

طبقه‌بندی تصویر مدل رقومی سطح لایدار بر اساس نیمرخ‌های ریخت‌شناسی چندشکلی و شبکه نواحی تصادفی عمیق مبتنی بر تبدیل تحلیل تفکیک پذیری خطی

بهنام اصغری بیرامی^{۱*}، محمدرضا سیف^۲

۱- پژوهشگر خبره گروه مهندسی نقشه‌برداری و داده‌های مکانی، دانشکده عمران، نقشه‌برداری و مهندسی دفاعی، دانشگاه امام حسین (ع)، تهران، ایران
۲- استادیار گروه مهندسی نقشه‌برداری و داده‌های مکانی، دانشکده عمران، نقشه‌برداری و مهندسی دفاعی، دانشگاه امام حسین (ع)، تهران، ایران

تاریخ دریافت مقاله: ۱۴۰۳/۱۰/۱۸ تاریخ پذیرش مقاله: ۱۴۰۵/۰۲/۲۳

چکیده

اطلاعات ارتفاعی مشابه در رده‌های زمینی مختلف، طبقه‌بندی عوارض و رده‌های زمینی را در تصاویر مدل رقومی سطح (*DSM*) حاصل شده از حسگرهای لایدار (*LiDAR*) به امری چالش‌برانگیز تبدیل می‌کند. علاوه بر اطلاعات ارتفاعی، تصاویر *DSM* حاوی اطلاعات مکانی ارزشمندی نیز می‌باشد که این اطلاعات می‌تواند کمک شایانی به بهبود دقت طبقه‌بندی کند. در سال‌های اخیر روش‌های یادگیری عمیق به عنوان ابزاری قدرتمند برای استخراج اطلاعات و طبقه‌بندی تصاویر تبدیل شده‌اند. علی‌رغم نتایج مطلوب عمده‌ی این روش‌ها، بسیاری از رویکردهای یادگیری عمیق پیشنهادی دارای ساختاری پیچیده هستند و به سخت‌افزار پیشرفته و حجم نمونه آموزشی زیاد نیاز دارند. به عنوان یک راه حل، این مقاله یک راهبرد جدید برای طبقه‌بندی *DSM* به منظور دستیابی به نقشه‌های دقیق پوشش زمین پیشنهاد می‌کند. روش پیشنهادی، به نام *MMP-MLDANet*، از نیمرخ‌های ریخت‌شناسی چندشکلی (*MMP*) و شبکه‌های نواحی تصادفی عمیق مبتنی بر تبدیل تحلیل تفکیک-پذیری خطی با مقیاس چندگانه (*MLDANet*) به منظور استخراج ویژگی استفاده می‌کند. در نهایت یک سیستم طبقه‌بندی‌کننده چندگانه بر مبنای ماشین‌های بردار پشتیبان (*SVM*) به منظور طبقه‌بندی ویژگی‌های عمیق تولیدی توسعه داده شده است. بر اساس آزمایش‌های انجام‌شده بر روی تصاویر تک باند *DSM*، روش ارائه شده در وضعیت وجود تعداد محدودی از نمونه‌های آموزشی در مناطق هیوستون و ترنتو به دقت کلی بترتیب ۹۰٫۸۵٪ و ۹۸٫۴۹٪ دست یافت که از برخی روش‌های موجود در این حوزه بهتر است.

کلیدواژه‌ها: مدل رقومی سطح، لایدار، یادگیری عمیق، طبقه‌بندی، نیمرخ ریخت‌شناسی.

* نویسنده مکاتبه‌کننده: تهران- اتوبان شهید بابایی- بعد از پل لشگرک - روبروی حکیمیه - دانشگاه جامع امام حسین (ع) - موقعیت امام صادق (ع).

تلفن: ۰۹۳۵۵۸۴۵۶۳۶

۱- مقدمه

سنجده‌های لیزر اسکن یا لایدار^۱ (*LiDAR*) نوعی از حسگرهای سنجش از دوری هستند که از پالس‌های لیزری برای اندازه‌گیری فاصله بین سنجنده و اشیاء استفاده می‌کند. خروجی لایدار عمدتاً به صورت ابر نقطه نمایش داده می‌شوند که به طور گسترده در زمینه‌های مختلفی مانند مطالعات شهری، پایش جنگل، مطالعات زیست‌محیطی و مدیریت مخاطرات طبیعی مورد استفاده قرار می‌گیرند [۱، ۲، ۳ و ۴]. مدل رقومی سطح^۲ (*DSM*) یکی از محصولات اصلی لایدار است که از ابر نقطه و پس از طی مراحل نظیر پایش پردازش، حذف نویز و رستری‌سازی به دست می‌آید [۵]. در تصاویر *DSM* نهایی روشنایی هر پیکسل بیانگر اطلاعات ارتفاعی در آن پیکسل است. به طور نظری می‌توان در نظر داشت که اگر در ناحیه‌ای ارتفاع عامل تمایز میان رده‌های^۳ مختلف زمینی باشد (مثلاً درخت از چمن)، *DSM* ویژگی مطلوبی برای طبقه‌بندی سطح زمین است.

به طور سنتی در مطالعات پیشین از داده‌ی *DSM* به عنوان اطلاعات کمکی همراه با ویژگی‌های طیفی برای افزایش دقت طبقه‌بندی پوشش زمین استفاده شده است. در تحقیق صادقی و همکاران (۲۰۱۶) یک روش تلفیقی کارآمد به منظور طبقه‌بندی داده‌های ابرطیفی و لایدار ارائه شده است. در این روش با ساخت گراف مجاورت از روی نمونه‌های آموزشی و تلفیق سه فضای ویژگی (ارتفاعی، مکانی و طیفی)، سپس اعمال تبدیل تصویرسازی‌های حافظ محلی^۴ (*LPP*)، دقت طبقه‌بندی نسبت به روش‌های پیشین افزایش می‌یابد [۶]. در تحقیق سجادی و آینه (۲۰۱۸) روشی برای شناسایی خودکار عوارض شهری با تلفیق تصاویر ابرطیفی و

داده‌های لایدار ارائه شده است [۷]. در این روش، ابتدا با استفاده از تبدیل نویز کمینه تعداد باندهای ابرطیفی کاهش یافته و سپس با تصاویر ارتفاعی و شدت حاصل از لایدار در سطح پیکسل ادغام می‌شوند. در ادامه، هفت ماشین بردار پشتیبان^۵ (*SVM*) نتایج را طبقه‌بندی کرده، با رأی‌گیری در سطح تصمیم نتایج تلفیق شده و در نهایت با اعمال عملگرهای ریخت-شناسی^۶ و تبدیل هاف، عوارض شهری بازسازی می‌گردند. در مقاله‌ای دیگر، سجادی و پارسیان (۲۰۱۸) روشی نوین برای تلفیق داده‌های ابرطیفی و لایدار مبتنی بر یادگیری ماشین ارائه شده است که در آن به استخراج خودکار عوارض ساختمانی پرداخته می‌شود [۸]. در این روش، ابتدا با تلفیق ویژگی‌های مکانی-ارتفاعی لایدار و ویژگی‌های طیفی ابرطیفی، سطح‌بندی اولیه عوارض انجام شده و سپس با اعمال الگوریتم یادگیری ماشین، ساختمان‌ها از سایر عوارض تفکیک می‌شوند. نتایج کمی از دقت بالای روش پیشنهادی در استخراج عوارض ساختمانی حکایت دارد. در تحقیق هونگ و همکاران (۲۰۲۰) شبکه *EndNet* پیشنهاد شده است که یک معماری رمزگذار-رمزگشای عمیق است و از آن برای طبقه‌بندی مشترک داده‌های ابرطیفی و لایدار استفاده شده است [۹]. در تحقیق دیگری، شی و همکاران (۲۰۲۴) یک شبکه عمیق چند مقیاسی مبتنی بر سازوکار توجه^۷ متقابل معرفی کرده‌اند که استخراج ویژگی و طبقه‌بندی مشترک را بهبود می‌بخشد [۱۰]. همچنین لیو و همکاران (۲۰۲۴) اخیراً یک شبکه استخراج ویژگی چند مقیاسی و چند جهته جهت طبقه‌بندی ترکیبی داده‌های ابرطیفی و لایدار پیشنهاد کرده‌اند که به طور مؤثر ویژگی‌های مکانی و طیفی را مدل‌سازی و ترکیب می‌کند [۱۱]. در سال‌های اخیر، روش‌های پیشرفته‌تری نیز برای این

¹ Light Detection And Ranging

² Digital surface model

³ Classes

⁴ Locality preserving projections

⁵ Support vector machines

⁶ Morphological operators

⁷ Attention mechanism

تصاویر ابرطیفی را با اطلاعات ارتفاعی داده‌های لایدار برای طبقه‌بندی ادغام می‌کند [۱۵]. هر چند که کارایی ویژگی‌های ارتفاعی به عنوان ویژگی‌های مکمل در کنار اطلاعات طیفی در تحقیقات مختلفی اثبات شده است، با این حال در سال‌های اخیر علاقه فزاینده‌ای از سوی محققین به طبقه‌بندی دقیق تصاویر تک باند *DSM* به وجود آمده است. هر چند این موضوع به دلیل اطلاعات مشابه ارتفاعی که در طبقه‌های مختلف زمین یافت می‌شود اساساً موضوعی چالش‌برانگیز است، اما *DSM* حاوی اطلاعات مکانی/محتوایی ارزشمندی هستند که به طور بالقوه می‌تواند دقت طبقه‌بندی را افزایش دهد [۱۶]. از سویی دیگر با توجه به رشد سریع مدل‌های هوش مصنوعی جدید محققین امیدوار هستند که با استفاده از این مدل‌ها بتواند به سطوح دقت بالاتری در طبقه‌بندی دست یابند.

در سال‌های اخیر، محققین مختلف سعی کرده‌اند روش‌های نوآورانه‌ای را برای طبقه‌بندی و استخراج اطلاعات از داده‌های لایدار پیشنهاد کنند. در مقاله‌ی عقیقی و همکاران (۲۰۱۸)، کارایی شش روش طبقه‌بندی شامل K همسایه نزدیک، درخت تصمیم، بیز ساده، شبکه عصبی مصنوعی، *SVM* و میدان تصادفی مارکوف برای طبقه‌بندی ابرنقاط لایدار در محیط شهری ارزیابی شده است [۱۷]. داده‌های مورد استفاده از مجموعه داده مرجع شهر واینیخن آلمان بوده و ویژگی‌های هندسی، شدت، تصاویر هوایی و نیز ویژگی‌های مبتنی بر مقادیر ویژه با استفاده از یک ساختار مکعبی جدید استخراج شده‌اند. نتایج نشان می‌دهند که مدل میدان تصادفی مارکوف به عملکرد بهتری نسبت به سایر روش‌ها دست پیدا کرده است. در تحقیق جعفری و موحد (۲۰۲۲)، روشی برای استخراج ساختمان‌ها با استفاده از تلفیق داده‌های لایدار هوابرد و تصاویر اولتراکم در منطقه بندرانزلی ارائه شده است [۱۸]. این روش شامل سه مرحله اصلی فیلتر کردن داده‌های لایدار و استخراج ساختمان‌ها با

منظور ارائه شده‌اند.

روش تلفیق تعاملی تطبیقی $IACF-Net^1$ یک شبکه تعاملی تطبیقی مبتنی بر ادغام شبکه‌های عمیق تلفیقی 2 (*CNN*) و شبکه مبدل 3 (*Transformer*) است که با بهره‌گیری از ماژول‌های توجه همزمان و توجه متقابل به کشف همبستگی‌های درون داده‌ای و بین‌وجهی می‌پردازد [۱۲]. این مقاله شبکه *IACF-Net* مبتنی بر ترکیب *CNN* و *Transformer* را پیشنهاد می‌کند تا جفت‌شدگی غیرخطی در داده‌های ابرطیفی و افت اطلاعات محلی در حین تلفیق چندوجهی را برطرف سازد. آزمایش‌ها روی سه مجموعه داده معیار نشان می‌دهد که *IACF-Net* دقت کلی بالاتری نسبت به سایر مدل‌های پیشرفته داشته و کارایی خود را در طبقه‌بندی مشترک داده‌های ابرطیفی و لایدار اثبات می‌کند. در تحقیق دیگری یک شبکه تلفیق گراف تطابقی ناهمگن برای طبقه‌بندی مشترک داده‌های ابرطیفی و لایدار پیشنهاد شده است که با استفاده از ماژول‌های تقویت شاخه، یادگیری تطابقی و ساختار گراف پویا، روابط ناهمگن را مدل‌سازی کرده و دقت کلی را در چند مجموعه داده نسبت به روش‌های پیشرفته بهبود می‌بخشد [۱۳]. در یک تحقیق دیگر یک شبکه تلفیق سلسله‌مراتبی طیفی-مکانی مبتنی بر جبر هندسی برای طبقه‌بندی مشترک تصاویر ابرطیفی و داده‌های لایدار پیشنهاد شده است [۱۴]. روش مذکور با استفاده از عملگرهای هندسی یکپارچه، روابط فضایی و طیفی را در قالب یک ساختار سلسله‌مراتبی مدل‌سازی کرده و دقت طبقه‌بندی را نسبت به روش‌های رقیب بهبود می‌بخشد. در تحقیق دیگر، بهاوانام (۲۰۲۴) یک چارچوب مبتنی بر شبکه‌های مبدل بینایی 4 (*ViT*) را پیشنهاد داد که به طور موثر اطلاعات طیفی-مکانی

¹ Interactive adaptive cross fusion network

² Convolutional neural network

³ Transformers networks

⁴ Vision Transformers

اساس توصیفگرهای ماتریس کرنل محلی که از ویژگی-های MP به دست آمده‌اند توسعه دادند و از آن برای بهبود نتایج طبقه‌بندی DSM استفاده کردند [۲۴]. همچنین اخیراً بیرامی (۲۰۲۴) در مقاله‌ی دیگری یک سیستم CNN جمعی دو مرحله‌ای پیشنهاد داده است که در آن از نیمرخ‌های ریخت‌شناسی چند شکلی^۶ (MMP) به منظور طبقه‌بندی DSM استفاده می‌شود [۱۶]. به تازگی، روش‌های نوآورانه‌تری نیز در این حوزه ارائه شده است. در پژوهشی دیگر، دای و همکاران (۲۰۲۴) شبکه $Spectrum-LiDAR$ را معرفی کردند که مبتنی بر رمزگذار مبدل و مکانیسم خودتوجهی^۷ در حوزه فرکانس است و با تبدیل داده‌ها به حوزه فرکانس با استفاده از تبدیل فوریه، وابستگی‌های برد بلند و جزئیات فرکانس بالا را برای تمایز دقیق رده‌های پوشش زمین استخراج می‌کند [۲۵]. همچنین دنگ و همکاران (۲۰۲۴) یک شبکه تلفیق اطلاعات همسایگی چندمقیاسه ارائه کردند که با استفاده همزمان از نواحی^۸ چندمقیاسه و یک ماژول توجه به استخراج همزمان جزئیات و ویژگی‌های کلی از داده‌های ارتفاعی می‌پردازد [۲۶].

همان‌طور که از مرور پیشینه تحقیق دریافت می‌شود عمده‌ی مطالعات موجود در حوزه طبقه‌بندی تصاویر تک باند DSM بر اساس روش‌های یادگیری عمیق هستند. این روش‌ها عموماً دارای سه نقطه ضعف هستند. اول اینکه این روش‌ها دارای ساختاری پیچیده و زمان‌بر هستند؛ افزون بر آن، پیاده‌سازی آن‌ها به تعداد زیادی نمونه‌ی آموزشی و همچنین نرم‌افزارها و سخت‌افزارهای ویژه‌ای نیاز دارد. دوم اینکه این روش‌ها عمدتاً تنها از اطلاعات موجود در لایه آخر شبکه آن هم تنها در یک مقیاس مکانی برای برجسب‌زنی پیکسل استفاده می‌کنند و اطلاعات لایه‌های دیگر را به طور

خوشه‌بندی طیفی در نرم‌افزار $eCognition$ ، مقایسه با نتایج روش حد آستانه ارتفاعی در $ENVI LiDAR$ و در نهایت ادغام مرزهای استخراج شده می‌باشد. ارزیابی نتایج بر روی ۴۱۷ ساختمان نشان داد که روش ارائه شده قادر به استخراج ساختمان‌ها در تراکم‌های مختلف با دقت ارتفاعی بسیار بالا بوده است. قمیسی و همکاران (۲۰۱۷) یک روش جدید مبتنی بر SVM هسته مرکب^۱ و نیمرخ‌های انقراضی^۲ (EP) تولید شده از ویژگی‌های پایه لایدار مختلف مانند DSM ، نسبت پژواک، واریانس ارتفاع نقطه، باقیمانده‌های برازش صفحه و شدت پیشنهاد کردند [۱۹]. در مطالعه دیگر، وانگ و همکاران (۲۰۱۸) روشی برای طبقه‌بندی DSM بر اساس نیمرخ‌های ریخت‌شناسی^۳ (MP) چند خاصیتی^۴ (MAP) به عنوان ویژگی‌های ورودی CNN با یک تابع فعال‌سازی جدید به نام واحدهای خطی وزن‌دار سیگموئید پیشنهاد کردند [۲۰]. همچنین وانگ و همکاران (۲۰۲۰) مدل عمیق ترکیبی کپسولی باقیمانده‌ای را پیشنهاد کردند که از شبکه‌های باقیمانده‌ای و شبکه‌های کپسولی عمیق برای طبقه‌بندی داده‌های لایدار بهره می‌برد [۲۱]. به منظور استخراج ویژگی‌های قوی و متمایز از داده‌های ورودی، وو و همکاران (۲۰۲۰) یک الگوریتم طبقه‌بندی DSM جدید را ارائه کردند که روش تلفیق اکتاو^۵ را با شبکه عمیق کپسولی ترکیب می‌کند [۲۲]. همچنین وانگ و همکاران (۲۰۲۰) یک روش یادگیری عمیق را معرفی کردند که شبکه‌های عصبی مولد شرطی، واحدهای باقیمانده و $DropBlock$ را برای بهبود طبقه‌بندی داده‌های DSM ترکیب می‌کند [۲۳]. در مطالعه دیگری، بیرامی و مختارزاده (۲۰۲۳) فضای ویژگی جدیدی را بر

¹ Composite Kernel

² Extinction Profiles

³ Morphological profiles

⁴ Multiattribute profiles

⁵ Octave convolution

⁶ Multishape Morphological Profiles

⁷ Self-attention

⁸ Patches

های آموزشی حجیم و سخت‌افزار پیچیده) و روش‌های سنتی (عدم استخراج ویژگی‌های سلسله مراتبی) طراحی شده است. روشی حاضر بر مبنای ویژگی‌های عمیق استخراج شده از ویژگی‌های *MMP* با استفاده از شبکه‌های نواحی تصادفی عمیق چند مقیاسه^۵ (*MLDANet*) مبتنی بر تبدیل تحلیل تفکیک‌پذیری خطی^۶ (*LDA*) است. در این روش پس از استخراج ویژگی‌های *MMP* به عنوان ویژگی‌های پایه استخراج شده از تصویر تک باند *DSM*، از این ویژگی‌ها به منظور تولید ویژگی‌های سلسله مراتبی عمیق چند مقیاسه استفاده می‌شود. این ویژگی‌های ثانویه غنی از اطلاعات پس از الصاق به ویژگی‌های اولیه *MMP*، در نهایت به منظور تولید برچسب هر پیکسل به یک سیستم طبقه‌بندی‌کننده *SVM* چندگانه تزریق می‌شود. روش پیشنهادی این پژوهش با پوشش دادن نقاط ضعف مدل‌های پیشین، گامی رو به جلو در ارتقای دقت طبقه‌بندی تصاویر تک‌باند *DSM* محسوب می‌شود.

این مقاله به شرح زیر ادامه می‌یابد. روش پیشنهادی برای طبقه‌بندی *DSM* در بخش ۲ معرفی می‌شود. بخش ۳ مجموعه داده‌های *DSM* به کار رفته معرفی می‌شود. در بخش ۴، نتایج تجربی مورد تجزیه و تحلیل قرار گرفته و در نهایت نتیجه‌گیری مطالعه در بخش ۵ انجام شده است.

۲- روش‌شناسی تحقیق

در این بخش، پس از ارائه تشریحی اجمالی از فلوچارت کلی مدل توسعه‌داده‌شده، جزئیات ساختاری و نظری هر یک از گام‌های عملیاتی تبیین می‌گردد.

۲-۱- نمای کلی روش پیشنهادی

فلوچارت روش این مطالعه با نام *MMP-MLDANet* در شکل (۱) نمایش داده شده است. این روش شامل چهار مرحله اصلی است:

⁵ Multiscale LDA-based Deep Random Patches Networks

⁶ Linear discrimination analysis

مناسبی در نظر نمی‌گیرند. سوم اینکه دقت این روش‌ها به کیفیت و تنوع داده‌های آموزشی وابسته است و در برخی موارد، روش‌های غیرعمیق نیز می‌توانند نتایج رقابتی ارائه دهند. از سوی دیگر، وابستگی شدید شبکه‌های عمیق مرسوم به بهینه‌سازی مبتنی بر گرادیان، پدیده‌ی بیش‌برازش^۱ را در مواجهه با نمونه‌های آموزشی اندک تشدید می‌کند. لذا توسعه‌ی راهبردهایی نوین برای استخراج ویژگی‌های عمیق سلسله‌مراتبی پایدار و کم‌هزینه بدون نیاز به فرآیند بازانتشار خطا^۲ لازم به نظر می‌رسد. بنابراین، همچنان نیاز به توسعه روش‌های جدیدتر و بررسی عملکرد آنها در شرایط گوناگون وجود دارد.

در بیشتر روش‌های یادگیری عمیق موجود برای طبقه‌بندی *DSM*، تمرکز عمدتاً بر ویژگی‌های ارتفاعی بوده است و اطلاعات مکانی و ساختاری غنی موجود در *DSM* به‌طور کامل استخراج و مورد استفاده قرار نگرفته‌اند. همچنین، در بسیاری از مطالعات پیشین، به دلیل محدودیت تک‌باند بودن تصویر *DSM* (محدود بودن تعداد ویژگی‌های موجود)، حجم زیاد پردازش و پیچیدگی‌های محاسباتی، کارایی طبقه‌بندی‌کننده‌های جمعی^۳ و نسل جدید آنها یعنی روش‌های یادگیری عمیق جمعی به‌طور کامل بررسی نشده است. این محدودیت‌ها باعث شده‌اند که بسیاری از روش‌های موجود نتوانند به‌طور مؤثر از اطلاعات غنی و سلسله‌مراتبی موجود در *DSM* بهره‌برداری کنند. در این مطالعه، روشی ترکیبی مبتنی بر یادگیری عمیق و یادگیری ماشین سنتی برای طبقه‌بندی تصاویر *DSM* ارائه شده است. این رویکرد با نام *MMP-MLDANet*^۴ شناخته می‌شود به‌طور هدفمند برای غلبه بر محدودیت‌های روش‌های یادگیری عمیق (نیاز به داده-

¹ Overfitting

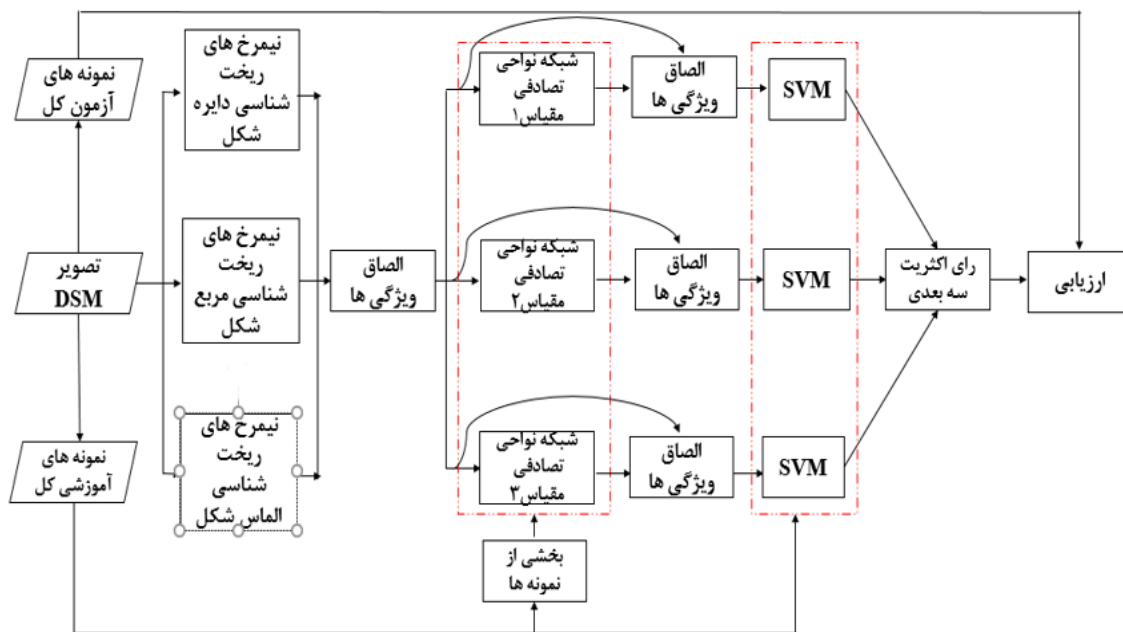
² Backpropagation

³ Ensemble learning

⁴ Multishape Morphological Profiles and Multiscale LDA-based Deep Random Patches Networks

- (۳) طبقه‌بندی ویژگی‌های حاصل با سیستم طبقه‌بندی کننده‌ی *SVM* چندگانه و ترکیب نتایج با روش رأی‌گیری اکثریت سه‌بعدی.
- (۴) ارزیابی نتایج طبقه‌بندی

- (۱) استخراج ویژگی‌های پایه مکانی با استفاده از ویژگی‌های *MMP*.
- (۲) تولید ویژگی‌های عمیق سلسله‌مراتبی چندمقیاسه با شبکه نواحی تصادفی عمیق مبتنی بر تبدیل *LDA*.



شکل ۱: فلوچارت روش MMP-MLDANet

و اشکال مختلف (دایره، مربع، الماس) ایجاد می‌شوند. خروجی این گام مکعب داده به صورت $X_{MMP} \in \mathbb{R}^{M \times N \times n_{MMP}}$ است که در آن n_{MMP} تعداد باندهای ویژگی‌های مکانی ریخت‌شناسی چندشکلی است. این روش امکان ثبت ویژگی‌های متنوع مکانی موجود در داده‌های *DSM* را فراهم می‌کند که برای تمایز بین طبقات پوشش زمین کارا هستند. در مرحله بعد این بردارهای ویژگی با هم الصاق^۳ شده و تشکیل مکعب داده مکانی اولیه را می‌دهد.

۲-۱-۲- استخراج ویژگی‌های عمیق چند مقیاسه با *LDANet*

این گام به عنوان ورودی ویژگی‌های *MMP* به صورت

در روش پیشنهادی، ورودی $I \in \mathbb{R}^{M \times N}$ (تصویر تک باند *DSM*) و خروجی $C \in \mathbb{R}^{M \times N}$ (نقشه طبقه‌بندی) است که در آن M و N به ترتیب طول و عرض تصویر هستند. در ادامه، گام‌های اصلی این روش به طور خلاصه شرح داده می‌شوند و سپس جزئیات نظری هر گام در زیربخش‌های مجزا ارائه می‌گردد.

۲-۱-۱- استخراج ویژگی‌های پایه *MMP*

در روش پیشنهادی ابتدا از تصاویر تک باند *DSM* ($I \in \mathbb{R}^{M \times N}$) به عنوان ورودی استفاده شده و ویژگی‌های *MP* از طریق عملگرهای ریخت‌شناسی باز (*OP*) و بسته^۱ (*CL*) با استفاده از عناصر ساختاری در اندازه‌ها

¹ Opening operator

² Closing operator

³ Stacking

نظری هر یک از اجزای روش پرداخته می‌شود.

۲-۲- استخراج ویژگی‌های پایه MMP

ویژگی‌های MP به طور وسیع به عنوان یک ابزار کارآمد برای استخراج ویژگی‌های مکانی از تصاویر سنجش از راه دور به حساب می‌آید. این ویژگی‌ها به وسیله‌ی اپراتورهای ریخت‌شناسی پایه‌ای OP و CL با در نظر گرفتن یک بازه از ابعاد مشخصی از عنصر ساختاری (i) به صورت رابطه (۱) معرفی می‌شوند [۲۷]:

رابطه (۱)

$$MP(x)=[CL_i(x), \dots, DSM(x), \dots, OP_i(x)]$$

با این حال، با توجه به وجود عوارض با هندسه‌ی متفاوت در تصاویر DSM عموماً رویکردهای مبتنی بر ویژگی‌های MMP که در آن از عنصر ساختاری^۵ با اشکال مختلف در تولید نیمرخ استفاده می‌شوند، مؤثرتر هستند. اشکال مختلف عنصر ساختاری که در این حوزه بیشتر به کار می‌روند شامل دایره^۶، مربع و الماس است و یک بردار ویژگی MMP به صورت رابطه (۲) نشان داده می‌شود [۲۷]:

رابطه (۲)

$$MMP(x)=[MP_{Disk}(x), MP_{Square}(x), MP_{Diamond}(x)]$$

۲-۳- استخراج ویژگی‌های عمیق چند مقیاسه با

$LDANet$:

شبکه نواحی تصادفی عمیق مبتنی بر تبدیل LDA که با نام $LDANet$ شناخته می‌شود بر خلاف بسیاری دیگر از مدل‌های عمیق موجود نیازی به فرایند آموزش و بازانتشار خطا ندارد و تنها با هدف استخراج ویژگی‌های مکانی عمیق به صورت نظارت‌شده به کار می‌رود [۲۸]. شکل (۲) روند استخراج ویژگی به وسیله این شبکه را نشان می‌دهد.

از x_{MMP} از مرحله قبلی را دریافت می‌کند و از آنها به منظور تولید ویژگی‌های مکانی ثانویه عمیق استفاده می‌کند. ویژگی‌های MMP به شبکه $LDANet$ با مقیاس‌های ورودی مختلف داده می‌شود و ویژگی‌های ثانویه عمیق چند مقیاسه تولید می‌شوند. منظور از مقیاس در اینجا به این معنی است که در ساختار شبکه $LDANet$ از ابعاد مختلفی از پنجره‌های تلفیقی حول هر پیکسل به منظور تولید ویژگی عمیق استفاده می‌شود. در مرحله بعد، در هر مقیاس، بردارهای ویژگی عمیق تولیدشده به ویژگی‌های اصلی MMP اضافه می‌شوند. خروجی نهایی شبکه در هر مقیاس به صورت مکعب ویژگی $d_{deep} \in \mathbb{R}^{M \times N \times n_{deep}}$ می‌باشد. از آنجایی که این گام از ویژگی‌های عمیق چند مقیاسه استخراج شده از شبکه $LDANet$ استفاده می‌کند، نام آن $MLDANet$ قرار داده شده است.

۲-۱-۳- طبقه‌بندی با SVM و رأی‌گیری اکثریت

سه بعدی

سپس ویژگی‌های ترکیبی به دست آمده از گام قبلی (d_{deep}) به صورت جداگانه برای هر مقیاس وارد یک طبقه‌بندی کننده SVM مجزا شده و نقشه‌های طبقه‌بندی اولیه تولید می‌شود. نوع هسته^۱ به کار رفته در هر شاخه طبقه‌بندی کننده تابع پایه شعاعی^۲ است که پارامترهای آن به وسیله روش ارزیابی متقاطع^۳ به دست آمده است. در نهایت نقشه نهایی طبقه‌بندی به کمک روش رأی اکثریت^۴ سه بعدی تعیین می‌شود ($C^{M \times N} \in C$).

۲-۱-۴- ارزیابی نتایج طبقه‌بندی

در گام نهایی نیز دقت طبقه‌بندی به وسیله‌ی ماتریس ابهام و معیارهای دقت مستخرج از آن ارزیابی می‌گردد. پس از این نمای کلی، در زیربخش‌های بعدی به تشریح

¹ Kernel

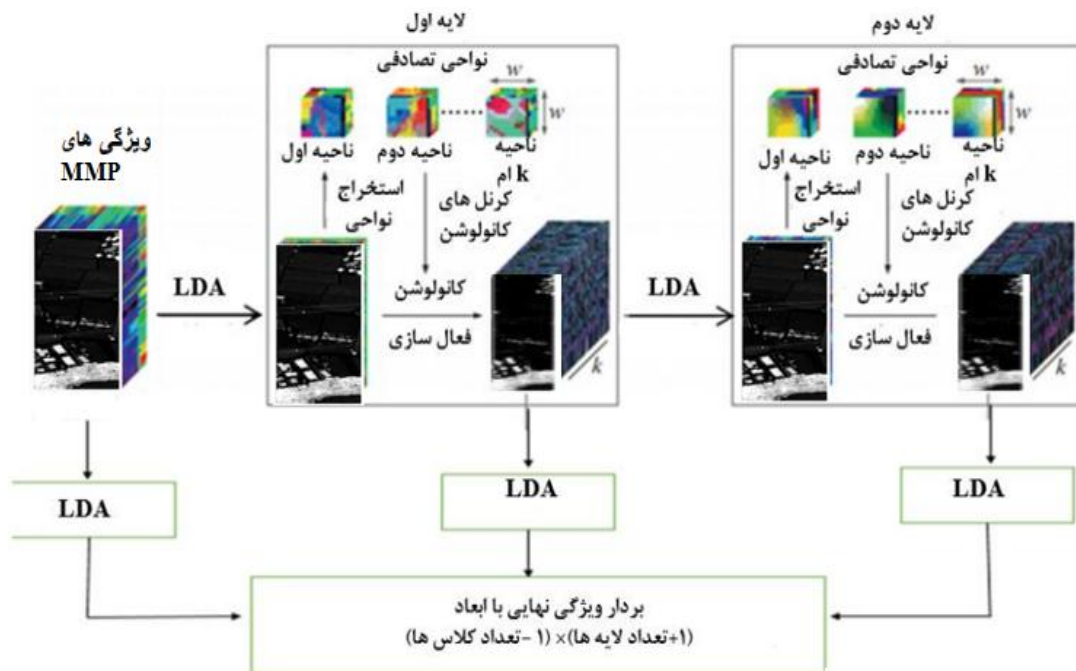
² Radial basis function (RBF)

³ Cross-validation

⁴ Majority voting

⁵ Structuring element

⁶ Disk



شکل ۲: استخراج ویژگی عمیق با استفاده از روش LDANet [۲۸]

یک بار تابع فعال‌سازی خطی اصلاح شده ($ReLU$) اعمال می‌شود. به منظور تولید ورودی برای لایه بعدی مجدداً بر روی تصویر حاصل شده از مرحله قبل تبدیل LDA اعمال می‌شود و این فرایند مجدداً تکرار می‌شود. در نهایت پس از رسیدن به عمق تعیین شده توسط کاربر، بر روی تمامی ویژگی‌های حاصل شده در هر عمق یک بار دیگر تبدیل LDA انجام می‌شود و ویژگی‌های نهایی به یکدیگر الصاق می‌شوند و بردار ویژگی‌های عمیق نهایی را تشکیل می‌دهند.

از آنجایی که می‌توان ابعاد مختلفی را به عنوان ابعاد پنجره‌های نواحی تصادفی در نظر گرفت، در این مقاله به منظور تولید ویژگی‌های عمیق چندمقیاسه ابعاد پنجره‌های 5×5 ، 9×9 و 13×13 در نظر گرفته شده است. تولید ویژگی‌های عمیق با این رویکرد سبب می‌شود که جزئیات بافتی ریز و درشت عوارض تصویر DSM به طور مطلوبی استخراج گردد. این کار قدرت

مرحله استخراج ویژگی با این روش به شرح زیر است: در این روش، ابتدا بر روی تصویر MMP حاصل از مرحله قبل یک تبدیل LDA اولیه اعمال می‌شود. سپس از سه مؤلفه اول LDA (بزرگترین مقادیر ویژه) استفاده می‌شود. در هر لایه شبکه، نواحی تصادفی سه‌بعدی از تصویر کاهش‌یافته استخراج می‌شوند. عملیات تلفیق به صورت رابطه (۳) انجام می‌شود:

$$F^{(l)} = R_b^{(l)} * K_{i,b}^{(l)}$$

$$b = 1 \dots B_l \quad i = 1 \dots k$$

که در آن:

- l : شماره لایه
- $R_b^{(l)}$: باند b ام تصویر ورودی به لایه l
- B_l : تعداد باندهای ورودی به لایه l
- $K_{i,b}^{(l)}$: کرنل حاصل از باند b و ناحیه تصادفی i ام
- $*$: عملگر تلفیق دو بعدی (که روی هر باند به طور جداگانه اعمال می‌شود و نتایج جمع می‌شوند)
- k : تعداد نواحی تصادفی در هر لایه

در مرحله بعد بر روی مکعب داده‌ی F به دست آمده

¹ Rectified linear unit

۲-۵- ارزیابی نتایج طبقه‌بندی

به منظور محاسبه دقت طبقه‌بندی در این مقاله از ماتریس ابهام^۱ و چهار معیار مستخرج از آن با نام‌های دقت کلی^۲ (OA)، دقت کاربر^۳ (UA)، دقت تولیدکننده^۴ (PA) و ضریب کاپا^۵ ($Kappa$) به شرح زیر استفاده می‌شود [۳۰]:

- **ماتریس ابهام:** جدولی است که تعداد پیکسل‌های تخصیص‌یافته به هر رده در نقشه را در مقابل رده‌های مرجع زمینی نمایش می‌دهد. درایه‌های قطر اصلی، طبقه‌بندی‌های درست و درایه‌های خارج از قطر، انواع خطاها را به صورت یک‌جا نشان می‌دهند.
- **معیار OA :** این معیار درصد پیکسل‌های درست طبقه‌بندی‌شده نسبت به کل پیکسل‌ها را نشان می‌دهد. OA با تقسیم تعداد پیکسل‌های صحیح طبقه‌بندی‌شده بر تعداد کل پیکسل‌ها محاسبه می‌شود و معیاری ساده و جامع برای سنجش عملکرد کلی طبقه‌بندی‌کننده ارائه می‌دهد.
- **معیار UA :** نشان می‌دهد اگر نقشه پیکسلی را به یک رده‌ی خاص نسبت دهد، چقدر احتمال دارد که در دنیای واقعی هم واقعاً همان رده باشد. به زبان دیگر، این معیار خطای پذیرش را ارزیابی می‌کند و میزان اعتماد کاربر به هر رده نمایش‌داده‌شده روی نقشه را مشخص می‌سازد.
- **معیار PA :** بیان می‌کند که از میان تمام پیکسل‌های واقعی یک رده در زمین، چه نسبتی به‌درستی در نقشه به همان رده اختصاص یافته‌اند. این سنجح خطای حذف را نشان می‌دهد و از نگاه تولیدکننده، توانایی طبقه‌بندی‌کننده در شناسایی کامل یک عارضه را می‌سنجد.

¹ Confusion matrix

² Overall accuracy

³ User accuracy

⁴ Producer accuracy

⁵ Kappa coefficient

تفکیک‌پذیری رده‌ها را افزایش داده و سبب تولید نقشه‌های طبقه‌بندی هموارتری می‌شود [۲۹]. در نهایت در هر مقیاس، بردارهای ویژگی عمیق تولیدشده در هر مقیاس به ویژگی‌های اصلی ریخت‌شناسی چندشکلی اضافه شده و مکعب‌های ویژگی نهایی را تشکیل می‌دهند.

۲-۴- طبقه‌بندی با SVM و رأی‌گیری اکثریت سه‌بعدی

پس از استخراج ویژگی‌های عمیق چند مقیاسه با شبکه $LDANet$ ، یک طبقه‌بندی‌کننده جداگانه به ازای هر مقیاس در نظر گرفته می‌شود. در این مطالعه از SVM با کرنل تابع پایه شعاعی استفاده شده است. پارامترهای هر SVM با استفاده از روش اعتبارسنجی متقاطع روی نمونه‌های آموزشی تعیین می‌گردند. همچنین لازم به ذکر است که تنظیمات مذکور برای طبقه‌بندی‌کننده SVM در همه شاخه‌ها یکسان در نظر گرفته شده است. به این ترتیب، برای هر پیکسل سه برچسب پیش‌بینی‌شده (مربوط به سه مقیاس مختلف) تولید می‌شود. به منظور ترکیب این پیش‌بینی‌ها و افزایش پایداری و دقت طبقه‌بندی، از روش رأی‌گیری اکثریت سه‌بعدی استفاده می‌گردد [۳۰]. برخلاف رأی‌گیری اکثریت یک‌بعدی مرسوم که در آن برچسب نهایی هر پیکسل صرفاً بر اساس بیشترین تکرار برچسب در میان دسته‌بندی‌های مختلف برای همان پیکسل تعیین می‌شود، در روش سه‌بعدی، برای هر پیکسل یک پنجره مکانی (در این مقاله 5×5) در گرفته شده و رأی‌گیری با در نظر گرفتن برچسب‌های پیش‌بینی‌شده برای همه پیکسل‌های درون آن پنجره از هر سه مقیاس انجام می‌شود. برچسبی که بیشترین فراوانی را در این حجم مکانی-مقیاسی داشته باشد، به عنوان برچسب نهایی آن پیکسل انتخاب می‌شود. این راهبرد باعث کاهش نویز پیکسلی، هموارسازی نقشه طبقه‌بندی و بهبود یکپارچگی نواحی همگن می‌شود، به ویژه در شرایطی که تعداد نمونه‌های آموزشی محدود است.

شهری است، در سال ۲۰۱۲ جمع‌آوری شده است. بنا بر نقشه حقیقت زمینی این صحنه شامل ۱۵ رده شهری مانند ساختمان‌ها، آب، خاک، درختان و جاده‌ها می‌باشد و به طور کلی شامل ۱۵۰۲۹ نمونه‌ی برجسپدار است. شکل (۳) تصویر *DSM* منطقه و نقشه حقیقت زمینی را نشان می‌دهد.


مجموعه داده دوم این مطالعه به نام ترنتو شناخته می‌شود که از جنوب ناحیه شهری ترنتو در ایتالیا اخذ شده است. این داده توسط حسگر لایدار *Optech ALTM 3100EA* جمع‌آوری شده است. این صحنه شامل ۶۰۰×۱۶۶ پیکسل، با حد تفکیک مکانی ۱ متر است. این مجموعه داده شامل ۶ نوع رده زمینی با مجموع ۳۰۲۱۴ نمونه برجسپدار است. شکل (۴) تصویر *DSM* منطقه و نقشه حقیقت زمینی را نشان می‌دهد.

• **معیار *Kappa***: این معیار میزان توافق بین طبقه‌بندی انجام‌شده و حقیقت زمینی را با در نظر گرفتن احتمال توافق تصادفی ارزیابی می‌کند. ضریب کاپا از طریق فرمول خاصی محاسبه می‌شود که اثر توافق تصادفی را از دقت کلی کسر می‌کند و معیاری قوی برای سنجش کیفیت طبقه‌بندی ارائه می‌دهد.


این معیارها به دلیل سادگی، قابلیت تفسیر و ارائه یک دید جامع از عملکرد روش‌های طبقه‌بندی انتخاب شده‌اند و امکان مقایسه عادلانه با سایر روش‌ها را فراهم می‌کنند.

۳- داده‌های مورد استفاده

مجموعه داده اول این مطالعه به نام دانشگاه هیوستون شناخته می‌شود که توسط کارشناسان خبره به منظور رقابت ادغام داده‌ی *IEEE* معرفی شده است. این تصویر دارای ابعاد ۱۹۰۵×۳۴۹ با حد تفکیک مکانی ۲/۵ متر است که از پردیس دانشگاه هیوستون که یک ناحیه



شکل ۳: داده‌ی هیوستون



شکل ۴: داده‌ی ترنتو

استخراج نمونه‌ها از راهبرد نمونه‌گیری تصادفی استفاده شده است که در این روش در هر رده ۴۰ نمونه به عنوان نمونه آموزشی در نظر گرفته می‌شود، در حالی که از بقیه به عنوان نمونه‌های آزمون استفاده می‌شوند. این ترکیب نمونه‌ها در روش‌های مختلف مورد بررسی در بخش بعدی کاملاً یکسان است.

روش *MMP-MLDANet* به منظور تولید ویژگی‌های ریخت‌شناسی چند شکلی از سه شکل متمایز عناصر ساختاری، یعنی دایره، مربع و الماس، با ابعاد در محدوده ۲ تا ۲۵ استفاده می‌کند. همچنین مهم‌ترین پارامترهای شبکه *LDANet* هم به شرح جدول (۱) است.

این پارامترها بر اساس سعی و خطا طوری انتخاب شده‌اند که تناسبی میان سرعت و دقت الگوریتم پیشنهادی وجود داشته باشد. ما آزمایش‌های خود را در یک رایانه شخصی مجهز به پردازنده *Core i5 4590* $3.3GHz$ و ۸ گیگابایت رم انجام داده‌ایم.

۴- تحلیل نتایج

در این بخش در ابتدا ملاحظات پیاده‌سازی آزمایش‌ها ارائه می‌گردد. سپس خروجی نتایج طبقه‌بندی ارائه و تحلیل می‌گردد. در نهایت نیز بحث و مقایسه خروجی‌ها با روش‌های موجود در پیشینه تحقیق آورده شده است.

۴-۱- ملاحظات پیاده‌سازی

در سنجش از دور، جمع‌آوری نمونه‌های آموزشی معمولاً به علت زمان‌بر بودن و هزینه‌های بالا با سختی همراه است و به همین دلیل، الگوریتم‌های پیشنهادی باید بتوانند در شرایط داده‌های آموزشی محدود عملکرد مناسبی داشته باشند؛ اگرچه با افزایش تعداد نمونه‌های آموزشی، به طور کلی می‌توان انتظار داشت که دقت نیز بهبود یابد. از این رو در این مطالعه، رویکرد پیشنهادی ما طوری طراحی شده است که بتواند در شرایط داده‌های آموزشی محدود، به دقت‌های مطلوبی در طبقه‌بندی *DSM* برسد. در این مقاله، عملکرد روش *MMP-MLDANet* با استفاده از دو مجموعه داده *DSM* هیوستون و ترنتو مورد ارزیابی قرار می‌گیرد. به منظور

جدول ۱: پارامترهای شبکه *LDANet*


۳	تعداد لایه‌های عمیق
۵ و ۹ و ۱۳	ابعاد پنجره‌های ورودی
۲۰	تعداد نواحی تصادفی در هر لایه
۳	تعداد مؤلفه‌های <i>LDA</i> به کار رفته در هر لایه

می‌شود. این روش‌های پایه به شرح زیر هستند:

- *DSM-SVM*: در این رویکرد که به نوعی در مطالعه قمیسی و همکاران (۲۰۱۷) پیشنهاد شده است، تصویر تک باند *DSM* لایدار با استفاده از الگوریتم *SVM* طبقه‌بندی می‌شود [۱۹].
- *DSM-CNN*: در این رویکرد که در مطالعه وانگ و همکاران (۲۰۱۸) شده است، تصویر تک باند *DSM* لایدار با استفاده از الگوریتم *CNN* طبقه‌بندی می‌شود [۲۰].
- *MMP-SVM*: در این رویکرد که به نوعی در مطالعه وانگ و همکاران (۲۰۱۸) پیشنهاد شده است، ابتدا ویژگی‌های *MMP* از تصویر تک باند *DSM* لایدار ایجاد شده و سپس این ویژگی‌ها با الگوریتم *SVM* طبقه‌بندی می‌شود [۲۰].
- *MMP-CNN*: در این رویکرد که به نوعی در تحقیق بیرامی (۲۰۲۴) پیشنهاد شده است، ویژگی‌های *MMP* تولید شده از تصویر تک باند *DSM* لایدار با استفاده از الگوریتم *CNN* طبقه‌بندی می‌شود [۱۶].

۴-۲- تحلیل نتایج

در ابتدای این بخش آزمایشی با هدف بررسی کارایی راهبرد چند مقیاسه به کار رفته در رویکرد *MLDANet* طراحی شده است. به این منظور نتایج دقت کلی طبقه‌بندی برای دو مجموعه داده مذکور به هنگام استفاده از اندازه پنجره‌های گوناگون حول هر پیکسل در کنار نتایج راهبرد چند مقیاسه در شکل (۵) نشان داده است. همان‌طور که در این شکل ملاحظه می‌شود، تلفیق هم‌زمان پنجره‌ها (روش چندمقیاسه) دقت نهایی را نسبت به هر مقیاس منفرد افزایش می‌دهد. این یافته مؤید آن است که عوارض زمینی در ابعاد متفاوتی ظاهر می‌شوند و یک مقیاس ثابت به تنهایی توان توصیف کامل همه طبقات را ندارد. رویکرد چندمقیاسه با پوشش هم‌زمان جزئیات ریز (پنجره کوچک) و ساختارهای بزرگ (پنجره بزرگ)، قدرت تفکیک‌پذیری را به‌طور مطلوبی بهبود می‌بخشد [۳۱]. در ادامه روش *MMP-MLDANet* به طور جامع در برابر چندین روش پایه طبقه‌بندی *DSM* دیگر ارزیابی



شکل ۵: بررسی کارایی راهبرد چند مقیاسه

نتایج کمی برای داده‌های هیوستون و ترنتو به ترتیب یافته‌های کلیدی به تفکیک در ادامه آمده است. در جداول (۲) و (۳) ارائه شده است.

جدول ۲: نتایج دقت برای داده‌ی هیوستون

رده	تعداد نمونه آموزش	تعداد نمونه آزمون	DSM-SVM		DSM-CNN		MMP-SVM		MMP-CNN		MMP-MLDANet	
			UA %	PA %	UA %	PA %	UA %	PA %	UA %	PA %	UA %	PA %
۱	۴۰	۱۲۱۱	۶۱,۳۴	۲۰,۳۱	۶۸	۶۲,۵۱	۸۷,۰۲	۸۰,۹۲	۸۱,۳۴	۸۰,۶۷	۸۸,۴۴	۹۱,۶۵
۲	۴۰	۱۲۱۴	۳۰,۵۰	۲۳,۰۶	۵۶,۵۶	۴۲,۵۸	۷۸,۷۰	۷۵,۲۰	۷۹,۷۹	۷۶,۱۱	۸۶,۷۹	۸۲,۲۸
۳	۴۰	۶۵۷	۵۶,۲۲	۶۶,۶۶	۸۴,۴۳	۹۱,۶۲	۹۸,۹۲	۹۸,۰۲	۹۶,۰۱	۹۹,۰۸	۱۰۰	۹۸,۰۲
۴	۴۰	۱۲۰۴	۳۹,۸۲	۳۳,۶۳	۸۳,۸۰	۸۸,۹۵	۸۹,۵۰	۸۷,۸۷	۷۵,۷۰	۷۷,۶۵	۹۲,۷۱	۸۹,۸۶
۵	۴۰	۱۲۰۲	۴۷,۴۱	۴۲,۷۶	۶۰,۲۲	۴۸	۹۱,۲۳	۹۱,۸۴	۹۲,۰۸	۸۸,۰۱	۹۳,۱۶	۹۰,۶۸
۶	۴۰	۲۸۵	۲۲,۲۷	۶۲,۴۵	۳۹,۳۰	۷۱,۵۷	۷۷,۷۷	۸۵,۹۶	۷۸,۱۵	۸۹,۱۲	۹۰,۸۴	۸۷,۰۱
۷	۴۰	۱۲۲۸	۲۱,۷۶	۶۷,۸۳	۷۹,۲۸	۸۱,۳۵	۸۳,۴۴	۸۷,۴۵	۷۶,۲۳	۸۹,۲۱	۸۷,۴۴	۹۰,۷۱
۸	۴۰	۱۲۰۴	۶۴,۹۵	۳۹,۸۶	۹۱,۰۳	۸۱,۸۱	۹۸,۳۸	۹۰,۹۴	۹۱,۸۰	۹۱,۱۹	۹۶,۷۵	۹۴,۰۱
۹	۴۰	۱۲۱۲	۲۰,۳۱	۱۰,۸۹	۵۶,۵۸	۴۶,۷۸	۸۲,۳۶	۷۸,۶۳	۷۸,۹۶	۷۵,۵۷	۷۹,۴۲	۸۰,۲۸
۱۰	۴۰	۱۱۸۷	۱۰,۳۲	۳,۲۰	۸۰,۹۹	۶۶,۰۴	۹۴,۴۴	۹۵,۹۵	۹۵,۳۶	۹۵,۲۸	۹۳,۷۳	۹۲,۰۸
۱۱	۴۰	۱۱۹۵	۴۰,۶۰	۵۷,۱۵	۸۴,۸۸	۸۷,۸۶	۹۶,۸۱	۹۱,۷۱	۹۵,۳۵	۹۲,۸	۹۶,۸۳	۹۲,۰۵
۱۲	۴۰	۱۱۹۳	۷۳,۵۰	۷,۲۰	۵۰,۵۵	۶۰,۶۰	۸۵,۶۲	۹۰,۸۶	۸۶,۰۷	۷۹,۷۹	۸۶,۵	۹۱,۸۶
۱۳	۴۰	۴۲۹	۱۶,۴۷	۹,۷۹	۵۷,۷۱	۸۴,۶۱	۷۷,۲۲	۹۷,۲۰	۸۰,۸۸	۹۷,۶۶	۸۳,۶۶	۹۷,۹
۱۴	۴۰	۳۸۸	۳۱,۶۲	۷۸,۰۹	۵۳,۱۴	۸۵,۰۵	۸۱,۷۰	۹۸,۹۶	۹۰,۸۴	۹۹,۷۴	۹۷,۹۷	۱۰۰
۱۵	۴۰	۶۲۰	۴۵,۹۱	۶۱,۶۱	۶۵,۷۲	۷۴,۸۳	۹۷,۸۹	۹۷,۴۱	۹۲,۱۳	۹۴,۵۱	۹۷,۹۴	۱۰۰
OA(%)			۳۴,۹۲		۶۹,۲۵		٪۸۸,۶۴		۸۵,۸۱		۹۰,۸۵	
Kappa×۱۰۰(%)			۲۹,۴۴		۶۶,۴۸		٪۸۷,۵۴		۸۴,۴۵		۸۹,۹۶	

جدول ۳: نتایج دقت برای داده‌ی ترنتو

رده	تعداد نمونه آموزش	تعداد نمونه آزمون	DSM-SVM		DSM-CNN		MMP-SVM		MMP-CNN		MMP-MLDANet	
			UA %	PA %	UA %	PA %	UA %	PA %	UA %	PA %	UA %	PA %
۱	۴۰	۳۹۹۴	۳۶,۹۷	۲۷,۱۱	۸۲,۴۲	۹۰,۵۱	۹۳,۳۷	۹۵,۳۴	۹۹,۸۸	۸۶,۲۲	۹۹,۲۴	۹۹,۲۴
۲	۴۰	۲۸۶۳	۲۶,۷۴	۴۸,۴۸	۷۶,۶۵	۹۷,۱۳	۸۳,۸۴	۹۷,۵۲	۹۷,۵۵	۹۷,۷۲	۹۶,۶۶	۹۹,۱۲
۳	۴۰	۴۲۹	۴,۸۵	۷۳,۱۲	۵۰,۹۵	۷۲,۸۹	۲۳,۸۴	۷۲,۸۹	۲۵,۳۵	۸۲,۲۳	۷۱,۱۸	۹۵,۶۷
۴	۴۰	۹۰۸۳	۷۹,۶۰	۵۹,۸۰	۹۹,۴۵	۹۶,۰۸	۹۹,۶۲	۹۷,۷۴	۱۰۰	۹۹,۷۶	۱۰۰	۹۹,۸۷
۵	۴۰	۱۰۴۶۱	۷۷,۸۹	۶۲,۷۳	۹۹,۳۴	۷۷,۸۰	۹۷,۸۲	۹۳,۸۴	۹۹,۵۷	۹۴,۷۶	۹۹,۰۶	۹۹,۵۴
۶	۴۰	۳۱۳۴	۰	۰	۶۵,۷۸	۹۱,۶۰	۹۴,۲۴	۶۸,۵	۸۳,۲۵	۹۶,۱۷	۹۸,۰۴	۸۹,۸۲
OA(%)			۴۹,۳۳		۸۸,۲۵		۹۲,۶۲		۹۵,۳۸		۹۸,۴۹	
Kappa×۱۰۰			۳۶,۳۶		۸۴,۷۰		۹۰,۱۵		۹۳,۸۳		۹۷,۹۶	

۴-۲-۱- برتری روش پیشنهادی نسبت به روش‌های بدون استخراج ویژگی مکانی (*DSM-CNN* و *SVM*)

روش *DSM-SVM* که تنها از مقادیر ارتفاعی خام هر پیکسل استفاده می‌کند، به دلیل تشابه ارتفاعی بین رده‌های مختلف عملکرد بسیار ضعیفی دارد. دقت کلی این روش برای داده هیوستون تنها ۳۴/۹۲٪ و برای ترنتو ۴۹/۳۳٪ است. این مقادیر نشان می‌دهد که طبقه‌بندی بر اساس ارتفاع خالص عملاً در مناطق شهری با عوارض متنوع غیرقابل اعتماد است. روش *DSM-CNN* با وجود استفاده از معماری *CNN* بدون ویژگی‌های مکانی غنی (مانند *MMP*) عملکرد متوسطی دارد. به صورت کلی استفاده از روش طبقه‌بندی *CNN* در مقایسه با روش *SVM* به نتایج بسیار بهتری منجر می‌شود. علت این امر رویکرد متفاوت روش *CNN* در مقایسه با روش *SVM* است که در آن بجای در نظر گرفتن ویژگی‌های ورودی به صورت بردار، ویژگی‌ها به صورت پیچ به شبکه *CNN* وارد می‌شوند. همچنین روش *CNN* با وجود لایه‌های استخراج ویژگی مختلف توانایی بیشتری در تولید اطلاعات مؤثر مکانی/محتوایی در فرایند طبقه‌بندی دارد. دقت کلی روش *DSM-CNN* به ترتیب به ۶۹/۲۵٪ (هیوستون) و ۸۸/۲۵٪ (ترنتو) می‌رسد. هر چند این مقادیر بهتر از *DSM-SVM* هستند، اما کماکان در داده هیوستون بیش از ۲۰٪ و در ترنتو بیش از ۱۰٪ از روش پیشنهادی پایین‌ترند. این فاصله نشان می‌دهد که صرفاً استفاده از شبکه عمیق بدون ورودی غنی مکانی نمی‌تواند به سطوح دقت بالایی منجر شود. در مقابل، روش *MMP-MLDANet* با دقت کلی ۹۰/۸۵٪ در هیوستون و ۹۸/۴۹٪ در ترنتو، به ترتیب حدود ۲۰٪ و ۱۰٪ بهبود نسبت به *DSM-CNN* دارد. این ارقام به وضوح بیانگر ضرورت و اثربخشی رویکرد پیشنهادی این تحقیق است.

۴-۲-۲- برتری روش پیشنهادی نسبت به روش‌های مبتنی بر ویژگی‌های مکانی (*MMP-CNN* و *SVM*)

روش *MMP-SVM* که در آن فقط ویژگی‌های *MMP* با طبقه‌بندی‌کننده *SVM* ترکیب شده‌اند، دقت کلی ۸۸/۶۴٪ در هیوستون و ۹۲/۶۲٪ در ترنتو به دست می‌آورد. این نتایج نسبت به *DSM-SVM* پیشرفت چشمگیری دارند و نشان می‌دهند که ویژگی‌های *MMP* به تنهایی نیز اطلاعات ارزشمندی را استخراج می‌کنند. روش *MMP-CNN* که ویژگی‌های *MMP* را به یک شبکه *CNN* متشکل از سه لایه تلفیق و یک لایه تمام متصل می‌دهد، دقت کلی را به ۸۵/۸۱٪ (هیوستون) و ۹۵/۳۸٪ (ترنتو) افزایش می‌دهد اما همچنان از روش پیشنهادی عقب‌تر است. *MMP-MLDANet* با بهره‌گیری از استخراج ویژگی‌های عمیق سلسله‌مراتبی نظارت‌شده (از طریق اعمال مکرر *LDA* و تلفیق با کرنل‌های تصادفی) چند مقیاسه بر روی ویژگی‌های *MMP* قادر است الگوهای انتزاعی‌تر و تفکیک‌پذیرتری را یاد بگیرد. برتری *MMP-MLDANet* نسبت به *MMP-CNN* و *MMP-SVM* در جداول (۲) و (۳) گواه این ارتقاء ناشی از عمق‌بخشی به ویژگی‌هاست، به طوری که در هیوستون دقت کلی را نسبت به *MMP-CNN* حدود ۵ درصد و در ترنتو حدود ۳ درصد افزایش می‌دهد. همچنین ضریب کاپا برای روش حاضر در هیوستون ۸۹/۹۶٪ و در ترنتو ۹۷/۹۶٪ است که بالاترین مقدار در میان همه روش‌ها می‌باشد.

۴-۲-۳- تحلیل دقت هر رده (دقت تولیدکننده و دقت کاربر)

بررسی دقیق جداول (۲) و (۳) و جداول ماتریس ابهام (پیوست) نشان می‌دهد که روش حاضر به ویژه در رده‌هایی که دشواری تشخیص بالایی دارند، بهبود قابل توجهی ایجاد کرده است. به عنوان مثال در داده هیوستون:

• رده «چمن تنش دیده» (رده ۲): دقت کاربر از ۳۰/۵٪ در *DSM-SVM* به ۸۶/۷۹٪ در *MMP-*

حالی که دقت بالاتری نیز ارائه می‌دهد. این مزیت ناشی از عدم نیاز به فرایند بازانتشار خطا و آموزش طولانی در روش *MLDANet* است. در مقابل، روش‌های مبتنی بر *SVM* بدون استخراج ویژگی عمیق (مانند *DSM-SVM* و *MMP-SVM*) زمان کمتری دارند، اما دقت بسیار پایین‌تری هم دارند.

به منظور بررسی هزینه پیاده‌سازی روش پیشنهادی باید توجه داشت که این روش شامل سه بخش اصلی است: هزینه مرحله *MMP* به دلیل پیاده‌سازی بهینه ناچیز است. بخش غالب زمان مربوط به شبکه *LDANet* چند مقیاسه است که در هر لایه، تلفیق ۲۰ فیلتر تصادفی با تصویر انجام می‌شود؛ زمان این بخش با مربع ابعاد پنجره متناسب است، از این رو حالت چندمقیاسه حدود سه برابر کندتر از یک مقیاس میانی عمل می‌کند. زمان طبقه‌بندی *SVM* و رأی‌گیری اکثریت نیز کمتر از ۱۰٪ کل زمان است. در روش حاضر به نظر می‌رسد که افزایش تعداد لایه‌ها (*L*) یا تعداد فیلترها (*N*) زمان را به‌طور خطی، و افزایش ابعاد پنجره (*p*) آن را به‌طور درجه‌دوم افزایش می‌دهد. پیکربندی پیاده‌سازی کنونی نقطه تعادلی مطلوب میان دقت و سرعت است. افزون بر این، عملیات تلفیق و تولید *MMP* ذاتاً موازی پذیرند و با استفاده از روش‌های پردازش موازی همین زمان ۳۰ ثانیه نیز کاهش‌پذیر خواهد بود. در نهایت باید توجه داشت که تعادل بین دقت بالا و بار محاسباتی در روش پیشنهادی برقرار است.

جدول ۴: زمان پردازش

	<i>DSM-SVM</i>	<i>DSM-CNN</i>	<i>MMP-SVM</i>	<i>MMP-CNN</i>	<i>MMP-MLDANet</i>
زمان پردازش	حدود ۳ ثانیه	حدود ۱۵۰ ثانیه	حدود ۸ ثانیه	حدود ۱۲۰ دقیقه	حدود ۳۰ ثانیه

تشخیص رده‌ها است. روش‌های *MMP-SVM* و *DSM-CNN* نویز کمتری دارند اما همچنان پیکسل‌های به اشتباه طبقه‌بندی‌شده در بین رده‌ها دیده می‌شود. روش *MMP-CNN* نتایج نسبتاً همواری تولید می‌کند،

MLDANet و دقت تولیدکننده از ۲۳٫۰۶٪ به ۸۲٫۲۸٪ رسیده است.

• رده «چمن مصنوعی» (رده ۳): دقت کاربر از ۵۶٫۲۲٪ (*DSM-SVM*) به ۱۰۰٪ در *MMP-MLDANet* بهبود یافته است.

• رده «راه آهن» (رده ۱۱): دقت کاربر از ۴۰٫۶۰٪ در *DSM-CNN* به ۹۶٫۸۳٪ در روش پیشنهادی افزایش یافته است.

در داده ترنتو نیز موارد مشابه دیده می‌شود:

• رده «ساختمان» (رده ۲): دقت کاربر از ۲۶٫۷۴٪ در *DSM-SVM* به ۱۰۰٪ در *MMP-MLDANet* رسیده است.

• رده «جاده» (رده ۶): دقت تولیدکننده از صفر درصد (*DSM-SVM*) به ۹۸٫۰۴٪ در روش حاضر رسیده است.

این بهبودها نشان می‌دهد که ترکیب ویژگی‌های عمیق مستخرج از *MLDANet* با ویژگی‌های پایه *MMP*، توانسته است در بسیاری از رده‌ها تفکیک‌پذیری را بهبود داده و دقت طبقه‌بندی را افزایش دهد.

۴-۲-۴ تحلیل زمان پردازش


میانگین زمان اجرای روش‌ها برای داده ترنتو (داده‌ی سبک‌تر) در جدول (۴) آورده شده است. تمام روش‌ها در یک سیستم و در شرایط کاملاً یکسان پیاده‌سازی شده‌اند. روش پیشنهادی با زمان حدود ۳۰ ثانیه، حدود ۵ برابر سریع‌تر از *DSM-CNN* (۱۵۰ ثانیه) و بسیار سریع‌تر از *MMP-CNN* (۱۲۰ دقیقه) عمل می‌کند، در

۴-۲-۵ بحث کیفی و بصری نقشه‌های طبقه‌بندی


شکل‌های (۶) و (۷) نقشه‌های طبقه‌بندی شده توسط روش‌های مختلف را نشان می‌دهند. روش *DSM-SVM* دارای نویز شدید پیکسلی و اشتباهات فاحش در

قابل توجهی هموارتر و با مرزهای دقیق‌تر هستند. این مشاهدات کیفی با یافته‌های عددی مطابقت کامل دارد.


اما در برخی رده‌ها همچنان خطا وجود دارد. در مقابل، نقشه‌های تولید شده توسط *MMP-MLDANet* به طور




نمونه‌های آموزشی




نمونه‌های آزمون




DSM-SVM




DSM-CNN



MMP-SVM




MMP-CNN




MMP-MLDANet


شکل ۶: تصاویر نمونه‌های آموزشی و آزمون و نتایج طبقه‌بندی روش‌های مختلف در داده هیوستون




نمونه‌های آموزشی




نمونه‌های آزمون




DSM-SVM




DSM-CNN



MMP-SVM



MMP-CNN



MMP-MLDANet

شکل ۷: تصاویر نمونه‌های آموزشی و آزمون و نتایج طبقه‌بندی روش‌های مختلف در داده ترنتو

۳-۴- بحث

شبکه نواحی تصادفی عمیق در این مطالعه به دلیل عدم نیاز به فرآیند آموزش پیچیده و بازانتشار خطا ترجیح داده شده و مبنای روش ارائه شده قرار گرفته است. این شبکه با استفاده از تبدیل LDA به صورت نظارت شده، ویژگی‌های مکانی سلسله‌مراتبی و چندمقیاسه را به طور کارآمد استخراج می‌کند. این روش نسبت به مدل‌های عمیق سنتی، نیاز به داده‌های آموزشی کمتر و سخت‌افزار ساده‌تری دارد و در عین حال ویژگی‌های غنی و متمایزی تولید می‌کند که دقت طبقه‌بندی را بهبود می‌بخشد. روش $MMP-MLDANet$ ارائه شده در این مطالعه ترکیبی از یادگیری عمیق و یادگیری ماشین سنتی است. رویکرد ترکیبی ارائه شده با استفاده از ویژگی‌های عمیق استخراج شده از ویژگی‌های MMP و طبقه‌بندی کننده‌های SVM جمعی این امکان را می‌دهد که دقت طبقه‌بندی در شرایط با داده‌های آموزشی محدود به طور چشمگیری بهبود یابد. می‌توان انتظار داشت که با افزایش تعداد نمونه‌های آموزشی، عملکرد روش $MMP-MLDANet$ بهبود یابد. بنا بر پیشینه تحقیق، روش‌های موجود عموماً اطلاعات DSM را یا در ترکیب با ویژگی‌های دیگر یا به تنهایی برای طبقه‌بندی پوشش زمین به کار می‌برند.

به عنوان نمونه در مقالات صادقی و همکاران (۲۰۱۶)، ژانگ و همکاران (۲۰۲۲) و وانگ و همکاران (۲۰۲۲) از اطلاعات ترکیبی حاصل از تصویر ابرطیفی و DSM برای طبقه‌بندی پوشش زمین استفاده شده است [۳۲، ۳۳]. معیار OA روش ارائه شده در تحقیق صادقی و همکاران (۲۰۱۶) برابر ۸۳٪ بر روی داده‌ی هیوستون بوده است که کمتر از روش مقاله حاضر است [۶].

نتایج نهایی روش‌های ارائه شده در تحقیق ژانگ و همکاران (۲۰۲۲) به ترتیب در داده‌های هیوستون و ترنتو بیانگر OA ۸۵٫۵۴٪ و ۹۶٫۷۲٪ و تحقیق وانگ و همکاران (۲۰۲۲) به ترتیب برابر با ۸۲٫۲۰٪ و ۹۲٫۳۱٪ است که از روش مطالعه حاضر کمتر است [۳۲ و ۳۳].

این مقایسه‌ها نشان می‌دهد که در صورتی که از اطلاعات نهفته در DSM به طور مطلوبی بهره‌برداری شود (همانطور که در روش پیشنهادی $MMP-MLDANet$ بهره‌برداری شد) می‌توان حتی بدون اطلاعات طیفی اضافی نیز به سطوح دقت مطلوبی رسید. در حوزه مطالعات موجود در پیشینه تحقیق که بر روی طبقه‌بندی تصاویر تک باند DSM تمرکز دارند، می‌توان به مقالات بیرامی (۲۰۲۴)، وانگ و همکاران (۲۰۲۰)، بیرامی و همکاران (۲۰۲۳)، بهاوانام (۲۰۲۴) و دای و همکاران (۲۰۲۴) اشاره کرد [۱۵، ۱۶، ۲۲، ۲۳ و ۲۵].

نتایج تحقیق بیرامی (۲۰۲۴) بر روی داده ترنتو که از یک معماری دو مرحله‌ای عمیق استفاده می‌کند نشان از حصول به دقت OA ۹۷٫۳۲٪ دارد که کمتر از روش حاضر است [۱۶]. نتایج مطالعه‌ی بیرامی و همکاران (۲۰۲۳) که از یک روش کرنلی پیشرفته استفاده می‌کند بر روی داده‌های هیوستون و ترنتو به ترتیب نشان از حصول به دقت OA ۹۰٫۰۸٪ و ۹۳٫۴۲٪ دارد که این نتایج نیز بیانگر عملکرد بهتر روش پیشنهادی مقاله حاضر است [۲۴]. همچنین روش $MMP-MLDANet$ برای طبقه‌بندی تک‌باند DSM با OA ۹۰٫۸۵٪ در هیوستون و ۹۸٫۴۹٪ در ترنتو، در مقایسه با روش‌های GAN موجود مانند وانگ و همکاران (۲۰۲۰) که OA ۹۲-۹۴٪ در سناریوهای نوپزی گزارش کرده اما روی هیوستون/ترنتو مستقیماً آزمایش نشده، عملکرد بهتری با ۴۰ نمونه آموزشی و زمان پردازش مطلوب ارائه می‌دهد [۲۳].

در مقابل روش‌های مبتنی بر ViT ، مانند $ViT-CA$ که در بهاوانام (۲۰۲۴) ارائه شده است، با OA ۸۸٫۳٪ در داده‌ی هیوستون، $Spectrum Transformer$ ارائه شده در دای و همکاران (۲۰۲۴) با OA ۵۹٫۱۲٪ در هیوستون و ۹۲٫۴۶٪ در ترنتو، به دلیل وابستگی به داده‌های حجیم، دقت پایین‌تری نسبت به روش این مقاله دارند که با استخراج ویژگی‌های مکانی MMP و $MLDANet$ ، دقت بالاتر و بار محاسباتی کمتری فراهم

بدون نیاز به بازانتشار خطا در شبکه *LDANet* است. افزون بر این، نقشه‌های طبقه‌بندی تولید شده توسط روش حاضر از نظر کیفی هموارتر بوده و دارای مرزهای دقیق‌تر و نویز پیکسلی کمتری نسبت به سایر روش‌ها هستند. در مجموع، روش *MMP-MLDANet* با ترکیب ویژگی‌های مکانی *MMP*، ویژگی‌های عمیق نظارت‌شده حاصل از روش *LDANet* چندمقیاسه و بهره‌گیری از سیستم طبقه‌بندی چندگانه با رأی‌گیری سه‌بعدی، توانسته است با تعداد محدود نمونه‌های آموزشی (۴۰ نمونه در هر رده) به دقت‌های مطلوب بر روی دو مجموعه داده شهری و نیمه‌شهری دست یابد که دست کم از بسیاری از روش‌های موجود در پیشینه تحقیق بهتر است.

پیشنهاد می‌شود در مطالعات آتی، عملکرد روش حاضر با استفاده از روش‌های پیشرفته‌تر استخراج ویژگی‌های مکانی (مانند نیمرخ‌های انقراضی یا ویژگی‌های فرکتالی) بهبود یابد. همچنین ارزیابی روش بر روی داده‌های متنوع‌تر (مانند مناطق غیرشهری، جنگلی یا داده‌های ترکیبی ابرطیفی و لایدار) از محورهای تحقیقاتی آتی خواهد بود.

می‌کند [۱۵ و ۲۵].

به صورت کلی می‌توان نتیجه گرفت که روش ارائه شده در مطالعه‌ی حاضر نسبت به روش‌های موجود در پیشینه تحقیق عملکرد مطلوبی از خود نشان داده است.

۵- نتیجه‌گیری

در این پژوهش، یک الگوریتم ترکیبی جدید به نام *MMP-MLDANet* برای طبقه‌بندی تصاویر تک‌باند *DSM* لایدار ارائه شد. روش پیشنهادی از سه مرحله اصلی تشکیل شده است: نخست استخراج ویژگی‌های مکانی پایه با استفاده از ویژگی‌های *MMP* با عناصر ساختاری دایره، مربع و الماس در اندازه‌های مختلف. دوم، تولید ویژگی‌های عمیق سلسله‌مراتبی با شبکه *LDANet* که مبتنی بر تبدیل *LDA* به صورت چند مقیاسه و ادغام با ویژگی‌های *MMP* سوم، طبقه‌بندی ویژگی‌های حاصل با دسته‌بندهای *SVM* چندگانه و ترکیب نتایج با رأی‌گیری اکثریت سه‌بعدی.

روش مقاله حاضر بر روی دو مجموعه داده استاندارد *DSM* (هیوستون با ۱۵ رده و ترنتو با ۶ رده) ارزیابی شد. در شرایط محدودیت داده‌های آموزشی (تنها ۴۰ نمونه تصادفی در هر رده)، روش *MMP-MLDANet* به دقت کلی ۹۰٫۸۵٪ در داده‌ی هیوستون و ۹۸٫۴۹٪ داده‌ی ترنتو دست یافت. همچنین ضریب کاپا به ترتیب برای هیوستون برابر ۸۹٫۹۶٪ و برای ترنتو برابر ۹۷٫۹۶٪ به دست آمد. این نتایج نسبت به روش‌های پایه شامل *DSM-CNN*، *DSM-SVM* و *MMP-SVM* و *MMP-CNN* برتری چشمگیری را نشان می‌دهد؛ به عنوان مثال در داده هیوستون روش پیشنهادی دقت کلی را نسبت به *DSM-CNN* حدود ۲۲٪ و نسبت به *MMP-CNN* حدود ۵٪ افزایش داده است. بررسی دقیق دقت تولیدکننده و دقت کاربر در هر رده نشان داد که روش ارائه شده در بسیاری از رده‌ها بهبود قابل توجهی ایجاد کرده است. همچنین تعادل بین دقت بالا و زمان پردازش مطلوب در روش پیشنهادی برقرار است. این مزیت عمدتاً ناشی از ماهیت غیرتکراری و

پیوست

ماتریس‌های ابهام حاصل از طبقه‌بندی روش‌های مختلف برای داده‌های هیوستون و ترنتو در ادامه ارائه شده است.

برای داده‌ی هیوستون:

DSM-SVM

۲۴۶	۱۲۴	۰	۱۷	۲۸۹	۵۱	۱۱۳	۰	۴	۴۱	۱۵۰	۰	۲	۱۴۱	۳۳
۰	۲۸۰	۳۳	۲	۸۹	۴۷	۲۹۲	۱	۱۲۷	۲۷	۶۸	۰	۳۰	۱۱۴	۱۰۴
۰	۰	۴۳۸	۰	۰	۰	۹	۰	۰	۰	۰	۰	۰	۰	۲۱۰
۰	۰	۲	۴۰۵	۲	۱	۶۵۱	۱۱۴	۱	۱	۴	۱۵	۲	۵	۱
۱۵۴	۲۰	۱۰	۰	۵۱۴	۵۴	۹۵	۰	۱۲۸	۳۹	۱۰۸	۰	۳۵	۲۳	۲۲
۰	۲۲	۰	۳	۰	۱۷۸	۲۰	۰	۱۸	۴	۹	۰	۲۷	۲	۲
۰	۲	۱۰	۲۴۴	۸	۵	۸۳۳	۹۸	۳	۱	۳	۱۲	۰	۲	۷
۰	۰	۰	۱۹۱	۰	۰	۵۲۹	۴۸۰	۰	۰	۰	۴	۰	۰	۰
۱	۱۱۴	۷	۱	۴۹	۵۵	۳۶۲	۰	۱۳۲	۴۲	۱۵۸	۰	۳۶	۲۴۹	۶
۰	۱۷۰	۱۶	۱۸	۳۵	۱۱۵	۳۸۱	۳۴	۵۱	۳۸	۲۸۹	۰	۱۲	۲۴	۱۴
۰	۱۰	۲۵	۰	۳۲	۳	۲۰۷	۲	۲۸	۱۲۰	۶۸۳	۰	۳	۴۸	۳۴
۰	۹۲	۰	۱۳۶	۲۸	۱۹۶	۲۶۲	۱۰	۹۹	۳۴	۱۵۱	۸۶	۶۶	۳۰	۳
۰	۴۸	۳	۰	۲۰	۹۴	۵۳	۰	۶۲	۲۱	۵۹	۰	۴۲	۱۷	۱۰
۰	۳۶	۱	۰	۲۸	۰	۱۶	۰	۰	۰	۰	۰	۰	۳۰۳	۴
۰	۰	۲۳۴	۰	۰	۰	۴	۰	۰	۰	۰	۰	۰	۰	۲۸۲

DSM-CNN

۷۵۷	۸۰	۱۹	۱۲	۵۶	۲۹	۱۹	۰	۵۳	۸	۱۹	۷۹	۲۴	۱۷	۲۹
۱۳۸	۵۱۷	۹	۰	۵۸	۴	۷	۲	۱۷۷	۱	۲۴	۱۱۳	۶	۷۳	۸۵
۰	۰	۶۰۲	۰	۱	۰	۰	۰	۰	۰	۰	۰	۰	۰	۵۴
۰	۰	۰	۱۰۷۱	۰	۱	۱۳۱	۰	۱	۰	۰	۰	۰	۰	۰
۱۰۴	۸۶	۱۲	۰	۵۷۷	۴۹	۱۵	۲	۳۷	۵۸	۰	۱۱۹	۵۳	۵۶	۳۴
۰	۱۰	۰	۱۱	۳	۲۰۴	۰	۰	۲۱	۷	۰	۲۰	۹	۰	۰
۰	۶	۰	۱۸۴	۰	۷	۹۹۹	۲	۸	۰	۲۰	۰	۰	۲	۰
۰	۲	۰	۰	۰	۲	۳۱	۹۸۵	۳	۳۷	۱	۱۴۱	۰	۲	۰
۱۳	۸۴	۰	۰	۹۴	۱۰۷	۲۱	۰	۵۶۷	۷	۶۴	۱۴۱	۲۳	۷۵	۱۶
۴۸	۶۶	۴	۰	۳۴	۱۷	۳۶	۶۶	۹	۷۸۴	۰	۷۹	۳۹	۵	۰
۰	۴	۰	۰	۰	۵۶	۰	۰	۴۲	۹	۱۰۵۰	۴	۲۵	۵	۰
۵۰	۴۴	۰	۰	۵۰	۳۲	۱	۲۴	۷۶	۳۴	۳۶	۷۲۳	۸۷	۳۵	۱
۰	۱	۰	۰	۱۵	۱۱	۰	۰	۶	۹	۲۰	۴	۳۶۳	۰	۰
۱	۶	۰	۰	۲۷	۰	۰	۰	۰	۱	۳	۷	۰	۳۳۰	۱۳
۱	۸	۶۷	۰	۴۳	۰	۰	۱	۲	۱۳	۰	۰	۰	۲۱	۴۶۴

MMP-SVM

۹۸۰	۱۳۹	۰	۲۴	۳۳	۰	۱	۰	۲۱	۰	۰	۷	۰	۶	۰
۵۰	۹۱۳	۰	۰	۴	۲۹	۱۱	۰	۵۵	۳۰	۲	۵۸	۶	۵۶	۰
۰	۰	۶۴۴	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۱۳
۰	۲	۰	۱۰۵۸	۰	۱	۱۳۰	۱۰	۳	۰	۰	۰	۰	۰	۰
۱۷	۱	۰	۰	۱۱۰۴	۷	۰	۰	۲۹	۱۹	۱	۲۰	۳	۱	۰
۲۲	۰	۰	۲	۳	۲۴۵	۷	۰	۶	۰	۰	۰	۰	۰	۰
۰	۰	۰	۹۱	۰	۰	۱۰۷۴	۳	۴۲	۰	۱۴	۰	۲	۲	۰
۰	۰	۰	۲	۰	۰	۵۲	۱۰۹۵	۰	۰	۰	۵۵	۰	۰	۰
۲۷	۹۰	۰	۴	۲۱	۱۸	۶	۴	۹۵۳	۰	۱۰	۴۲	۳۵	۲	۰
۰	۰	۰	۱	۲۸	۱	۰	۰	۰	۱۱۳۹	۲	۰	۱۶	۰	۰
۱۲	۰	۰	۰	۸	۱۱	۱	۱	۸	۱۷	۱۰۹۶	۰	۴۱	۰	۰
۶	۱۳	۰	۰	۰	۳	۳	۰	۳۸	۱	۶	۱۰۸۴	۲۰	۱۹	۰
۸	۰	۰	۰	۰	۰	۱	۰	۲	۰	۱	۰	۴۱۷	۰	۰
۱	۲	۰	۰	۰	۰	۱	۰	۰	۰	۰	۰	۰	۳۸۴	۰
۰	۰	۷	۰	۹	۰	۰	۰	۰	۰	۰	۰	۰	۰	۶۰۴

MMP-CNN

۹۷۷	۱۳۵	۰	۲۱	۱۳	۰	۴	۰	۳۹	۷	۰	۲۱	۲	۰	۲
۱۲۶	۹۲۴	۰	۰	۹	۰	۱۱	۰	۷۲	۳۲	۰	۲۰	۱	۱۱	۸
۰	۰	۶۵۱	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۶
۰	۰	۰	۹۲۵	۰	۰	۲۲۹	۳۰	۰	۰	۰	۰	۰	۰	۰
۴۴	۰	۰	۰	۱۰۵۸	۵	۱۵	۰	۳۳	۴	۰	۴۰	۳	۰	۰
۸	۰	۰	۸	۱	۲۵۴	۰	۰	۵	۰	۰	۰	۹	۰	۰
۰	۰	۰	۲۲۰	۰	۰	۹۸۵	۰	۲۱	۰	۲	۰	۰	۰	۰
۰	۰	۰	۴۲	۰	۰	۲۱	۱۰۹۸	۰	۰	۰	۴۳	۰	۰	۰
۳۶	۵۱	۰	۹	۲۴	۱۸	۱۶	۰	۹۱۶	۰	۳۶	۲۷	۵۵	۳	۲۱
۲	۵	۰	۰	۳۵	۱۰	۰	۱	۰	۱۱۳۱	۰	۳	۰	۰	۰
۰	۰	۰	۰	۶	۳۴	۱	۰	۱۹	۶	۱۱۰۹	۰	۲۰	۰	۰
۰	۵۲	۰	۰	۰	۴	۰	۶۷	۵۳	۶	۱۶	۹۵۲	۹	۲۱	۱۳
۸	۰	۰	۰	۰	۰	۰	۰	۲	۰	۰	۰	۴۱۹	۰	۰
۰	۱	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۳۸۷	۰
۰	۰	۲۷	۰	۳	۰	۰	۰	۰	۰	۰	۰	۰	۴	۵۸۶

MMP-MLDANet

۱۱۱۰	۳۵	۰	۲۴	۱۰	۰	۳	۰	۱۸	۰	۰	۱۱	۰	۰	۰
۴۱	۹۹۹	۰	۰	۱	۱۹	۴	۰	۶۵	۲۰	۰	۵۰	۷	۸	۰
۰	۰	۶۴۴	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۱۳
۰	۰	۰	۱۰۸۲	۰	۰	۱۰۴	۸	۱۰	۰	۰	۰	۰	۰	۰
۳۰	۰	۰	۰	۱۰۹۰	۰	۰	۰	۳۹	۲۳	۰	۲۰	۰	۰	۰
۲۷	۰	۰	۰	۰	۲۴۸	۶	۰	۴	۰	۰	۰	۰	۰	۰
۰	۰	۰	۵۲	۰	۰	۱۱۱۴	۰	۵۱	۰	۱۱	۰	۰	۰	۰
۰	۰	۰	۹	۰	۰	۴۱	۱۱۳۲	۰	۰	۰	۲۲	۰	۰	۰
۲۴	۹۲	۰	۰	۲۲	۰	۰	۸	۹۷۳	۰	۶	۵۲	۳۵	۰	۰
۰	۰	۰	۰	۴۲	۰	۰	۲	۱۴	۱۰۹۳	۰	۱۶	۰	۰	۰
۱۵	۰	۰	۰	۲	۶	۲	۰	۱۶	۲۹	۱۱۰۰	۰	۲۵	۰	۰
۰	۲۵	۰	۰	۳	۰	۰	۰	۳۴	۱	۱۹	۱۰۹۶	۱۵	۰	۰
۸	۰	۰	۰	۰	۰	۰	۰	۱	۰	۰	۰	۴۲۰	۰	۰
۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۳۸۸	۰
۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۶۲۰

برای داده‌ی ترنتو:

DSM-SVM

۱۰۸۳	۴۳	۱۴۸۵	۰	۱۳۸۳	۰
۲	۱۳۸۸	۱۷	۱۳۸۴	۷۲	۰
۴۸	۱	۳۲۱	۰	۶۹	۰
۳	۳۵۸۵	۴	۵۴۳۲	۵۹	۰
۱۶۶۵	۸۰	۲۱۵۳	۰	۶۵۶۳	۰
۱۲۸	۹۲	۲۶۲۷	۸	۲۷۹	۰

DSM-CNN

۳۶۱۵	۶۲	۴۳	۰	۴۰	۲۳۴
۰	۲۷۸۱	۰	۴۳	۰	۳۹
۱۳	۰	۳۲۰	۰	۵	۱۰۱
۰	۳۵۶	۰	۸۷۲۷	۰	۰
۷۱۴	۲۱۹	۲۶۵	۵	۸۱۳۹	۱۱۱۹
۴۴	۲۱۰	۰	۰	۹	۲۸۷۱

MMP-SVM

۳۸۰۸	۷	۱۳۶	۵	۱۵	۲۳
۱۵	۳۷۹۲	۰	۰	۸	۴۸
۹۸	۰	۳۲۰	۱	۱۱	۹
۰	۲۰۱	۱	۸۸۷۸	۰	۳
۷۳	۲۴	۴۷۷	۲۲	۹۸۱۷	۴۸
۸۴	۳۰۶	۴۰۸	۵	۱۸۴	۲۱۴۷

MMP-CNN

۳۴۴۴	۰	۲۰۱	۰	۲۷	۳۲۲
۰	۲۷۹۸	۰	۰	۰	۶۵
۴	۰	۳۶۱	۰	۰	۷۴
۰	۰	۰	۹۰۶۲	۰	۲۱
۰	۰	۴۲۴	۰	۹۹۱۳	۱۲۴
۰	۷۰	۳۵	۰	۱۵	۳۰۱۴

MMP-MLDANet

۳۹۶۴	۰	۲۳	۰	۰	۷
۱۲	۲۸۳۸	۰	۰	۴	۹
۱۵	۰	۴۲۰	۰	۰	۴
۰	۱۱	۰	۹۰۷۲	۰	۰
۰	۰	۱۲	۰	۱۰۴۱۳	۳۶
۳	۸۷	۱۳۵	۰	۹۴	۲۸۱۵

مراجع

- [1] F.J. Aguilar, F.A. Rodríguez, M.A. Aguilar, A. Nemmaoui, and F. Álvarez-Taboada, "Forestry Applications of Space-Borne LiDAR Sensors: A Worldwide Bibliometric Analysis", *Sensors*, vol. 24(4), pp. 1106, 2024.
- [2] T. T. Sankey, L. Tango, J. Tatum, and J. B.Sankey, "Forest fire, thinning, and flood in wildland-urban interface: UAV and lidar-based estimate of natural disaster impacts", *Landscape Ecology*, vol. 39(3), pp. 58, 2024.
- [3] L. Hauptman, D. Mitsova, and T.R. Briggs, "Hurricane Ian Damage Assessment Using Aerial Imagery and LiDAR: A Case Study of Estero Island, Florida", *Journal of Marine Science and Engineering*, vol 12(4), pp. 668, 2024.
- [4] H. Liu, C. Mou, J. Yuan, Z. Chen, L. Zhong, and X. Cui, "Estimating Urban Forests Biomass with LiDAR by Using Deep Learning Foundation Models", *Remote Sensing*, vol. 16(9), pp. 1643, 2024.
- [5] A. Wang, D.Xue, H. Wu, and Y. Gu, "Efficient convolutional neural architecture search for LiDAR DSM classification", *IEEE Transactions on Geoscience and Remote Sensing*, vol. 60, pp. 1-17, 2022.
- [6] B. Sadeqi, H. Ebadi, Y. Maqsudi, "Fusion of hyperspectral and lidar data in class based classification of land covers in urban area", presented at *The 1st National Conference on Geospatial Information Technology*, Tehran K.N. Toosi University of Technology, Iran, 2016, <https://sid.ir/paper/841430/fa>.
- [7] S.Y. Sajjadi, O. Aieneh, "Urban Features Production with Combining LiDAR and Hyperspectral Data", *Journal of Geospatial Information Technology*, vol. 6 (1), pp. 1-14, 2018, <http://jgit.kntu.ac.ir/article-1-560-fa.html>.
- [8] S. Y. Sajjadi, and S. Parsian, "Building Extraction from Fused Hyperspectral and LiDAR Data using Machine Learning Technique", *Iranian Journal of Remote Sensing and GIS*, vol. 10(2), pp. 1-14, 2018.
- [9] D. Hong, L. Gao, R. Hang, B. Zhang, and J. Chanussot, "Deep encoder-decoder networks for classification of hyperspectral and LiDAR data", *IEEE Geoscience and Remote Sensing Letters*, vol. 19, pp. 1-5, 2020.
- [10] H. Ge, L. Wang, H. Pan, Y. Liu, C. Li, D. Lv, and H. Ma, "Cross Attention-Based Multi-Scale Convolutional Fusion Network for Hyperspectral and LiDAR Joint Classification", *Remote Sensing*, vol. 16(21), pp. 4073, 2024.
- [11] Y. Liu, Z. Ye, Y. Xi, H. Liu, W. Li, and L. Bai, "Multi-Scale and Multi-Direction Feature Extraction Network for Hyperspectral and LiDAR Classification", *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 17, pp 9961-9973, 2024, DOI: 10.1109/JSTARS.2024.3400872.
- [12] Y. Zhao, H. Li, W. Bao, and N. Song, "IACF-Net: Interactive adaptive cross fusion network for collaborative classification of hyperspectral and LiDAR data", *Infrared Physics and Technology*, vol. 153, pp.106318, 2026, <https://doi.org/10.1016/j.infrared.2025.106318>.
- [13] H. Jing, S. Wu, L. Zhang, F. Meng, Y. Yan, Y. Wang, and Z. Du, "Heterogeneous Contrastive Graph Fusion Network for Classification of Hyperspectral and LiDAR Data", *IEEE Transactions on Geoscience and Remote Sensing*, vol. 63, pp 1-17, 2025, <https://doi.org/10.1109/tgrs.2025.3596265>.
- [14] R. Wang, X. Ye, Y. Huang, M. Ju, and W. Xiang, "GASSF-Net: Geometric Algebra Based Spectral-Spatial Hierarchical Fusion Network for Hyperspectral and LiDAR Image Classification", *Remote Sensing*, vol. 16,

- pp. 3825, 2024,
<https://doi.org/10.3390/rs16203825>.
- [15] S. R. Bhavanam, "Vision Transformer-Driven LiDAR Data Fusion for Enhanced Hyperspectral Image Classification", presented at 2024 IEEE India Geoscience and Remote Sensing Symposium (InGARSS), Goa, India. <https://doi.org/10.1109/InGARSS61818.2024.10983980>.
- [16] B.A. Beirami, "Multishape Morphological-based Two-Stage CNN for LiDAR-DSM Classification", *International Journal of Smart Electrical Engineering*, vol. 13(2), pp. 157-162, 2024. <https://doi.org/10.82234/ijsee.2024.1124039>.
- [17] F. Aghighi, O. Ebadati, and H. Aghighi, "Classification of LiDAR Points Cloud Using Markov Random Field and Machine Learning Techniques", *Iranian Journal of Remote Sensing and GIS*, vol. 9(2), pp. 41-60, 2018.
- [18] F. Jafari, and F. Movahed, "Evaluating and measuring the extracted data of buildings with using lidar", *Journal of Geography and Planning*, vol. 25(78), pp. 117-137, 2022, doi: 10.22034/gp.2021.44657.2790.
- [19] P. Ghamisi, and B. Hoefle, "LiDAR data classification using extinction profiles and a composite kernel support vector machine", *IEEE Geoscience and Remote Sensing Letters*, vol 14(5), pp. 659-663, 2017.
- [20] A. Wang, X. He, P. Ghamisi, and Y. Chen, "LiDAR data classification using morphological profiles and convolutional neural networks", *IEEE Geoscience and Remote Sensing Letters*, vol. 15(5), pp. 774-778, 2018.
- [21] A. Wang, D. Xue, H. Wu, and Y. Iwahori, "A novel LiDAR data classification algorithm combined capsnet with resnet", *Sensors*, vol. 20(4), pp. 1151, 2020.
- [22] H. Wu, M. Cao, A. Wang, and M. Wang, "Classification of LiDAR data combined octave convolution with capsule network", *IEEE Access*, vol. 8, pp. 16155-16165, 2020.
- [23] A. Wang, D. Xue, H. Wu, Y. Iwahori, "LiDAR data classification based on improved conditional generative adversarial networks", *IEEE Access*, vol.8, pp. 209674-209686, 2020.
- [24] B.A. Beirami, and M. Mokhtarzade, "Land Covers Classification from LiDAR-DSM Data Based on Local Kernel Matrix Features of Morphological Profiles", *International Journal of Engineering*, vol. 36(09), pp. 1611, 2023.
- [25] S. Dai, H. Wu, J. Li, Y. Iwahori, and A. Wang, "Enhanced LiDAR Data Classification through Spectrum Transformer Networks", presented at 2024 6th International Conference on Video, Signal and Image Processing, Ningbo, China, <https://doi.org/10.1145/3708568.3708593>.
- [26] J. Dong, K. Liu, J. Han, M. Zhang, X. Zhao, W. Li, X. Li, and M. Rao, "Multiscale Neighborhood Information Fusion Network for Classification of Remote Sensing LiDAR Images", *IEEE Sensors Journal*, vol. 24(10), pp. 16601-16613, 2024.
- [27] B.A. Beirami, "Face Recognition based on Multi-shape Morphological Profiles-based Covariance Descriptors and Log-Euclidean Kernel SVM", presented at 2022 9th IEEE Iranian Joint Congress on Fuzzy and Intelligent Systems (CFIS), Bam, Iran, 2022, <https://doi.org/10.1109/CFIS54774.2022.9756491>.
- [28] B.A. Beirami, and M. Mokhtarzade, "Improving the performance of RPNet with LDA for extracting the deep features for the classification of hyperspectral images", *Engineering Journal of Geospatial Information Technology*, vol. 10(1), pp. 1-15, 2022, <http://jgit.kntu.ac.ir/article-1-727-en.html>.
- [29] S. Tahermanesh, M. Mokhtarzade, and B.

- A. Beirami, "Enhancing change detection in multi-temporal optical images using a novel multi-scale deep learning approach based on LSTM", *Advances in Space Research*, vol. 75(10), pp. 7082-7111, 2025.
- [30] B.A. Beirami, M.A. Pirbasti, and V. Akbari, "Fractal-Based Ensemble Classification System for Hyperspectral Images", *IEEE Geoscience and Remote Sensing Letters*, vol. 20, pp. 1-5, 2023, <https://doi.org/10.1109/LGRS.2023.3330608>.
- [31] O. Sharifi, M. Mokhtarzadeh, and B.A. Beirami, "A new deep learning approach for classification of hyperspectral images: Feature and decision level fusion of spectral and spatial features in multiscale CNN", *Geocarto International*, vol. 37(14), pp. 4208-4233, 2022. <https://doi.org/10.1080/10106049.2021.1882006>.
- [32] H. Zhang, J. Yao, L. Ni, L. Gao, and M. Huang, "Multimodal attention-aware convolutional neural networks for classification of hyperspectral and LiDAR data", *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 16, pp. 3635-3644, 2022.
- [33] A. Wang, S. Xing, M. Li, Y. Yang, S. Ding, H. Wu, and Y. Iwahori, "Collaborative classification of hyperspectral and LiDAR data based on dual-branch convolutional neural network", presented at *IEEE IGARSS 2022-2022 IEEE International Geoscience and Remote Sensing Symposium, Kuala Lumpur, Malaysia, 2022*. <https://doi.org/10.1109/IGARSS46834.2022.9883344>.



MMP-MLDANet: Classification of LiDAR-DSM Image Based on Multishape Morphological Profiles and Multiscale LDA-based Deep Random Patches Networks

Behnam Asghari Beirami^{1*}, *Mohammad Reza Seif*²

- 1- Senior Researcher in Surveying Engineering & Geospatial Data Department - Faculty of Civil, Surveying and Defense Engineering - Imam Hussein University - Tehran - Iran
2- Assistant Professor of Surveying Engineering & Geospatial Data Department- Faculty of Civil, Surveying and Defense Engineering - Imam Hossein University - Tehran - Iran

Abstract

Similar elevation information in different land classes makes it challenging to classify features and land classes in Digital Surface Model (DSM) images obtained from LiDAR sensors. In addition to the elevation data, the DSM images contain valuable spatial information that can greatly improve the classification accuracy. In recent years, deep learning techniques have emerged as powerful tools for feature extraction and image classification. Despite achieving appropriate results, many proposed deep learning approaches have complex structures and require advanced hardware and large training datasets. As a solution, this paper proposes a new strategy for DSM classification to produce accurate land-cover maps. The proposed method, named MMP-MLDANet, uses multishape morphological profiles (MMP) and multiscale LDA-based deep random patches networks (MLDANet) for feature extraction. Finally, a multiple-classifier system that is based on support vector machines (SVMs) is developed to classify the resulting deep features. According to the experiments conducted on single-band DSM images of the Houston and Trento areas, the proposed method achieves the desired overall accuracies of 90.85% and 98.49% with a limited number of training samples, outperforming some of the existing methods in this field.

Key words : *Digital Surface Model, Lidar, Deep Learning, Classification, Morphological Profile.*