

ارائه یک روش کارآمد با استفاده از ادغام ویژگی‌های شبکه عصبی کانولوشنی عمیق برای تشخیص ابر به کمک باندهای بازتابی از تصاویر ماهواره‌ای لندست-۸

ارسطو زارعی^۱، رضا شاه حسینی^{۲*}، سید مرتضی سیدموسوی^۳

۱- کارشناسی ارشد، دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، دانشکده فنی، دانشگاه تهران

۲- استادیار دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، دانشکده فنی، دانشگاه تهران

۳- دانشجوی کارشناسی ارشد، دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، دانشکده فنی، دانشگاه تهران

تاریخ دریافت مقاله: ۱۴۰۰/۰۴/۳۰ تاریخ پذیرش مقاله: ۱۴۰۱/۰۹/۰۱

چکیده

شناسایی ابر در کاربردهای مختلف تصاویر ماهواره‌ای چندطیفی مرحله‌ای مهم در پیش پردازش می‌باشد، به طور خاص در برنامه‌های مرتبط با بلایای طبیعی مانند نظارت بر سیل یا نقشه برداری سریع خسارت که در بحث زمان و داده‌ها دارای اولویت هستند و نیاز به روش‌هایی دارند که ماسک ابری دقیق را در مدت زمان کوتاه به طور آتی تولید کنند. در این مطالعه، یک شبکه عصبی پیچیده عمیق برای تشخیص ابر در مجموعه داده‌های لندست-۸ در سطح پیکسل ارائه شد. شبکه پیشنهادی در این مطالعه دو ویژگی اصلی داشت: (۱) چندین هسته پیچشی با اندازه‌های چندگانه، و (۲) لایه‌های کانولوشنی مستقیم در شاخه رمزگشا. باند مادون قرمز نزدیک در این مطالعه به ورودی‌های شبکه شامل باندهای قرمز، سبز و آبی اضافه شد تا عملکرد شبکه را بهبود ببخشد. در معماری شبکه پیشنهادی، شاخه‌های رمزگذار-رمزگشای متقارن با تراکم نقشه‌های ویژگی حاصل از تعدد فیلترها و طراحی فیلترهای با ابعاد مختلف، زمینه محلی و کلی را جهت شناسایی دقیق ابر و حاشیه‌های آن فراهم کردند که برای استخراج ویژگی‌های مکانی در مقیاس‌های سطح بالا استفاده می‌شوند. نقشه‌های ویژگی حاصل از مقیاس‌های متعدد، نمونه‌برداری و تلفیق شده و جهت بازایی خروجی با دقت‌های بالا به کار گرفته می‌شوند. در نهایت روش پیشنهادی با استفاده از ۳۵۰۰ قطعه از تصاویر ماهواره لندست-۸ با چالش‌های متنوع ابر با به کارگیری از چندین هسته در اندازه‌های 3×3 و 5×5 با نمره $F1$ برابر ۹۶٫۶ و شاخص ژاکارد ۹۳٫۵ نسبت به روش‌های دیگر دقت بالاتری را ارائه داد. به طور کلی در روش پیشنهادی نسبت به روش‌های مقایسه شده در مجموعه داده یکسان اما تصحیح نشده، به ویژه در مناطق پوشیده از سطح روشن، نتایج بهتری را به دست آورد.

کلید واژه‌ها: سنجش از دور، لندست-۸، شبکه عصبی کانولوشنی، شناسایی ابر.

* نویسنده مکاتبه کننده: گروه فتوگرامتری و سنجش از دور، دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، پردیس دانشکده‌های فنی، دانشگاه تهران، تهران، ایران.

تلفن: ۰۲۱۶۱۱۱۴۵۲۷

Email: rshahosseini@ut.ac.ir

۱- مقدمه

وجود ابر مانع از قرارگیری عوارض سطح زمین در میدان دید ماهواره می‌شود. این امر پردازش‌های بعدی سنجش از دور مانند شناسایی تغییرات، طبقه‌بندی پوشش سطح زمین و به دست آوردن دمای سطح زمین را با مشکل مواجه می‌کند که منجر به کاهش دقت اطلاعات به دست آمده و نقشه‌های تولید شده در شرایطی که تصویر بدون ابر از منطقه مورد مطالعه در دسترس نیست؛ می‌شود [۱، ۲، ۳ و ۴]. بنابراین ماسک ابر از پیش‌پردازش‌های مهم و ضروری در سنجش از دور می‌باشد. در شرایطی که تاریخ تصویربرداری یک پارامتر مهم باشد، جایگزینی تصویر ابری با تصویر بدون ابر امکانپذیر نمی‌باشد. همچنین شناسایی پیکسل‌های ابری و تعیین درصد پوشش ابر تصویر می‌تواند به عنوان معیاری برای موفق بودن تصویربرداری در نظر گرفته شود [۵، ۶ و ۷]. تشخیص ابر در تصاویر ماهواره‌ای نوری از اهمیت بالایی برخوردار است. در سال‌های اخیر، تحقیقات زیادی در زمینه شناسایی ابر بر روی انواع مختلف تصاویر ماهواره‌ای از جمله لندست^۱، تصاویر طیف‌سنج با وضوح متوسط^۲، سنتینل^۳ و طیف سنج تصویربرداری با وضوح متوسط^۴ از اطلاعات باندها طیفی مادون قرمز حرارتی و با قدرت تفکیک مکانی پایین، استفاده کرده‌اند [۸، ۹، ۱۰ و ۱۱].

ابرها در تصاویر لندست را می‌توان با استفاده از آزمون‌های طیفی، تمایز زمانی و روش‌های آماری تشخیص داد. آزمایش‌های طیفی برای ابرها بر اساس مشاهده تابش (برای باندهای حرارتی)، بازتاب (برای باندهای بازتابنده) یا سایر مقادیر مشتق شده، به عنوان مثال شاخص پوشش گیاهی اختلاف نرمال شده^۵ در بخش‌هایی محدود قرار دارند. بنابراین یک یا دو حدآستانه

برای هر باند اصلی یا مشتق شده مورد استفاده قرار می‌گیرد که اگر مقادیر در محدوده مورد انتظار باشند، مورد آزمایش قرار گیرند. نتایج برای باندهای مختلف به طور معمول با استفاده از توابعی مانند درخت تصمیم ادغام می‌شوند. به این ترتیب میتوان ابرها را از پیکسل‌های واضح تشخیص داد [۱۲، ۱۳ و ۱۴]. تمایز زمانی بر این واقعیت استوار است که ابرها پویا هستند. با توجه به اینکه ابرها در حال حرکت هستند، اغلب تفاوت‌های قابل توجهی بین تصاویر گرفته شده در تاریخ‌های مختلف وجود دارد. با مقایسه تصاویر چندزمانی، پیکسل‌های با اختلاف زیاد ابر شناخته می‌شوند [۱۵ و ۱۶]. در روش‌های آماری از ویژگی‌های مکانی و طیفی ابرها برای برآورد پوشش ابر و تشخیص ابرها استفاده می‌شود [۱۷ و ۱۸]. معمولاً، تشخیص پیکسل به عنوان یک مسئله طبقه‌بندی در نظر گرفته می‌شود و با استفاده از مدل‌های طبقه‌بندی مانند ماشین بردار پشتیبان^۶ (SVM)، شبکه‌های عصبی^۷ (NN) و شبکه‌های عصبی کانولوشنی^۸ (CNN) حل می‌شود. وظیفه طبقه‌بندی جهت شناسایی ابر باید در سطح پیکسل انجام شود نه در سطح شیء زیرا اختصاص برجسب بر اساس محتوای شیء، اطلاعات کافی را فراهم نمی‌کند [۱۹، ۲۰، ۲۱ و ۲۲].

تابع ماسک^۹ (FMask) و الگوریتم‌های ارزیابی خودکار پوشش ابری^{۱۰} (ACCA) از مشهورترین الگوریتم‌های مبتنی بر حدآستانه برای شناسایی ابر هستند. در این روش‌ها، از درخت تصمیم برای برجسب‌گذاری هر پیکسل به عنوان ابر یا غیر ابر استفاده می‌شود. در هر شاخه درخت، تصمیم بر اساس نتیجه یک عملکرد آستانه‌ای استفاده می‌شود که از یک یا چند باند طیفی

⁶ Support Vector Machine⁷ Neural Networks⁸ Convolutional Neural Network⁹ Function of Mask¹⁰ Automated Cloud-Cover Assessment¹ Landsat² Moderate Resolution Imaging Spectroradiometer³ Sentinel⁴ Medium Resolution Imaging Spectrometer⁵ Normalized Difference Vegetation Index

تواند ویژگی‌های محلی موجود در یک قسمت کوچک را استخراج کند. در مقابل، یک شبکه کانولوشن عمیق می‌تواند ویژگی‌های کلی موجود در یک قسمت بزرگ از تصویر ورودی را استخراج کند؛ زیرا این بخش بزرگ قبل از اینکه نمایش نهایی آن توسط لایه نهایی تولید شود، توسط بسیاری از لایه‌ها متصل می‌شود. علاوه بر این، ویژگی‌های مختلف در چندین سطح نیز به عنوان نقشه ویژگی‌های متوسط ارائه می‌شوند. این بدان معنی است که شبکه‌های کانولوشنی عمیق می‌توانند ویژگی‌ها را در چندین سطوح مختلف استخراج کنند. شبکه عصبی کانولوشن عمیق با موفقیت در انواع مشکلات بینایی ماشین، از جمله تشخیص جسم و تقسیم تصویر برای برچسب گذاری چند مورد مربوط به تشخیص ابر استفاده شده است. دلیل موفقیت شبکه‌های کانولوشنی عمیق، توانایی آنها در یادگیری و بهره‌برداری از چنین ویژگی‌های چند سطحی در داده‌ها است [۳۴ و ۳۵]. با بهره‌گیری استفاده از ویژگی‌های کانولوشن عمیق، روش‌های مبتنی بر یادگیری عمیق در انجام وظایف طبقه‌بندی تصویر به دقت بالایی دست یافته‌اند و با پیشرفت تکنیک‌های جدید به طور مداوم از صحت و دقت، اطمینان حاصل می‌شود [۳۶]. در مطالعات اخیر، شبکه‌های عصبی کانولوشنی به ابزار جدیدی برای تشخیص ابر در جامعه سنجش از دور تبدیل شده‌اند. در مطالعه‌ای متئو و همکاران (۲۰۱۷)، یک معماری شبکه عصبی کانولوشن ساده برای پوشش ابر تصاویر چند طیفی طراحی کردند. نتایج حاکی از آن است که شبکه عصبی کانولوشن در مقایسه با رویکرد یادگیری ماشین کلاسیک نوید حل مشکلات پوشش‌های ابری را دارند [۳۷]. همچنین توسط ژو و همکاران (۲۰۱۷) راهکاری ارائه شده است که در آن تصاویر ابتدا تقسیم بندی می‌شوند و سپس ابرهای موجود در بخش‌های مختلف توسط شبکه عصبی کانولوشن آموزش دیده برچسب گذاری می‌شوند. نتایج نشان می‌دهد که روش پیشنهادی می‌تواند ابر را با دقت و ثبات بالاتر از روش‌های مقایسه شده تشخیص دهد [۳۸].

استفاده می‌کند. تبدیل بهینه شده مه^۱ (*HOT*) از جمله گروه‌های روش دستی است که با استفاده از رابطه بین پاسخ‌های طیفی باندهای قرمز و آبی، ابرها و ابرهای ضخیم را از سایر پیکسل‌ها جدا می‌کند [۶ و ۲۴]. روش‌های مبتنی بر یادگیری عمیق از روش‌های حدآستانه برتر هستند؛ زیرا نتایج بهتری را ارائه داده‌اند. با این حال، بیشتر این روش‌ها هنوز نمی‌توانند ماسک‌های ابر قوی و دقیق را در تصاویری که مناطق غیر ابر در کنار ابرها وجود دارد، فراهم کنند [۲۵].

یادگیری ماشین در زمینه‌های مختلف سنجش از دور کاربردهای زیادی در سال‌های اخیر داشته است، به عنوان زیرمجموعه یادگیری ماشین، یادگیری عمیق پیشرفت‌های بزرگی را ایجاد کرده است و اکنون در زمینه سنجش از دور در حال پیشرفت است که اخیراً شناسایی ابر در تصاویر سنجش از دور با استفاده از این روش‌ها انجام شده است [۲۶، ۲۷، ۲۸، ۲۹، ۳۰ و ۳۱]. شبکه‌های عصبی کانولوشن شامل لایه‌هایی متشکل از گره‌هایی است که در سه بعد متناسب با ردیف‌ها، ستون‌ها و کانال‌های یک تصویر رنگ واقعی^۲ یا رنگ کاذب^۳ مرتب شده‌اند [۳۲]. شبکه‌های عصبی کانولوشن کانولوشن نمایش تصویر چند کاناله را تسهیل می‌کنند، زیرا هر پیکسل را می‌توان با یک گره نشان داد و هر تصویر ورودی یا نقشه ویژگی را می‌توان با یک لایه نشان داد. یک تصویر مستقیماً به شبکه کانولوشن وارد می‌شود و براساس یک سری پیچیدگی‌های تصویر لایه به لایه ارسال می‌شود. به این ترتیب، زمینه تصویر در میان پیکسل‌های همسایه توسط پیچیدگی‌ها ثبت می‌شود [۳۳]. با بهره‌گیری از قدرت محاسباتی بهبود یافته *GPU*، شبکه‌های عصبی کانولوشن عمیق با لایه‌های مختلف توسط محققان بینایی ماشین در سال‌های اخیر ایجاد شده‌اند. یک شبکه کانولوشن کم‌عمق می-

^۱ Haze Optimized Transformation^۲ Red, Green, Blue (RGB)^۳ Red, Green, Blue, Near infrared (RGBN)

عنوان یک مجموعه داده مرجع استفاده کردیم^۱، که نقشه واقعیت در آن به صورت خودکار و دستی برای افزایش دقت ایجاد شده‌اند [۳۹ و ۴۰]. این مجموعه داده شامل تصاویری از ماهواره لندست-۸ است که از سنسور تصویرگر عملیاتی زمین^۲ (OLI) جمع آوری شده است. این مجموعه داده از تصاویر ماهواره‌ای با ابعاد بزرگ بین ۸۰۰۰ تا ۱۰۰۰۰ پیکسل مربع استفاده می‌کند که برای ایجاد قطعه‌هایی قابل استفاده برای طبقه‌بندی معنایی تصویر مفید هستند. قابل ذکر است که مجموعه‌های آموزشی و آزمایشی ارائه شده شامل طیف گسترده‌ای از ویژگی‌های جغرافیایی است که نمایانگر مناطق مختلف است (شکل (۱)).

در این تحقیق با توجه به اینکه بسیاری از قسمت‌های حاشیه تصویر بدون ابر هستند و اطلاعات با شباهت زیادی در آن‌ها وجود داشت، سعی گردید که برای آموزش و تست مدل، قطعه‌هایی انتخاب شود که شامل چالش‌های متنوع و به دور از افزونگی اطلاعات مشابه باشند. در این تحقیق با رویکرد مورد نظر ۳۵۰۰ قطعه تصویر با ابعاد ۳۸۴×۳۸۴ در چهار باند قرمز، سبز، آبی و مادون قرمز نزدیک (RGBN) همراه با یک لایه مربوط به نقشه واقعیت جهت فرآیند آموزش مدل در نظر گرفته شده است، که ۱۰٪ آن برای بحث اعتبارسنجی هنگام آموزش شبکه به کار برده شده است. همچنین برای آزمایش مدل آموزش داده شده ۱۵ قطعه تصویر که دارای چالش هستند مشابه با مجموعه داده‌های آموزشی جهت ارزیابی عملکرد روش پیشنهادی بعنوان نمونه‌های آزمایشی استفاده شدند.


اگرچه روش‌های قبلی شناسایی ابر مبتنی بر یادگیری عمیق می‌توانند دقت نسبتاً بالایی را کسب کنند، اما مناطق مطالعاتی در تحقیقات پیشین، اغلب شامل مناطقی با سطح همگن می‌باشند. بنابراین توجه به شناسایی ابرها در مناطق مختلف (شامل کوه‌های پوشیده از برف، مناطق با زمینه روشن که از لحاظ طیفی مشابه با ابر هستند) در تصاویر ماهواره‌ای لندست-۸، موضوع قابل توجهی است. این تحقیق، یک شبکه رمزگذار-رمزگشای عمیق که نسخه اصلاح شده شبکه U-Net استاندارد است را برای محلی سازی سطح پیکسل ابر در تصاویر لندست-۸ پیشنهاد کرد. در این معماری ایده اصلی ما نسبت به شبکه‌های قبلی شامل به کارگیری هسته‌های پیچشی با اندازه‌های مختلف بطور آبی و استفاده از لایه‌های کانولوشنی مستقیم در شاخه رمزگشا برای حل چالش‌های مرتبط با تغییر اندازه و شکل ابر است. اهداف اصلی در این مطالعه عبارت است از: (۱) استخراج ابرها از تصاویر ماهواره‌ای لندست-۸ که از مناطق جهانی در انواع مختلف پوشش زمین جمع آوری شده است، (۲) استفاده از شبکه عصبی کانولوشنی چند مقیاس به صورت رمزگذار و رمزگشا، به طوری که در شاخه رمزگشا علاوه بر لایه‌های ترانزفاده کانولوشن از لایه‌های مستقیم کانولوشنی نیز به منظور بازسازی بهتر خروجی از تجمیع ویژگی‌های استخراج شده از لایه رمزگذار و رمزگشا استفاده شده است، (۳) بررسی کارایی مدل ارائه شده در صورت ادغام باندهای مرئی با مادون قرمز نزدیک و مقایسه آن با تحقیقاتی که اخیراً انجام شده است.

۲- داده و مناطق مطالعاتی

برای شناسایی ابر، ما از مجموعه داده Cloud-38 معرفی شده در تحقیق مهاجرانی و همکاران (۲۰۱۹) و تجدید نظر در مطالعه مهاجرانی و همکاران (۲۰۱۸) به

^۱ <https://github.com/SorourMo/38-Cloud-A-Cloud-Segmentation-Dataset>

^۲ Operational Land Imager



شکل ۱: نقشه توزیع تصاویر انتخاب شده از مجموعه داده 38-Cloud ماهواره لندست-۸

۳- روش پیشنهادی

همانطور که در شکل (۲) نشان داده شده است، معماری روش پیشنهادی یک شبکه، کاملاً کانولوشن است که در آن خروجی، یک نقشه پیکسل به پیکسل با همان عرض و طول تصویر ورودی است. شبکه کاملاً کانولوشن^۱ (FCN) برای کارهای طبقه‌بندی تصویر به صورت پیکسل به پیکسل استفاده می‌شود که در آن لایه کاملاً متصل شده، که هر نورون در یک لایه را به هر نورون در لایه دیگر متصل می‌کند، با یک لایه کانولوشن جایگزین می‌شود تا شبکه بتواند به جای تولید برچسب کلاس برای کل تصویر، هر پیکسل را در تصویر طبقه‌بندی کند [41]. شبکه پیشنهاد شده با معماری‌های قبلی تشخیص ابر متفاوت است، که از لایه‌های کاملاً متصل برای تولید یک برچسب کلاس برای کل قطعه تصویر استفاده می‌کنند [۳۷، ۳۸]. به طور کلی مهمترین خصوصیات شبکه ارائه شده شامل موارد فوق می‌باشد:

(۱) ما از یک روش رمزگذار-رمزگشا متقارن که در شاخه رمزگشا علاوه بر لایه‌های معکوس کانولوشن از

لایه‌های مستقیم کانولوشنی نیز به منظور استخراج ویژگی‌های با سطح بالا استفاده می‌کنیم که قادر به ضبط تمام ویژگی‌های ابر ریز و درشت و پیکسل‌های همسایه آنها باشد.


(۲) همچنین، در معماری مورد نظر از ادغام ویژگی کانولوشن با ابعاد مختلف فیلترها طراحی و استفاده شده است تا از ویژگی‌های کانولوشن مقیاس‌های مختلف استفاده کامل کند و دقت تشخیص ابر را بیشتر بهبود بخشد.

(۳) در نظر گرفتن طیف گسترده‌ای از ویژگی‌های جغرافیایی جهانی برای ارزیابی قابلیت تعمیم‌پذیری الگوریتم پیشنهادی.

۳-۱- مفاهیم اولیه در شبکه‌های کانولوشنی

طراحی یک شبکه عصبی کانولوشنی شامل طراحی فیلتر، انتخاب تابع فعالیت مناسب، لایه‌های جمع‌کننده یا کاهش ابعاد و نحوه آموزش و اصلاح وزن‌های شبکه عصبی کانولوشنی می‌باشد که مفاهیم پایه را در زیربخش‌هایی که در ادامه آورده شده توضیح خواهیم داد.

^۱ Fully Convolutional Network



شکل ۲: معماری روش پیشنهادی برای شناسایی ابر در تصاویر ماهواره لندست-۸

نیاز به حدس زدن مقادیر مناسب حد ثابت را نیز از بین می برد [۴۵].

۳-۱-۲- انتخاب تابع فعالیت^۴ و نرمال سازی دسته‌ای^۵

تابع فعالیت، یک نگاشت ساده از ورودی وزن دار جمع شده به خروجی نرون است. در واقع ورودی‌های وزن دار جمع شده و از طریق یک تابع فعالیت، که بعضاً تابع انتقال نامیده می‌شود، منتقل می‌شوند. این یک تابع فعال سازی نیز نامیده می‌شود زیرا بر آستانه فعال شدن نرون و قدرت سیگنال خروجی حاکم است [۴۶]. در این تحقیق باتوجه به روند محاسباتی سریع و نرمال کردن خروجی هر لایه بین صفر و مثبت بینهایت از تابع فعالیت واحد خطی اصلاح شده $ReLU$ استفاده شده است که اثرات نویز بر روی گرادیان در این تابع بسیار کم است [۴۷ و ۴۸].

هدف از لایه نرمال سازی دسته‌ای نرم کردن ورودی‌ها به تابع فعالیت است. در صورت نرمال سازی ورودی‌ها مفید خواهند بود زیرا عملکردهای تابع فعالیت را به نحوی حفظ می‌کند که ثابت نیستند. در این حالت، مشتق تابع فعالیت با توجه به ورودی آن‌ها غیر صفر است. اگر این مشتقات صفر باشند، وزن لایه‌های قبل از لایه تابع فعالیت دیگر به روز نمی‌شوند. از این رو، شبکه هنگام استفاده از نرمال سازی دسته‌ای سریعتر یاد می‌گیرد. با توجه به محاسبه گروهی از نمونه‌های متریک مانند میانگین و انحراف معیار از داده‌های ورودی این تکنیک انجام می‌شود [۴۹].

۳-۱-۳- کدگذاری از طریق کاهش ابعاد

کاهش ابعاد^۶ یک تکنیک برای کوچک سازی نمونه است که باعث کاهش میزان اطلاعات منتقل شده از شبکه می‌شود. کاهش ابعاد انواع مختلفی دارد که رویه بیشینه متداول ترین رویکرد آن است. رویکرد بیشینه

۳-۱-۱- ابعاد فیلتر و نحوه مقدار دهی اولیه

برای استخراج ویژگی از تصاویر فیلترها و آشکارسازهای ویژگی بر روی تصاویر ورودی اعمال می‌شوند. فیلترها با توجه به پارامترهای وزن موجود در آنها به شناسایی ویژگی‌های مختلف در تصویر مانند لبه‌ها، خطوط عمودی، خطوط افقی و خم‌ها کمک می‌کنند [۴۲]. عمق فیلتر در شبکه عصبی کانولوشن باید با عمق تصویر ورودی مطابقت داشته باشد. تعداد کانال‌های رنگی در فیلتر باید همانند تصویر ورودی باقی بماند [۴۳].

قبل از آموزش شبکه، باید مقادیر وزن‌ها، مقداردهی اولیه شوند. بایاس بصورت یک عدد ثابت یک در نظر گرفته می‌شود و بنابراین مقداردهی اولیه مسئله‌ای برای بایاس نیست. شبکه‌های عصبی به طور قابل توجهی به مقادیر اولیه وزن حساس هستند و بنابراین مقدار دهی اولیه وزن مهم است. مقدار دهی اولیه وزن‌ها در شبکه‌های عصبی کانولوشنی برای مقابله با محو شدگی گرادیان^۱ و انفجار گرادیان^۲ صورت می‌گیرد. مشکل محو شدگی گرادیان اغلب در شبکه‌هایی که مقادیر وزن‌ها کوچک باشد اتفاق می‌افتد و مشکل انفجار گرادیان زمانی اتفاق می‌افتد که مقادیر وزن‌ها بزرگ انتخاب شود [۴۴].

الگوریتم مقداردهی اولیه گلورت^۳ از روش‌های شناخته شده در بحث شبکه‌های عصبی کانولوشنی است. در حقیقت دو نسخه از مقداردهی اولیه گلورت وجود دارد: گلورت یکنواخت (مورد استفاده در این تحقیق) و گلورت نرمال. هر دو نسخه کاملاً شبیه به یکدیگر هستند؛ با این تفاوت که در روش دوم مقادیر تصادفی به جای توزیع یکنواخت از توزیع نرمال طبیعت می‌کنند. تکنیک مقداردهی اولیه *Glorot* نه تنها بهتر از مقداردهی اولیه تصادفی یکنواخت عمل می‌کند بلکه

^۴ Activation Function

^۵ Batch-Normalization

^۶ Rectified Linear Units

^۷ Pooling


^۱ Vanishing Gradient

^۲ Exploding Gradient

^۳ Glorot

حداکثر با اندازه 2×2 به عنوان مثال ۷۵٪ از اطلاعات ورودی را دور می اندازد، که باعث کاهش تعداد پارامترهای لایه های بعدی می شود. این امر باعث می شود که احتمال موجه شدن با بیش برآزش کاهش و سرعت محاسبات افزایش یابد [۵۰].

یک آرایه را به عنوان ورودی می گیرد و هر بلوک از مقادیر پیکسل ها را با مقادیر حداکثر جایگزین می کند در مقابل رویکرد میانگین، میانگین مقادیر را برای هر بلوک در نظر می گیرد (شکل (۳)). کاهش ابعاد روی هر لایه عمق به طور مستقل عمل می کند، بنابراین فقط ابعاد جانبی تغییر می کند. رویکرد



شکل ۳: فرآیند کاهش ابعاد با رویکرد بیشینه و مقایسه آن با رویه میانگین [۵۱].


آزمایش دقت های بالایی را ارائه خواهد داد و از بحث بیش برآزش جلوگیری می کند [۵۳ و ۵۲]. حال یک شبکه عصبی را با تعداد لایه های مخفی L به طوریکه $L \in 1, \dots, L$ در نظر می گیریم. همچنین z^l را بعنوان بردار ورودی و y^l را بعنوان خروجی لایه مخفی l تعریف می کنیم. W^l و b^l به ترتیب پارامترهای وزن و بایاس برای لایه l هستند. حال برای لایه مخفی i که $i \in 0, \dots, L-1$ برای بلوک معمولی بدون حذف تصادفی عمق از رابطه (۱) و جهت حذف تصادفی عمق از رابطه (۲) استفاده می شود [۵۲]. در روابط (۱) و (۲)، f تابع فعالیت و r^l برداری از متغیرهای تصادفی مستقل برنولی برای یک لایه است که هر کدام از نورون ها با احتمال p در شبکه حفظ و با احتمال $p-1$ از شبکه حذف می شوند (شکل (۴)).

۳-۱-۴- روش حذف تصادفی جهت جلوگیری از بیش برآزش

در شبکه های عصبی بزرگ که روی مجموعه ای از داده ها آموزش دیده اند، می توانند با ایجاد تعداد زیادی از نقشه های ویژگی که حاصل از فیلترهای مختلف است، بر روی داده های آموزشی به خوبی و با دقت بالا مدل شوند. این تأثیر یادگیری مدل در مورد نویزهای آماری داده های آموزشی مشکل ساز می باشد، که در نتیجه آن ارزیابی عملکرد مدل برای مجموعه داده آزمایشی ضعیف است. در واقع خطای کلی به دلیل بیش برآزش افزایش می یابد. یک روش برای کاهش بیش برآزش، متناسب کردن همه شبکه های عصبی مختلف ممکن در یک مجموعه داده و متوسط سازی پیش بینی ها از هر مدل است. این در عمل امکان پذیر نیست و می توان با استفاده از مجموعه کوچکی از مدل های مختلف که یادگیری گروهی نامیده می شود، مدل تقریبی را ارائه داد که نتایج ارزیابی هم در روند آموزش و هم در روند

$$z_i^{l+1} = W_i^{l+1} y^l + b_i^{l+1}, y_i^{l+1} = f(z_i^{l+1}) \quad \text{رابطه (۱)}$$

$$\tilde{y}^l = r^l * y^l, z_i^{l+1} = W_i^{l+1} \tilde{y}^l + b_i^{l+1}, y_i^{l+1} = f(z_i^{l+1}) \quad \text{رابطه (۲)}$$



شکل ۴: (الف) شبکه با حذفی تصادفی عمق، (ب) شبکه استاندارد [۵۳].

گسسته (۰ یا ۱) هستند و مانند رگرسیون پیوسته نیستند [۳۳].

داده‌های مورد استفاده در سنجش از دور اغلب دارای خطا می‌باشند (وجود نویز در تصویر)، بنابراین طراحی یک تابع هزینه مناسب، اجتناب‌ناپذیر است. در زمینه قطعه‌بندی تصویر با به کارگیری روش‌های یادگیری عمیق، افزایش خاصیت یکنوایی تابع خطا، موجب بهبود عملکرد شبکه در فرآیند به روزرسانی و خروجی نهایی می‌شود. فرآیند به روزرسانی اغلب بر مبنای گرادیان صورت می‌گیرد، به همین منظور در صورتی که تابع هزینه خاصیت یکنوایی بیشتری داشته باشد، روند مشتق‌گیری به منظور رسیدن به یک آموزش بهینه یعنی همگرایی مطلوب مقادیر خطا آسان می‌گردد [۵۳].

با توجه به مسئله تحقیق که طبقه‌بندی باینری است ما باید مشاهدات خود را در هر دو برچسب براساس

۳-۱-۵- تابع هزینه آنتروپی متقاطع باینری^۱

تابع هزینه، اندازه‌گیری خطای یک پیش‌بینی با توجه به داده واقعیت زمین است. انتخاب عملکرد تابع هزینه برای رسیدن به دقت‌های بالا در آموزش شبکه بسیار مهم است و به نحوه حل آن نیز بستگی دارد. با این حال، فقط یک خطای احتمالی در هر کاربرد وجود ندارد و تابع خطایی که استفاده می‌شود باید براساس تجربه و براساس ویژگی‌ها به کار گرفته شود. اگر به عنوان مثال از شبکه عصبی برای تقریب یک تابع استفاده می‌شود که اساساً یک رگرسیون است، میانگین خطای مربع^۲ (MSE) انتخاب مناسبی است. وقتی صحبت از طبقه‌بندی می‌شود، سایر توابع خطا بهتر هستند زیرا متغیرهای وابسته در کارهای طبقه‌بندی

¹ Binary Cross Entropy

² Mean Squared Error

۳-۲-۱- ادغام ویژگی‌های حاصل از فیلترهای با ابعاد مختلف

ایده استفاده از ویژگی‌های استخراج شده در مقیاس‌های مختلف حاصل از فیلترهای با ابعاد مختلف برای تهیه خصوصیات محلی و کلی است که در نقشه ویژگی‌های رمزگذاری اولیه جزئیات مکانی بیشتری را حفظ می‌کند که منجر به مرزهای تصحیح شده‌تر می‌شود [۳۵]. رمزگذار ویژگی‌های مکانی با ابعاد پایین‌تر را به صورت چند مقیاس توسط لایه‌های کانولوشن از تصویر ورودی استخراج می‌کند که در آن از لایه‌های کاهش ابعاد برای نمونه‌برداری از نقشه‌های ویژگی استفاده می‌کند. شاخه رمزگشا نقشه‌های ویژگی‌ها را توسط لایه‌های معکوس کانولوشن که در آن نیز از لایه‌های کانولوشن برای استخراج ویژگی‌های معنایی سطح بالا استفاده می‌شود، نمونه برداری و بازسازی می‌کند. نقشه‌های ویژگی در اندازه‌های برابر در لایه‌های رمزگذار و لایه‌های رمزگشا مربوطه توسط اتصالات تجمیع^۱ به هم متصل می‌شوند و براساس آن ویژگی‌هایی خلاصه‌تر و با تمایز بالا تولید می‌شوند. توجه داشته باشید که اتصالات تجمیع، اتصالات اضافی بین گره‌ها در لایه‌های مختلف شبکه عصبی است که از یک یا چند لایه عبور می‌کند. چنین ارتباطاتی می‌تواند به حفظ جزئیات مکانی بیشتر در نقشه‌های ویژگی بازسازی شده حاصل از رمزگشا کمک کند و همچنین آموزش شبکه‌های بسیار عمیق را امکان پذیر می‌کند.

۳-۲-۲- لایه‌های کانولوشنی

یک لایه کانولوشن بیشترین لایه مورد استفاده در شبکه پیشنهادی چه در هر دو شاخه رمزگذار و رمزگشا برای استخراج ویژگی و ادغام ویژگی است. ورودی هر لایه کانولوشنی یک نقشه ویژگی بصورت $h \times w \times c$ است که در آن h و w به ترتیب ارتفاع و عرض نقشه ویژگی، و c تعداد کانال می‌باشد. با فرض

ویژگی‌ها تفکیک کنیم. تابع آنتروپی متقاطع باینری هر یک از احتمالات پیش بینی شده را با خروجی کلاس واقعی مقایسه می‌کند که می‌تواند ۰ یا ۱ باشد. سپس نمره محاسبه شده احتمالات را براساس فاصله از مقدار مورد انتظار محاسبه می‌کند. این بدان معنی است که مقادیر پیش بینی شده چقدر نزدیک یا دور از مقدار واقعی است، که با هدف حداقل کردن آن در فرآیند آموزش سعی می‌شود که پارامترهای شبکه با دقت بالایی به روزرسانی شوند [۵۵]. این تابع خطا به صورت رابطه (۳) تعریف می‌گردد.

رابطه (۳)

$$H_p q = -\frac{1}{N} \sum_i y_i \log p_{y_i} + (1 - y_i) \log (1 - p_{y_i})$$

در رابطه (۳)، y برچسب پیکسل است و p_{y_i} احتمال پیش بینی پیکسل حاوی ابر برای همه N پیکسل است.

۳-۲-۲- لایه‌ها در معماری شبکه پیشنهادی

الگوریتم پیشنهادی یک معماری بصورت رمزگذار- رمزگشا با فرآیند یادگیری *End-to-End* است که از تعدادی لایه‌های کانولوشن و لایه‌های معکوس کانولوشن تشکیل شده‌اند. فرآیند یادگیری *End-to-End* به مفهوم یادگیری تمام ویژگی‌های استخراج شده در روند آموزش مدل و آزمایش آن بدون استفاده از هرگونه روش پیش پردازش می‌باشد [۵۶ و ۵۷]. معماری روش پیشنهادی یک معماری یادگیری عمیق با طول شبکه ۵ می‌باشد. همچنین در این شبکه بجای استفاده از لایه‌های کانولوشنی با ابعاد فیلتر ثابت از یک رویکرد جدید نیز استفاده شده است. این رویکرد شامل به کارگیری فیلترهایی با ابعاد مختلف برای روند آموزش جهت تشخیص جزئیات بیشتر در حاشیه‌های ابر ارائه شده است. در بخش قبلی به مفاهیم اولیه اشاره شد حال با استفاده از آنها به توضیح بخش‌های اصلی شبکه پیشنهادی می‌پردازیم.

¹ Concatenate

معیارها مهمتر است و پارامترها بر این اساس تنظیم شوند. اگر طبقه‌بندی کننده خود را برای افزایش یکی از پارامترهای دقت یا Recall بهینه کنیم و دیگری را نادیده بگیریم، میانگین هارمونیک آن دو پارامتر به سرعت کاهش می‌یابد. پارامتر نمره $F1$ به عنوان میانگین هارمونیک دو پارامتر دقت و Recall تعریف می‌شود که بهینه بودن آن نشان از تعادل برای دو پارامتر دقت و Recall خواهد بود [۵۹]. معادله نمره $F1$ بصورت رابطه (۴) است:

$$F1 = \frac{2 \times TP}{2 \times TP + FP + FN} \quad \text{رابطه (۴)}$$

با این حال، به دلیل امکان عدم تعادل کلاس‌های ابر و غیر ابر، برای درک عملکرد واقعی مدل، معیارهای اضافی لازم است محاسبه شوند زیرا دقت در مجموعه داده‌هایی که نامتعادل هستند، می‌تواند گمراه کننده باشد. به همین دلیل، ما شاخص ژاکارد (JI) را نیز محاسبه و استفاده خواهیم کرد. شاخص ژاکارد یک معیار استاندارد برای تقسیم‌بندی معنایی است. این شاخص پیکسل‌هایی را که بین پیش‌بینی و داده واقعیت با هم هم‌پوشانی دارند می‌گیرد و آن را بر روی تمام پیکسل‌های موجود در پیش‌بینی یا داده واقعیت تقسیم می‌کند [۶۰]. در طبقه‌بندی باینری، شاخص ژاکارد را می‌توان به صورت زیر تعریف کرد:

$$JI = \frac{TP}{TP + FP + FN} \quad \text{رابطه (۵)}$$

در رابطه‌های (۴) و (۵)، TP بیانگر تعداد پیکسل‌های ابر در کلاس ابر، FP بیانگر تعداد پیکسل‌های ابر در کلاس غیر ابر و FN بیانگر تعداد پیکسل‌های کلاس غیر ابر در کلاس ابر می‌باشد.

۴-۲ نتایج

همانطور که در بخش داده به آن اشاره کردیم ۱۵ نمونه مختلف که دارای چالش می‌باشند برای انجام آزمایش انتخاب گردید. نتایج حاصل از روش پیشنهادی بصورت

اینکه لایه کانولوشن دارای k تعداد فیلتر با ابعاد $r \times r \times c$ باشد، خروجی لایه کانولوشن یک نقشه ویژگی با ابعاد $h' \times w' \times k$ خواهد بود. اگر W_i و b_i پارامترهای وزن و بایاس مربوط به فیلتر i باشند، نقشه ویژگی Y_i را می‌توان با نقشه ویژگی ورودی X با استفاده از معادله $Y_i = W_i * X + b_i$ به دست آورد. بر روی خروجی نقشه‌های ویژگی در هر لایه کانولوشن غیر از لایه آخر جهت جلوگیری از بحث بیش برازش و تسریع فرآیند آموزش نرمال‌سازی دسته‌ای و به دنبال آن تابع فعالیت واحد خطی اصلاح شده ($ReLU$) اعمال می‌شود [۴۹]. یک راه حل مناسب برای حفظ ابعاد تصویر ورودی در شبکه‌های کانولوشنی، استفاده از پدینگ با مقادیر صفر در تصویر ورودی می‌باشد. در عمل، استفاده از این روش موجب حفظ تمامی مقادیر در فرآیند استخراج ویژگی از تصویر ورودی می‌شود.

۳-۲-۲ لایه‌های معکوس کانولوشنی

لایه‌های معکوس کانولوشن برای نمونه‌برداری و بازسازی نقشه‌های ویژگی استفاده می‌شوند. معکوس کانولوشن به اصطلاح ترانهاده کانولوشن نیز گفته می‌شود و در جهت مخالف با کانولوشن طبیعی پیش می‌رود [۵۸]. در معماری ارائه شده در این تحقیق، برای بازیابی شکل نقشه ویژگی اولیه در مرحله رمزگذار، از کانولوشن معکوس به عنوان لایه رمزگشایی استفاده می‌کنیم.

۴-۴ نتایج و بحث

در این بخش، ابتدا معیارهای ارزیابی دقت جهت تجزیه و تحلیل روش پیشنهادی معرفی می‌شوند، سپس نتایج به دست آمده از روش پیشنهادی با تحقیقات پیشین در حوزه شناسایی ابر مقایسه می‌شوند. در پایان این بخش، بحثی درباره نتایج، نقاط قوت و محدودیت‌های روش پیشنهادی در مقایسه با مطالعات دیگر، ارائه می‌شود.

۴-۱ معیارهای ارزیابی دقت


غالباً اینگونه است که تغییر برخی پارامترها در مرحله پیش‌بینی بر دقت و Recall تأثیر می‌گذارد. بسته به مسئله تحقیق، باید تصمیم گرفته شود که کدام یک از


^۱ Jaccard Index


ارزیابی عدد در جدول (۱) و بصورت بصری برای نمونه- است.
های انتخاب شده در شکل (۵) و (۶) نمایش داده شده

جدول ۱: نتایج ارزیابی آشکارسازی ابرها در تصاویر ماهواره لندست-۸ با استفاده از روش پیشنهادی.


معیار	$F1$ (%)	JI (%)
نمونه آزمایشی ۱	۹۷٫۵	۹۵٫۲
نمونه آزمایشی ۲	۹۴٫۵	۸۹٫۶
نمونه آزمایشی ۳	۹۷٫۴	۹۵٫۱
نمونه آزمایشی ۴	۱۰۰	۱۰۰
نمونه آزمایشی ۵	۹۴٫۶	۸۹٫۷
نمونه آزمایشی ۶	۹۹٫۲	۹۸٫۳
نمونه آزمایشی ۷	۹۶٫۶	۹۳٫۶
نمونه آزمایشی ۸	۹۷٫۶	۹۵٫۳
نمونه آزمایشی ۹	۹۷٫۲	۹۴٫۶
نمونه آزمایشی ۱۰	۹۴٫۹	۹۰٫۴
نمونه آزمایشی ۱۱	۹۹٫۲	۹۸٫۵
نمونه آزمایشی ۱۲	۹۶٫۱	۹۲٫۴
نمونه آزمایشی ۱۳	۹۴٫۷	۹۰٫۰
نمونه آزمایشی ۱۴	۹۴٫۹	۹۰٫۱
نمونه آزمایشی ۱۵	۹۵٫۳	۹۱٫۰
میانگین کلی ارزیابی	۹۶٫۶	۹۳٫۵







شکل ۵: نتایج آشکارسازی ابرها در تصاویر ماهواره لندست-۸ با استفاده از روش پیشنهادی.



شکل ۶: مقایسه نتایج عددی نمونه های مختلف ارزیابی آشکارسازی ابرها در تصاویر ماهواره لندست-۸ با استفاده از روش پیشنهادی.

۳-۴- ارزیابی، تجزیه و تحلیل دقت

میانگین نتایج دقیق ارزیابی کمی برای تمامی نمونه-های آزمایشی جهت تشخیص ابر در جدول (۲) ذکر شده است که از آن می‌توان دریافت که روش پیشنهادی همراه با داده‌های اصلاح شده بالاترین

مقادیر شاخص ژاکارد و نمره $F1$ را نسبت به روش‌های $Fmask$ ، $Cloud-Net$ ، FCN و $Cloud-Net+$ در تحقیقات پیشین دارند [۱، ۳۹ و ۴۱]. قابل ذکر است که همه روش‌های فوق با داده $Cloud-38$ از تصاویر ماهواره لندست-۸ آموزش داده شده‌اند.

جدول ۲: مقایسه نتایج عددی حاصل از تحقیقات پیشین با روش پیشنهادی.

روش	$F1$ (%)	JI (%)
FCN [۴۰]	۹۱٫۸	۸۵٫۰
$Fmask$ [۷]	۹۲٫۳	۸۵٫۹
$Cloud-Net$ [۳۹]	۹۳٫۲	۸۷٫۳
$Cloud-Net+$ [۴۱]	۹۴٫۱	۸۸٫۹
روش پیشنهادی	۹۶٫۶	۹۳٫۵

عملکرد بهتری ارائه داده‌اند با این حال روش پیشنهادی از دقت‌های بالاتری نیز نسبت به این دو روش برخوردار است و مقادیر $96/6$ در نمره $F1$ و $93/5$ را در شاخص ژاکارد کسب کرد که این می‌تواند به دلیل موارد فوق در بحث داده و معماری شبکه روش مورد نظر باشد: (۱) در این تحقیق با توجه به اینکه بسیاری از قسمت‌های حاشیه تصویر در داده $Cloud-38$ بدون ابر هستند و اطلاعات با شباهت زیادی در آن‌ها وجود داشت سعی شده است که برای آموزش و آزمون مدل قطعه‌هایی انتخاب شود که هم شامل چالش‌های متنوع باشد و هم تعادل بین کلاس‌های هدف و غیر هدف ایجاد شود، (۲) شاخه رمزگشا نقشه‌های ویژگی‌ها را توسط لایه‌های معکوس کانولوشن که در آن نیز از لایه‌های کانولوشن برای استخراج ویژگی‌های معنایی سطح بالا استفاده می‌شود، نمونه برداری و بازسازی می‌کند. نقشه‌های ویژگی در اندازه‌های برابر در لایه‌های رمزگذار و لایه‌های رمزگشا مربوطه توسط اتصالات تجمیع به هم متصل می‌شوند و براساس آن ویژگی‌هایی خلاصه‌تر و با تمایز بالا تولید می‌شوند. چنین ارتباطاتی می‌تواند به حفظ جزئیات مکانی بیشتر در نقشه‌های ویژگی بازسازی شده حاصل از شاخه رمزگشا کمک کند، و (۳) در معماری روش پیشنهادی از ادغام ویژگی کانولوشن با ابعاد مختلف فیلترها طراحی و استفاده شده است تا از ویژگی‌های کانولوشن مقیاس‌های مختلف استفاده کامل کند و دقت تشخیص ابر را بهبود دهد.

۵- نتیجه‌گیری

در این تحقیق، ما یک شبکه عصبی کانولوشنی ابری انتها به انتها را با تولید ویژگی‌ها در دو مقیاس مختلف برای تصاویر ماهواره لندست-۸ پیشنهاد کردیم که مزایای معماری رمزگذار-رمزگشا و رمزگشای پیشرفته را ترکیب می‌کند. از یک طرف می‌توان از کاستی‌های الگوریتم‌های تشخیص سنتی ابر مانند روش $Fmask$ مانند وابسته بودن به پارامتر، زمان‌بر بودن و دامنه کاربرد محدود اجتناب کرد. اگرچه روش‌های سنتی مبتنی بر قاعده برای شناسایی ابر در تصاویر با وضوح

نتایج عددی نشان می‌دهد که روش پیشنهادی ویژگی‌های مرتبط‌تری را از تصاویر ورودی استخراج و ادغام می‌کند و بنابراین ماسک‌های ابری تولید می‌کند که شباهت بیشتری به واقعیت‌های زمینی دارند که به صورت دستی و اتوماتیک استخراج می‌شوند. طبق مطالعات گذشته روش $Fmask$ در استخراج ابرهای نازک موثر است و تحت اکثر شرایط عملکردی قوی نشان می‌دهد. با این حال، $Fmask$ به راحتی در مناطق پوشیده از برف / یخ، مناطق ساحلی، مناطق آبی و غیره، عوارض را به عنوان ابر اشتباه می‌گیرد و این یکی از ضعف‌های اصلی این مدل است. روش FCN نیز علاوه بر مشکلات روش قبلی در تشخیص ابرهای نازک در حاشیه ابرهای ضخیم دچار اشتباه می‌شود و عملکرد مناسبی را ارائه نمی‌دهد.

به طور کلی، روش‌های سنتی تشخیص ابر قادر به استخراج بیشتر ابرها در تصاویر ماهواره‌ای هستند. با بهره‌گیری از اطلاعات طیفی فراوان در تصاویر لندست-۸ و با وضوح بالا، روش $Fmask$ در تحقیقات پیشین به ابرهای نازک تصاویر لندست حساسیت نشان داده است. با این حال واضح است که روش $Fmask$ به راحتی سطوح روشن را به عنوان ابر اشتباه می‌گیرد. همچنین روش FCN در مرزهای ابر بسیار خوب نیست، FCN برخی از سطوح روشن را اشتباه طبقه‌بندی می‌کند و برخی از ابرهای کوچک را در مناطق محلی از دست می‌دهد، در حالیکه روش پیشنهادی خطاهای کمتری نسبت به FCN و $Fmask$ در ماسک‌ها را به دست آورده و با توجه به نتایج روش پیشنهادی در جدول (۲) نسبت به روش‌های FCN و $Fmask$ دقت بالاتری را در پی داشته است. روش‌های $Cloud-Net$ و $Cloud-Net+$ تمام مشکلات دو روش قبلی را پوشش داده و با توجه به نتایج روش $Cloud-Net$ که مقادیر $93/2$ و $87/3$ را به ترتیب برای معیارهای نمره $F1$ و شاخص ژاکارد بدست آورد و مقادیر $94/1$ و $88/9$ که به ترتیب برای معیارهای نمره $F1$ و شاخص ژاکارد توسط روش $Cloud-Net+$ کسب شد می‌توان نتیجه گرفت که

و کاهش باندهای طیفی، تأثیرات منفی بر تشخیص ابر را کاهش می‌دهد. نتایج تجربی نشان می‌دهد که روش ادغام ویژگی‌های حاصل از فیلترهای با ابعاد مختلف، تصحیح نسبی داده ورودی نسبت به داده مرجع و استفاده از تکنیک‌هایی مانند روش حذف تصادفی در طول فرآیند آموزش به بهبود عملکرد مدل کمک می‌کنند. بر اساس نتایج جدول (۲)، روش پیشنهادی مقادیر شاخص ژاکارد و نمره $F1$ بالاتری نسبت به دیگر روش‌ها در مجموعه داده یکسان، به ویژه در مناطق پوشیده از سطح روشن را به دست آورد که میزان دقت برای هر معیار به ترتیب برابر با ۹۳/۵ و ۹۶/۶ درصد می‌باشد. اثربخشی روش پیشنهادی بدین معنی است که نویدبخش خوبی برای کاربرد عملی با انواع مختلف تصاویر ماهواره‌ای است. در تحقیقات آینده، موضوع استخراج ابر و سایه ابر با استفاده از سری زمانی تصاویر ماهواره سنتینل-۲ و شبکه‌های عصبی کانولوشنی *Transformer* مورد بررسی قرار خواهند گرفت.

متوسط و پایین، که دارای اطلاعات طیفی نسبتاً فراوانی هستند، عملکرد خوبی دارند. با این وجود، با افزایش توان تفکیک مکانی تصویر و کاهش کانال‌های طیفی موجود، به دلیل پس زمینه‌های روشن و ابرهای نازکی که به راحتی اشتباه گرفته می‌شوند، دقت تشخیص ابر کاهش می‌یابد.

این تحقیق، با استفاده ترکیبی از ویژگی‌های طیفی، مکانی و زمانی به کاهش روند تخریب دقت کمک کرده است. در واقع، در روش پیشنهاد با در نظر گرفتن:

(۱) تصحیح داده ورودی به شبکه جهت ایجاد تعادل در کلاس‌های هدف و غیر هدف،

(۲) ترکیبی از ویژگی‌های کانولوشن چند مقیاس

(۳) استفاده از یک روش رمزگذار-رمزگشا متقارن پیشرفته که در شاخه رمزگشا علاوه بر لایه‌های معکوس کانولوشن از لایه‌های مستقیم کانولوشن نیز به منظور استخراج ویژگی‌های با سطح بالا بهره می‌برد توانسته تعریف دقیق هدف را تا حد ممکن به دقت‌های بالا برساند؛ بنابراین به دلیل افزایش توان تفکیک مکانی

مراجع

- [1] Zhu, Zhe, Shixiong Wang, and Curtis E. Woodcock. "Improvement and expansion of the Fmask algorithm: Cloud, cloud shadow, and snow detection for Landsats 4-7, 8, and Sentinel 2 images." *Remote sensing of Environment* 159 (2015): 269-277.
- [2] Braaten, Justin D., Warren B. Cohen, and Zhiqiang Yang. "Automated cloud and cloud shadow identification in Landsat MSS imagery for temperate ecosystems." *Remote Sensing of Environment* 169 (2015): 128-138.
- [3] Lin, Chao-Hung, Bo-Yi Lin, Kuan-Yi Lee, and Yi-Chen Chen. "Radiometric normalization and cloud detection of optical satellite images using invariant pixels." *ISPRS Journal of Photogrammetry and Remote Sensing* 106 (2015): 107-117.
- [4] Wu, Teng, Xiangyun Hu, Yong Zhang, Lulin Zhang, Pengjie Tao, and Luping Lu. "Automatic cloud detection for high resolution satellite stereo images and its application in terrain extraction." *ISPRS Journal of Photogrammetry and Remote Sensing* 121 (2016): 143-156.
- [5] Choi, Hyeungu, and Robert Bindaschadler. "Cloud detection in Landsat imagery of ice sheets using shadow matching technique and automatic normalized difference snow index threshold value decision." *Remote Sensing of Environment* 91, no. 2 (2004): 237-242.
- [6] Irish, Richard R., John L. Barker, Samuel N. Goward, and Terry Arvidson. "Characterization of the Landsat-7 ETM+ automated cloud-cover assessment (ACCA) algorithm." *Photogrammetric engineering & remote sensing* 72, no. 10 (2006): 1179-1188.
- [7] Zhu, Xiaolin, and Eileen H. Helmer. "An automatic method for screening clouds and cloud shadows in optical satellite image

- time series in cloudy regions." *Remote sensing of environment* 214 (2018): 135-153.
- [8] Zhu, Zhe, and Curtis E. Woodcock. "Object-based cloud and cloud shadow detection in Landsat imagery." *Remote sensing of environment* 118 (2012): 83-94.
- [9] Ishida, Haruma, Yu Oishi, Keitaro Morita, Keigo Moriwaki, and Takashi Y. Nakajima. "Development of a support vector machine based cloud detection method for MODIS with the adjustability to various conditions." *Remote sensing of environment* 205 (2018): 390-407.
- [10] Frantz, David, Erik Haß, Andreas Uhl, Johannes Stoffels, and Joachim Hill. "Improvement of the Fmask algorithm for Sentinel-2 images: Separating clouds from bright surfaces based on parallax effects." *Remote sensing of environment* 215 (2018): 471-481.
- [11] Mei, Linlu, Marco Vountas, Luis Gómez-Chova, Vladimir Rozanov, Malte Jäger, Wolfhardt Lotz, John P. Burrows, and Rainer Hollmann. "A Cloud masking algorithm for the XBAER aerosol retrieval using MERIS data." *Remote Sensing of Environment* 197 (2017): 141-160.
- [12] Hollingsworth, Ben V., Liqiang Chen, Stephen E. Reichenbach, and Richard R. Irish. "Automated cloud cover assessment for Landsat TM images." In *Imaging Spectrometry II*, vol. 2819, pp. 170-179. SPIE, 1996.
- [13] Scaramuzza, Pasquale L., Michelle A. Bouchard, and John L. Dwyer. "Development of the Landsat data continuity mission cloud-cover assessment algorithms." *IEEE Transactions on Geoscience and Remote Sensing* 50, no. 4 (2011): 1140-1154.
- [14] Vermote, Eric, Chris Justice, Martin Claverie, and Belen Franch. "Preliminary analysis of the performance of the Landsat 8/OLI land surface reflectance product." *Remote Sensing of Environment* 185 (2016): 46-56.
- [15] Wang, Bin, Atsuo Ono, Kanako Muramatsu, and Noboru Fujiwara. "Automated detection and removal of clouds and their shadows from Landsat TM images." *IEICE Transactions on information and systems* 82, no. 2 (1999): 453-460.
- [16] Jin, Suming, Collin Homer, Limin Yang, George Xian, Joyce Fry, Patrick Danielson, and Philip A. Townsend. "Automated cloud and shadow detection and filling using two-date Landsat imagery in the USA." *International Journal of Remote Sensing* 34, no. 5 (2013): 1540-1560.
- [17] Molnar, G., and J. A. Coakley Jr. "Retrieval of cloud cover from satellite imagery data: A statistical approach." *Journal of Geophysical Research: Atmospheres* 90, no. D7 (1985): 12960-12970.
- [18] Ricciardelli, E., F. Romano, and V. Cuomo. "Physical and statistical approaches for cloud identification using meteosat second generation-spinning enhanced visible and infrared imager data." *Remote sensing of environment* 112, no. 6 (2008): 2741-2760.
- [19] Lee, Yoonkyung, Grace Wahba, and Steven A. Ackerman. "Cloud classification of satellite radiance data by multicategory support vector machines." *Journal of Atmospheric and Oceanic Technology* 21, no. 2 (2004): 159-169.
- [20] Tian, Bin, Mukhtiar A. Shaikh, Mahmood R. Azimi-Sadjadi, Thomas H. Vonder Haar, and Donald L. Reinke. "A study of cloud classification with neural networks using spectral and textural features." *IEEE transactions on neural networks* 10, no. 1 (1999): 138-151.
- [21] Chai, Dengfeng, Shawn Newsam, Hankui K. Zhang, Yifan Qiu, and Jingfeng Huang. "Cloud and cloud shadow detection in Landsat imagery based on deep convolutional neural networks." *Remote sensing of environment* 225 (2019): 307-

- 316.
- [22] Yu, Xiaohe, and David J. Lary. "Cloud Detection Using an Ensemble of Pixel-Based Machine Learning Models Incorporating Unsupervised Classification." *Remote Sensing* 13, no. 16 (2021): 3289.
- [23] Qiu, Shi, Zhe Zhu, and Binbin He. "Fmask 4.0: Improved cloud and cloud shadow detection in Landsats 4-8 and Sentinel-2 imagery." *Remote Sensing of Environment* 231 (2019): 111205.
- [24] He, Xing Yuan, Jian Bo Hu, Wei Chen, and Xiao Yu Li. "Haze removal based on advanced haze-optimized transformation (AHOT) for multispectral imagery." *International Journal of Remote Sensing* 31, no. 20 (2010): 5331-5348.
- [25] Mohajerani, Sorour, Reza Asad, Kumar Abhishek, Neha Sharma, Alysha van Duynhoven, and Parvaneh Saeedi. "Cloudmaskgan: A content-aware unpaired image-to-image translation algorithm for remote sensing imagery." In *2019 IEEE International Conference on Image Processing (ICIP)*, pp. 1965-1969. IEEE, 2019.
- [26] Aghdami-Nia, Mohammad, Reza Shah-Hosseini, Amirhossein Rostami, and Saeid Homayouni. "Automatic coastline extraction through enhanced sea-land segmentation by modifying Standard U-Net." *International Journal of Applied Earth Observation and Geoinformation* 109 (2022): 102785.
- [27] Rostami, Amirhossein, Reza Shah-Hosseini, Shabnam Asgari, Arastou Zarei, Mohammad Aghdami-Nia, and Saeid Homayouni. "Active Fire Detection from Landsat-8 Imagery Using Deep Multiple Kernel Learning." *Remote Sensing* 14, no. 4 (2022): 992.
- [28] Seyed Mousavi, Seyed Morteza, and Mehdi Akhoondzadeh Hanzaei. "Monitoring and Prediction of the changes in water zone of wetlands using an intelligent neural-fuzzy system based on data from Google Eearth Engine system (Case study of Anzali Wetland, 2000-2019)." *Engineering Journal of Geospatial Information Technology* 9, no. 4 (2022): 19-42.
- [29] Zhang, Liangpei, Lefei Zhang, and Bo Du. "Deep learning for remote sensing data: A technical tutorial on the state of the art." *IEEE Geoscience and remote sensing magazine* 4, no. 2 (2016): 22-40.
- [30] Zhang, Liangpei, Lefei Zhang, and Bo Du. "Deep learning for remote sensing data: A technical tutorial on the state of the art." *IEEE Geoscience and remote sensing magazine* 4, no. 2 (2016): 22-40.
- [31] Hu, Kai, Dongsheng Zhang, Min Xia, Ming Qian, and Binyu Chen. "LCDNet: Light-weighted Cloud Detection Network for High-resolution Remote Sensing Images." *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* (2022).
- [32] LeCun, Yann, Léon Bottou, Yoshua Bengio, and Patrick Haffner. "Gradient-based learning applied to document recognition." *Proceedings of the IEEE* 86, no. 11 (1998): 2278-2324.
- [33] Goodfellow, Ian, Yoshua Bengio, and Aaron Courville. *Deep learning*. MIT press, 2016.
- [34] Girshick, Ross, Jeff Donahue, Trevor Darrell, and Jitendra Malik. "Rich feature hierarchies for accurate object detection and semantic segmentation." In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 580-587. 2014.
- [35] Chen, Liang-Chieh, George Papandreou, Iasonas Kokkinos, Kevin Murphy, and Alan L. Yuille. "Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs." *IEEE transactions on pattern analysis and machine intelligence* 40, no. 4 (2017): 834-848.
- [36] Li, Zhiwei, Huanfeng Shen, Yancong Wei, Qing Cheng, and Qiangqiang Yuan. "Cloud

- detection by fusing multi-scale convolutional features." *ISPRS Ann. Photogramm. Remote Sens. Spat. Inf. Sci* 4 (2018): 149-152.
- [37] Mateo-García, Gonzalo, Luis Gómez-Chova, Julia Amorós-López, Jordi Muñoz-Marí, and Gustau Camps-Valls. "Multitemporal cloud masking in the Google Earth Engine." *Remote Sensing* 10, no. 7 (2018): 1079.
- [38] Xie, Fengying, Mengyun Shi, Zhenwei Shi, Jihao Yin, and Danpei Zhao. "Multilevel cloud detection in remote sensing images based on deep learning." *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 10, no. 8 (2017): 3631-3640.
- [39] Mohajerani, Sorour, and Parvaneh Saeedi. "Cloud-Net: An end-to-end cloud detection algorithm for Landsat 8 imagery." In *IGARSS 2019-2019 IEEE International Geoscience and Remote Sensing Symposium*, pp. 1029-1032. *IEEE*, 2019.
- [40] Mohajerani, Sorour, Thomas A. Krammer, and Parvaneh Saeedi. "Cloud detection algorithm for remote sensing images using fully convolutional neural networks." *arXiv preprint arXiv:1810.05782* (2018).
- [41] Long, Jonathan, Evan Shelhamer, and Trevor Darrell. "Fully convolutional networks for semantic segmentation." In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 3431-3440. 2015.
- [42] Guo, Jianhua, Jingyu Yang, Huanjing Yue, Hai Tan, Chunping Hou, and Kun Li. "CDnetV2: CNN-based cloud detection for remote sensing imagery with cloud-snow coexistence." *IEEE Transactions on Geoscience and Remote Sensing* 59, no. 1 (2020): 700-713.
- [43] Wieland, Marc, Yu Li, and Sandro Martinis. "Multi-sensor cloud and cloud shadow segmentation with a convolutional neural network." *Remote Sensing of Environment* 230 (2019): 111203.
- [44] Francis, Alistair, Panagiotis Sidiropoulos, and Jan-Peter Muller. "CloudFCN: Accurate and robust cloud detection for satellite imagery with deep learning." *Remote Sensing* 11, no. 19 (2019): 2312.
- [45] Glorot, Xavier, and Yoshua Bengio. "Understanding the difficulty of training deep feedforward neural networks." In *Proceedings of the thirteenth international conference on artificial intelligence and statistics*, pp. 249-256. *JMLR Workshop and Conference Proceedings*, 2010.
- [46] Leshno, Moshe, Vladimir Ya Lin, Allan Pinkus, and Shimon Schocken. "Multilayer feedforward networks with a nonpolynomial activation function can approximate any function." *Neural networks* 6, no. 6 (1993): 861-867.
- [47] Krizhevsky, Alex, Ilya Sutskever, and Geoffrey E. Hinton. "Imagenet classification with deep convolutional neural networks." *Communications of the ACM* 60, no. 6 (2017): 84-90.
- [48] Agarap, Abien Fred. "Deep learning using rectified linear units (relu)." *arXiv preprint arXiv:1803.08375* (2018).
- [49] Ioffe, Sergey, and Christian Szegedy. "Batch normalization: Accelerating deep network training by reducing internal covariate shift." In *International conference on machine learning*, pp. 448-456. *PMLR*, 2015.
- [50] Albawi, Saad, Tareq Abed Mohammed, and Saad Al-Zawi. "Understanding of a convolutional neural network." In *2017 international conference on engineering and technology (ICET)*, pp. 1-6. *Ieee*, 2017.
- [51] Yu, Dingjun, Hanli Wang, Peiqiu Chen, and Zhihua Wei. "Mixed pooling for convolutional neural networks." In *International conference on rough sets and knowledge technology*, pp. 364-375. *Springer, Cham*, 2014.
- [52] Nowlan, Steven, and Geoffrey E. Hinton. "Adaptive soft weight tying using gaussian mixtures." *Advances in Neural Information*

Processing Systems 4 (1991).

- [53] Srivastava, Nitish, Geoffrey Hinton, Alex Krizhevsky, Ilya Sutskever, and Ruslan Salakhutdinov. "Dropout: a simple way to prevent neural networks from overfitting." *The journal of machine learning research* 15, no. 1 (2014): 1929-1958.
- [54] Khoshboresh-Masouleh, Mehdi, and Reza Shah-Hosseini. "A multi-scale convolutional neural network for automatic cloud and cloud shadow detection from Gaofen-1 images." *Engineering Journal of Geospatial Information Technology* 8, no. 4 (2021): 45-68.
- [55] Ho, Yaoshiang, and Samuel Wookey. "The real-world-weight cross-entropy loss function: Modeling the costs of mislabeling." *IEEE Access* 8 (2019): 4806-4813.
- [56] Ball, John E., Derek T. Anderson, and Chee Seng Chan Sr. "Comprehensive survey of deep learning in remote sensing: theories, tools, and challenges for the community." *Journal of applied remote sensing* 11, no. 4 (2017): 042609.
- [57] Moradi, Fatemeh, Farzaneh Dadrass Javan, and Farhad Samadzadegan. "Potential evaluation of visible-thermal UAV image fusion for individual tree detection based on convolutional neural network." *International Journal of Applied Earth Observation and Geoinformation* 113 (2022): 103011.
- [58] Noh, Hyeonwoo, Seunghoon Hong, and Bohyung Han. "Learning deconvolution network for semantic segmentation." In *Proceedings of the IEEE international conference on computer vision*, pp. 1520-1528. 2015.
- [59] Chicco, Davide, and Giuseppe Jurman. "The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation." *BMC genomics* 21, no. 1 (2020): 1-13.
- [60] Gonzales, Cindy, and Wesam Sakla. "Semantic segmentation of clouds in satellite imagery using deep pre-trained U-nets." In *2019 IEEE Applied Imagery Pattern Recognition Workshop (AIPR)*, pp. 1-7. IEEE, 2019.
- [61] Mohajerani, Sorour, Thomas A. Krammer, and Parvaneh Saeedi. "Cloud detection algorithm for remote sensing images using fully convolutional neural networks." *arXiv preprint arXiv:1810.05782* (2018).



An efficient method using the fusion of deep convolutional neural network features for cloud detection using Landsat-8 OLI spectral bands

Arastou Zarei ¹, Reza Shah-Hosseini ^{2*}, Seyed Morteza Seyed Mousavi³

1- Ms.c, School of Surveying & Geospatial Engineering, College of Engineering, University of Tehran, Tehran, Iran.

2- Assistant Professor, School of Surveying & Geospatial Engineering, College of Engineering, University of Tehran, Tehran, Iran.

3- Ms.c Student, School of Surveying & Geospatial Engineering, College of Engineering, University of Tehran, Tehran, Iran.

Abstract

Cloud segmentation is a critical pre-processing step for any multi-spectral satellite image application. In particular, disaster-related applications e.g., flood monitoring or rapid damage mapping, which are highly time and data-critical, require methods that produce accurate cloud masks in a short time while being able to adapt to large variations in the target domain (induced by atmospheric conditions, different sensors, and scene properties). This research presented a deep convolutional neural network for cloud detection in the Landsat-8 dataset at the pixel level. Two key components of the proposed network are convolutional layers in the decoder branch and two convolution kernels in various scales. The near-infrared band in this study was added to the network inputs, including red, green, and blue bands, in order to improve the network performance. In the proposed network architecture, the encoder-decoder branches which are symmetrical with the density of feature maps resulting from the multiplicity of filters and the designing of multi-dimension filters, provided a local and general context for the accurate identification of the cloud and its margins which are used to extract the spatial features in high-level scales. However, multi-scale feature maps will be sampled and integrated to accuracy o-generate high Finally, the proposed method uses 3500 patches of Landsat-8 satellite images with various cloud challenges by using several kernels in sizes 3×3 and 5×5 with an F1-score of 96.6 and a Jaccard index (JI) of 93.5, provides a higher accuracy than the other methods. In general, the suggested method outperformed the alternatives in the same, uncorrected data set in terms of accuracy, particularly in regions with bright surfaces. Due to the effectiveness of the proposed framework, it has a lot of potential for practical application with different types of satellite images.

Key words: Remote Sensing, Landsat-8, Convolution Neural Network, Cloud Detection.

Correspondence Address: Photogrammetry & Remote Sensing Group, School of Surveying & Geospatial Engineering, College of Engineering, University of Tehran, Tehran, Iran.

Tel : +98 21 61114527.

Email: rshahosseini@ut.ac.ir