کند یا خیر؟ پاسخ‌های فراوانی به این سوال داده شده است که از جمله‌ی آن‌ها می‌توان تعریف قیدهای خاص جهت ادغام داده‌های مختلف را نام برد [۱]، که طبق آن، باید همپوشانی طیفی و مکانی در بین داده‌ها وجود داشته باشد. در نتیجه، نمی‌توان هر داده‌ای را با داده‌های دیگر تلفیق کرد و لازم است تا مقایسه‌ای اولیه بین داده‌ها صورت گیرد. در صورتی که تنها یک تصویر از منطقه‌ی مورد نظر وجود داشته باشد، الگوریتم‌هایی که جهت استخراج عوارض معرفی خواهند شد، محدود به باندهای طیفی و قدرت تفکیک مکانی مربوط به همان تصویر خواهد بود که امکان عدم استخراج کامل عوارض مورد نظر به‌دلیل کافی نبودن داده‌های اولیه وجود خواهد داشت، ولی در صورت استفاده از مجموعه‌ای از داده‌های طیفی و مکانی به طور همزمان که دارای خصوصیات متفاوتی هستند، امکان شناسایی و استخراج عوارض موجود افزایش خواهد یافت. هدف اصلی در ادغام داده‌ها را می‌توان دست‌یابی به دقت بیشتر و یا استخراج تعداد بیشتری از عوارض دانست که با استفاده از یک دسته از داده‌ها قابل استخراج نباشد. اگر با افزودن داده‌ی جدید، دقت استخراج عوارض و یا تعداد عوارض استخراج شده تغییری نکند و یا میزان تغییرات کم باشد، در آن صورت استفاده از داده‌ی جدید تنها حجم محاسبات را افزایش داده است و استفاده از آن بی ارزش خواهد بود.

ارتفاع به ترتیب از تصاویر ابرطیفی و لیدار موجود از منطقه به عنوان ویژگی‌های مورد نظر انتخاب شدند و سپس، با تعریف قیدهایی در مورد ارتفاع و شاخص پوشش گیاهی عوارض مورد استخراج شدند. در روش نظارت شده با استفاده از روش کاهش ابعاد MNF و روش طبقه‌بندی (RF) به شناسایی و استخراج عوارض پرداختند سپس جواب‌های به دست آمده با یکدیگر ترکیب شده و بر روی آن‌ها رأی‌گیری انجام شد و در نهایت یک مرحله ترمیم و بازسازی اعمال گردید. عباسی و همکاران در سال ۲۰۱۵، از ادغام داده لیدار و ابرطیفی برای طبقه‌بندی از روش بیشترین شباهت استفاده کردند<sup>[۸]</sup>، از روش داده لیدار ماتریس رخداد توان (GLCM)<sup>۳</sup> و بر روی تصویر ابرطیفی روش‌های تحلیل مولفه‌های اصلی (PCA<sup>۴</sup>) و کسر نویز کمینه (MNF<sup>۵</sup>) را اعمال کردند سپس روی هر کدام از ویژگی‌ها روش طبقه‌بندی بیشترین شباهت اعمال گردید و در نهایت جواب‌های به دست آمده با الگوریتم بیزن ادغام شدند.

از بین همه‌ی روش‌های یادگیری ماشین جهت طبقه‌بندی عوارض، بیشتر از روش ماشین‌بردار پشتیبان استفاده شده، چون این روش با کمترین داده‌های آموزشی می‌تواند بهترین طبقه‌بندی را ارائه کند و از همه مهم تر اینکه این روش کمتر دچار مشکل بیش برآش<sup>۶</sup> می‌شود.

هدف اصلی این پژوهش استخراج عوارض مختلف شهری به کمک ادغام تصاویر ابرطیفی هوایی و داده لیدار است. برای این منظور در این تحقیق از روش ماشین‌بردار پشتیبان به گونه متفاوتی بهره‌گرفته شده است. بدین ترتیب که برای تعیین کلاس نهایی هر پیکسل، بین چند نتایج ماشین‌بردار

از باندها و انتقال آن به دیگر باند ها و در نتیجه امکان تولید خطا در نتایج کلاس‌بندی وجود دارد. در روش ادغام بر مبنای تصمیم، رأی‌گیری بیشترین نقش را ایفا می‌کند [۲]. بدین منظور مقالات زیادی به استفاده از روش رأی اکثریت در روش‌های فتوگرامتری و سنجش از دور پرداخته‌اند که از این میان می‌توان به مقالات [۲، ۳ و ۴]<sup>۷</sup>، اشاره کرد. روش‌های رأی‌گیری وزن دار نیز برای ادغام نتایج حاصل از چند طبقه‌بندی کننده با دقت‌های متفاوت ارائه شده‌اند که به وزن دهی به نتایج بر اساس کیفیت و دقت هر کدام از روش‌های طبقه‌بندی کننده می‌پردازند [۱ و ۵].

روش ادغام نتایج براساس الگوریتم بیزن<sup>۸</sup>. توسط ژنگ در سال ۲۰۰۵ مورد استفاده قرار گرفت. وی از روش ادغام براساس الگوریتم بیزن برای ادغام نتایج چندین روش مختلف پردازش تصویر برای تشخیص بیماری استفاده کرد. در سال ۲۰۱۴ بیگدلی و همکارانش روشی برای طبقه‌بندی عوارض شهری از تلفیق تصاویر ابرطیفی و لیدار ارائه کردند [۶]. به این منظور ابتدا چند بردار ویژگی از تصویر حاصل از داده‌ی لیدار و تصویر ابرطیفی تولید کردند، سپس چندین روش ماشین‌بردار پشتیبان بر اساس هر کدام از بردارهای ویژگی آموزش داده شدند و چندین کلاس‌بندی متفاوت تولید کردند و در آخر بین نتایج به دست آمده به روش بیزن رأی‌گیری انجام شد و بدین ترتیب عوارض موجود از منطقه استخراج شدند. روش برگزیده ادغام داده‌ها توسط انجمن سنجش از دور و علوم زمین (IEEE) در سال ۲۰۱۴ ارائه گردیده است. این روش، از دو روش مختلف جهت کلاس‌بندی تصاویر موجود استفاده می‌کند [۸]. اولین مرحله‌ی روش برگزیده، کلاس‌بندی نظارت نشده است. در کلاس‌بندی نظارت نشده، ابتدا شاخص پوشش گیاهی و

<sup>۳</sup> Random Forest

<sup>۴</sup> Gray Level Co-Occurrence Matrix

<sup>۵</sup> Principal Component Analysis

<sup>۶</sup> Minimum Noise Fraction

<sup>۷</sup> Overfitting

<sup>۸</sup> Bayesian Theorem

<sup>۹</sup> Institute of Electrical and Electronics Engineers

با سیستم مختصات جغرافیایی GCS-83 اخذ شده‌اند. لذا، نیازی به تبدیل سیستم مختصات در منطبق کردن تصاویر نیست و می‌توان از آن‌ها مستقیماً در تشکیل تصویر و انجام محاسبات استفاده کرد. شکل (۱) ترکیب رنگی کاذب منطقه را نشان می‌دهد.

## ۲-۲- روشهای MNF کاهش ابعاد فضای ویژگی

روش MNF که حالت تعمیم یافته روش PCA است، یک فضای تبدیل یافته ایجاد می‌کند که در آن بر اساس ابعاد بالای فضای اولیه به شناسایی موقعیت پیکسل‌های نویزی می‌پردازد و پس از حذف آن‌ها و تولید باندهای طیفی فارغ از نویز، از حجم پردازشی تصویر اولیه می‌کاهد [۱۱]. روش کار بدین ترتیب است: اگر تصویر ابرطیفی با  $d$  باند در اختیار داشته باشیم که تعداد پیکسل‌های هر باند آن برابر با  $n$  باشد، تصویر اصلی را می‌توان به صورت برداری  $X_{n \times d}$  نمایش داد. رابطه (۱) [۱۲]:

$$X = (X_1, \dots, X_n)^T \quad (1)$$

هر بردار طیفی موجود برای هر پیکسل که شامل مقادیر طیفی ثبت شده برای یک پیکسل در باندهای طیفی مختلف است را می‌توان به صورت حاصل جمع سیگنال و نویز به صورت رابطه (۲) بیان کرد [۱۲]:

$$X_i = S_i + N_i \quad (2)$$

با فرض عدم وابستگی سیگنال و نویز می‌توان به رابطه (۳) دست یافت [۱۲]:

$$\Sigma_X^T = \Sigma_S^T + \Sigma_N^T. \quad (3)$$

که در آن برای تمام مقادیر  $i$  داریم:  $\Sigma_X^N = cov(N_i)$ ،  $\Sigma_S^T = cov(S_i)$ ،  $\Sigma_X^T = cov(X_i)$  عبارتند از: ماتریس‌های کواریانس مجموع، سیگنال و نویز. تبدیل MNF، تعداد  $d$  ترکیب خطی بدون وابستگی به صورت رابطه (۴) را محاسبه می‌کند [۱۲]:

$$v_{ik} = a_k^T X_i, \quad k = 1, 2, \dots, d \quad (4)$$

این رابطه، به خوبی می‌تواند مقدار نویز را کمینه کند. از تعریف ارائه شده در رابطه (۳) به سادگی می‌توان

پشتیبان مختلف رایگیری انجام می‌شود. در نهایت از عملگرهای مورفولوژی ریاضی برای ترمیم شکل ساختمان‌ها و از تبدیل هاف برای بازسازی عوارض شبکه‌ی حمل و نقل زمینی و استخراج ردیف درخت‌کاری بر روی نتایج بدست آمده استفاده می‌شود تا عوارض ساخته شده توسط انسان دارای ساختاری منظم تر بشوند.

## ۲- مواد و روش‌ها

در ادامه به معرفی داده‌های مورد استفاده و روش‌های استفاده شده پرداخته می‌شود.

## ۲-۱- داده‌های مورد استفاده و منطقه مورد مطالعه

داده‌های مورد استفاده توسط انجمن سنجش از دور و علوم زمین مؤسسه IEEE از محوطه دانشگاه هیوستن<sup>۱</sup> آمریکا در سال ۲۰۱۲ برداشت شده‌اند. این مجموعه داده شامل دو منبع داده است که منبع اول شامل تصویر ابرطیفی است که دارای ۱۴۴ باند طیفی در حوزه‌های مرئی و مادون قرمز نزدیک و میانی است. قدرت تفکیک مکانی تصویر ابرطیفی اخذ شده ۲/۵ متر و ابعاد آن ۱۹۰۵ در ۳۴۹ پیکسل است. منبع دوم شامل ابر نقطه‌ای سنجنده‌ی لیدار هوایی با تراکم ۱ نقطه در هر ۲/۵ متر مربع است که به عبارتی دیگر می‌توان قدرت تفکیک مکانی مربوط به تصویری که از آن حاصل خواهد شد را ۲/۵ متر در نظر گرفت. این مجموعه داده شامل امواج بازگشته از عوارض منطقه در ۵ سطح مختلف است که میزان نفوذ امواج در عوارضی مانند پوشش گیاهی که سطحی غیر منظم و متخلخل و قابل نفوذ دارند را نشان می‌دهد. تصویر ابرطیفی و نقاط لیدار نویز در سیستم تصویر یو تی ام (UTM) و در زون ۱۵ شمالی

<sup>1</sup> Huston

<sup>2</sup> Point Cloud

<sup>3</sup> Universal Transvers Marcatur

ماتریس  $\Sigma_X^S$  می‌پردازیم. اگر سیگنال و نویز با یکدیگر دارای همبستگی نباشند، از روابط (۳ و ۴) خواهیم داشت (رابطه (۱۰)):

$$A\Sigma_X^T A^T = \Lambda + I, \quad A\Sigma_X^N A^T = I \quad (10)$$

در نتیجه، بردارهای ویژه حاصل از قطری سازی  $\Sigma_X^T$  و  $\Sigma_X^N$  با بردارهای ویژه حاصل از قطری سازی  $\Sigma_X^S$  و  $\Sigma_X^N$  برابرند و مقادیر ویژه آنها به صورت رابطه (۱۱) محاسبه می‌شوند [۱۲]:

$$\mu_i = \lambda_i + 1, \quad i = 1, 2, \dots, d \quad (11)$$

باید توجه شود که در صورت استفاده از ماتریس کواریانس نمونه، روابط (۳، ۱۰ و ۱۱) به صورت تقریبی برقرار هستند. به عنوان یکی از دلایل آن نیز می‌توان امکان کوچک تر بودن  $\mu_i$  از ۱ را در تصاویر ابرطیفی عنوان کرد. با این وجود، چنین اتفاقی معمولاً در باند  $x$  های آخر تصویر ابرطیفی که از نسبت سیگنال به نویز بسیار پائینی برخوردار است و هیچ سیگنال قابل مشاهده‌ای در آنها وجود ندارد اتفاق می‌افتد که برای ما اهمیت چندانی ندارند و در نتیجه، انتخاب تعداد باند های تصویر جدید بر مبنای مقدار ویژه بزرگتر از ۲ در نظر گرفته می‌شود.

**۳-۲- طبقه‌بندی کننده ماشین بردار پشتیبان الگوریتم SVM** اولین بار در سال ۱۹۶۳ ارائه شد [۱۴]، و در سال ۱۹۹۵ برای حالت غیر خطی تعییم داده شد [۱۸]. این الگوریتم از حقه‌ی کرنل<sup>۱</sup> جهت تبدیل فضای داده‌ی اولیه به فضایی با ابعاد بیشتر به منظور ساده‌سازی مسئله استفاده می‌کند [۱۵].

در روش ماشین‌های بردار پشتیبان، بردارهای ورودی به یک فضای چند بعدی که غالباً ابعادی بزرگ‌تر از ابعاد فضای ورودی دارد نگاشت می‌شوند. به این ابرصفحه، ابرصفحه با حداقل مرز جداکننده گفته می‌شود.

<sup>1</sup> Kernel Trick

دریافت که نسبت سیگنال به نویز برای  $k$  امین تبدیل خطی از رابطه (۵) به دست می‌آید [۱۲]:

$$\text{رابطه (۵)}$$

$$SNR_k = a_k^T \Sigma_X^S a_k / a_k^T \Sigma_X^N a_k, \quad k = 1, 2, \dots, d$$

در ادامه به معرفی قیود جهت نرمال کردن رابطه (۵) پرداخته می‌شود (روابط (۶ و ۷)).

$$\text{رابطه (۶)} \quad a_k^T \Sigma_X^N a_k = 1, \quad k = 1, 2, \dots, d$$

این رابطه بیانگر آن است که کواریانس نویز بر روی باندهای نویزی به دست آمده از تبدیل MNF برابر با ۱ است [۱۲]. از طرفی، لازمه‌ی عدم همبستگی بین باندها در تبدیل خطی به صورت رابطه (۷) بیان می‌شود [۱۱]:

قیود معرفی شده در روابط (۶ و ۷) با قیود روش آنالیز مؤلفه‌های اصلی، ماتریس  $\Sigma_X^N$  با ماتریس PCA یک جایگزین می‌شود و به همین دلیل تبدیل MNE یک تبدیل متعامد است، در حالی که تبدیل

تبدیلی غیرمتعامد خواهد بود.

$$\text{رابطه (۷)} \quad a_l^T \Sigma_X^N a_k = 0$$

$$l = k + 1, 2, \dots, d,$$

$$k = 1, 2, \dots, d - 1$$

به عبارتی دیگر، می‌توان ماتریس بردارهای ویژه را به گونه‌ای به دست آورد که رابطه (۸) را ارضاء نماید [۱۲]:

$$\text{رابطه (۸)} \quad A\Sigma_X^S A^T = \Lambda, \quad A\Sigma_X^N A^T = I$$

که در آن،  $\Lambda$  ماتریسی قطری از مقادیر ویژه غیر منفی است ( $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_d \geq 0$ )، و  $I$

ماتریس یکه است. سطر  $k$  از ماتریس  $A$  برابر است با  $\lambda_k = SNR_k$  و  $a_k^T \Sigma_X^N a_k$ . جهت برقراری رابطه (۸)، باید ماتریس  $\Sigma_X^N$  مثبت معین و وارون‌پذیر باشد [۱۳].

مقادیر ویژه را نیز می‌توان با محاسبه  $d$  ریشه‌ی چند جمله‌ای رابطه (۹) به دست آورد:

$$\left| (\Sigma_X^N)^{-1} \Sigma_X^S - \lambda I \right| = 0 \quad (9)$$

جهت محاسبه  $\Sigma_X^N$ ، از روش Shift-difference استفاده شده است. در ادامه به توضیح نحوه‌ی برآورده



شکل ۱: منطقه مورد مطالعه

رابطه (۱۲)

$$\tilde{L}(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j k(x_i, x_j)$$

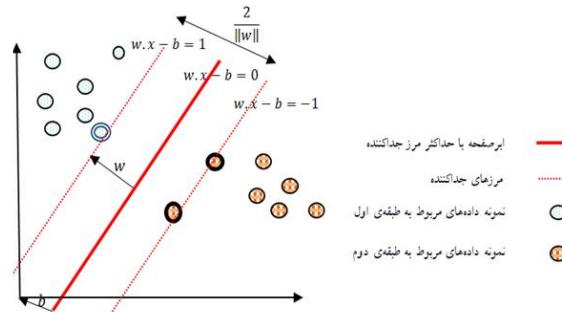
که در آن،  $k(x_i, x_j)$  تابع کرنل است که می‌تواند شامل هر معادله‌ی غیر خطی باشد. در حالت خطی، تابع کرنل برابر است با:  $x_i^T x_j + b$  و در حالت غیر خطی می‌تواند به صورت حاصل ضرب توابعی از  $x_i$  و  $x_j$  بیان شود:  $(x_i \cdot \varphi)(x_j) \cdot \varphi(x_i) \cdot \varphi(x_j)$ . برخی از معادلاتی که بیشترین کاربرد در تولید کرنل را دارند در جدول (۱) آورده شده‌اند [۱۸].

تابع کرنل (RBF) بیشترین کاربرد را در بین توابع کرنل نام بردشده در جدول (۱) دارد. دلیل نام‌گذاری این تابع کرنل از آن جهت است که ابرصفحه‌های جداساز در آن به صورت شعاعی تعریف می‌شوند و به شکل منحنی‌های بسته به طبقه‌بندی داده‌ها در فضای ویژگی می‌پردازند. مقدار  $\gamma$  نیز برابر با معکوس تعداد بردارهای ویژگی در نظر گرفته شد.

#### ۴-۲ روش پیشنهادی

در این قسمت به تشریح روش پیشنهادی پرداخته می‌شود. از آنجاکه تصویر ابرطیفی موجود دارای نویز بسیار بالایی در بین باندهای طیفی است، در اثر استفاده از روش کلاس‌بندی پیکسل مبنای SVM، دقت نتایج به دست آمده رضایت‌بخش نخواهد بود. در نتیجه، پیش از استفاده از هر گونه روش یادگیری ماشین لازم است تا باندهای نویزی موجود در تصویر ابرطیفی از بین باندهای موجود حذف شوند. در این مقاله به منظور کاهش نویز و نیز

روش ماشین‌های بردار پشتیبان خطی سعی دارند تا با ساختن یک ابرصفحه<sup>۱</sup> (که می‌تواند دارای معادله‌ی خطی یا غیر خطی باشد)، در فضایی بالاتر داده‌ها را از هم تفکیک کنند [۱۶]. این روش، بهترین ابرصفحه را پیدا می‌کند که با حداقل فاصله<sup>۲</sup> از محدوده‌ی مربوط به دو کلاس داده، داده‌های مربوط به دو کلاس را از یکدیگر تفکیک نماید.



شکل ۲: ابرصفحه با حداقل مرج جداساز به همراه مرزهای جداساز برای طبقه‌بندی نمونه داده‌های مربوط به دو کلاس متفاوت. نمونه‌های قرار گرفته بر روی مرزها بردارهای پشتیبان نام دارند [۱۷].

در حالت کلی، رابطه (۱۲) که مربوط به معادله‌ی ابرصفحه‌ی خطی است را می‌توان به حالت کلی تعمیم داد (رابطه (۱۳)), تا تعریف معادلات مربوط به ابرصفحه‌ی غیر خطی را نیز شامل شود [۱۸].

$$\text{رابطه (۱۲)} \quad -\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j x_i^T x_j + \sum_{i=1}^n \alpha_i$$

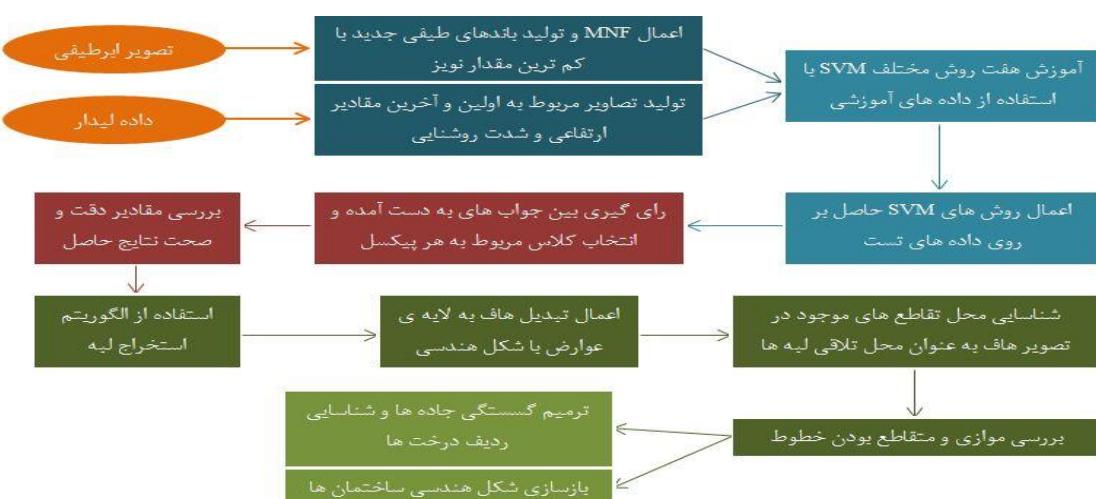
<sup>1</sup> Hyper-plane<sup>2</sup> Maximum Margin

به صورت پیکسلی خواهد بود. در نتیجه، احتمال گستاخی در عوارض پیوسته و یا حضور عوارض منفرد در نتایج به دست آمده وجود خواهد داشت. در نتیجه، ضرورت اعمال یک مرحله پس پردازش به منظور تصحیح عوارض پیوسته و ترمیم هندسه ای منظم عوارضی که به دست انسان ساخته شده اند، وجود خواهد داشت. به همین دلیل، پس از استخراج تمامی عوارض مرتبط با کلاس های موجود در داده های آموزشی، لبه های مربوط به عوارض به دست آمده به صورت جدایگانه آشکار سازی می شوند. سپس، با استفاده از تبدیل هاف بر روی تصویر مربوط به لبه ها امتداد و جهت هر عارض محاسبه می گردد و عوارض دارای گستاخی ترمیم می شوند. شکل (۳) فلوچارت روش پیشنهادی را نشان می دهد.

کاهش همبستگی بین باندهای طیفی، از روش MNF استفاده می شود. به منظور طبقه بندی داده ها از روش SVM در یک شیوه متفاوت بهره گرفته می شود. SVM بدین صورت که بجای استفاده از یک مرحله SVM بر روی تمام داده های آموزش موجود، طبقه بندی کننده SVM با معادله پایه شعاعی بر روی هفت زیر مجموعه مختلف از داده های آموزشی، آموزش داده می شوند و هر یک به طور جداگانه به طبقه بندی عوارض موجود در تصاویر می پردازند. سپس، بین نتایج به دست آمده از هفت روش یادگیری ماشین بردار پشتیبان رای گیری انجام می شود تا کلاس نهایی مربوط به هر پیکسل مشخص شود. در این مقاله تابع کرنل مورد استفاده از نوع RBF می باشد. از آن جا که روش SVM تنها بر اساس پیکسل های اولیه آموزش می بیند، لذا نتایج حاصل از آن نیز

جدول ۱: معادله های مربوط به تابع کرنل برخی معادلات غیر خطی معمول

عنوان معادله غیر خطی	معادله مربوط به تابع کرنل
معادله چند جمله ای همگن	$k(x_i, x_j) = (x_i \cdot x_j)^d$
معادله چند جمله ای ناهمگن	$k(x_i, x_j) = (x_i \cdot x_j + 1)^d$
معادله تابع پایه شعاعی (RBF)	$k(x_i, x_j) = \exp(-\gamma \ x_i - x_j\ ^2), \gamma > 0$
معادله سیگموئید (تانژانت هذلولی)	$k(x_i, x_j) = \tanh(\gamma x_i \cdot x_j + c), k > 0, c > 0$



شکل ۳: فلوچارت روش پیشنهادی ارائه شده در این مقاله

<sup>1</sup> Radial Basis Function

### ۳- نتایج

در این بخش پیاده‌سازی روش پیشنهادی توضیح داده شده و نتایج بدست آمده ارزیابی می‌شود.

#### ۳-۱-پیاده‌سازی روش پیشنهادی

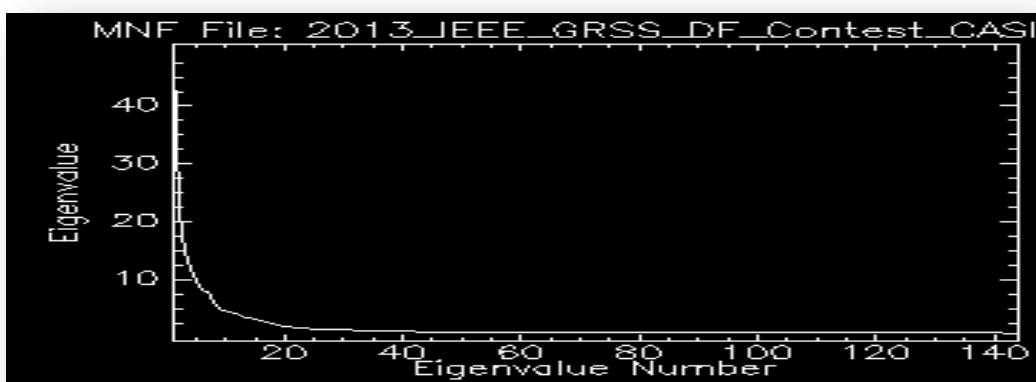
ابتدا داده‌ی ابرنقطه‌ی لیدار موجود، با استفاده از نرم‌افزار (ENVI) به صورت شبکه‌ای منظم یا به عبارتی بهتر به تصویر لیدار تبدیل شدند. کاهش باندهای طیفی مربوط به تصویر ابرطیفی موجود با استفاده از روش MNF انجام شد. به این منظور، با استفاده از مقادیر ویژه‌ی مربوط به هر کدام از باندها و در نظر گرفتن باندهای دارای مقادیر ویژه‌ی بزرگ‌تر از ۲، تعداد ۱۹ باند از بین ۱۴۴ باند طیفی اولیه انتخاب شدند و تصویری جدید حاصل شد که مولفه‌های آن مستقل از تصویر اولیه هستند و مقدار نویز در هر کدام از مولفه به ترتیب، افزایش پیدا می‌کند. این امر در شکل (۴)، به خوبی قابل مشاهده است. در ادامه‌ی مراحل روش پیشنهادی، به جای استفاده از تصویر ابرطیفی اولیه از ۱۹ مولفه‌ی اول تولید شده از روش MNF استفاده شد. بنابراین با در نظر گرفتن ۴ تصویر به دست آمده از ابرنقطه‌ی لیدار، در کل ۲۳ ویژگی در اختیار قرار گرفت که طبقه‌بندی کننده‌های هفت گانه‌ی (RBF-SVM)<sup>۱</sup> به دست آمده از (LOOCV) بر روی آن‌ها اعمال خواهد شد.

جهت اجرای طبقه‌بندی از بسته‌ی نرم‌افزاری (LIBSVM) که برای نرم‌افزار متلب توسعه داده شده است، استفاده شد. پس از اخذ نقشه‌های طبقه‌بندی شده هفت گانه، بین نتایج حاصل رأی گرفته شد و برچسب نهایی به هر پیکسل با توجه به بیشترین تعداد آرا در بین کلاس‌ها به آن پیکسل اختصاص داده شد. جهت بررسی نتایج در حالت

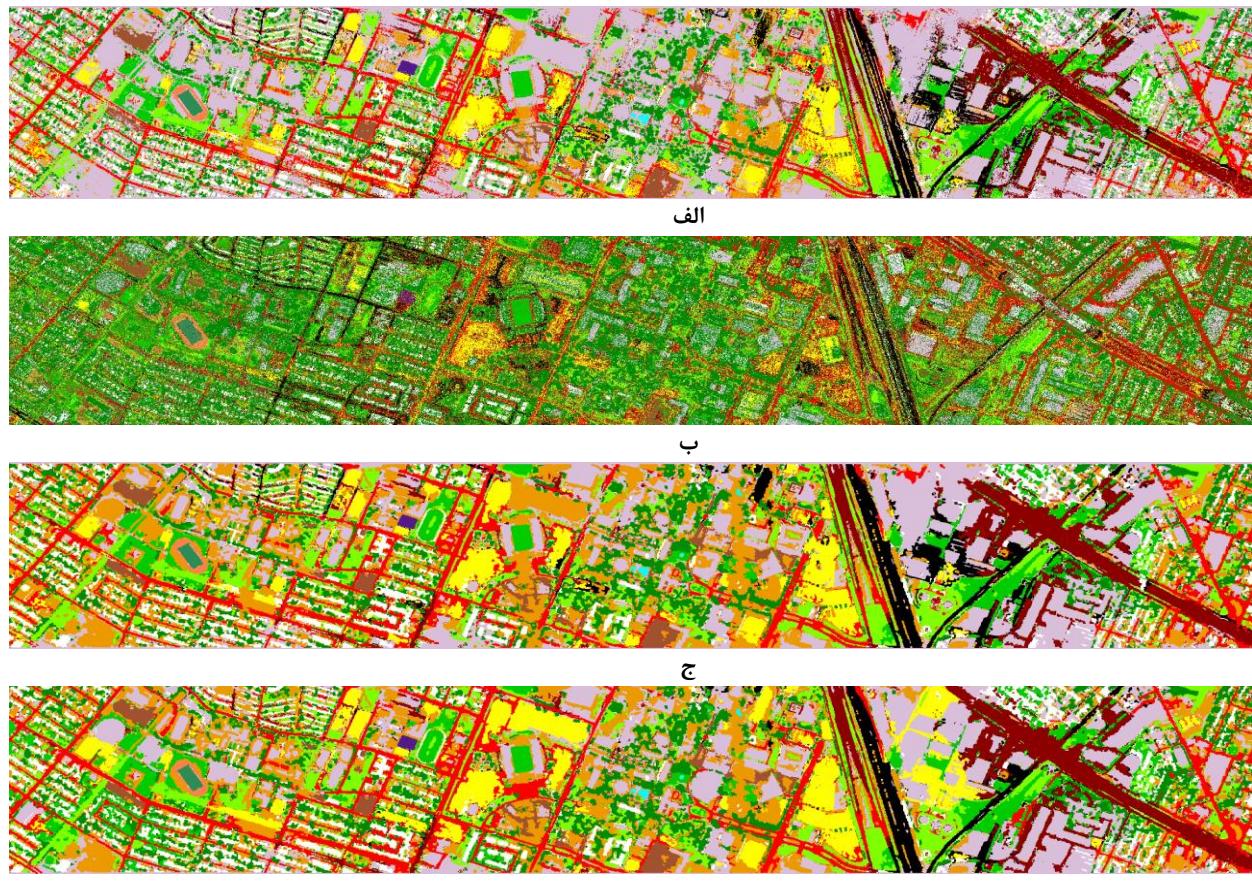
<sup>۱</sup> Leave One Out Cross Validation

جدول ۲. تعداد نمونه های آموزشی و نمونه های آزمایشی کلاس های مختلف عوارض منطقه مورد مطالعه

نوع عارضه	تعداد پیکسل های آموزشی	تعداد پیکسل های تست	رنگ هر عارضه
گیاه سالم	۱۹۸	۱۰۵۳	
گیاه خشک شده	۱۹۰	۱۰۶۴	
ترکیبی از گیاه سالم و خشک	۱۹۲	۵۰۵	
درخت	۱۸۸	۱۰۵۶	
خاک	۱۸۶	۱۰۵۶	
آب	۱۸۲	۱۴۳	
ساختمان مسکونی	۱۹۶	۱۰۷۲	
ساختمان تجاری	۱۹۱	۱۰۵۳	
جاده	۱۹۳	۱۰۵۹	
بزرگراه	۱۹۱	۱۰۳۶	
راه آهن	۱۸۱	۱۰۵۶	
پارکینگ عمومی	۱۹۲	۱۰۴۱	
پارکینگ اختصاصی	۱۸۴	۲۸۵	
زمین تنیس	۱۸۱	۲۴۷	
زمین دو و میدانی	۱۸۷	۴۷۳	



شکل ۴: مقادیر ویژه باندهای جدید به دست آمده از تبدیل MNF بر روی تصویر ابر طیفی اولیه با ۱۴۴ باند طیفی



شکل ۵: (الف). کلاس‌بندی ابرطیفی با استفاده از ۷ روش SVM (ب). کلاس‌بندی تصویر ۴ با باندی لیدار با استفاده از ۷ روش SVM (ج). کلاس‌بندی تصویر ۲۳ با باندی ابرطیفی و لیدار با استفاده از یک روش SVM (د). کلاس‌بندی تصویر ۲۳ با باندی ابرطیفی و لیدار با استفاده از ۷ روش SVM



شکل ۶: نتیجه‌ی کلاس‌بندی به دست آمده از روش برگزیده در مسابقه‌ی بین‌المللی ادغام داده‌ها

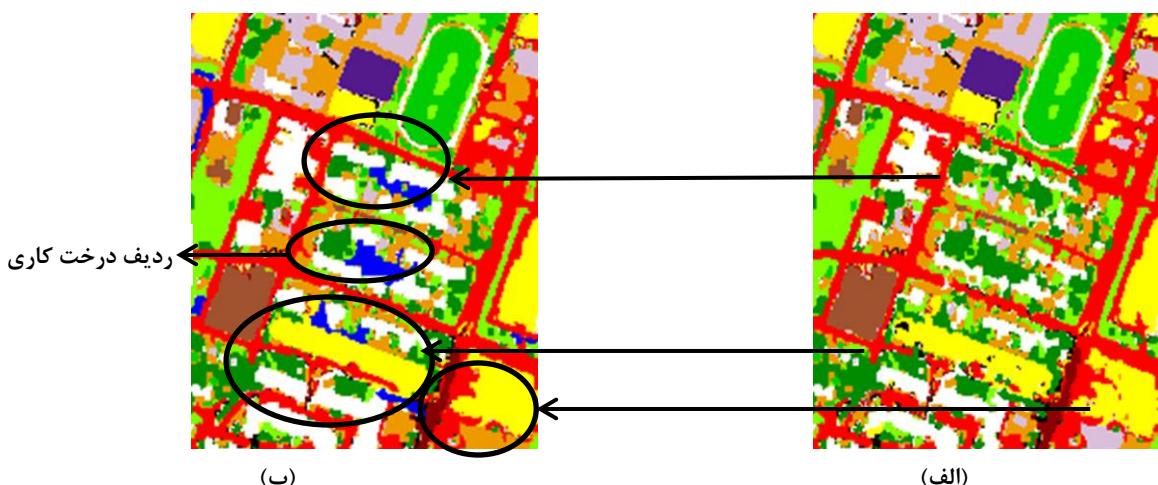
به این منظور از روش استخراج لبه‌ی Canny استفاده شد. سپس، امتداد خطوطی که در بازه‌ی شعاعی ۱۰ پیکسلی برای شبکه‌ی حمل و نقل زمینی و ۳ پیکسلی برای عوارض ساختمانی حضور داشتند بررسی شده و ارتباط هر کدام از آن‌ها با استفاده از تبدیل هاف مشخص شد. در نتیجه، با داشتن خطوطی از شبکه‌ی حمل و نقل زمینی که در یک امتداد قرار می‌گیرند، آن‌ها را با استفاده از یک ردیف پیکسل از جنس

عارضی که به دست انسان ساخته شده‌اند، مانند عوارض ساختمانی (تجاری، مسکونی، پارکینگ عمومی، پارکینگ اختصاصی، زمین تنیس و محدوده‌ی دو و میدانی) و عوارض شبکه‌ی حمل و نقل زمینی (اتوبان، جاده و راه آهن)، همگی دارای هندسه‌ی منظمی هستند که با تعریف آن می‌توان شکل منظم این دسته از عوارض را بازسازی کرد. ابتدا باید تصویری از لبه‌های عوارض ذکر شده به وجود آید،

سه عارضه‌ی درخت در یک امتداد قرار می‌گرفتند، آن مجموعه عوارض به عنوان ردیف درخت کاری در نظر گرفته می‌شدند. در ضمن، شرط دیگری برای انتخاب عارضه‌ی درخت به عنوان ردیف درخت کاری، تعداد پیکسل‌های تشکیل دهنده‌ی عارضه‌ی درخت بود که در کنار نسبت طول به عرض آن بررسی می‌شد. اگر تعداد پیکسل‌های تشکیل دهنده‌ی عارضه‌ی درخت از ۵ بیشتر و نسبت طول به عرض آن نیز از ۳ بیشتر باشد، در آن صورت، باز هم عارضه‌ی موجود به عنوان ردیف درخت کاری در نظر گرفته می‌شود.

همان عارضه به یکدیگر متصل کرده و به حالت پیوسته در می‌آوریم. از طرف دیگر، عوارض ساختمانی نیز دارای شکل هندسی منظم و مستطیل شکل هستند. به همین دلیل، به منظور بازسازی شکل منظم هندسی آن‌ها از تبدیل مورفولوژی بستن با المان ساختاری مربعی شکل به ابعاد ۳ پیکسل استفاده شد. عارضه‌ی درخت را نیز می‌توان به دو کلاس مجزا تقسیم کرد: درخت و ردیف درخت کاری. بقیه‌ی عوارض پوشش گیاهی، عارضه‌ی سطحی هستند.

به منظور تعیین نقطه‌ای و خطی بودن عارضه‌ی درخت، در اطراف هر عارضه‌ی درخت یک شعاع همسایگی به اندازه‌ی ۵ پیکسل در نظر گرفته شد و اگر حداقل



شکل ۷ (الف) کلاس بندی تصاویر موجود به روشنی‌های، (ب) ترمیم عوارض استخراج شده با استفاده از تعریف شیء به جای عارضه. لزاندر این تصویر در جدول (۲) آورده شده است

۱۵ کلاس عارضه‌ی مورد نظر از بین داده‌های تست به صورت جدول (۳) محاسبه شدند تا برای هر کدام از این روش‌ها به صورت کلی یک مقدار صحت کلی و ضریب کاپا ارائه شود تا بر اساس آن با یکدیگر مقایسه شوند.

### ۳-۲- ارزیابی دقیقت نتایج

پس از محاسبه‌ی پارامترهای صحت کلی و ضریب کاپا مربوط به چهار روش نام برده شده برای هر کدام از عوارض موجود در منطقه، مقادیر این پارامترها به صورت کلی و به منظور شناسایی و استخراج همزمان

جدول ۳: صحت کلی و ضریب کاپا روش‌های معرفی شده در استخراج تمامی عوارض موجود در منطقه

تصاویر ابرطیفی و لیدار با <i>SVM</i>	تصاویر ابرطیفی و لیدار با یک <i>SVM</i>	تصویر لیدار <i>SVM</i> ۷	تصویر ابرطیفی <i>SVM</i> ۷ با	روش برگزیده در مسابقه‌ی بین‌المللی ادغام داده	صحت کلی (%)	ضریب کاپا
۹۹,۵۲	۹۰,۴۹	۹۳,۰۳	۹۸,۶۲	۹۰,۳۰		
۰,۹۵۸	۰,۷۵۷	۰,۴۳۱	۰,۸۹۹	۰,۸۹۵		

#### ۴- نتیجه‌گیری

در این تحقیق روشی جهت استخراج عوارض مختلف شهری از داده‌های لیدار و ابرطیفی ارائه شده است که در آن از طبقه‌بندی کننده SVM به صورت چندگانه استفاده شده است. جهت بررسی مزایای استفاده توأم از دو منبع داده لیدار و تصاویر ابرطیفی، نتایج مربوط به کلاس‌بندی در دو حالت استفاده‌ی مجزا از هر کدام از تصاویر ابرطیفی و لیدار نیز محاسبه شدند که در نتیجه مقادیر صحت کلی و ضریب کاپا برای این دو حالت نیز محاسبه شدند. صحت کلی و ضریب کاپا در صورت استفاده از تصویر لیدار به منظور کلاس‌بندی به ترتیب برابر با ۰,۹۳۰۳ درصد و ۰,۴۳۱ و در صورت استفاده از تصویر ابرطیفی به منظور کلاس‌بندی به ترتیب برابر با ۹۸,۶۲ درصد و ۰,۸۹۹ محاسبه شدند. در نتیجه، با افزایش ضریب کاپای مربوط به تصویر ابرطیفی از ۰,۸۹۹ به ۰,۹۵۸ با افزودن داده‌ی لیدار، نشان دهنده‌ی تأثیر مثبت استفاده همزمان از این دو منبع داده در بهبود نتایج کلاس‌بندی است. با توجه به نتایج به دست آمده از روش پیشنهادی، استفاده از یک روش SVM بر روی بردارهای ویزگی اولیه و کلاس‌بندی آن‌ها منجر به تولید جواب بهینه نمی‌شود و بهتر آن است تا با رأی‌گیری بین خروجی‌های چندین طبقه‌بندی کننده SVM که هر یک به وسیله زیر مجموعه متفاوتی از نمونه‌های آموزشی تعلیم دیده‌اند، کلاس نهایی هر پیکسل مشخص شود. لذا، استفاده از روش ادغام در سطح تصمیم، نتایج بهتری تولید می‌کند. بنابراین می‌توان نتیجه گرفت که اگر به جای استفاده از چند روش SVM از یک روش گروهی استفاده کنیم، با ثابت‌ماندن دقیق، کلاس‌بندی عوارض منطقه مورد نظر با سرعت بیشتری به دست خواهد آمد.

همانطور که از نتایج جدول (۳) مشخص است، مقادیر صحت کلی و ضریب کاپا در روش استفاده همزمان از تصاویر لیدار و ابرطیفی با هفت روش SVM مختلف به منظور استخراج عوارض، بیشتر از دو حالتی است که فقط از یکی از این تصاویر به منظور استخراج عوارض SVM استفاده شود، همچنین از روش یک مرحله SVM بیشتر است، زیرا زمانی که فقط از یک مرحله SVM جهت استخراج عوارض استفاده می‌شود خطای طبقه‌بندی تصادفی افزایش می‌یابد و در نتیجه دقت طبقه‌بندی به شدت پایین می‌آید همان‌طور که از جدول (۳) بر می‌آید دقت طبقه‌بندی با یک مرحله SVM در مقابل استخراج عوارض با تصاویر ابرطیفی با هفت روش SVM مختلف کمتر است در صورتی که روش یک مرحله SVM شامل اطلاعات ارتفاعی لیدار نیز می‌باشد، در نهایت استفاده توأم از هر دو منبع داده و طبقه‌بندی آن‌ها با چندین روش SVM مختلف باعث بهبود نتایج مربوط به کلاس‌بندی شده است. همچنین روش ارائه شده در این مقاله نشان دهنده‌ی بهبود حدوداً ۹ درصدی در صحت کلی و مقدار ۰,۰۶ در ضریب کاپا نسبت به روش برگزیده موسسه (GRSS<sup>۱</sup>) می‌باشد. پس از بازسازی عوارض استخراج شده از روش پیشنهادی، پارامترهای صحت کلی و ضریب کاپا بار دیگر برای داده‌های تست محاسبه و با مقادیر به دست آمده برای روش پیشنهادی مقایسه شدند. به طور کلی، مقدار صحت کلی برابر با ۹۴,۴۸ درصد و مقدار ضریب کاپا برابر با ۰,۹۵۱ به دست آمدند که در مقایسه با صحت کلی ۹۹,۵۲ درصد و ضریب کاپای ۰,۹۵۸ پیش از اعمال تصحیحات، تغییرات زیادی نداشتند. در نتیجه، اشیاء استخراج شده پس از اعمال ترمیم‌های معرفی شده به اندازه‌ی عوارض استخراج شده از روش پیشنهادی قابل قبول هستند و علاوه بر بهبود بصری نتایج، دقت و صحت آن‌ها را نیز حفظ کرده‌اند.

<sup>۱</sup> Geoscience & Remote Sensing Society

## مراجع

- [1] P. Pahlevani, H. Amini Amir Kalaei, and S. Sadeghian, "Extracting Land Digital Model from Lidar Data and Aerial Images and Identifying Urban Buildings and Passages by Present Nerve Network", Journal of Soft Computing and Information Technology", Vol. 2, No. 4, 1394.
- [2] S. Sadeghian, A. Aieneh, "Extraction of Vegetation Cover in Urban Areas by Means of Merging of Lidar and Superiority Data", Presented at 22nd Geomatics National Conference, Tehran, Iran, 1394.
- [3] A. Benediktsson. and I. Kanellopoulos, "Classification of Multisource and Hyperspectral Data based on Decision Fusion", IEEE Transactions on Geoscience and Remote Sensing, Vol. 37, No. 3, pp. 1367-1377, 1999.
- [4] M. Turker, and D. Koc-San, "Building Extraction from High-Resolution Optical Space-borne Images using the Integration of Support Vector Machine (SVM) Classification", Hough Transformation and Perceptual Grouping, International Journal of Applied Earth Observation and Geoinformation, Vol. 34, pp. 58-69, 2015.
- [5] A. Matkan, M. Hejeb, and S. Sadeghian, "Road Extraction from Lidar Data using Support Vector Machine Classification, Photogrammetric Engineering and Remote Sensing (PE&RS) Journal, Vol. 80, No. 5, pp. 409-422, May 2014.
- [6] Z. Azizi, and S. Sadeghian, "Forest Canopy Modeling with LIDAR Data and Digital Aerial Imagery, 2nd International Conference on Sensors and Models in Photogrammetry and Remote Sensing (SMPR'13, Tehran, Iran, 2013.
- [7] B. Bigdeli, F. Samadzadegan, and P. Reinartz, "A decision Fusion Method Based on Multiple Support Vector Machine System for Fusion of Hyperspectral and LiDAR Data", International Journal of Image and Data Fusion, Vol. 5, No. 3, pp. 196-20, 2014.
- [8] C.W. Geerling, M. L. abrador-Garcia, J.G.P.W. Clevers, A.M.J. Ragas, and A.J.M. Smits, "Classification of Floodplain Vegetation by Data fusion of Spectral (CASI) and LIDAR Data", International Journal of Remote Sensing, Vol. 28, pp. 4263-4284, 2007.
- [9] M. Voss, and R. Sugumaran, "Seasonal Effect on Tree Species Classification in an Urban Environment using Hyper-spectral Data, LIDAR and an Object-oriented Approach Sensors", Vol. 8, pp. 3020-3036, 2008.
- [10] G.W. Geerling,, M.J. Vreeken-Buus, P. Jesse, A.M.J. Ragas, and A.J.M. Smits. "Mapping River Floodplain Ecotopes by Segmentation of Spectral (CASI) and Structural (LIDAR)" Remote Sensing Data, River Research and Applications, Vol. 25, No. 7, pp. 795-813, 2009.
- [11] J.W. Boardman, and F.A. Kruse, "Automated Spectral Analysis: A geological Example using AVIRIS Data, Northern Grapevine Mountains, Nevada: in Proceedings", 10th Thematic Conference, Geologic Remote Sensing, Vol. 9, No. 12, May 1994, San Antonio, Texas, Chapter I, pp. 407-418, 1994.
- [12] A.A. Green, M. Berman, P. Switzer, and M.D. Craig, "A Transformation for Ordering Multispectral Data in Terms of Image Quality with Implications for Noise Removal", IEEE Transactions on Geoscience and Remote Sensing, Vol. 26, No. 1, pp. 65-74, 1988.
- [13] F. Graybill, Matrices with applications in statistics, 2nd Edition, Wadsworth, Belmont, California. 1983.
- [14] V. Vapnik, and A. LERNER, "Pattern Recognition using Generalized Portrait Method", Automation and Remote Control, Vol. 24, pp. 774-780, 1963.
- [15] T. Joachims, "Making large-scale SVM learning practical", in B. Schölkopf, C.J.C

- . Burges, and A.J. Smola, Editors, Advances in Kernel Methods - Support Vector Learning, Cambridge, MA, MIT Press, 1998.
- [16] V. Vapnik, Statistical Learning Theory, Wiley, New York, 1998.
- [17] B.E Boser, I. Guyon, V. Vapnik, "A Training Algorithm for Optimal Margin Classifiers", Proceedings of the Fifth Annual Workshop on Computational Learning Theory, ACM Press, pp. 144–152, 1992.
- [18] C. Cortes, V. Vapnik, "Support Vector Network. Machine Learning", Vol. 20, pp. 273-297, 1995.



## Urban Features Production with Combining LiDAR and Hyperspectral Data

Seyed Yousef Sajjadi<sup>1\*</sup>, Omid Aineh<sup>2</sup>

1- Assistant Prof. , Dep. Of Surveying Engineering, Tafresh University, Tafresh Iran  
2- Msc Student, Dep. Of Surveying Engineering, Tafresh University, Tafresh Iran

### Abstract

The main problems of hyper spectral data are large number of bands, high dependency between them and different signal to noise ratio in each band. To reduce dimensions of the feature space, minimizing noise and spectral dependence between bands, the MNF method has been applied to achieve better results in this paper. By applying this algorithm, the 144 bands of hyper spectral data were reduced to 19 suitable bands. Then from LiDAR data, the image height and intensity of the return signal received from the first and the last pulse of the laser were examined by LiDAR sensor. At last, the 19 spectral bands extracted from hyper spectral data have been fusion with 4 images of LiDAR data at the pixel level to create 23 suitable spectral bands. In order to detect and extract any study feature of the area on 23 spectral bands, seven different SVM methods were applied and finally by majority voting in the decision-making level between 7 obtained results, the class of each pixel was turned out. Morphology closing transform for repairing buildings and Hough transform for reconstructing the network effects of the fragmentation of land transportation were used on the results of pixels basis SVM method to regulate man-made side structure as well as the individual pixels which reduced. The results in this paper indicates the 99.52% overall accuracy and .958 kappa efficiency which compared to the GRSS chosen institution method. 0.6 Kappa coefficient has been improved. Used data are air-borne LiDAR and hyper spectral scenes requested and downloaded from the organized of a recent contest in data fusion domain.

**Key words:** Hyper Spectral, LiDAR, Morphology, Support Vector Machine, Fusion.

**Correspondence Address :** Photogrammetric Group, Department of Geomatics, School of Civil Engineering,  
University of Tafresh, Tafresh, Iran  
Tel : +98 86 3622 7659  
Email: sajjadi@tafreshu.ac.ir