

ترکیب تصاویر ابرطیفی هوایی و داده‌های لیدار برای تولید عوارض شهری

سید یوسف سجادی^{۱*}، امید آینه^۲

۱- استادیار دانشکده نقشه‌برداری دانشگاه تفرش

۲- دانشجوی کارشناسی ارشد دانشکده نقشه‌برداری دانشگاه تفرش

تاریخ دریافت مقاله: ۱۳۹۶/۰۸/۱۰ 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 داده‌های لیدار و ابرطیفی استفاده می‌شود. مهمترین مشکل تصاویر ابرطیفی تعداد زیاد باندها و وابستگی بالای بین آن‌ها و نیز نسبت سیگنال به نویز متفاوت در باندهای مختلف می‌باشد، 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 می‌شود، با اعمال این روش تصاویر ابرطیفی با ۱۴۴ باند به ۱۹ تصویر تبدیل یافته مناسب کاهش می‌یابند. سپس از ابر نقاط لیدار تصاویر ارتفاعی و شدت بازگشت‌های اول و آخر لیزر تولید می‌شوند. در نهایت ۱۹ تصویر تبدیل یافته حاصل از تصاویر ابرطیفی با ۴ تصویر تولید شده از داده‌های لیدار در سطح پیکسل باهم ادغام می‌شوند و تصویری با ۲۳ ویژگی مناسب به وجود می‌آید. به منظور شناسایی و استخراج هر کدام از عوارض منطقه، هفت ماشین یادگیری بردار پشتیبان (SVM) اجرا می‌شوند و نهایتاً با ادغام اطلاعات در سطح تصمیم که با رأی‌گیری بین ۷ جواب به دست آمده، انجام می‌شود، کلاس مربوط به هر پیکسل مشخص می‌گردد. در ادامه از عملگر انسداد مورفولوژی ریاضی برای ترمیم ساختمان‌ها و از تبدیل هاف برای بازسازی شبکه‌ی حمل و نقل استفاده می‌شود تا عوارض ساخت دست بشر دارای ساختاری منظم‌تر بشوند و حضور پیکسل‌های منفرد نیز کاهش یابد. روش فوق روی یک مجموعه داده مربوط به محوطه دانشگاه هیوستن آمریکا پیاده‌سازی شده است. این مجموعه داده همراه با داده‌های جانبی شامل نمونه‌های آموزشی و آزمایشی دقیق، توسط انجمن سنسجش از دور و علوم زمین مهندسان برق و الکترونیک در سال ۲۰۱۲ برداشت شده و پیشتر در یک مسابقه‌ی بین‌المللی ادغام داده مورد استفاده قرار گرفته‌اند.

کلید واژه‌ها: تصاویر ابرطیفی، لیدار، ماشین بردار پشتیبان، مورفولوژی، ادغام.

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

تلفن: ۰۹۱۲۶۹۴۱۸۸۵ - ۰۸۶۳۶۲۴۱۲۹۰

۱- مقدمه

با پیشرفت علم فتوگرامتری در زمینه‌ی تولید سنجنده‌های جدید با قدرت تفکیک طیفی و مکانی بالاتر و تهیه‌ی تصاویری از سطح زمین با سطح نویز پایین‌تر، همواره ارائه‌ی روش‌هایی جهت استخراج عوارض گوناگون از این تصاویر به‌عنوان موضوعی مهم مد نظر دانشمندان و محققین بوده است. وجود سنجنده‌های مختلف و تنوع داده‌های تهیه شده از سنجنده‌های مختلف همواره باعث مطرح شدن این سؤال بوده است که آیا وجود تفاوت بین داده‌های مختلف امکان تکمیل اطلاعات موجود از عوارض را فراهم می‌کند یا خیر؟ پاسخ‌های فراوانی به این سؤال داده شده است که از جمله‌ی آن‌ها می‌توان تعریف قیده‌های 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 خواهند بود که امکان عدم استخراج کامل عوارض مورد نظر به دلیل 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.

اما در صورتی که فرایند ادغام داده‌ها به درستی صورت بگیرد، مجموعه‌ای از اطلاعات در اختیار خواهند 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 به‌عنوان 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 عارضه 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

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^3) 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 [۸]، از روش داده لیدار ماتریس رخداد توام $(GLCM^4)$ و بر روی تصویر ابرطیفی روش‌های تحلیل مولفه‌های اصلی (PCA^5) و کسر نویز کمینه (MNF^6) 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 برآزش^۷ 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 بهره گرفته شده است. بدین ترتیب که برای تعیین کلاس نهایی هر پیکسل، بین چند نتایج ماشین‌بردار

از باندها و انتقال آن به دیگر باندها و در نتیجه امکان تولید خطا در نتایج کلاس‌بندی وجود دارد. در روش ادغام بر مبنای تصمیم، رأی‌گیری بیشترین نقش را ایفا می‌کند [۲]. بدین‌منظور 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]، اشاره کرد. روش‌های رأی‌گیری وزن‌دار نیز برای ادغام نتایج حاصل از چند طبقه‌بندی کننده با دقت‌های متفاوت ارائه شده‌اند که به وزن‌دهی به نتایج بر اساس کیفیت و دقت هر کدام از روش‌های طبقه‌بندی کننده می‌پردازند [۱ و ۵].

روش ادغام نتایج براساس الگوریتم بیزن^۱ 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 بیزین رأی‌گیری انجام شد و بدین ترتیب عوارض موجود از منطقه استخراج شدند. روش برگزیده ادغام داده‌ها توسط انجمن سنجش از دور و علوم زمین انجمن مهندسان برق و الکترونیک $(IEEE^2)$ 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، ابتدا شاخص پوشش گیاهی و

³ Random Forest⁴ Gray Level Co-Occurrence Matrix⁵ Principal Component Analysis⁶ Minimum Noise Fraction⁷ Overfitting¹ Bayesian Theorem² 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- روش MNF جهت 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]:

$$X = (X_1, \dots, X_n)^T \quad \text{رابطه (۱)}$$

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]:

$$X_i = S_i + N_i \quad \text{رابطه (۲)}$$

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

$$\Sigma_X^T = \Sigma_X^S + \Sigma_X^N. \quad \text{رابطه (۳)}$$

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

$$v_{ik} = a_k^T X_i, \quad k = 1, 2, \dots, d \quad \text{رابطه (۴)}$$

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

پشتیبان مختلف رای گیری 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 به‌دست 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 مؤسسه‌ی IEEE از محوطه دانشگاه هیوستن^۱ 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 نقطه‌ی^۲ 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 بازگشتی 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 نیز در سیستم تصویر یو تی ام (UTM^۳) و در زون ۱۵ شمالی

^۱ Huston

^۲ Point Cloud

^۳ Universal Transvers Marcatur

ماتریس \sum_X^S می پردازیم. اگر سیگنال و نویز با یکدیگر دارای همبستگی نباشند، از روابط (۳ و ۸) خواهیم داشت (رابطه (۱۰)):

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

در نتیجه، بردارهای ویژه حاصل از قطری سازی \sum_X^T و \sum_X^N با بردارهای ویژه حاصل از قطری سازی \sum_X^S و \sum_X^N برابرند و مقادیر ویژه آنها به صورت رابطه (۱۱) محاسبه می شوند [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 می توان امکان کوچک تر بودن μ_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 مشاهده ای در آنها وجود ندارد اتفاق می افتد 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 می شود.

۲-۳- طبقه بندی کننده ماشین بردار پشتیبان

الگوریتم SVM اولین بار در سال ۱۹۶۳ ارائه شد [۱۴]، و در سال ۱۹۹۵ برای حالت غیر خطی تعمیم داده شد [۱۸]. این الگوریتم از حقهی کرنل^۱ جهت تبدیل فضای داده ی اولیه به فضایی با ابعاد بیشتر به منظور ساده سازی مسئله استفاده می کند [۱۵].

در روش ماشین های بردار پشتیبان، بردارهای ورودی به یک فضای چند بعدی که غالباً ابعادی بزرگ تر از ابعاد فضای ورودی دارد نگاشت می شوند. به این ابرصفحه، ابرصفحه با حداکثر مرز جداکننده گفته می شود.

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

$$\text{رابطه (۵)}$$

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

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

$$a_k^T \sum_X^N a_k = 1, \quad k = 1, 2, \dots, d \quad (6)$$

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، لازمی عدم همبستگی بین باندها در تبدیل خطی به صورت رابطه (۷) بیان می شود [۱۱]:

قیود معرفی شده در روابط (۶ و ۷) با قیود روش آنالیز مؤلفه های اصلی متفاوت است. در روش آنالیز مؤلفه های اصلی، ماتریس \sum_X^N با ماتریس یکه جایگزین می شود و به همین دلیل تبدیل PCA یک تبدیل متعامد است، در حالی که تبدیل MNE تبدیلی غیرمتعامد خواهد بود.

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

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

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

به عبارتی دیگر، می توان ماتریس بردارهای ویژه $A_{d \times d}$ را به گونه ای به دست آورد که رابطه (۸) را ارضا نماید [۱۲]:

$$A \sum_X^S A^T = \Lambda, \quad A \sum_X^N A^T = I \quad (8)$$

که در آن، Λ 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 a_k^T و $SNR_k = \lambda_k$. جهت برقراری رابطه (۸)، باید ماتریس \sum_X^N مثبت معین و وارون پذیر باشد [۱۳]. مقادیر ویژه را نیز می توان با محاسبه ی d ریشه ی چند جمله ای رابطه (۹) به دست آورد:

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

جهت محاسبه ی \sum_X^N ، از روش Shift-difference استفاده شده است. در ادامه به توضیح نحوه ی بر آورد

¹ Kernel Trick



شکل ۱: منطقه مورد مطالعه

رابطه (۱۳)

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


که در آن، $k(x_i, x_j)$ تابع کرنل است که می‌تواند شامل هر معادله ی غیر خطی باشد. در حالت خطی، تابع کرنل برابر است با: $x_i^T x_j$ و در حالت غیر خطی می‌تواند به صورت حاصل ضرب توابعی از x_i و x_j بیان شود: $\varphi(x_i) \cdot \varphi(x_j)$. 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 برده شده 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 γ نیز برابر با معکوس تعداد بردارهای ویژگی در نظر گرفته شد.

۲-۴- 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 رضایت بخش 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^۱ (که می‌تواند دارای معادله ی خطی یا غیر خطی باشد)، در فضایی بالاتر داده‌ها را از هم تفکیک کنند [۱۶]. این روش، بهترین ابرصفحه را پیدا می‌کند که با حداکثر فاصله^۲ از محدوده ی مربوط به دو کلاس داده، داده‌های مربوط به دو کلاس را از یکدیگر تفکیک نماید.



شکل ۲: ابرصفحه با حداکثر مرز 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 معادله ی ابرصفحه ی خطی است را می‌توان به حالت کلی تعمیم داد (رابطه (۱۳))، تا تعریف معادلات مربوط به ابرصفحه ی غیر خطی را نیز شامل شود [۱۸].

رابطه (۱۲)

$$-\frac{1}{\gamma} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j x_i^T x_j + \sum_{i=1}^n \alpha_i$$

¹ Hyper-plane

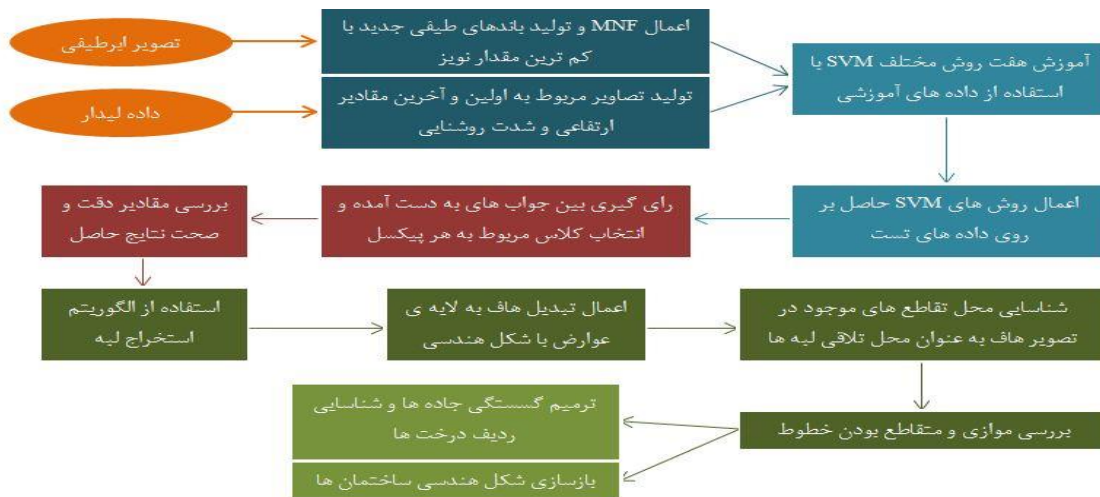
² Maximum Margin

به‌صورت پیکسلی خواهند بود. در نتیجه، احتمال گسستگی در عوارض پیوسته و یا حضور عوارض منفرد در نتایج به‌دست آمده وجود خواهد داشت. در نتیجه، ضرورت اعمال یک مرحله پس پردازش به‌منظور تصحیح عوارض پیوسته و ترمیم هندسه‌ی منظم عوارضی که به‌دست انسان ساخته شده‌اند، وجود خواهد داشت. به‌همین دلیل، پس از استخراج تمامی عوارض مرتبط با کلاس‌های موجود در داده‌های آموزشی، لبه‌های مربوط به عوارض به‌دست آمده به‌صورت جداگانه آشکارسازی می‌شوند. سپس، با استفاده از تبدیل هاف بر روی تصویر مربوط به لبه‌ها امتداد و جهت هر عارضه محاسبه می‌گردد و عوارض دارای گسستگی ترمیم می‌شوند. شکل (۳) فلوچارت روش پیشنهادی را نشان می‌دهد.

کاهش همبستگی بین باندهای طیفی، از روش MNF استفاده می‌شود. به‌منظور طبقه‌بندی داده‌ها از روش SVM در یک شیوه متفاوت بهره گرفته می‌شود. بدین‌صورت که بجای استفاده از یک مرحله SVM بر روی تمام داده‌های آموزش موجود، طبقه‌بندی کننده SVM با معادله پایه شعاعی بر روی هفت زیر مجموعه مختلف از داده‌های آموزشی، آموزش داده می‌شوند و هر یک به‌طور جداگانه به طبقه‌بندی عوارض موجود در تصاویر می‌پردازند. سپس، بین نتایج به‌دست آمده از هفت روش یادگیری ماشین‌بردار پشتیبان رای‌گیری انجام می‌شود تا کلاس نهایی مربوط به هر پیکسل مشخص شود. در این مقاله تابع کرنل مورد استفاده از نوع RBF می‌باشد. از آن جا که روش SVM تنها بر اساس پیکسل‌های اولیه آموزش می‌بیند، لذا نتایج حاصل از آن نیز

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

عنوان معادله‌ی غیر خطی	معادله‌ی مربوط به تابع کرنل
معادله‌ی چند جمله‌ای همگن	$k(x_i, x_j) = (x_i \cdot x_j)^d$
معادله‌ی چند جمله‌ای ناهمگن	$k(x_i, x_j) = (x_i \cdot x_j + 1)^d$
معادله‌ی تابع پایه شعاعی (RBF) ^۱	$k(x_i, x_j) = \exp(-\gamma \ x_i - x_j\ ^2), \gamma > 0$
معادله‌ی سیگموئید (تانزانگ 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

¹ Radial Basis Function

۳- نتایج

در این بخش پیاده‌سازی روش پیشنهادی توضیح داده شده و نتایج به دست 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) به دست آمده از (LOOCV¹) بر روی آن‌ها اعمال خواهند 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


استفاده توام از داده‌های لیدار و ابرطیفی یا به کارگیری آنها به صورت جداگانه و نیز مقایسه در حالت استفاده از یک مرحله SVM یا رای گیری بین خروجی‌های هفت SVM مختلف، نتایج مربوط به استخراج عوارض در چهار حالت مختلف به شرح زیر بررسی شدند:

- ۱- استخراج عوارض از تصویر ابرطیفی از ۱۹ مولفه اول تبدیل MNF تصویر ابرطیفی، با استفاده از رای گیری بین نتایج کلاس‌بندی حاصل از هفت SVM روش مختلف (شکل (۵-الف))،
- ۲- استخراج عوارض از ۴ تصویر لیدار به کمک رأی گیری بین نتایج هفت روش مختلف (شکل (۵-ب))،
- ۳- استخراج عوارض از کل ۲۳ ویژگی حاصل از ادغام داده‌ی ابرطیفی و لیدار به کمک یک مرحله SVM (شکل (۵-ج))
- ۴- استخراج عوارض از کل ۲۳ ویژگی حاصل از ادغام داده‌های ابرطیفی و لیدار با استفاده از اعمال هفت روش مختلف (شکل (۵-د)).

¹ Leave One Out Cross Validation

جدول ۲. تعداد نمونه‌های آموزشی و نمونه‌های آزمایشی کلاس‌های مختلف عوارض منطقه مورد مطالعه

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



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



الف



ب



ج



د

شکل ۵: الف). کلاس بندی تصویر ۱۹ باندي ابرطيفي با استفاده از ۷ روش SVM، ب). کلاس بندی تصویر ۴ باندي ليدار با استفاده از ۷ روش SVM، ج). کلاس بندی تصویر ۲۳ باندي ابرطيفي و ليدار با استفاده از يك روش SVM، د). کلاس بندی تصویر ۲۳ باندي ابرطيفي و ليدار با استفاده از ۷ روش SVM




شکل ۶: نتیجهی کلاس بندی به دست آمده از روش برگزیده در مسابقه‌ی بین المللی ادغام داده‌ها

به این منظور از روش استخراج لبه ی 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

عوارضی 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 به‌عنوان ردیف درخت‌کاری در نظر گرفته می‌شدند. در ضمن، شرط دیگری برای انتخاب عارضه‌ی درخت به‌عنوان ردیف درخت‌کاری، 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 به‌عنوان ردیف درخت‌کاری 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 درخت‌کاری. 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 روش پیشنهادی، (ب) ترمیم عوارض استخراج شده با استفاده از تعریف شیء به جای عارضه. لژاندر این تصویر در جدول (۲) آورده شده است

۳-۲- ارزیابی دقت نتایج

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

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

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

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

۴- نتیجه گیری

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 توام 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 ۹۳٫۰۳ 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 ویژگی 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 ثابت ماندن دقت، 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 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 همان طور 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 توام 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 برگزیده‌ی موسسه (GRSS^۱) 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 نداشته‌اند. 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.

¹ 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 Geo-information*, 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^{1*}, Omid Aieneh²

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