

سنجش کارایی ویژگی‌های بافتی GLCM در افزایش دقت طبقه‌بندی تصاویر حاصل از ادغام تصاویر تک‌باند و ابرطیفی مناطق مسکونی و صنعتی جنوب شهر تهران

احمد ملک‌نژاد^۱، حسن قاسمیان^{۲*}، فردین میرزاپور^۳

^۱ کارشناس ارشد سنجش از دور - دانشکده علوم انسانی - دانشگاه تربیت مدرس

a.malekny@gmail.com

^۲ استاد دانشکده برق و کامپیوتر - دانشگاه تربیت مدرس

ghassemi@modares.ac.ir

^۳ دکتری مهندسی برق - مخابرات دانشکده برق و کامپیوتر - دانشگاه تربیت مدرس

f.mirzapour@modares.ac.ir

(تاریخ دریافت فروردین ۱۳۹۳، تاریخ تصویب خرداد ۱۳۹۴)

چکیده

اکثر الگوریتم‌های طبقه‌بندی داده‌های سنجش از دور بر اساس ویژگی‌ها و اطلاعات طیفی پیکسل‌ها عمل می‌کنند. این مسئله باعث نادیده گرفتن اطلاعات مکانی مفید قابل استخراج از این تصاویر، مانند؛ بافت تصاویر می‌شود. استفاده هم‌زمان از بافت و اطلاعات طیفی مبحثی است که به آن کمتر پرداخته شده است. در این پژوهش تاثیر استفاده از بافت تصویر تک‌باند سنجنده ALI بر دقت طبقه‌بندی تصاویر ابرطیفی سنجنده هایپریون در محیط‌های شهری بررسی شده است. اطلاعات بافت تصویر تک‌باند با استفاده از ماتریس رخداد هم‌زمان (GLCM) استخراج شده است. طبقه‌بندی نیز با به‌کارگیری روش ماشین بردار پشتیبان (SVM) و در سه مرحله انجام پذیرفت: طبقه‌بندی اطلاعات طیفی تصویر ابرطیفی، طبقه‌بندی تصاویر ادغام شده به دست آمده از روش تبدیل رنگ نرمالیزه (CNT)، و نهایتاً طبقه‌بندی با استفاده هم‌زمان از بافت تصویر تک‌باند و تصاویر ابرطیفی ادغام شده. تاثیر نوع ویژگی بافت استخراجی از ماتریس رخداد هم‌زمان و همچنین اندازه پنجره استخراج بافت در پوشش‌های مختلف بررسی شد. نتایج پیاده‌سازی‌ها نشان داد که استفاده از ویژگی‌های بافتی در کنار ویژگی‌های طیفی تصاویر حاصل از ادغام، می‌تواند دقت طبقه‌بندی مناطق شهری، مانند؛ بافت مسکونی و مناطق صنعتی را به طور کلی، حدود ۵ درصد بهبود ببخشد. افزایش دقت در برخی از کلاس‌ها تا حدود ۱۵ درصد بوده است.

واژگان کلیدی: سنجش از دور، تصاویر ابرطیفی، ادغام تصاویر، بافت تصویر، طبقه‌بندی

۱- مقدمه

پوشش‌های شهری با دارا بودن محیطی ناهمگون با تغییرپذیری نسبتاً زیاد جزئیات آن و تنوع در مصالح سازنده (بتن، آسفالت، فلزات، پوشش گیاهی و خاک)، محیطی پیچیده برای کارهای مطالعاتی در حوزه سنجش از دور می‌باشد. وجود پوشش‌های ناهمگون و متنوع، شناسایی انواع کاربری‌های ارضی شهری را به فرایندی پیچیده تبدیل نموده است، به گونه‌ای که مدل‌سازی چنین پوشش‌هایی در تصاویر چندطیفی متداول با تعداد باندهای محدود امری پیچیده، دشوار و در اغلب موارد همراه با خطای زیاد می‌باشد.

تصاویر حاصل از سنجنده‌های ابرطیفی با دارا بودن بیش از ۱۰۰ باند طیفی، می‌توانند در رفع این نقیصه به میزان زیادی مؤثر باشند. از جمله این سنجنده‌ها، می‌توان به سنجنده هایپرپایون با ۲۲۴ باند اشاره کرد. در برخی تحقیقات از تصاویر این سنجنده برای مطالعات مناطق شهری استفاده شده است [۱ و ۲]. مهم‌ترین مانع در استفاده از سنجنده مذکور در این گونه مطالعات، قدرت تفکیک مکانی پایین آن (۳۰ متر) می‌باشد. بهبود دقت داده‌های این سنجنده مستلزم به‌کارگیری روش‌ها و تکنیک‌های خاصی است که از آن جمله می‌توان به ادغام تصاویر ابرطیفی با تصاویر پانکروماتیک دارای دقت مکانی بالا اشاره کرد [۷-۳]. رویکرد دیگر، بهبود دقت طبقه‌بندی این داده‌ها با استفاده از اطلاعات مکانی در کنار اطلاعات طیفی است. از جمله این روش‌ها می‌توان به روش میدان تصادفی مارکوف (MRF) و استفاده از ویژگی‌های بافت تصویر اشاره کرد [۸-۱۰]. در [۲] با استفاده از روش میدان‌های تصادفی مارکوف، افزایش محسوسی در دقت طبقه‌بندی پوشش‌های کاربری حاصل از به‌کارگیری تصاویر سنجنده ETM+ ماهواره لندست گزارش شده است. استفاده هم‌زمان از اطلاعات بافت و اطلاعات طیفی تصاویر سنجنده IKONOS نیز در تحقیق دیگری [۸] به منظور طبقه‌بندی اجتماعات گیاهی جزیره Heard در نزدیکی قطب جنوب مورد استفاده قرار گرفته است. نتایج به دست آمده، نشان دهنده افزایش ۶ درصدی دقت

خروجی حاصل از ادغام فاکتور بافت با اطلاعات طیفی بوده است.

یکی از قابلیت‌های ماهواره EO-1 که حامل سنجنده هایپرپایون می‌باشد، ارائه تصویر تک‌طیفی با قدرت تفکیک مکانی ۱۰ متر است که توسط سنجنده ALI و به صورت هم‌زمان با تصویر ابرطیفی (با قدرت تفکیک مکانی ۳۰ متر) دریافت می‌گردد. هرچند که تحقیقات زیادی در زمینه ادغام تصویر ابرطیفی سنجنده هایپرپایون با تصویر تک‌طیفی سنجنده ALI انجام گرفته [۱۱ و ۱۲]، استفاده از محتوای غنی بافتی موجود در تصویر تک‌طیفی در بهبود طبقه‌بندی تصاویر ابرطیفی متناظر، کمتر مورد مطالعه و توجه قرار گرفته است.

پژوهش پیش رو در نظر دارد تا استفاده هم‌زمان از بافت تصویر تک‌باند سنجنده ALI و اطلاعات طیفی تصویر ابرطیفی سنجنده هایپرپایون را برای طبقه‌بندی پوشش‌های زمینی در پهنه شهری جنوب تهران مورد بررسی قرار دهد. در این تحقیق، برای ادغام تصویر تک‌باند سنجنده ALI با تصویر ابرطیفی هایپرپایون به منظور تولید تصویر ابرطیفی دارای قدرت تفکیک مکانی ۱۰ متر، از روش ادغام تبدیل رنگ نرمالیزه (CNT) استفاده می‌شود. پس از تولید این تصویر، با افزودن ویژگی‌های بافت مستخرج از تصویر تک‌طیفی حاصل از روش ماتریس رخداد هم‌زمان (GLCM) به آن، بردار ویژگی جدید را با استفاده از طبقه‌بندی SVM طبقه‌بندی کرده، نتایج را بررسی می‌کنیم.

در ادامه، در بخش ۲، مشخصات داده مورد استفاده و منطقه متناظر را معرفی خواهیم کرد. در بخش ۳ نیز روش پیشنهادی مطرح شده و در بخش ۴ یافته‌های تحقیق را بررسی می‌کنیم. در انتها در بخش ۵، به جمع‌بندی موضوع خواهیم پرداخت.


۲- داده و منطقه مورد مطالعه

منطقه مورد مطالعه در این پژوهش، مشتمل بر بخشی از ناحیه جنوب غربی تهران می‌باشد که شامل کاربری‌های ارضی نسبتاً متنوعی است. علت انتخاب این منطقه وجود اکثر پدیده‌های شاخص و عوارض ساخت بشر، مانند؛

۲ Color Normalized Transform

۳ Gray-Level Co-occurrence Matrix

۱ Markov Random Field




شکل ۲- نمودار بلوکی روش پیشنهادی. ویژگی‌های طیفی حاصل از ادغام داده‌ها در سطح پیکسل به روش CNT، در کنار ویژگی‌های بافتی استخراج شده از تصویر تک‌باند قرار می‌گیرند و وارد طبقه‌بند SVM می‌شوند.

۳- روش تحقیق

این تحقیق متکی بر تکنیک‌های آزمایشگاهی است. ویژگی‌های منطقه واقع در تصاویر، تهیه و مورد پردازش اولیه قرار گرفت. در ادامه با توجه به الگوریتم به‌کارگرفته شده برای ادغام تصاویر، مراحل آماده‌سازی در محیط‌های نرم‌افزاری (ENVI و MATLAB) صورت گرفته است. نقشه خروجی از این مرحله پس از طبقه‌بندی به عنوان نقشه اولیه جهت انطباق‌سنجی با کاربری‌های واقعی در سطح زمین به وسیله پیمایش میدانی کنترل و به‌هنگام‌سازی شده است. ارزیابی دقت نقشه خروجی پس از اعمال یافته‌های میدانی مرحله پایانی این تحقیق بوده است که خروجی آن نقشه نهایی کاربری‌های اراضی محدوده مورد مطالعه است (شکل ۲).

مناطق مسکونی، معابر، باغات، مزارع و زمین‌های بایر در صحنه است.



شکل ۱- موقعیت مکانی منطقه مورد مطالعه

جدول ۱- کلاس‌های موضوعی مستخرج از تصاویر

شماره	نام پوشش	شماره	نام پوشش
۱	مزارع ذرت	۸	باغ نوع ۱
۲	زمین‌های بایر نوع ۱	۹	باغ نوع ۲
۳	زمین‌های بایر نوع ۲	۱۰	ردیف‌های درخت
۴	پوشش مسکونی	۱۱	سقف فلزی کارخانجات
۵	پوشش صنعتی	۱۲	زمین‌های آیش
۶	خاک بدون پوشش گیاهی	۱۳	زمین‌های شخم‌خورده
۷	جاده‌ها و معابر	۱۴	صنایع کوچک

این منطقه، مشتمل بر ۶۲۳۴ هکتار از اراضی کشاورزی و سکونتگاهی تهران در مجاورت آزادراه‌های آزادگان و خلیج فارس می‌باشد (شکل ۱).

تصاویر استفاده شده در این تحقیق، هر دو از ماهواره EO-1 اخذ شده‌اند. داده ابرطیفی مورد استفاده، از سنجنده هایپریون این ماهواره اخذ گردیده که دارای ۲۲۴ باند در محدوده طیفی ۰/۳۵۵ تا ۲/۵۵ میکرون با عرض باند ۱۰ نانومتر است. تصویر تک‌طیفی مورد استفاده نیز از سنجنده ALI مستقر بر همین ماهواره اخذ شده است. این تصویر دارای قدرت تفکیک مکانی ۱۰ متر در محدوده طیفی ۰/۴۸ تا ۰/۶۹ میکرون می‌باشد. از این تصویر برای ادغام با تصویر ابرطیفی و هم‌چنین استخراج بافت تصاویر استفاده شده است. پوشش‌های زمینی عمده موجود در سطح منطقه متناظر (۱۴ پوشش)، از طریق بررسی میدانی و استفاده از تصاویر با قدرت تفکیک مکانی بالا انتخاب شد (جدول ۱).



(الف) (ب) (پ)

شکل ۳- تصویر مورد مطالعه؛ (الف) تصویر رنگی ساخته شده از داده ابرطیفی هایپریون، (ب) تصویر تک‌طیفی ALI، و (پ) تصویر رنگی ساخته شده از داده ابرطیفی حاصل از ادغام این دو به روش CNT

N_b نشان داده شده است. مراحل ادغام به روش CNT به صورت زیر می‌باشد (شکل ۲):

- انتخاب زیرمجموعه‌ای از باندهای داده ابرطیفی که دارای اشتراک طیفی با تصویر تک‌طیفی هستند
- یکسان‌سازی قدرت تفکیک مکانی باندهای انتخابی با تصویر تک‌طیفی و هم‌مختصات کردن آن‌ها

- استفاده از رابطه (۱) برای ادغام باندهای انتخابی داده ابرطیفی با تصویر تک‌طیفی، و استخراج تصویر ابرطیفی ادغام شده [۱۴].

نتیجه اعمال این الگوریتم به داده ابرطیفی هایپریون در شکل ۳ نشان داده شده است.

۳-۱- استخراج اطلاعات بافت

روش‌های استخراج بافت تصاویر را می‌توان به چهار دسته عمده تقسیم نمود: ساختاری، آماری، استخراج بافت بر اساس مدل، و استخراج بافت بر اساس تبدیل. روش ماتریس رخداد همزمان (GLCM) از جمله روش‌های آماری استخراج بافت است که توسط Haralick در سال ۱۹۷۳ ارائه شده است [۱۵]. این روش بر اساس فاصله و زاویه میان دو زوج پیکسل که در یک پنجره با ابعاد مشخص قرار گرفته‌اند به محاسبه بردارهای ویژگی می‌پردازد. در تحقیق اولیه Haralick، ۲۳ ویژگی معرفی گردید که در سال ۱۹۷۹، وی این ۲۳ ویژگی را به ۸ ویژگی تقلیل داد [۱۶].

تصاویر ابرطیفی سنجنده EO-1 به علت پهنای باند بسیار کم، بیشتر از تصاویر چند طیفی تحت تاثیر عوامل جوی می‌باشند؛ لذا لازم است با به‌کارگیری الگوریتم‌های تصحیح اتمسفری اثرات جوی به حداقل رسانده شود. از سوی دیگر باندهای تصویر ابرطیفی دارای پدیده استریپ یا جا افتادگی خطی اطلاعات هستند که قبل از تصحیح اتمسفری باید این باندها به دقت تصحیح و باز سازی شوند [۱۳].

بعد از حذف باندهای ناسالم تصویر ابرطیفی، (باندهای تخریب شده، باندهای جذبی، باندهای کالیرنه نشده) در نهایت ۲۲۴ باند اولیه به ۱۳۴ باند کاهش یافت. در مرحله بعد، الگوریتم FLAASH^۱ برای انجام اصلاحات اتمسفری مورد استفاده قرار گرفت تا داده نهایی برای فرایند ادغام آماده گردد.

تصحیح هندسی به منظور هم‌مختصات نمودن تصاویر مورد نظر برای ادغام انجام پذیرفت. بدین منظور با مرجع قراردادن تصویر تک‌طیفی، فرایند تثبیت و هم‌مختصات کردن با استفاده از ۱۹ نقطه کنترل زمینی و معادلات چندجمله‌ای درجه ۲ در کل تصویر با دقت ۰/۴۲ پیکسل انجام گردید. در مرحله بعد برای درون‌یابی تصویر، از روش نزدیک‌ترین همسایه استفاده گردید. علت استفاده از این روش، حفظ بیشتر اطلاعات طیفی نسبت به سایر روش‌های درون‌یابی است.

در این پژوهش، ادغام تصاویر با استفاده از روش تبدیل رنگ نرمالیزه (CNT) صورت پذیرفته است. این روش یکی از روش‌های ادغام مبتنی بر مولفه‌های رنگی است که از تصویر تک‌طیفی به صورت مستقیم استفاده می‌نماید. کارایی این روش در صورتی تامین خواهد شد که هم‌پوشانی طیفی زیادی بین تصویر چندطیفی و تصویر تک‌طیفی وجود داشته باشد. ادغام به روش CNT بر اساس رابطه زیر انجام می‌پذیرد:

$$MS_i^F = \frac{MS_i \times Pan}{\sum_{j=1}^{N_b} MS_j} \quad (۱)$$

که در آن، MS_i سطح روشنایی هر پیکسل در باند i -ام و مخرج کسر، مجموع سطوح روشنایی همان پیکسل در تمام باندها است. تعداد باندهای تصویر چندطیفی نیز با

^۱ Fast Line of Sight Atmospheric Analysis Spectral Hypercubes

جدول ۲- ویژگی‌های بافتی GLCM. در این روابط p_d ماتریس GLCM نرمالیزه با ابعاد $N \times N$ و N تعداد سطوح خاکستری تصویر مورد پردازش است.

ویژگی	رابطه
میانگین	$\mu_x = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} i p_d(i, j)$
واریانس	$\sigma_x^2 = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} (i - \mu_x)^2 p_d(i, j)$
همگنی	$\sum_{i=0}^{N-1} \sum_{j=0}^{N-1} \frac{1}{1 + (i - j)^2} p_d(i, j)$
کنتراست	$\sum_{i=0}^{N-1} \sum_{j=0}^{N-1} (i - j)^2 p_d(i, j)$
عدم مشابهت	$\sum_{i=0}^{N-1} \sum_{j=0}^{N-1} i - j p_d(i, j)$
آنترپی	$-\sum_{i=0}^{N-1} \sum_{j=0}^{N-1} \ln(p_d(i, j)) p_d(i, j)$
ممان دوم زاویه‌ای	$\sum_{i=0}^{N-1} \sum_{j=0}^{N-1} (p_d(i, j))^2$
همبستگی	$\frac{\sum_{i=0}^{N-1} \sum_{j=0}^{N-1} (i - \mu_x)(j - \mu_y) p_d(i, j)}{\sigma_x \sigma_y}$

این ویژگی‌ها در جدول ۲ نمایش داده شده‌اند. در این پژوهش نیز از این ۸ ویژگی استفاده شده است. پارامترهای موثر در ویژگی‌های GLCM عبارتند از؛ اندازه پنجره همسایگی و فاصله میان زوج پیکسل‌های مورد استفاده در استخراج ماتریس GLCM. تغییر این دو پارامتر می‌تواند تاثیر چشمگیری در ویژگی‌های نهایی داشته باشد. در این تحقیق از چهار اندازه پنجره ۳، ۵، ۷ و ۹ برای محاسبه ماتریس رخداد همزمان استفاده و تاثیر آن بررسی شده است. فاصله بهینه میان زوج پیکسل‌ها در تحقیقات پیشین به صورت یک فاصله عمودی و یک فاصله افقی، $d = (1, 1)$ ، تعیین شده است [۱۷]. در این تحقیق نیز از این فاصله برای محاسبه میان زوج پیکسل‌ها استفاده شده است.

۳-۲- طبقه‌بندی تصاویر

عملیات طبقه‌بندی با استفاده از طبقه‌بند ماشین بردار پشتیبان (SVM) انجام شده است. علت انتخاب این طبقه‌بند، مقاوم بودن آن در برابر تعداد کم نمونه‌های

آموزشی و عملکرد قابل قبول‌تر نسبت به سایر روش‌های طبقه‌بندی معمول، مانند؛ شبکه‌های عصبی و حداکثر احتمال است [۱۸ و ۱۹]. SVM در واقع یک طبقه‌بند دو کلاسی خطی بوده، به دنبال یافتن ابرصفحه‌ای است که قادر به جدا کردن داده‌های آموزشی بر اساس معادله بهینه‌سازی زیر باشد:

$$\left\{ \begin{array}{l} \min \left\{ \frac{1}{2} \|w\|^2 + C \sum_{i=1}^K \xi_i \right\} \\ y_i (w^T x_i + b) \geq 1 - \xi_i ; i = 1, \dots, K \end{array} \right. \quad (2)$$

در رابطه بالا، x_i و y_i به ترتیب بردار ویژگی و برچسب کلاس مربوط به پیکسل i -ام بوده، w و b به ترتیب، ضرایب معادله ابرصفحه مورد نظر و مقدار ثابت آن هستند. کمینه کردن عبارت اول، یعنی $\frac{1}{2} \|w\|^2$ ، باعث بیشینه کردن فاصله بین نزدیک‌ترین نمونه‌های آموزشی کلاس‌ها (یا به عبارت دیگر؛ بردارهای پشتیبان آن) و ابرصفحه مرزی می‌شود که قدرت تعمیم طبقه‌بند از داده‌های آموزشی به داده‌های آزمایشی را بالا می‌برد. در عبارت دوم نیز وجود پارامتر C برای بالا بردن هزینه طبقه‌بندی اشتباه نمونه‌های آموزشی است (ξ_i)، فاصله نمونه آموزشی x_i از ابرصفحه مرزی است در صورتی که اشتباه طبقه‌بندی شده باشد). باید دقت داشت که افزایش این پارامتر موجب کاهش قابلیت تعمیم طبقه‌بندی و عدم انطباق صحیح با عوارض موجود در تصویر می‌گردد [۲۰ و ۲۱].

به علت این که در بیشتر موارد عملی، کلاس‌ها در فضای اولیه خود معمولاً به صورت خطی قابل جداسازی نیستند، داده‌ها به یک فضای ویژگی با ابعاد بالاتر انتقال می‌یابند [۲۲]. این انتقال به صورت ضمنی و با به کارگیری تکنیک هسته^۲ انجام می‌شود. هسته‌های متنوعی در این زمینه معرفی شده‌اند که می‌توان از آن جمله به چهار هسته اشاره کرد: خطی، چند جمله‌ای، گاوسی یا RBF^۳ و سیگموئید. این هسته‌ها، به ترتیب، در روابط زیر آمده‌اند:

$$K(x_i, x_j) = x_i^T x_j \quad (3)$$

$$K(x_i, x_j) = (\gamma x_i^T x_j + r)^d \quad (4)$$

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2) \quad (5)$$

^۲ Kernel trick

^۳ Radial Basis Function

^۱ Support Vector Machine

$$K(x_i, x_j) = \tanh(\gamma x_i^T x_j + r) \quad (6)$$

پارامترهای γ ، r و d در روابط بالا، مقادیری هستند که باید توسط کاربر انتخاب شوند. به این پارامترها باید C را هم اضافه کرد که در رابطه (۱) توضیح داده شد. به دلیل کارایی بهتر هسته گاوسی در طبقه‌بندی تصاویر سنجش از دور [۲۲-۲۴]، ما نیز از این هسته استفاده کرده‌ایم.

به منظور پیاده‌سازی طبقه‌بند SVM، از بسته نرم‌افزاری e1071 در زبان برنامه‌نویسی R استفاده شد که پیش از این در پژوهش‌های دیگر نیز به کار گرفته شده است [۲۲، ۲۵، ۲۶]. از مزیت‌های این بسته نرم‌افزاری، قابلیت تنظیم پارامترهای طبقه‌بند است که با استفاده از تابع tune انجام می‌شود. این قابلیت باعث می‌شود تا این بسته نرم‌افزاری در کران‌های تعیین شده توسط کاربر، که معمولاً توانی از دو می‌باشد، به جستجوی پارامترهای بهینه در طبقه‌بندی پرداخته و پارامترهای بهینه (در مورد این پژوهش دو پارامتر C و γ) را استخراج نماید.

در این تحقیق در تمام طبقه‌بندی‌ها، به منظور آموزش طبقه‌بند، ۲۰ درصد نمونه‌های برچسب‌دار هر کلاس را به صورت تصادفی به عنوان نمونه آموزشی انتخاب می‌کنیم. سایر نقاط (۸۰ درصد باقیمانده) را به عنوان نمونه آزمایشی برای ارزیابی به کار می‌بریم.

۴- یافته‌های تحقیق

در تحقیق حاضر، تصاویر ابرطیفی و تصویر تک‌طیفی ALI هم در سطح پیکسل و هم در سطح ویژگی ادغام شدند. برای ارزیابی این ادغام‌ها، در ابتدا تصاویر ابرطیفی اصلی با استفاده از نمونه‌های آموزشی و پیش از فرایند ادغام، طبقه‌بندی گردیدند. نتایج این طبقه‌بندی با طبقه‌بندی داده ابرطیفی حاصل از ادغام در سطح پیکسل (به روش CNT) مقایسه گردید. این نتایج در جدول ۳ آمده است. همان‌گونه در این جدول می‌بینیم، طبقه‌بندی تصویر ابرطیفی ادغام شده به روش CNT دارای عملکرد مناسب‌تری است (افزایش ۱۴/۷ درصدی به طور میانگین) که آن را می‌توان ناشی از قدرت تفکیک مکانی بالاتر و کاهش پیکسل‌های مخلوط دانست. به‌علاوه، در کلاس‌های ۱۰، ۱۱ و ۱۴ تصویر ادغام شده توانسته است نتایج بسیار بهتری ایجاد کند؛ به ترتیب، افزایش ۵۵/۵،


۸۷/۲ و ۶۹/۵ درصد. البته، در زمین‌های آیش، کشاورزی و بایر، افزایش دقت ناچیز می‌باشد که آن را می‌توان ناشی از وجود پهنه‌های وسیع در این پوشش‌ها و عدم نیاز به قدرت تفکیک مکانی بالا دانست.

جدول ۳- تاثیر افزایش قدرت تفکیک مکانی داده ابرطیفی هایپریون (در اثر ادغام با داده تک‌طیفی ALI) بر دقت طبقه‌بندی پوشش‌های شهری مختلف (جدول ۱)؛ ستون آخر، میزان افزایش دقت را نشان می‌دهد.

شماره کلاس	داده ابرطیفی اصلی	داده ابرطیفی ادغامی (CNT)	میزان افزایش دقت
۱	۹۱/۴	۹۹/۷	۸/۳
۲	۹۶/۳	۹۷/۰	۰/۷
۳	۹۹/۱	۹۹/۶	۰/۶
۴	۶۱/۹	۷۰/۱	۸/۲
۵	۳۹/۴	۴۰/۶	۱/۲
۶	۶۹/۲	۴۵/۸	-۲۳/۴
۷	۱/۹	۰/۶	-۱/۳
۸	۹۸/۱	۹۸/۱	۰
۹	۶۷/۳	۷۱/۳	۴/۰
۱۰	۲۱/۴	۷۶/۹	۵۵/۵
۱۱	۰/۰	۸۷/۲	۸۷/۲
۱۲	۹۹/۴	۹۹/۲	-۰/۲
۱۳	۹۹/۱	۹۵/۴	-۳/۷
۱۴	۳/۷	۷۳/۲	۶۹/۵
متوسط	۶۰/۶	۷۵/۳	۱۴/۷

در مرحله بعد، اثر افزودن ویژگی‌های مختلف GLCM (استخراج شده از داده تک‌باند ALI، با استفاده از پنجره‌های همسایگی با اندازه‌های متفاوت) در بهبود دقت طبقه‌بندی بررسی شد. نتایج افزودن این ویژگی‌ها در بهبود دقت طبقه‌بندی سه کلاس پوشش مسکونی، پوشش صنعتی و صنایع کوچک، به ترتیب در سه شکل ۴، ۵ و ۶ نمایش داده شده است. در این شکل‌ها، دقت طبقه‌بندی ویژگی‌های طیفی (حاصل از ادغام) با رنگ سبز روشن و با نام «فقط طیفی» مشخص شده است. مقدار این دقت و همچنین مقدار بالاترین دقت حاصل از افزودن ویژگی‌های GLCM نیز بر روی نمودارها درج شده است.

در کلاس پوشش مسکونی، افزودن ویژگی‌های بافتی سبب افزایش حدود ۶ درصدی دقت طبقه‌بندی (از ۷۰/۰۸ به ۷۶/۶۴ درصد) شده است. این میزان، برای پوشش صنعتی ۱۵ درصد و برای مناطق صنعتی کوچک و پراکنده ۱۴ درصد است.




شکل ۳- تاثیر افزودن ویژگی‌های بافتی در دقت طبقه‌بندی مناطق صنعتی. (توضیحات مانند شکل ۴)

جدول ۴- دقت طبقه‌بندی کلی حاصل از افزودن ویژگی‌های بافتی مختلف (به دست آمده از پنجره همسایگی با اندازه پنجره متفاوت) به بردار ویژگی طیفی داده ابرطیفی حاصل از ادغام.

اندازه پنجره				ویژگی اضافه شده به بردار ویژگی طیفی
۳	۵	۷	۹	
۸۶/۶	۸۷/۳	۸۸/۵	۹۰/۱	میانگین
۸۶/۳	۸۶/۶	۸۶/۶	۸۷/۶	واریانس
۸۶/۹	۸۸/۷	۸۸/۷	۸۹/۷	همگنی
۸۶/۴	۸۶/۴	۸۶/۶	۸۶/۸	کنتراست
۸۸/۳	۹۰/۰	۹۰/۲	۹۰/۵	عدم مشابهت
۸۷/۱	۸۸/۹	۸۹/۰	۹۰/۵	آنترپوی
۸۷/۳	۸۸/۶	۸۸/۵	۹۰/۱	ممان دوم زاویه‌ای
۸۷/۳	۸۸/۰	۸۷/۴	۸۷/۳	هم‌بستگی
۸۶/۱				صرفاً طیفی (CNT)

مشابه پوشش مسکونی، در این حالت نیز افزایش دقت با افزایش اندازه پنجره رابطه مستقیم دارد. در کلاس صنایع کوچک، اندازه پنجره با افزایش دقت دارای رابطه مستقیم نیست و با افزایش اندازه پنجره از مقدار ۵، کاهش دقت با افزایش اندازه پنجره مشاهده می‌شود.

دقت کلی طبقه‌بندی حاصل از افزودن هر یک از ویژگی‌های GLCM به بردار ویژگی طیفی نیز، در جدول ۴ نشان داده شده است.




شکل ۴- تاثیر افزودن ویژگی‌های بافتی در دقت طبقه‌بندی مناطق مسکونی. دقت طبقه‌بندی ویژگی‌های طیفی (حاصل از ادغام) با نام «فقط طیفی» مشخص شده است. مقدار این دقت و همچنین مقدار بالاترین دقت حاصل از افزودن ویژگی‌های GLCM نیز بر روی نمودارها درج شده است.




شکل ۵- تاثیر افزودن ویژگی‌های بافتی در دقت طبقه‌بندی صنایع کوچک. (توضیحات مانند شکل ۴)

بهترین عملکرد را در کلاس مسکونی نیز ویژگی همگنی (در اندازه پنجره ۹) داشته است. افزایش اندازه پنجره باعث بهبود دقت طبقه‌بندی در این کلاس می‌شود. در پوشش صنعتی نیز بهترین دقت با افزودن ویژگی واریانس (در اندازه پنجره ۹) به دست آمده است.



شکل ۷- نقشه موضوعی حاصل از: (الف) طبقه‌بندی ویژگی‌های طیفی تصویر ادغام شده، و (ب) طبقه‌بندی همان ویژگی‌ها با افزودن ویژگی بافت (آنتروپی) به آن‌ها.



شکل ۸- مقایسه بخش‌هایی از نقشه موضوعی حاصل از: (الف) طبقه‌بندی ویژگی‌های طیفی تصویر ادغام شده، و (ب) طبقه‌بندی همان ویژگی‌ها با افزودن ویژگی بافت (آنتروپی) به آن‌ها

اعدادی که در هر اندازه پنجره دارای بیش‌ترین مقادیر می‌باشند با رنگ تیره‌تر نمایش داده شده‌اند. بالاترین

میزان دقت با مقدار $90/50$ مربوط به بردارهای ویژگی آنتروپی و عدم مشابهت با اندازه پنجره ۹ است که $4/4$ درصد افزایش دقت را نشان می‌دهد.

در شکل ۷-الف، نقشه موضوعی تولید شده توسط طبقه‌بندی ویژگی‌های طیفی تصویر ادغام شده نمایش داده شده است. شکل ۷-ب نیز نتیجه حاصل از افزودن ویژگی آنتروپی (با اندازه پنجره ۹) را نشان می‌دهد که می‌توان در مقایسه با شکل ۷-الف، پاره‌ای بهبودها را در آن مشاهده کرد. برای مقایسه دقیق‌تر، بخش‌هایی از این نقشه‌ها در شکل ۸ در کنار هم نمایش داده شده است. در این شکل، بهبود لبه‌ها، بارزسازی مناسب‌تر مناطق مسکونی (که با رنگ سبز تیره مشخص شده‌است)، بارزسازی بیشتر جاده‌ها و حذف پیکسل‌های غیرمرتبط را به ترتیب در ردیف‌های بالا به پایین، می‌توان دید.

۵- نتیجه‌گیری

اگر چه بررسی اثر ادغام تصاویر سنجنده هایپریون با سایر سنجنده‌ها در بهبود نتایج طبقه‌بندی بارها مورد بحث و بررسی قرار گرفته است، استفاده از اطلاعات بافت در این زمینه مقوله‌ای نوین می‌باشد. اخذ هم‌زمان تصویر سنجنده ALI و سنجنده هایپریون (به علت قرار گرفتن هر دو سنجنده در ماهواره EO-1) و قدرت تفکیک مکانی ۱۰ متر تصویر تک‌طیفی سنجنده ALI در مقابل قدرت تفکیک مکانی ۳۰ متری هایپریون، این امکان را فراهم می‌آورد تا به گونه‌ای از اطلاعات مکانی دقیق‌تر تصویر ALI در طبقه‌بندی داده‌های هایپریون استفاده گردد.

رویکرد استفاده هم‌زمان از بافت تصویر تک‌طیفی در طبقه‌بندی تصاویر ابرطیفی رویکردی کاملاً جدید بوده و در پژوهش دیگری بررسی نشده است. استفاده از این ویژگی‌های بافتی در طبقه‌بندی توانست پوشش‌های کاربری شهری با پیکسل‌های مختلط (با اختلاط زیاد)، مانند؛ ردیف‌های درخت، جاده‌ها و معابر، و پوشش مسکونی، را به نحو چشمگیری بهبود بخشد. دقت کلی طبقه‌بندی حدود ۵ درصد افزایش یافته و در کلاس‌های مورد بررسی در محیط شهری، مانند؛ پوشش مسکونی، پوشش صنعتی و صنایع کوچک و پراکنده بین ۶ تا ۱۵ درصد افزایش دقت مشاهده گردید.

سپاسگزاری

در پایان لازم می‌دانیم که از زحمات مهندس حسن کوشا که در تهیه تصاویر ادغامی ما را یاری رساند تشکر نماییم. همچنین از زحمات مهندس وحید عیسوی که در زمینه بررسی عامل بافت در تصاویر چند طیفی پژوهش نموده و در تکمیل این پژوهش یاری‌رسان بودند تشکر می‌گردد.

به علت گستردگی روش‌های ادغام تصاویر و متنوع بودن ویژگی‌های مکانی، در این پژوهش تنها افزودن تکویژگی‌های بافتی GLCM به تصویر ابرطیفی حاصل از روش CNT مورد بررسی قرار گرفت. به همین دلیل، به نظر می‌رسد تحقیقات بیشتری در این زمینه لازم است تا به بهترین ترکیب از «روش ادغام» و «روش استخراج ویژگی‌های مکانی»، و همچنین به‌کارگیری روش‌های کاراتر برای ادغام در سطح ویژگی، دست یافت.

مراجع

- [1] Welikanna, D.R., Tolpekin, V. and Yogesh K., (2008). "Analysis of the Effectiveness of Spectral Mixture Analysis and Markov Random Field Based Super Resolution Mapping Over an Urban Environment". International Archives of the Photogrammetry, Remote Sensing and Spatial Information Science, Vol. XXXVII.Part B7, PP.641-649.
- [2] Kasetkasem, T., Arora, M.K., and Varshney, P.K (2005). "Super resolution land cover mapping using a Markov random field based approach." Remote Sensing of Environment. Vol 96, No. 3-4, PP 302-314.
- [3] Ghahremani, M., and Ghassemian, H., (2015). "Remote-sensing image fusion based on curvelets and ICA," International Journal of Remote Sensing, vol. 36, pp. 4131-4143.
- [4] Pour, A.B., and Hashim, M. (2013). "Fusing ASTER, ALI and Hyperion data for enhanced mineral mapping". International Journal of Image and Data Fusion, Vol. 4, No. 2, PP 1-20.
- [5] Shahdoosti, H. R., and Ghassemian, H., (2015). "Fusion of MS and PAN Images Preserving Spectral Quality," Geoscience and Remote Sensing Letters, IEEE, vol. 12, pp. 611-615.
- [6] Licciardi, G. A., Khan, M. M., And Chanussot, J. (2012). "Fusion of hyperspectral and panchromatic images: A hybrid use of induction and nonlinear PCA", Proc. 19th IEEE International Conference on Image Processing (ICIP), PP. 2133-2136. 30 September - 3 October 2012, Orlando, Florida, USA.
- [7] Shahdoosti, H. R, and Ghassemian, H. (2016). "Combining the spectral PCA and spatial PCA fusion methods by an optimal filter," Information Fusion, vol. 27, pp. 150-160.
- [8] Murray, H., Lucieer, A., and Williams, R. (2010). "Texture-based classification of sub-Antarctic vegetation communities on Heard Island". International Journal of Applied Earth Observation and Geoinformation, Vol. 12, No. 3, PP. 138-149.
- [9] Mirzapour, F. and Ghassemian, H., (2015). "Improving hyperspectral image classification by combining spectral, texture, and shape features," International Journal of Remote Sensing, vol.36, pp.1070-1096.
- [10] Khodadadzadeh, M., Rajabi, R., and Ghassemian, H., (2011). "A novel approach for spectral-spatial classification of hyperspectral data based on SVM-MRF method," in Geoscience and Remote Sensing Symposium (IGARSS), IEEE International, pp. 1890-1893.
- [11] Goodenough, D. G., Dyk, A., Niemann, K. O., Pearlman, J. S., Chen, H., Han, T. and West, C. (2003). "Processing Hyperion and ALI for forest classification". IEEE Transactions on Geoscience and Remote Sensing, Vol. 41, No. 6, PP. 1321-1331.
- [12] Pande, H., Tiwari, P. S., and Dobhal, S. (2009). "Analyzing hyper-spectral and multi-spectral data fusion in spectral domain". Journal of the Indian Society of Remote Sensing, Vol. 37, No. 3, PP. 395-408.
- [13] Kawishwar.P, (2007). "Atmosphere correction models for retrievals of calibrated spectral profiles from Hyperion EO-1 data". International Institute for Geo-Information Science and Earth Observation. Master Thesis. Enschede, The Netherlands (2007).

- [14] Dobhal, S. (2008). "Performance analysis of high-resolution and hyperspectral data fusion for classification and linear feature extraction". Master Thesis, ITC, Enschede (2008).
- [15] Haralick, R. M., Shanmugam, K., and Dinstein, I. H. (1973). "Textural features for image classification". IEEE Transactions on Systems, Man and Cybernetics, Vol. 6, PP 610-621.
- [16] Haralick, R. M. (1979). "Statistical and structural approaches to texture". IEEE Proceedings, Vol. 67, No. 5, PP 786-804.
- [17] Hall-Beyer, M., (2007). GLCM Texture: A Tutorial, Version 2.10. Viewed 16, Available at: <http://www.fp.ucalgary.ca/mhallbey/tutorial.htm>.
- [18] Féret, J., Asner, G. P. (2013). "Tree species discrimination in tropical forests using airborne imaging spectroscopy". Geoscience and Remote Sensing, IEEE Transactions on, Vol. 51, No. 1, PP.73-84.
- [19] Mountrakis, G., Im, J., and Ogole, C. (2011). "Support vector machines in remote sensing: A review". ISPRS Journal of Photogrammetry and Remote Sensing, Vol. 66, No. 3, PP 247-259.
- [20] Mather, P., & Tso, B. (2009). "Classification methods for remotely sensed data (Second Edition)". CRC press. Boca Raton.
- [21] Goumehei, E. (2010). "Contextual image classification with support vector machine". Master Thesis, ITC, Enschede
- [22] Colgan, M. S., Baldeck, C. A., Féret, J. B., And Asner, G. P. (2012). "Mapping savanna tree species at ecosystem scales using support vector machine classification and BRDF correction on airborne hyperspectral and LiDAR data". Remote Sensing, Vol. 4, NO. 11, PP 3462-3480.
- [23] Huang, C., Davis, L. S., And Townshend, J. R. G. (2002). "An assessment of support vector machines for land cover classification". International Journal of Remote Sensing, Vol. 23, No. 4, PP 725-749.
- [24] Petropoulos, G. P., Knorr, W., Scholze, M., Boschetti, L., and Karantounias, G. (2010). "Combining ASTER multispectral imagery analysis and support vector machines for rapid and cost-effective post-fire assessment: a case study from the Greek wildland fires of 2007". Natural Hazards and Earth System Science, Vol. 10, No. 2, PP 305-317.
- [25] Oommen, T., Misra, D., Twarakavi, N. K., Prakash, A., Sahoo, B., and Bandopadhyay, S. (2008). "An objective analysis of support vector machine based classification for remote sensing". Mathematical geosciences, Vol. 40, No. 4, PP 409-424.
- [26] Lizarazo, I. (2008). "SVM-based segmentation and classification of remotely sensed data". International Journal of Remote Sensing, Vol. 29, No. 24, PP 7277-7283.