

طبقه‌بندی پوشش زمین مبتنی بر روش‌های یادگیری ماشین و یادگیری عمیق با استفاده از تصاویر ماهواره‌ای سنتینل-۲، مطالعه موردی: منطقه‌ی شهری غرب تهران

دانا سعیدی^۱، سید احسان خانکشی‌زاده^۲، طیبه مناقبی^{۳*}، محمد کریمی^۴، علی محمدزاده^۵

^۱ دانشجوی دکتری سیستم‌های اطلاعات مکانی-دانشکده مهندسی نقشه‌برداری-دانشگاه صنعتی خواجه نصیرالدین طوسی
d.saeedi@email.kntu.ac.ir

^۲ دانشجوی دکتری سنجش از دور - دانشکده مهندسی نقشه‌برداری-دانشگاه صنعتی خواجه نصیرالدین طوسی
seyedehsan.khankeshizadeh@email.kntu.ac.ir

^۳ استادیار دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی-پردیس دانشکده‌های فنی دانشگاه تهران
t.managhebi@ut.ac.ir

^۴ دانشیار دانشکده مهندسی نقشه‌برداری-دانشگاه صنعتی خواجه نصیرالدین طوسی
mkarimi@kntu.ac.ir

^۵ استاد دانشکده مهندسی نقشه‌برداری-دانشگاه صنعتی خواجه نصیرالدین طوسی
a_mohammadzadeh@kntu.ac.ir

(دریافت: اردیبهشت ۱۴۰۳، تصویب: شهریور ۱۴۰۳)

چکیده

تولید نقشه‌های پوششی زمین اطلاعات مهمی از نوع اراضی و ویژگی‌های آن‌ها را فراهم کرده و در به روزرسانی نقشه‌های شهری، مدیریت منابع طبیعی، حفاظت از محیط زیست و توسعه پایدار نقش مهمی دارد. در این رابطه استفاده از تکنیک‌های پردازش تصویری و داده‌های رایگان سنجش از دور یک روش بهینه برای تولید نقشه پوششی زمین (LCM) محسوب می‌شود. در این مطالعه جهت تولید LCM از رویکردهای مختلف هوش مصنوعی شامل الگوریتم‌های یادگیری ماشین (ML) و یادگیری عمیق (DL) استفاده شده‌است. رویکرد ML شامل دو مرحله‌ی استخراج ویژگی و طبقه‌بندی است. در بخش استخراج ویژگی از ویژگی‌های بافتی مستخرج از ماتریس هم‌رخداد سطح خاکستری (GLCM) اعم از میانگین، واریانس، همگنی، تضاد و آنتروپی استفاده گردید و در مرحله طبقه‌بندی الگوریتم‌های طبقه‌بندی کننده رگرسیون لجستیک (LR)، درخت تصمیم (DT)، جنگل تصادفی (RF) و ماشین بردار پشتیبان (SVM) به کار گرفته شد. در رویکرد DL از مدل‌های تقسیم‌بندی معنایی یادگیری عمیق شامل مدل‌های U-Net، U-Net++، ResU-Net و MRU-Net استفاده گردید. برای ارزیابی دقت الگوریتم‌های ML و DL در تولید نقشه کاربری زمین، از تصاویر سنتینل-۲ مربوط به دو منطقه واقع در غرب شهر تهران استفاده گردید. نتایج این مطالعه در سه بخش مختلف ML، DL و مقایسه آن‌ها مورد بررسی قرار گرفت. در بخش ML، مدل RF که از ترکیب باندهای اصلی تصویر و ویژگی‌های بافتی استفاده کرده بود، با دقت کلی ۹۵/۲۱٪ و ضریب کاپای ۹۲/۶۲٪ نسبت به سایر مدل‌ها عملکرد بهتری داشت. در بخش DL مدل MRU-Net با دقت کلی ۹۵/۳۳٪ و ضریب کاپای ۹۲/۷۳٪ در مقایسه با دیگر مدل‌های عمیق مطلوب‌ترین LCM را تولید کرد. مدل MRU-Net بدون استفاده از ویژگی‌های بافتی، بهبود دقت کلی و ضریب کاپای به ترتیب به میزان ۰/۵۳٪ و ۰/۸۲٪ نسبت به مدل RF با ترکیب باندهای اصلی تصویر داشت. همچنین، در مقایسه با مدل RF که از ترکیب باندهای اصلی و ویژگی‌های بافتی استفاده کرده بود، دقت کلی و ضریب کاپای مدل MRU-Net به ترتیب ۰/۱۲٪ و ۰/۱۱٪ بیشتر بود.

واژگان کلیدی: طبقه‌بندی پوشش زمین، یادگیری ماشین، یادگیری عمیق، U-Net

* نویسنده رابط

۱- مقدمه

طبقه‌بندی پوشش زمین اطلاعات حیاتی را برای برنامه‌ریزان شهری، فرآیندهای تصمیم‌گیری و تدوین سیاست‌های کاربری زمین فراهم می‌کند [۱]. تولید نقشه‌های پوششی زمین^۱ (LCM) نه تنها به درک از اجزا و ماهیت کره زمین کمک می‌کند بلکه به تشخیص تغییرات و مطالعه دینامیک شهری نیز کمک می‌نماید [۲، ۳]. این فرآیند امکان شناسایی و نظارت بر انواع مختلف کاربری‌های زمین، از جمله مناطق شهری، جاده‌ای، پوشش گیاهی و مناطق آبی را نیز فراهم می‌سازد. از جمله کاربردهای دیگر نقشه‌های پوششی زمین می‌توان به تجزیه و تحلیل مناسب تغییرات ریخت‌شناسی^۲ رودخانه، بهبود ارائه خدمات طبیعی اکوسیستم، مدیریت هوشمند منابع آبی و سایر مسائل مدیریت منابع طبیعی اشاره کرد [۴، ۵].

فناوری سنجش از دور^۳ (RS) مبتنی بر تصاویر ماهواره‌ای با کاهش هزینه و زمان نسبت به روش‌های طاقت فرسای نقشه‌برداری زمینی از جمله روش‌های کارآمد برای تولید LCM به شمار می‌رود [۶]. فناوری RS به لطف سنجنده‌های ماهواره‌ای مختلف و اخذ تصاویر مناسب با قدرت تفکیک‌های زمانی، مکانی و طیفی متنوع امکان تولید نقشه‌های جامع و دقیق از عوارض زمینی از جمله نقشه‌های کاربری اراضی^۴ (LUM)، مناطق شهری و پوشش گیاهی را فراهم می‌سازد [۷]. در این میان، سنجنده‌های ماهواره‌ای لندست-۵، ۸، ۹ و نیز سنتینل-۲^۵ با ارائه تصاویر رایگان گوی سبقت را از سایر سنجنده‌ها در حوزه تولید LCM ربوده‌اند [۸]. تصاویر حاصل از این سنجنده‌ها به دلیل حد تفکیک مناسب طیفی و زمانی، داده مناسبی برای مطالعه عرصه‌های طبیعی نظیر پهنه‌های آبی، جنگل، پوشش گیاهی و نیز مناطق شهری محسوب می‌شود [۹].

از یک دیدگاه، مطالعات و رویکردهای موجود در زمینه تولید LCM را می‌توان به دو دسته رویکردهای مبتنی بر یادگیری ماشین^۶ (ML) و یادگیری عمیق^۸ (DL) تقسیم

بندی نمود. دسته‌ی مربوط به روش‌های ML عمدتاً شامل دو مرحله‌ی استخراج ویژگی‌های طیفی و بافتی مختلف و طبقه‌بندی تصویر ورودی توسط ویژگی‌های استخراج شده‌است، حال آنکه در رویکردهای یادگیری عمیق، دو فرآیند استخراج ویژگی و طبقه‌بندی به صورت هم‌زمان و در قالب شبکه‌های عمیق انجام می‌شوند [۱۰]. در میان الگوریتم‌های مختلف ML، الگوریتم‌های جنگل تصادفی^۹ (RF)، درخت تصمیم^{۱۰} (DT) و ماشین بردار پشتیبان^{۱۱} (SVM) به طور گسترده برای طبقه‌بندی کاربری و پوشش زمین^{۱۲} (LULC) استفاده شده‌اند. کوپرس و همکاران [۱۱] برای تهیه LULC از الگوریتم RF همراه با تصاویر با حد تفکیک مکانی بسیار بالاتر^{۱۳} (VHR) و سنتینل-۲ چندزمانه استفاده کردند که در نهایت به دقت کلی^{۱۴} (OA) ۷۹٪ و مقدار ۷۲٪ در شاخص F1_score رسید. در تحقیق دیگری لین و دویوگ [۱۲] از تصاویر سنتینل-۲ و داده‌های لیدار^{۱۵} برای طبقه‌بندی دقیق پوشش زمین در سه سطح جزئیات (کم، متوسط، زیاد) استفاده کردند. براساس این تحقیق در نهایت، مدل SVM بهبود بیشتری از لحاظ دقت نسبت به مدل RF ایجاد کرده‌است. کواسی [۱۳] از داده‌های لندست-۸ برای طبقه‌بندی LULC در سواحل جنوب غربی آفریقا با استفاده از روش RF استفاده کرده‌است. نتایج نشان می‌دهند که مدل RF با دقت کلی ۷۹٪ به خوبی عمل کرده‌است و از دقت مدل SVM پیشی گرفته‌است. استفاده از این روش نشان داد که می‌توان به‌طور مؤثر و با دقت بالا LULC را در منطقه مورد مطالعه طبقه‌بندی کرد. پانتویا و همکاران [۱۴] از تصاویر لندست-۸ برای طبقه‌بندی پوشش زمین استفاده کرده و نتایج نشان داده‌اند که الگوریتم RF با دقت کلی ۹۶/۳۱٪ نسبت به مدل ترکیبی گوسی (GMM)^{۱۶} با دقت کلی ۹۰/۶۰، عملکرد بهتری داشته‌است. این مقاله بر اهمیت انتخاب الگوریتم مناسب در طبقه‌بندی پوشش زمین تأکید می‌کند و نشان می‌دهد که RF می‌تواند با دقت بیشتری پوشش زمین را طبقه‌بندی کند. ساینی و همکاران [۱۵] از سه الگوریتم SVM، RF و نزدیکترین همسایگی (KNN)^{۱۷}

۱۰ Decision Tree

۱۱ Support Vector Machines

۱۲ Land Use and Land Cover

۱۳ Very High Resolution

۱۴ Overall Accuracy

۱۵ Lidar

۱۶ Gaussian Mixture Models

۱۷ K-nearest neighbors

۱ Land Cover Map

۲ Morphology

۳ Remote Sensing

۴ Land Use Map

۵ Landsat

۶ Sentinel-2

۷ Machine Learning

۸ Deep learning

۹ Random Forest

برای طبقه‌بندی LULC در تصاویر سنتینل-۲ استفاده کردند. نتایج این پژوهش نشان داد که RF با دقت کلی ۹۱٪/۵۶ و مقدار ضریب کاپا^۱ ۸۹/۹۰٪ بهترین عملکرد را در بین الگوریتم‌ها ارائه داده‌است. از جمله ضعف‌های مربوط به رویکردهای مبتنی بر ML در زمینه تولید LCM می‌توان به نیاز آن‌ها به مهندسی بردار ویژگی، تعامل زیاد کاربر خبره و همچنین تعمیم‌پذیری پایین الگوریتم‌ها در زمان اعمال به سایر مناطق اشاره نمود [۱۰].

پیشرفت‌های اخیر در زمینه پردازنده‌های گرافیکی^۲ و به خصوص در حوزه شبکه‌های عصبی عمیق^۳ (DNN)، باعث رواج فناوری جدید در زمینه استفاده از DNN به عنوان روش‌های پیشرفته در زمینه طبقه‌بندی LCM شده‌است. این پیشرفت‌ها در سخت‌افزارها به ما این امکان را می‌دهند که از الگوریتم‌های DNN بر روی مجموعه وسیعی از داده‌ها، از جمله سری‌های زمانی و تصاویر ماهواره‌ای، بهره‌مند شویم. بر خلاف رویکردهای ML، استخراج و طبقه‌بندی ویژگی‌های انتزاعی پیچیده به طور خودکار در مدل‌های مبتنی بر DNN قابل انجام است. به عبارت دیگر، در مقایسه با رویکردهای ML، مدل‌های DNN امکان استخراج و طبقه‌بندی ویژگی‌های انتزاعی پیچیده را به طور خودکار دارند. به این ترتیب، این مدل‌ها می‌توانند بدون نیاز به تعریف دقیق ویژگی‌ها توسط انسان، خودبخود الگوهای پیچیده را از داده‌ها استخراج کرده و در فرآیند طبقه‌بندی از آن‌ها بهره‌مند شوند [۱۰، ۱۶]. این شبکه‌ها به طور گسترده در تحقیقات LCM به کار رفته‌اند.

در این زمینه، تحقیقات مختلف نشان داده‌اند که از میان معماری‌های مختلف DNN معماری‌های مبتنی بر شبکه‌های عصبی پیچشی^۴ (CNN) مانند VGG، ResNet و U-Net به دلیل استخراج کارآمد ویژگی‌ها، مدیریت و درک الگوهای پیچیده و ارائه استحکام در شرایط نویزی، از قابلیت بالایی برخوردارند. به عنوان مثال، مونتراکیش و حیدری [۱۷] با استفاده از تصاویر لندست-۵، ۷ و ۸ مدل‌های DL را توسعه داده و دقت‌های طبقه‌بندی بین ۸۶٪ تا ۹۵٪ را به دست آوردند که عملکرد بهتری نسبت به روش RF داشت. گارگ و همکاران [۱۸] هم ۳۹ مدل یادگیری انتقالی عمیق^۵ را برای طبقه‌بندی LULC ارزیابی کردند و نتیجه نشان داد که

ResNet50، EfficientNetV2B0 و ResNet152 بهترین عملکرد را داشتند. داستور و حسن [۱۹] معماری‌های مختلف CNN را با استفاده از داده‌های ماهواره سنتینل-۲ مقایسه کردند و به این نتیجه رسیدند که معماری VGG16 نتایج بهتری برای طبقه‌بندی پوشش زمین با دقت کلی ۷۱٪ ارائه می‌دهد.

تقسیم‌بندی معنایی^۶ به فرآیند اختصاص برچسب معنایی به هر پیکسل از تصویر برای شناسایی دقیق نواحی مختلف بر اساس نوع اشیاء یا ویژگی‌ها اشاره دارد و به تفکیک و دسته‌بندی دقیق نواحی تصویر کمک می‌کند. علاوه بر این، در حوزه تقسیم‌بندی معنایی مبتنی بر شبکه‌های CNN، مدل‌های VGGNet و U-Net به عنوان روش‌های برتر برای بهبود دقت در تولید نقشه‌های LULC به کار گرفته شده‌اند [۲۰]. در یک تحقیق دیگر، سه معماری مختلف CNN برای تولید LCM مورد ارزیابی قرار گرفت و نتایج مطالعه نشان داد که ResNet-50 دقت بالاتری را در مقایسه با سایر شبکه‌ها دارا است [۲۱].

علیرغم مطالعات گسترده‌ای که در حوزه تولید LCM با استفاده از روش‌های مختلف ML و DL انجام شده‌است، چالش‌ها و پیچیدگی‌هایی همچنان وجود دارند. از جمله این چالش‌ها می‌توان به کمبود مطالعات جامع در زمینه ارزیابی دقت مدل‌ها با استفاده از تصاویر رایگان سنتینل-۲، نبود نقشه‌های دقیق LCM برای منطقه مورد مطالعه و نیاز به بررسی دقت این روش‌ها در این منطقه خاص اشاره کرد. این عوامل اصلی‌ترین انگیزه‌های نویسندگان برای انجام این تحقیق بوده‌اند. در این پژوهش، با ارائه یک مطالعه جامع در زمینه طبقه‌بندی پوشش زمین و تمرکز بر ارزیابی دقت مدل‌های ML و DL، سعی شده‌است تا به بهبود درک از عملکرد این مدل‌ها در مواجهه با چالش‌های مذکور کمک شود.


این تحقیق با هدف استفاده از تصاویر رایگان ماهواره‌ای سنجنده سنتینل-۲ برای تولید LCM انجام شده‌است. در این پژوهش، دو دسته از معماری‌های ML و DL برای مقایسه و ارزیابی دقت تولید LCM مورد بررسی قرار گرفته‌اند.

۴ Convolutional neural network
۵ Deep Transfer Learning
۶ Semantic Segmentation

۱ Kappa coefficient
۲ Graphics processing unit
۳ Deep neural networks

۲- منطقه مورد مطالعه

تهران در موقعیت جغرافیایی ۵۱ درجه و ۶ تا ۳۸ دقیقه طول شرقی و ۳۵ درجه و ۳۴ تا ۵۱ دقیقه عرض شمالی واقع شده‌است. ارتفاع شهر از ۱۸۰۰ متر در شمال تا ۱۰۵۰ متر در جنوب متغیر است. این شهر در دامنه‌های جنوبی رشته کوه البرز و میان کوهستان و کویر گسترده شده‌است. منطقه مورد مطالعه با مساحت تقریبی ۱۹۵/۱۷ کیلومتر مربع در غرب تهران و شمال غربی استان تهران قرار دارد (شکل ۱).



شکل ۱: منطقه مورد مطالعه


۳- مواد و روش تحقیق

مطابق با روندنمای نشان داده در شکل ۲ جهت تولید LCM منطقه مورد مطالعه، از تصاویر سطح ۲ سنتینل-۲ برای آموزش و ارزیابی دقت مدل‌ها استفاده شده‌است. بدین منظور، ابتدا تصاویر تصحیح شده ماهواره‌ای سنتینل-۲


مربوط به مناطق آموزشی و آزمایشی (شکل ۱) در تاریخ ۱۴۰۲/۰۲/۱۸ اخذ گردید. در مرحله بعد بر چسبدهی نمونه‌ها به کلاس‌های مختلف پوشش زمین (آب، مناطق شهری، پوشش گیاهی، اراضی بایر و جاده‌ها) برای تصویر آموزشی (شکل ۳) و آزمایشی (شکل ۴) با استفاده از نرم‌افزار ArcMap انجام شد. در این فرایند، از تصاویر با حد تفکیک مکانی بالا در گوگل ارث برای اخذ نمونه‌ها استفاده شد. با ابزار Editing پلیگون‌های مختلف برای هر کلاس ترسیم و با Field Calculator مقادیر عددی (۰ تا ۵) به آن‌ها اختصاص یافت. سپس با استفاده از ابزار FeaturetoRaster این پلیگون‌ها به رستر تبدیل شدند تا نمونه‌های دقیق‌تری برای تحلیل و طبقه‌بندی فراهم شود. بعد از اعمال پیش پردازش‌های لازم، برای آموزش و ارزیابی دقت الگوریتم‌های ML و DNN از زبان برنامه‌نویسی پایتون استفاده شد. در نهایت، روند طبقه‌بندی تصاویر با استفاده از داده‌های آزمایشی مورد ارزیابی قرار گرفت و تحلیل نتایج صورت پذیرفت. در ادامه جزئیات هر یک از مراحل کار به تفصیل ارائه خواهد شد.

۳-۱- پیش‌پردازش


در این مطالعه داده‌های مورد استفاده در روش‌های مبتنی بر DNN نیاز به پیش‌پردازش‌های دارند که به دو مرحله داده‌افزایی^۱ و قطعه‌بندی^۲ تصاویر تقسیم می‌شود. به منظور تبدیل داده‌های ورودی استفاده شده برای مدل‌های DL به یک فرمت صحیح (به عبارتی یک آرایه چهار بعدی که شامل تعداد نمونه‌ها، سطرها، ستون‌ها و باندها می‌شود) که با کتابخانه Python Keras سازگار باشد و برای افزایش تعداد داده‌های آموزش و اعتبارسنجی، تمام داده‌های آموزش، اعتبارسنجی، آزمایشی و برچسب‌های متناظر آنها به قطعات مربعی با ابعاد 256×256 پیکسل تقسیم شدند. علاوه بر این، قطعات بعداً با چرخش به زاویه ۹۰ درجه و انعکاس افقی/عمودی به اندازه کافی افزایش یافتند تا داده‌های آموزش، اعتبارسنجی و آزمایشی به اندازه کافی تأمین شوند. مجموعه داده‌های حاصل برای آموزش و آزمایش به ترتیب با ابعاد $(N \times 256 \times 256 \times 3)$ و $(N \times 256 \times 256 \times 9)$ آماده شدند، N تعداد باندهای داده ورودی است که با توجه به اینکه تصاویر از سنجنده سنتینل-۲ هستند، تعداد باندها برابر ۱۳ است.



شکل ۲: روند کلی تحقیق



شکل ۳: تصویر سنتینل-۲ همراه با برچسب‌های تهیه شده برای منطقه آموزشی



شکل ۴: تصویر سنتینل-۲ همراه با برچسب‌های تهیه شده برای منطقه آزمایشی

۲-۳- یادگیری ماشین

در این مطالعه، روش‌های مبتنی بر ML در دو مرحله استخراج ویژگی و آموزش مدل یادگیری ماشین پیاده‌سازی شده‌اند.

۲-۳-۱- استخراج ویژگی

در تصاویر ماهواره‌ای با کلاس غالب شهری، از ویژگی‌های بافتی، مشتق شده از ماتریس هم‌رخداد سطح خاکستری^۱ (GLCM)، بهره‌گرفته می‌شود [۲۲]. این انتخاب به دلیل پیچیدگی ویژگی‌های شهری و توانایی بهتر در تفکیک مرزهای شهری و غیرشهری صورت گرفته‌است. استفاده از این ویژگی‌های بافتی به عنوان راهی ساده و موثر برای تولید نقشه‌های دقیق در روش‌های مبتنی بر یادگیری ماشین مطرح می‌شود [۱۰]. در این تحقیق، پنج ویژگی بافتی میانگین^۲، واریانس^۳، همگنی^۴، تضاد^۵ و آنترپی^۶ مورد استفاده قرار گرفته‌است. مزایای این ویژگی‌ها همراه با فرمول‌های آن‌ها در جدول ۱ گزارش شده‌است.

۲-۳-۲- الگوریتم‌های ML

الگوریتم‌های ML مورد استفاده در این مطالعه مشتمل بر چهار الگوریتم است که در ادامه به جزئیات آن‌ها اشاره می‌شود.

۲-۳-۲-۱- درخت تصمیم (DT)

الگوریتم DT یک نوع الگوریتم ML است که در هر دو

کاربرد طبقه‌بندی و رگرسیون استفاده می‌شود. ساختار این الگوریتم مشابه یک درخت است، که از ریشه شروع شده و با حرکت به سمت برگ‌ها، با توجه به قوانین مبتنی بر ویژگی‌های ورودی، پیش‌بینی برچسب برای هر داده ورودی صورت می‌گیرد. این درخت با تجزیه و تحلیل داده‌ها به دو صورت شاخه‌ها (براساس مقادیر ویژگی‌ها) و گره‌های برگ (که حاوی پیش‌بینی‌های نهایی هستند) ساخته می‌شود. به عبارت دقیق‌تر، در این مدل هر گره داخلی یک آزمون بر اساس یک ویژگی را نمایش می‌دهد. شاخه‌ها نتایج آزمون را نشان می‌دهند و گره‌های برگ تصمیم نهایی یا برچسب‌های کلاس را نمایش می‌دهند، که پس از محاسبه تمام ویژگی‌ها به آن‌ها می‌رسد. مسیرهای از ریشه تا برگ نمایانگر قوانین طبقه‌بندی هستند.

۲-۳-۲-۲- رگرسیون لجستیکی (LR)

LR یک الگوریتم رایج در ML است که برای مسائل کلاس‌بندی دو حالت (باینری)^۷ استفاده می‌شود. این الگوریتم احتمال وقوع یکی از دو کلاس را محاسبه می‌کند و با استفاده از یک حد آستانه (معمولاً ۰.۵)، خروجی احتمال را به یک برچسب دودویی (مثلاً ۰ یا ۱) تبدیل می‌کند. در این الگوریتم، ما به یادگیری یک مدل استاندارد برای تخمین احتمال وقوع هر کلاس بر اساس ویژگی‌های مستقل داده‌ها می‌پردازیم. سپس از این مدل برای پیش‌بینی کلاس‌های جدید استفاده می‌شود. مدل به صورت اتوماتیک پارامترهای خود را از داده‌های آموزشی یاد می‌گیرد [۲۴].

۵ Contrast

۶ Entropy

۷ Binary

۱ Gray Level Co-occurrence Matrix

۲ Mean

۳ Variance

۴ Homogeneity

جدول ۱: ویژگی‌های بافتی مورد استفاده برای الگوریتم‌های یادگیری ماشین

ویژگی	توضیحات	رابطه
میانگین	- متوسط میزان روشنایی یا سطح خاکستری در تصویر - حساس به تغییرات در زبری سطح یا ساختار بافت	$\text{Mean} = \sum_i \sum_j P(i, j) \cdot \text{GLCM}(i, j)$
واریانس	- اندازه‌گیری انحراف معیار (بخش) مقادیر پیکسل‌ها از میانگین - برجسته‌سازی تغییرات شدت نوری ناشی از تغییرات در بافت	$\text{Variance} = \sum_i \sum_j [P(i, j) \cdot (\text{GLCM}(i, j) - \text{Mean})^2]$
همگنی	- به اشتراک‌گذاری شباهت مقادیر پیکسل‌ها در نواحی مجاور - مقاوم در برابر نویز و مفید در تحلیل بافت‌های پیچیده	$\text{Homogeneity} = \sum_i \sum_j \frac{P(i, j)}{1 + i - j } \cdot \text{GLCM}(i, j)$
تضاد	- نشان‌دهنده تفاوت یا اختلاف بین مقادیر پیکسل‌ها در تصویر - کمک به تحلیل تغییرات شدت نوری بین نواحی مختلف بافت	$\text{Contrast} = \sum_i \sum_j (i - j)^2 \cdot P(i, j) \cdot \text{GLCM}(i, j)$
آنتروپی	- مقدار اطلاعات موجود در تصویر می‌باشد - بالاترین مقدار آنتروپی در تصاویر با بافت‌های مختلف و پیچیده	$\text{Entropy} = - \sum_i \sum_j P(i, j) \cdot \log_2(P(i, j) + \epsilon)$

۳-۲-۲-۳- جنگل تصادفی (RF)

RF یک روش محبوب در ML است که برای وظایف دسته‌بندی و پیش‌بینی استفاده می‌شود. این الگوریتم از چندین DT ترکیبی استفاده می‌کند که بر روی زیر مجموعه‌های تصادفی از داده‌ها، آموزش می‌بینند. هر درخت به صورت مستقل پیش‌بینی می‌کند و پیش‌بینی نهایی معمولاً توسط رای اکثریت انجام می‌شود [۲۵].

۳-۲-۲-۴- ماشین بردار پشتیبان (SVM)

SVM یک روش طبقه‌بندی آماری است که به خوبی بر روی الگوها و رگرسیون‌های غیرخطی تمرکز دارد. در این روش، با انتقال فضای ورودی به یک فضای با بُعد بالاتر، می‌توان مسائل غیرخطی را بهبود بخشید. این انتقال از طریق توابع کرنل^۱ انجام می‌شود که انواع مختلفی از آنها وجود دارد، از جمله کرنل گوسی^۲، خطی^۳، چندجمله‌ای^۴ و تانژانت هایپربولیک^۵. این تنوع در توابع کرنل امکان حل مسائل گوناگون و غیرخطی را فراهم می‌کند [۲۶].

۳-۳- شبکه‌های یادگیری عمیق

این شبکه‌ها از معماری‌های خاصی برخوردار هستند که در ادامه به آنها اشاره می‌شود.

۳-۳-۱- U-Net

شبکه U-Net یک معماری کانولوشنی با ساختار رمزگذار^۶-رمزگشا^۷ است که برای طبقه‌بندی تصاویر در سطح پیکسلی ایجاد شده است. این شبکه از چندین لایه پردازشی تشکیل شده است که به عنوان لایه‌های رمزگذار و معادلات آن به عنوان لایه‌های رمزگشا شناخته می‌شوند. ساختار لایه‌ها به صورت متقارن شبیه به حرف "U" است، به همین علت U-Net نامیده شده است. در قسمت لایه‌های رمزگذار، که هدف آن استخراج اطلاعات از داده‌های ورودی است، لایه‌های کانولوشنی و لایه‌های کاهش ابعاد واقع شده‌اند. در بخش رمزگشایی، که هدف آن بازسازی تصویر ورودی و موقعیت‌یابی مکانی دقیق برای هر پیکسل است، لایه‌های کانولوشنی به همراه لایه‌های کانولوشن ترانهاد^۸ و ترکیب^۹ حضور دارند [۲۷].

۶ Encoder

۷ Decoder

۸ Transpose Convolution

۹ Concatenate

۱ Kernel functions

۲ Gaussian Kernel

۳ Linear Kernel

۴ Polynomial Kernel

۵ Hyperbolic Tangent Kernel

۳-۳-۲ U-Net++

این مدل یک نسخه بهبود یافته از U-Net را ارائه می‌دهد. معماری این شبکه به صورت یک شبکه رمزگذار-رمزگشا است که شامل مسیرهای گذردهی چگال^۱ و تو در تو^۲ است. از این مسیرها برای ارتباط موثرتر بین نقاط مختلف شبکه استفاده می‌شود و هدف از طراحی مجدد آنها، کاهش شکاف معنایی بین نقشه‌های ویژگی از شبکه کدگذار و کدگشا است. این موضوع باعث تسهیل در فرآیند یادگیری توسط بهینه‌ساز می‌شود [۲۸].

۳-۳-۳ ResU-Net^۳

ResU-Net یک نوع از معماری U-Net است که از اتصالات باقی‌مانده^۴ بهره می‌برد. معمولاً، در فرآیند یادگیری، ممکن است مشکل محوشدگی گرادیان^۵ به وجود بیاید که باعث کاهش عملکرد شبکه می‌شود. اما با استفاده از اتصالات باقی‌مانده، اطلاعات از لایه به لایه بعدی به شکل مستقیم منتقل شده و این موضوع باعث می‌شود که مشکل محوشدگی گرادیان کاهش یابد. به عبارت دیگر، در ResU-Net، از ایده‌های معماری ResNet استفاده شده است تا از مشکلات مرتبط با گرادیان‌ها جلوگیری کرده و عملکرد بهتری را ارائه دهد [۲۹].

۳-۳-۴ MRU-Net^۶

MRU-Net یک نسخه بهبود یافته از معماری U-Net است که از بلوک MultiRes به جای توالی دو لایه کانولوشن در U-Net استفاده می‌کند. این بلوک با کنترل تعداد فیلترها در هر بلوک، به بهبود و بهینه‌سازی عملکرد مدل کمک می‌کند. MRU-Net از مسیرهای Res استفاده می‌کند که جایگزین اتصالات معمولی کوتاه در U-Net می‌شوند. این مسیرها، از طریق اعمال عملیات کانولوشن، اطلاعات معنایی را از ویژگی‌های مسیر رمزگذار استخراج کرده و قبل از ترکیب با ویژگی‌های مسیر رمزگشا، باعث کاهش فاصله معنایی و تطبیق بهتر بین این دو مجموعه ویژگی می‌شوند [۳۰].

۳-۴ معیارهای ارزیابی

جهت ارزیابی کمی عملکرد روش‌های ML و DL در تهیه LCM، غالباً این نقشه‌ها با نقشه‌های برجسب‌دار آنها مقایسه می‌شوند تا میزان تطابق نتایج با واقعیت بررسی شود. روابط (۱) تا (۳) معیارهای ارزیابی مورد استفاده در این مطالعه را نشان می‌دهند.

$$OA = \left(1 - \frac{FP + FN}{TP + FP + FN + TN}\right) \times 100\% \quad (1)$$

$$KC = \left(\frac{P_0 - P_e}{1 - P_e}\right) \times 100\% \quad (2)$$

$$\begin{cases} P_e = \frac{(TP + FN) \times (TP + FP) + (FN + TN) \times (FP + TN)}{(TP + FP + FN + TN)^2} \\ P_0 = \frac{TP + TN}{TP + FP + FN + TN} \end{cases}$$

$$F_s = \left(\frac{2TP}{2TP + FP + FN}\right) \times 100\% \quad (3)$$

در این معیارها، برای هر کلاس، $(TP)^7$ تعداد نمونه‌هایی که به درستی تشخیص داده شده‌اند، $(FP)^8$ تعداد نمونه‌هایی که به اشتباه به کلاس دیگری تخصیص یافته‌اند، $(FN)^9$ تعداد نمونه‌هایی که به اشتباه از کلاس مورد نظر حذف شده‌اند و $(TN)^{10}$ تعداد نمونه‌هایی که به درستی به کلاس مورد نظر تخصیص داده نشده‌اند را نشان می‌دهد.

۴- نتایج و بحث

نتایج تجربی این مطالعه در سه بخش جداگانه ارائه شده‌اند. در بخش اول، عملکرد مدل‌های مبتنی بر ML رایج مورد بررسی قرار گرفته‌است. در بخش دوم، تکنیک‌های طبقه‌بندی DL ارزیابی شده‌اند. در نهایت، بهترین نتایج حاصل از رویکردهای مبتنی بر ML و DL در بخش سوم مورد تجزیه، تحلیل و مقایسه قرار گرفته‌اند.

۴-۱- نتایج مربوط به مدل‌های یادگیری ماشین

ابتدا ویژگی‌های بافتی ذکر شده در جدول ۱، از تصویر ماهواره‌ای ورودی استخراج شدند که شامل پنج ویژگی مجزا بود (شکل ۵). سپس برای ارزیابی تأثیر ویژگی‌های استخراج

۶ MultiResUNet

۷ True Positive

۸ False Positive

۹ False Negative

۱۰ True Negative

۱ Dense skip pathways

۲ Nested

۳ Residual and UNet

۴ Residual Connections

۵ Vanishing Gradient

شده بر دقت طبقه‌بندی، دو رویکرد مورد بررسی قرار گرفت: اول، استفاده از باندهای اصلی تصویر به تنهایی به عنوان ورودی به مدل‌های طبقه‌بندی ML و دوم، ترکیب ویژگی‌های بافتی استخراج شده با باندهای اصلی تصویر به عنوان ورودی به این مدل‌ها. نتایج کیفی و کمی حاصل از LCM‌های تولید شده در این بخش، با توجه به ویژگی‌های ورودی، به ترتیب در شکل ۶ و جدول ۲ نشان داده شده‌است.

نتایج کیفی که در شکل ۶ ارائه شده‌است نشان می‌دهد که به طور مشترک الگوریتم‌های RF و SVM در مقایسه با سایر مدل‌های ML، به مراتب LCM دقیق‌تری را از منطقه مورد مطالعه ارائه داده‌اند. این اثر به ویژه در مناطق زوم شده از شکل ۷ مشهود است، جایی که منطقه بایر با حداقل نویز از سایر کلاس‌های پوششی موجود توسط این الگوریتم‌های طبقه‌بندی تمیز داده شده‌است. در عین حال، سایر الگوریتم‌های طبقه‌بندی عملکرد نسبتاً ضعیف‌تری در تفکیک دقیق این کلاس ارائه داده و نقشه‌های تولیدشده توسط آن‌ها دارای اختلاط کلاسی بالا هستند. این به دلیل توانایی مناسب الگوریتم RF در ترکیب و تشخیص الگوهای مختلف از تصویر ورودی، به همراه استفاده از مفاهیمی مانند مرزهای تصمیم چندگانه^۱ و توانایی SVM در مدل‌سازی و تفکیک داده‌های پیچیده با استفاده از مرزهای تصمیم غیرخطی است. همچنین، افزودن ویژگی‌های استخراج شده به باندهای اصلی تصویر منجر به بهبود جزئی در عملکرد تمام مدل‌های ML شده‌است.

همچنین براساس نتایج کمی گزارش شده در جدول ۲، مدل RF با ورودی ۱۸ باندهای، با دقت کلی ۹۵/۲۱٪ و ضریب کاپا ۹۲/۶۲٪ عملکرد بهتری نسبت به دیگر مدل‌های ML در دو حالت مختلف ویژگی‌های ورودی ارائه داده‌است. به طور خاص، در حالت ورودی ۱۸ باندهای، الگوریتم RF به افزایش دقت کلی به میزان ۸/۴۸٪، ۱/۵٪ و ۰/۲۹٪ نسبت به مدل‌های LR، DT و SVM منجر شده‌است. این به دلیل استفاده از الگوریتم RF که تعدادی از درخت‌های تصمیم را ترکیب می‌کند و هر کدام از آن‌ها به صورت مستقل با استفاده از ویژگی‌های تصادفی آموزش داده می‌شود، است. این ویژگی باعث می‌شود که مدل RF با تکیه بر یادگیری جمعی^۲ یک مدل بهینه برای تولید LCM را ارائه دهد که منجر به افزایش دقت کلی نقشه شده‌است.

در رابطه با تاثیر افزودن ویژگی‌های بافتی استخراج شده (حالت ۱۸ باندهای)، نتایج کمی در جدول ۲ نشان می‌دهند که ضریب کاپا در الگوریتم RF نسبت به حالت ۱۳ باندهای به میزان ۰/۲۹٪ افزایش یافته‌است. این نشان می‌دهد که افزودن ویژگی‌های بافتی به مدل RF می‌تواند به عنوان میانبر^۳ باعث افزایش دقت و توانایی مدل در تشخیص بافت‌های مختلف زمینی شود. این ویژگی‌ها ممکن است اطلاعات دقیق‌تری از کاربری‌های زمینی ارائه دهند که منجر به تطابق بیشتر نتایج با واقعیت و در نتیجه افزایش مقدار ضریب کاپا شود.

شایان ذکر است که مدل LR با ورودی ۱۳ باندهای، با دقت کلی ۸۶/۶۸٪ و ضریب کاپا ۷۹/۲۰٪ بدترین عملکرد را نسبت به سایر مدل‌های ML ارائه می‌دهد. این به دلیل سادگی الگوریتم LR است که قادر به مدل‌سازی بهینه از مجموعه داده‌های پیچیده نیست. با این حال، اضافه کردن داده‌های کمکی (ویژگی‌های بافتی) باعث بهبود ناچیز دقت کلی و ضریب کاپا به میزان ۰/۵٪ شده‌است.

جدول ۲: نتایج حاصل از الگوریتم‌های یادگیری ماشین

مدل	دقت کلی (%)	ضریب کاپا (%)
SVM 13B	۹۴/۹۵	۹۲/۱۶
SVM 18B	۹۴/۹۲	۹۲/۱۱
RF 13B	۹۴/۸۰	۹۱/۹۱
RF 18B	۹۵/۲۱	۹۲/۶۲
DT 13B	۹۲/۶۷	۸۸/۶۰
DT 18B	۹۳/۷۱	۹۰/۱۹
LR 13B	۸۶/۶۸	۷۹/۲۰
LR 18B	۸۶/۷۳	۷۹/۲۵

۴-۲- نتایج مربوط به مدل‌های یادگیری عمیق


در این بخش پس از انجام پیش‌پردازش‌های مربوط به داده‌افزایی و قطعه‌بندی، تصویر سنتینل-۲ به عنوان ورودی به مدل‌های DL معرفی شد. در این مرحله، فرایند استخراج ویژگی به صورت خودکار توسط مدل‌های DL انجام گرفت. نتایج کیفی و کمی این فرایند در شکل ۶ و جدول ۲ مشاهده می‌شود.

مطابق با نتایج کیفی که در شکل ۶ نشان داده شده‌است، می‌توان دریافت که مدل MRU-Net به طور کلی دقیق‌تر و با کمترین نویز نقشه LCM را نسبت به سایر مدل‌های DL برای منطقه مورد آزمایش ارائه داده‌است.

۳ Proxy

۱ Multi-class decision boundaries

۲ Ensemble learning



شکل ۵: ویژگی‌های استخراج شده از ماتریس هم‌رخداد سطح خاکستری



شکل ۶: LCMهای تولید شده با استفاده از مدل‌های ML در دو حالت ورودی ۱۳ باندی و ۱۸ باندی


همچنان که در شکل ۷ دیده می‌شود، مشخص است که مدل‌های U-Net، ResU-Net و U-Net++ بیشترین خطا را در تشخیص کلاس‌های آبی و جاده دارند. خطای مورد اشاره در این دو کلاس عمدتاً از جنس خطای از قلم افتادگی^۱ است، به این معنا که کلاس این نواحی به درستی تشخیص داده نشده و در روند طبقه‌بندی برچسب نادرستی به این پیکسل‌ها الصاق شده‌است. این مسأله نشان‌دهنده ضعف مدل‌ها در شناسایی و تفکیک صحیح این کلاس‌ها است و ممکن است ناشی از ضعف ساختار شبکه‌های مذکور در یادگیری الگوها به دلیل تعداد کم پیکسل‌های آموزشی از این دو کلاس باشد. با این حال، مدل MRU-Net از ادغام بهینه ویژگی‌ها در سطوح مختلف معماری استفاده می‌کند. این امکان را به مدل می‌دهد که اطلاعات دقیق و مناسبی از مجموعه داده‌های آموزشی محدود را استخراج کند و با وجود نمونه آموزشی کم باعث بهبود دقت قابل توجه در تشخیص کلاس‌های پوششی زمینی گردد. بر این اساس، کلاس‌های آبی و جاده در LCM تولید شده توسط مدل MRU-Net به طور دقیق‌تری تشخیص داده شده‌اند (شکل ۷).

معیارهای ارزیابی کمی گزارش شده در جدول ۲ نشان می‌دهد مدل MRU-Net با مقدار دقت کلی ۹۵/۳۳٪ و ضریب کاپا ۹۲/۷۳٪ بهترین عملکرد را نسبت به سایر مدل‌های DL داشته‌است. به طوریکه ضریب کاپا LCM تولید شده توسط مدل MRU-Net به ترتیب نسبت به مدل‌های U-Net، ResU-Net و U-Net++ به مقدار ۱۲/۴۷٪، ۱۰/۸۲٪ و ۲/۷۳٪ افزایش یافته‌است. افزایش عملکرد MRU-Net به دو عامل اصلی در معماری مدل برمی‌گردد: استفاده از بلوک MultiRes که تنظیم تعداد فیلترها در هر بلوک را انجام می‌دهد و عملکرد مدل را بهبود می‌بخشد و همچنین، استفاده از مسیرهای Res به جای اتصالات کوتاه معمولی در معماری U-Net که کارایی مدل را بهبود می‌بخشد. این اصلاحات منجر به بهبود تشخیص و طبقه‌بندی پوشش زمینی و در نتیجه باعث افزایش ضریب کاپا و دقت کلی مدل می‌شود. به طور خاص، بلوک‌های MultiRes اجازه می‌دهند تا مدل به‌طور مؤثرتری ویژگی‌های مختلف در سطوح مختلف را استخراج کند و مسیرهای Res کمک می‌کنند تا مدل بتواند از اطلاعات بیشتری بهره‌برداری کند و از کاهش دقت ناشی از مشکلات

معماری جلوگیری کند. در مقابل، مدل U-Net به دلیل سادگی معماری و عدم داشتن مکانیزم قوی در استخراج ویژگی‌های پیچیده، با دقت کلی ۸۶/۹۶٪ و ضریب کاپا ۸۰/۲۶٪، بدترین عملکرد را در بین مدل‌های مورد بررسی نشان داده‌است.

جدول ۳: نتایج حاصل از الگوریتم‌های یادگیری عمیق

مدل	دقت کلی (%)	ضریب کاپا (%)
UNet	۸۶/۹۶	۸۰/۲۶
UNet++	۹۳/۶۲	۹۰/۰۰
MRUNet	۹۵/۳۳	۹۲/۷۳
ResUNet	۸۸/۴۹	۸۱/۹۱



شکل ۷: LCM‌های تولید شده با استفاده از مدل‌های DL


^۱ Omission

۳-۴- نتایج مربوط به مقایسه مدل‌های یادگیری ماشین و عمیق

نتایج دو بخش قبل نشان دادند که مدل RF18b به عنوان بهینه‌ترین مدل ML و مدل MRU-Net به عنوان بهینه‌ترین مدل DL، بهترین عملکرد کمی و کیفی را در تولید LCM از منطقه مورد آزمایش ارائه داده‌اند. با توجه به نتایج گزارش شده در جداول ۲ و ۳، مشخص شده‌است که مقدار دقت کلی و ضریب کاپا برای مدل MRU-Net به ترتیب ۰/۵۳٪ و ۰/۸۲٪، بیشتر از مدل RF13b و همچنین در مقایسه با مدل RF18b به مقدار ۰/۱۲٪ و ۰/۱۱٪ درصد بیشتر است. این نتیجه نشان می‌دهد که مدل MRU-Net، بدون نیاز به مهندسی ویژگی (استخراج ویژگی‌های بافتی) و با تمرکز بر استخراج خودکار و

چندسطحی ویژگی‌ها در ساختار خود، دارای عملکرد نسبتاً بهتری نسبت به مدل RF13b است و قادر به رقابت با نتایج مدل RF18b می‌باشد.

به طور خاص، جهت مقایسه عملکرد این مدل‌ها برای هر کلاس، از معیار F-score استفاده شده‌است که نتایج آن در قالب نمودار در شکل ۹ نشان داده شده‌است. طبق این نتایج، مشخص است که مدل MRU-Net برای دو کلاس پوششی شهری و بایر به ترتیب ۲/۹۹٪ و ۶/۴۳٪ نسبت به مدل RF13b و ۰/۴۳٪ و ۱/۱٪ نسبت به مدل RF18b، عملکرد بهتری داشته‌است. در حالی که معیار F-score برای سه کلاس آب، پوشش گیاهی و جاده‌ها در مدل RF13b به ترتیب به مقدار ۱۰/۴۵٪، ۳/۳۶٪، ۱۳٪ و در مدل RF18b به ترتیب به مقدار ۱۰/۳۳٪، ۴/۱۱٪ و ۲/۹۶٪ نسبت به مدل MRU-Net بیشتر است.




شکل ۸: نتایج بزرگنمایی شده مربوط به مدل‌های یادگیری ماشین و یادگیری عمیق

دلیل نتایج متفاوت برای کلاس‌های پوششی مختلف به تعداد نمونه‌های آموزشی موجود برای هر کلاس برمی‌گردد. الگوریتم‌های DL برای دستیابی به دقت مطلوب در تشخیص کلاس‌های پوششی مورد نظر، به مراتب به تعداد نمونه‌های آموزشی بیشتری نسبت به مدل‌های ML نیاز دارند. این نمونه‌های آموزشی باید نماینده‌ی مناسبی از تنوع و توزیع داده‌ها در کلاس مربوطه باشند تا الگوریتم بتواند الگوهای معناداری را درک کند. با توجه به این واقعیت، الگوریتم یادگیری عمیق MRU-Net با تعداد نمونه‌های آموزشی بیشتر در دو کلاس پوششی شهری و بایر (جدول ۴) نسبت به الگوریتم یادگیری ماشین RF میزان F-score کلاسی بهتری داشته‌است. این امر معمولاً به دلیل توانایی الگوریتم‌های DL در یادگیری و استفاده از ویژگی‌های

پیچیده‌تر و اطلاعات بیشتر از داده‌ها برمی‌گردد. با افزایش تعداد نمونه‌های آموزشی و متعادل سازی این نمونه‌ها برای هر کلاس می‌توان عملکرد الگوریتم‌های DL را بهبود بخشید و دقت و کارایی آن‌ها را در تشخیص کلاس‌های پوششی افزایش داد.

جدول ۴: تعداد پیکسل داده آموزشی برای هر کلاس

کلاس	تعداد پیکسل
آب	۱۸۷۷۵
مناطق شهری	۲۷۷۱۷۶
پوشش گیاهی	۲۳۵۳۰۵
اراضی بایر	۴۳۵۸۳۱
جاده‌ها	۲۳۴۵۴



شکل ۹: نتایج حاصل از معیار F_score برای هر کلاس

تقسیم‌بندی معنایی، شامل U-Net، U-Net++، ResU-Net و MRU-Net استفاده گردید. جهت آموزش و ارزیابی هر دو رویکرد، از تصاویر ماهواره‌ای رایگان سنتینل-۲ اخذ شده از منطقه مطالعاتی شهری غرب تهران استفاده شد. نتایج این مطالعه در سه بخش ML، DL و مقایسه بهترین‌های هر رویکرد مورد تجزیه و تحلیل قرار گرفت. در ادامه، نتایج مهم حاصل شده به تفکیک هر بخش ارائه شده است:

۱. نتایج بخش اول نشان داد که استفاده از ویژگی‌های بافت استخراج شده از تصاویر ماهواره‌ای و در نتیجه افزایش ابعاد فضای ویژگی، منجر به افزایش دقت کلی و ضریب کاپا در طبقه‌بندی یادگیری ماشین گردید. در میان الگوریتم‌های

۵- نتیجه‌گیری

هدف پژوهش حاضر طبقه‌بندی پوششی زمین مبتنی بر رویکردهای نوین ML و DL با استفاده از تصاویر ماهواره‌ای رایگان است. در رویکرد ML، دو مرحله اصلی شامل استخراج ویژگی‌های بافتی مستخرج از ماتریس GLCM و طبقه‌بندی با استفاده از الگوریتم‌های طبقه‌بندی کننده LR، DT، RF و SVM است. در این بخش، تأثیر ویژگی‌های بافتی استخراج شده در کنار باندهای اصلی تصویر در LCM تولید شده مورد ارزیابی قرار گرفت. در رویکرد DL، از شبکه‌های U-Net مبنا

مدل RF13b عملکرد قابل توجهی داشته و می‌تواند با نتایج مدل RF18b رقابت کند. اما لازم به ذکر است که برای کلاس‌های پوششی با تعداد نمونه‌های آموزشی محدود، مدل‌های RF نسبت به MRU-Net نتایج بهتری ارائه داده‌اند. به طور کلی، نتایج این مطالعه نشان می‌دهد که استفاده از تصاویر ماهواره‌ای رایگان با قدرت تفکیک مکانی پایین، به همراه استفاده از مدل‌های DL پهنه مانند MRU-Net، به عنوان یک رویکرد کارآمد برای تهیه LCM مناسب است. توصیه می‌شود جهت بهبود دقت و قابلیت پیش‌بینی نوع و وضعیت کلاس‌های پوششی زمین، از تصاویر با رزولوشن بهتر و تعداد نمونه‌های آموزشی بیشتر و متعادل‌تر برای هر کلاس پوششی استفاده شود.

آزمایش شده، مدل RF با ورودی ۱۸ باند (ترکیب باندهای اصلی و ویژگی‌های بافتی) دقیق‌ترین نقشه پوششی زمین را تولید کرد.

۲. در نتایج بخش دوم مشاهده گردید که مدل یادگیری عمیق MRU-Net، با تکیه بر بلوک‌های MultiRes و اتصالات باقی‌مانده، توانایی بیشتری در یادگیری خودکار ویژگی‌های پیچیده از تصاویر را دارد که توانست منجر به عملکرد بهتر و تولید LCM دقیق‌تری نسبت به مدل‌های دیگر شود.

۳. نتایج بخش سوم نشان می‌دهد که مدل MRU-Net، بدون بهره‌گیری از ویژگی‌های بافتی و با تأکید بر استخراج چند سطحی ویژگی‌ها در ساختار خود، نسبت به

مراجع

- [۱] H. Waghela, S. Patel, P. Sudesan, S. Raorane, and R. Borgalli, "Land Use Land Cover Classification using Machine Learning," in *2022 International Conference on Automation, Computing and Renewable Systems (ICACRS)*, Pudukkottai, India: IEEE, Dec. 2022, pp. 708–711. doi: 10.1109/ICACRS55517.2022.10029176.
- [۲] A. S. Mahdi, "The Land Use and Land Cover Classification on the Urban Area," *Iraqi J. Sci.*, pp. 4609–4619, Oct. 2022, doi: 10.24996/ijss.2022.63.10.42.
- [۳] V. T. Chavan and S. J. Wagh, "Efficient Land Cover Classification for Urban Planning," in *Object Detection by Stereo Vision Images*, 1st ed., R. Arokia Priya, A. V. Patil, M. Bhende, A. Thakare, and S. Wagh, Eds., Wiley, 2022, pp. 185–194. doi: 10.1002/9781119842286.ch11.
- [۴] H. Xie and H. Huang, "Classification of Land Cover Remote-Sensing Images Based on Pattern Recognition," *Sci. Program.*, vol. 2022, pp. 1–15, Sep. 2022, doi: 10.1155/2022/8319692.
- [۵] S. Nalla, M. Totakura, D. Pidikiti, and K. Pranathi, "Monitoring Urban Growth Using Land Use Land Cover Classification," in *Information and Communication Technology for Competitive Strategies (ICTCS 2022)*, vol. 615, M. S. Kaiser, J. Xie, and V. S. Rathore, Eds., in *Lecture Notes in Networks and Systems*, vol. 615, Singapore: Springer Nature Singapore, 2023, pp. 275–283. doi: 10.1007/978-981-19-9304-6_27.
- [۶] V. Nasiri, A. Deljouei, F. Moradi, S. M. M. Sadeghi, and S. A. Borz, "Land Use and Land Cover Mapping Using Sentinel-2, Landsat-8 Satellite Images, and Google Earth Engine: A Comparison of Two Composition Methods," *Remote Sens.*, vol. 14, no. 9, p. 1777, Apr. 2022, doi: 10.3390/rs14091777.
- [۷] X. Yang and Z. Liu, "Using satellite imagery and GIS for land-use and land-cover change mapping in an estuarine watershed," *Int. J. Remote Sens.*, vol. 26, no. 23, pp. 5275–5296, Dec. 2005, doi: 10.1080/01431160500219224.
- [۸] A. Kumari and S. Karthikeyan, "Sentinel-2 Data for Land Use/Land Cover Mapping: A Meta-analysis and Review," *SN Comput. Sci.*, vol. 4, no. 6, p. 815, Oct. 2023, doi: 10.1007/s42979-023-02214-0.
- [۹] C. F. Brown *et al.*, "Dynamic World, Near real-time global 10 m land use land cover mapping," *Sci. Data*, vol. 9, no. 1, p. 251, Jun. 2022, doi: 10.1038/s41597-022-01307-4.
- [۱۰] E. Khankeshizadeh *et al.*, "A Novel Weighted Ensemble Transferred U-Net Based Model (WETUM) for Postearthquake Building Damage Assessment From UAV Data: A Comparison of Deep Learning- and Machine Learning-Based Approaches," *IEEE Trans. Geosci. Remote Sens.*, vol. 62, pp. 1–17, 2024, doi: 10.1109/TGRS.2024.3354737.
- [۱۱] S. Cuypers, A. Nascetti, and M. Vergauwen, "Land Use and Land Cover Mapping with VHR and Multi-Temporal Sentinel-2 Imagery," *Remote Sens.*, vol. 15, no. 10, p. 2501, May 2023, doi: 10.3390/rs15102501.
- [۱۲] C. Lin and N. D. Doyog, "Challenges of Retrieving LULC Information in Rural-Forest Mosaic Landscapes Using Random Forest Technique," *Forests*, vol. 14, no. 4, p. 816, Apr. 2023, doi: 10.3390/f14040816.

- [۱۳] C. J. A. Kouassi *et al.*, "GOOGLE EARTH ENGINE FOR LANDSAT IMAGE PROCESSING AND ASSESSING LULC CLASSIFICATION IN SOUTHWESTERN CÔTE D'IVOIRE," *Geod. Cartogr.*, vol. 49, no. 1, pp. 37–50, Mar. 2023, doi: 10.3846/gac.2023.16805.
- [۱۴] D. A. Pantoja, D. Spenassato, and L. R. Emmendorfer, "Comparison Between Classification Algorithms: Gaussian Mixture Model - GMM and Random Forest - RF, for Landsat 8 Images," *Rev. Gest. Soc. E Ambient.*, vol. 16, no. 3, p. e03234, Mar. 2023, doi: 10.24857/rgsa.v16n3-015.
- [۱۵] R. Saini and S. Rawat, "Land Use Land Cover Classification in Remote Sensing Using Machine Learning Techniques," in *2023 1st International Conference on Innovations in High Speed Communication and Signal Processing (IHCSPP)*, BHOPAL, India: IEEE, Mar. 2023, pp. 99–104. doi: 10.1109/IHCSPP56702.2023.10127126.
- [۱۶] A. Jafari *et al.*, "Enhancing a convolutional neural network model for land subsidence susceptibility mapping using hybrid meta-heuristic algorithms," *Int. J. Coal Geol.*, vol. 277, p. 104350, Aug. 2023, doi: 10.1016/j.coal.2023.104350.
- [۱۷] G. Mountrakis and S. S. Heydari, "Harvesting the Landsat archive for land cover land use classification using deep neural networks: Comparison with traditional classifiers and multi-sensor benefits," *ISPRS J. Photogramm. Remote Sens.*, vol. 200, pp. 106–119, Jun. 2023, doi: 10.1016/j.isprsjprs.2023.05.005.
- [۱۸] S. Garg, S. Jain, N. Dube, and N. Varghese, Eds., "Leveraging twin networks for land use land cover classification," in *Earth Observation Data Analytics Using Machine and Deep Learning: Modern tools, applications and challenges*, Institution of Engineering and Technology, 2023, pp. 51–65. doi: 10.1049/PBPC056E_ch4.
- [۱۹] H. Dastour and Q. K. Hassan, "A Comparison of Deep Transfer Learning Methods for Land Use and Land Cover Classification," *Sustainability*, vol. 15, no. 10, p. 7854, May 2023, doi: 10.3390/su15107854.
- [۲۰] G. Cecili, P. De Fioravante, P. Dichicco, L. Congedo, M. Marchetti, and M. Munafò, "Land Cover Mapping with Convolutional Neural Networks Using Sentinel-2 Images: Case Study of Rome," *Land*, vol. 12, no. 4, p. 879, Apr. 2023, doi: 10.3390/land12040879.
- [۲۱] H. Fahmi and W. P. Sari, "Analysis of deep learning architecture for patch-based land cover classification," in *2022 6th International Conference on Information Technology, Information Systems and Electrical Engineering (ICITISEE)*, Yogyakarta, Indonesia: IEEE, Dec. 2022, pp. 1–5. doi: 10.1109/ICITISEE57756.2022.10057895.
- [۲۲] Microwave Remote Sensing and Global Data Processing, SDAPSA, National Remote Sensing Centre, Balanagar, Hyderabad, India-500037, D. S. Rao, A. V. V. Prasad, and T. Nair, "Application of Texture Characteristics for Urban Feature Extraction from Optical Satellite Images," *Int. J. Image Graph. Signal Process.*, vol. 7, no. 1, pp. 16–24, Dec. 2014, doi: 10.5815/ijigsp.2015.01.03.
- [۲۳] L. Rokach and O. Maimon, *Data mining with decision trees: theory and applications*, Second edition. Hackensack, New Jersey: World Scientific, 2015.
- [۲۴] A. Zaidi and A. S. M. Al Luhayb, "Two Statistical Approaches to Justify the Use of the Logistic Function in Binary Logistic Regression," *Math. Probl. Eng.*, vol. 2023, pp. 1–11, Apr. 2023, doi: 10.1155/2023/5525675.
- [۲۵] Md. S. Chowdhury, "Comparison of accuracy and reliability of random forest, support vector machine, artificial neural network and maximum likelihood method in land use/cover classification of urban setting," *Environ. Chall.*, vol. 14, p. 100800, Jan. 2024, doi: 10.1016/j.envc.2023.100800.
- [۲۶] P. Ahmadi, T. Managhebi, H. Ebadi, and B. Asghari, "Improving the Classification of Hyperspectral Images Using the Combined Model of CapsNet and the Extreme Gradient Boosting," *Iran. J. Remote Sens. GIS*, vol. 15, no. 3, pp. 41–60, Aug. 2023, doi: 10.48308/gisj.2023.102347.
- [۲۷] E. Khankeshizadeh, A. Mohammadzadeh, A. Moghimi, and A. Mohsenifar, "FCD-R2U-net: Forest change detection in bi-temporal satellite images using the recurrent residual-based U-net," *Earth Sci. Inform.*, vol. 15, Nov. 2022, doi: 10.1007/s12145-022-00885-6.
- [۲۸] Z. Zhou, M. M. Rahman Siddiquee, N. Tajbakhsh, and J. Liang, *UNet++: A Nested U-Net Architecture for Medical Image Segmentation*. 2018.
- [۲۹] "ResUNet-a: A deep learning framework for semantic segmentation of remotely sensed data," *ISPRS J. Photogramm. Remote Sens.*, vol. 162, pp. 94–114, Apr. 2020, doi: 10.1016/j.isprsjprs.2020.01.013.
- [۳۰] N. Ibtehaz and M. S. Rahman, "MultiResUNet: Rethinking the U-Net architecture for multimodal biomedical image segmentation," *Neural Netw.*, vol. 121, pp. 74–87, Jan. 2020, doi: 10.1016/j.neunet.2019.08.025.